مرکز دانش شبکه خبرگان صنعت فولاد

کاربرد بینایی ماشین در مدیریت ایمنی صنعت فولاد

مقالات تخصصی | علی ارجمندی اصل | ۱۴۰۵/۰۸/۰۵

بررسی کاربرد عملی بینایی ماشین در ایمنی مینی‌میل‌های فولاد، رتبه‌بندی هشت سامانه تجاری با TOPSIS و مقایسه YOLOv8m، YOLOv5m و YOLOv9c برای تشخیص کلاه ایمنی در ۷۰۳ تصویر صنعتی.



نویسندگان اصلی: Ibukun Awolusi، Roy Lan و Jiannan Cai | نشریه AI، سال ۲۰۲۴

چکیده

محیط تولید فولاد به‌دلیل حضور ماشین‌آلات بزرگ، جابه‌جایی مواد سنگین و تنوع مخاطرات، از دشوارترین محیط‌های کاری برای مدیریت ایمنی است. در چنین شرایطی، جایگزین‌کردن پایش دستی و متکی بر قضاوت فردی با نظارتی خودکار و عینی اهمیت ویژه‌ای دارد. این پژوهش امکان به‌کارگیری بینایی ماشین را در مدیریت ایمنی کارخانه‌های فولاد بررسی می‌کند و تشخیص خودکار استفاده از کلاه ایمنی را به‌عنوان مطالعه موردی برمی‌گزیند. روش تحقیق سه بخش دارد: شناسایی و طبقه‌بندی مخاطرات، ارزیابی فناوری‌ها و اجرای یک مطالعه پایلوت. ابتدا خطرات تولید فولاد به‌صورت جامع مرور شده‌اند؛ سپس از روش تصمیم‌گیری چندمعیاره

TOPSIS برای انتخاب یک سامانه بینایی ماشین از میان هشت محصول تجاری استفاده شده است. در بخش آزمایشی، سه مدل YOLOv8m، YOLOv5m و YOLOv9c روی 703 تصویر خاکستری ثبت‌شده در یک کارخانه کوچک فولاد ارزیابی شدند. شاخص‌های ارزیابی شامل دقت مثبت (Precision)، یادآوری (Recall)، امتیاز F1، میانگین دقت متوسط (mAP)، ویژگی (Specificity) و سطح زیر منحنی (AUC) بود. نتایج از عملکرد کلی بالای این مدل‌ها در تشخیص کلاه ایمنی حکایت دارد؛ YOLOv9c به‌ویژه در تشخیص موارد نقض الزام ایمنی اندکی بهتر از دو مدل دیگر عمل کرد. بااین‌حال، نامتوازن‌بودن تعداد نمونه‌های کلاس‌ها و تشخیص درست موارد نداشتن کلاه ایمنی، به‌خصوص در تصاویر سیاه‌وسفید، چالش‌برانگیز بود. پژوهش نشان می‌دهد مدیریت ایمنی مبتنی بر بینایی ماشین در کارخانه فولاد امکان‌پذیر است؛ اما برای عبور از پیچیدگی‌های واقعی محیط صنعتی به مجموعه‌داده‌های بزرگ‌تر و متنوع‌تر و روش‌های پیشرفته‌تر نیاز داریم.

۱. مقدمه

فولاد ماده‌ای بسیار پرکاربرد است که در صنایع حیاتی مانند ساخت‌وساز، حمل‌ونقل، انرژی و تولید صنعتی استفاده می‌شود و از مهم‌ترین مصالح مهندسی و ساختمانی به‌شمار می‌رود. بااین‌حال، تولید آن محیط کاری دشوار و پرخطری پدید می‌آورد: کارکنان پیوسته با تجهیزات سنگین سروکار دارند و ممکن است در معرض گازهای سمی و خطرات متعدد قرار بگیرند. طبق اطلاعاتی که انجمن جهانی فولاد در سال 2022 از 55 سازمان، معادل 60 درصد اعضای مشارکت‌کننده، گردآوری کرد، در میان کارکنان و پیمانکاران 18,448 مورد آسیب‌دیدگی و 90 مورد مرگ گزارش شد. لغزش، سکندری‌خوردن و سقوط، و نیز تماس با ماشین‌آلات متحرک از مهم‌ترین عوامل این حوادث بودند [1]. آسیب‌های رایج این صنعت شامل ضربه مغزی، سوختگی، قطع عضو، آسیب نخاعی و سندرم تونل کارپال است.

مرورهای پژوهشی متعددی نشان داده‌اند که شناسایی به‌موقع خطرات می‌تواند سهم مهمی در کاهش این حوادث داشته باشد [2، 3]. صنعت فولاد نیز با اجرای دوره‌های آموزشی جامع، بهبود روش‌های تعمیرات و بهره‌برداری، خودکارسازی کارهای تکراری و به‌روزرسانی مداوم دستورالعمل‌های ایمنی، اقدام‌های پیشگیرانه گوناگونی انجام داده است [4، 5]. با وجود این پیشرفت‌ها، شناسایی خطر در کارخانه‌های فولاد هنوز باید از فرایندهای دستی به روش‌های خودکار حرکت کند تا خطاهای انسانی کمتر و مداخله‌های ایمنی مؤثرتر شوند.

بینایی ماشین به پشتوانه یادگیری عمیق می‌تواند فعالیت‌هایی مانند شناسایی، ردیابی، پایش و تشخیص رفتار را خودکار کند؛ قابلیت‌هایی که می‌توان آن‌ها را متناسب با نیازهای تولید فولاد به‌کار گرفت [6–8]. برای نمونه، شناسایی نزدیک‌شدن افراد به تجهیزات سنگین می‌تواند از حوادث مرگبار ناشی از ماشین‌آلات متحرک بکاهد [9، 10]. نظارت بر استفاده از تجهیزات حفاظت فردی (PPE) نیز کاربرد مهم دیگری است. بر پایه گزارش اداره

ایمنی و بهداشت شغلی آمریکا (OSHA)، استفاده درست از PPE می‌تواند تا 37.6 درصد از آسیب‌ها و بیماری‌های شغلی جلوگیری کند؛ در مقابل، استفاده‌نکردن از این تجهیزات در 12 تا 14 درصد از آسیب‌های شغلی منجر به ازکارافتادگی کامل نقش دارد [11]. مراکز کنترل و پیشگیری بیماری آمریکا (CDC) نیز اشاره می‌کنند که فولادکاران، به‌ویژه در حوادث لغزش و سقوط، در معرض آسیب‌های ضربه‌ای مغز هستند. استفاده از کلاه ایمنی می‌تواند احتمال چنین آسیبی را در این حوادث تا 70 درصد کاهش دهد [12]. کنترل دستی رعایت الزام کلاه ایمنی برای همه کارکنان یک مجموعه بزرگ فولاد عملاً امکان‌پذیر نیست؛ در اینجا تشخیص شیء مبتنی بر یادگیری عمیق می‌تواند نظارت را خودکار و دقیق‌تر کند.

کاربرد بینایی ماشین و یادگیری عمیق برای شناسایی خودکار خطر و پایش ایمنی در صنایعی مانند ساختمان و کشاورزی پیشرفت کرده است؛ اما هنوز سامانه‌ای که به‌طور خاص برای ایمنی در تولید فولاد طراحی و در این محیط آزمایش شده باشد، به‌خوبی توسعه نیافته است. همین خلأ فرصتی برای پیشرفت این حوزه ایجاد می‌کند. هدف پژوهش حاضر بررسی امکان و ظرفیت استفاده از بینایی ماشین در مدیریت ایمنی صنعت فولاد است. برای این منظور، مطالعه‌ای پایلوت با محور تشخیص خودکار کلاه ایمنی کارکنان از طریق یادگیری عمیق اجرا شد. در گام نخست، خطراتی که می‌توان با بینایی ماشین پایش کرد شناسایی و دسته‌بندی شدند؛ سپس با یک مدل تصمیم‌گیری چندمعیاره، نرم‌افزارهای تجاری قابل‌استفاده برای ایمنی فولاد ارزیابی شدند. این ارزیابی برای انتخاب سامانه‌ای مناسب و مؤثر ضرورت دارد. نتایج علاوه بر نشان‌دادن قابلیت بینایی ماشین در بهبود ایمنی کارخانه‌های فولاد، می‌تواند مبنایی برای کاربرد آن در دیگر صنایع پرخطر و ادغام فناوری‌های پیشرفته‌تر در مدیریت ایمنی باشد.

۲. پیشینه و مبانی

۲.۱. مروری بر فرایند فولادسازی

تولید فولاد عمدتاً به دو شیوه انجام می‌شود: کارخانه یکپارچه مبتنی بر کوره اکسیژنی پایه (BOF)، و کارخانه کوچک‌تر یا مینی‌میل مبتنی بر کوره قوس الکتریکی (EAF) [13]. این دو روش از نظر مواد اولیه و خطرات ذاتی با یکدیگر تفاوت دارند. در فرایند BOF، سنگ‌آهن و کک ابتدا در کوره بلند فرآوری می‌شوند و سپس در کنورتر اکسیژنی، واکنش‌های گرمازا ناخالصی‌هایی مانند کربن، سیلیسیم، منگنز و فسفر را حذف می‌کنند. در مقابل، ماده اولیه مینی‌میل‌ها عمدتاً قراضه فلزی یا آهن احیای مستقیم (DRI) است که در کوره قوس الکتریکی ذوب می‌شود [14].

هر دو روش به مدیریت ایمنی سخت‌گیرانه نیاز دارند، اما شرایط بهره‌برداری آن‌ها یکسان نیست. کارخانه‌های

یکپارچه معمولاً بزرگ‌ترند و تولید بالاتری از مینی‌میل‌ها دارند [15]. واحدهای EAF کوچک‌ترند، از نظر اقتصادی در مقیاس مورد اشاره با BOF تفاوت دارند و به‌دلیل کارکرد ناپیوسته، انعطاف بیشتری فراهم می‌کنند [16]. با وجود ظرفیت تولید پایین‌تر، ایمنی مینی‌میل‌ها اهمیتی اساسی دارد که در مقایسه با کارخانه‌های BOF گاهی دست‌کم گرفته می‌شود [14، 15]. رشد توجه به بازیافت فولاد و کاهش انتشار گازهای گلخانه‌ای، استفاده از EAF را افزایش داده است؛ این کوره‌ها می‌توانند برای تولید فولاد کربنی و آلیاژی، تا 100 درصد از قراضه استفاده کنند [17، 18]. این روند ضرورت تقویت ایمنی در مینی‌میل‌ها را دوچندان می‌کند.

۲.۲. مخاطرات شغلی در تولید فولاد

کارکنان صنعت فولاد با مخاطرات شغلی فراوانی روبه‌رو هستند [5] و پایش و کاهش آمار آسیب‌دیدگی و مرگ‌ومیر اهمیت حیاتی دارد. در این صنعت معمولاً از دو شاخص «نرخ فراوانی حوادث منجر به اتلاف وقت کاری» (LTIFR) و «نرخ فراوانی حوادث فوتی» (FFR) استفاده می‌شود. LTIFR تعداد آسیب‌های ناشی از کار است که کارکنان یا پیمانکاران را از انجام وظایف بازمی‌دارد و به‌ازای هر یک میلیون ساعت کار محاسبه می‌شود [19]. بنا بر گزارش انجمن جهانی فولاد، این شاخص از 4.55 در سال 2006 به 0.81 در سال 2021 رسیده؛ یعنی 82 درصد کاهش یافته است [19]. هدف نهایی همچنان نزدیک‌شدن به صفر حادثه است. شاخص FFR مرگ‌ومیر کارکنان و پیمانکاران را ثبت می‌کند. این شاخص، چون به ازدست‌رفتن جان انسان‌ها مربوط است، بسیار مهم است؛ اما معمولاً شاخصی پس‌نگر تلقی می‌شود، نه معیاری پیش‌دستانه [20، 21]. کاهش پیشگیرانه LTIFR می‌تواند به‌طور غیرمستقیم بر FFR نیز اثر بگذارد. بااین‌حال، افزایش FFR از 0.021 در سال 2019 به 0.03 در سال 2021 ــ معادل رشد 43 درصدی ــ نشان می‌دهد به تقویت پروتکل‌های ایمنی نیاز داریم [19].

پیچیدگی فعالیت‌های فولادسازی مخاطرات متعددی به همراه دارد. سازمان بین‌المللی کار [22] این خطرات را، مشابه صنایع ساختمانی، کشاورزی و تولید عمومی، در چهار گروه فیزیکی، شیمیایی، ایمنی و ارگونومیک طبقه‌بندی می‌کند. سروصدا، ارتعاش، گرمای شدید و تابش از مخاطرات فیزیکی‌اند؛ تماس با گازها و مواد زیان‌آور در گروه شیمیایی قرار می‌گیرد. لغزش، سکندری و سقوط، نزدیکی به ماشین‌آلات سنگین و برخورد اجسام سقوط‌کننده یا پرتاب‌شونده از مخاطرات اصلی ایمنی هستند و از مهم‌ترین عوامل آسیب در صنعت فولاد به‌شمار می‌روند [19]. پژوهش Kifle و همکاران [23] نیز این حوادث را در صدر عوامل آسیب‌دیدگی صنعت معرفی کرده است.

۲.۳. اقدامات ایمنی کنونی در صنعت فولاد

کاهش نرخ حوادث منجر به اتلاف وقت کاری (LTIFR) در دهه گذشته، نشان‌دهنده پیشرفت قابل‌توجه

صنعت فولاد در بهبود ایمنی محیط کار است [19]. مؤسسه ملی ایمنی و بهداشت شغلی آمریکا (NIOSH) پنج سطح کنترل خطر را بر حسب اثربخشی معرفی کرده است: تجهیزات حفاظت فردی، کنترل‌های اداری، کنترل‌های مهندسی، جایگزینی و حذف خطر [24]. استفاده از این اقدامات در کارخانه‌های فولاد رو به افزایش است.

برای نمونه، دستورالعمل‌های قفل‌کردن، برچسب‌گذاری و آزمودن بی‌برقی یا بی‌خطربودن تجهیز (LOTO) از کنترل‌های اداری مهم برای پیشگیری از حوادث تعمیراتی‌اند. استفاده منظم از PPE نیز با پیشرفت اینترنت اشیا (IoT)، فناوری‌های پوشیدنی و مشوق‌های ایمنی در حال تحول است [25]. کلاه‌ها، دست‌بندها و کمربندهای هوشمند می‌توانند بازخورد ایمنی را در لحظه به کارکنان برسانند و برای صنعت فولاد ارزشمند باشند [23، 26–29]. آموزش شناسایی خطر و روش‌های کار ایمن هم با شبیه‌سازهای تعاملی و واقعیت مجازی و افزوده پیشرفت کرده است [30، 31]. به‌گفته NIOSH، حذف خطر یا جایگزینی آن اثربخش‌ترین راه کنترل است، زیرا عامل خطر را از میان برمی‌دارد؛ ولی در فولادسازی، حذف کامل بعضی مخاطرات بدون توقف بخشی از عملیات عملی نیست. بنابراین تمرکز به کنترل‌های مهندسی معطوف می‌شود: استفاده از فناوری برای دورنگه‌داشتن کارکنان از خطر. اصلاح تجهیزات موجود یا استفاده از فناوری‌هایی مانند بینایی ماشین برای خودکارسازی برخی وظایف، از همین دسته اقدامات است.

۲.۴. کاربردهای بینایی ماشین در ایمنی و مروری بر مدل‌های YOLO

بینایی ماشین (CV) حوزه‌ای میان‌رشته‌ای است که با تحلیل تصاویر و ویدئوها، اطلاعات کاربردی را در زمان واقعی استخراج می‌کند. این فناوری با کمک به جداسازی افراد از موقعیت‌های خطرناک می‌تواند نوعی کنترل مهندسی مؤثر در ایمنی محیط کار باشد [32، 33]. «تشخیص شیء» یکی از وظایف اصلی بینایی ماشین است و هدف آن شناسایی و تعیین محل اشیا در تصویر یا ویدئوست. در میان روش‌های موجود، خانواده مدل‌های YOLO ــ سرواژه «فقط یک‌بار نگاه می‌کنی» ــ به‌دلیل توانایی تشخیص بلادرنگ توجه فراوانی جلب کرده است. نخستین مدل YOLO که Joseph Redmon و همکاران معرفی کردند [34]، تشخیص شیء را به‌جای یک مسئله طبقه‌بندی چندمرحله‌ای، یک مسئله رگرسیون واحد در نظر گرفت. همین تغییر امکان پردازش بلادرنگ را فراهم و YOLO را از چارچوب‌هایی مانند R-CNN و Fast R-CNN متمایز کرد.

نسخه YOLOv2 یا YOLO9000 با نرمال‌سازی دسته‌ای، طبقه‌بند با وضوح بالاتر و آموزش چندمقیاسی بهبود یافت و با ترکیب مجموعه‌داده‌های تشخیص و طبقه‌بندی، توانایی شناسایی بیش از 9000 دسته شیء را پیدا کرد [35]. در YOLOv3، پیش‌بینی چندمقیاسی همراه با اتصال‌های باقی‌مانده به کار رفت و جعبه‌های محدودکننده در سه مقیاس پیش‌بینی شدند؛ در نتیجه، تشخیص اشیای کوچک بهبود یافت. YOLOv4 که Bochkovskiy و همکاران توسعه دادند [36]، با ترکیب ستون فقرات CSPDarknet53، تجمیع مسیر PANet و تابع فعال‌ساز Mish برای اجرای کارآمد روی یک GPU بهینه شد و سرعت و دقت بهتری ارائه کرد. Ultralytics

در YOLOv5 قابلیت‌هایی مانند یادگیری خودکار لنگرهای جعبه محدودکننده، افزایش داده با موزاییک و تکامل ابرپارامترها را افزود. این نسخه در اندازه‌های کوچک، متوسط و بزرگ برای محدودیت‌های پردازشی و نیازهای دقت متفاوت عرضه شد [37]. نسخه‌های YOLOv6 و YOLOv7 عمدتاً کارایی و دقت را بهبود دادند؛ اما YOLOv8 تغییرهای معماری بیشتری برای تشخیص در موقعیت‌های دشوار، از جمله انسداد دید و پس‌زمینه پیچیده، ارائه کرد. YOLOv8 پنج اندازه nano (v8n)، small (v8s)، medium (v8m)، large (v8l) و extra-large (v8x) دارد و از تشخیص شیء، قطعه‌بندی تصویر، برآورد وضعیت بدن، ردیابی و طبقه‌بندی پشتیبانی می‌کند [37]. YOLOv9 نیز از معماری‌های ترکیبی شبکه عصبی، روش‌های پیشرفته افزایش داده و توابع زیان بهبودیافته بهره می‌برد تا دقت و پایداری بیشتری به دست آورد [38].

معماری YOLO در طول زمان دگرگونی‌های مهمی داشته است. «ستون فقرات» (Backbone) که نقشه ویژگی‌ها را از تصویر ورودی استخراج می‌کند، از Darknet-19 نسخه‌های اولیه به شبکه‌های عمیق‌تری مانند CSPDarknet53 رسیده است [37، 38]. بخش میانی یا «گردن» (Neck)، ویژگی‌های استخراج‌شده از لایه‌های مختلف را تجمیع می‌کند و معمولاً از PANet و FPN بهره می‌گیرد. «سر» (Head)، خروجی نهایی شامل جعبه‌های محدودکننده و احتمال تعلق به هر کلاس را تولید می‌کند. پیش‌بینی چندمقیاسی از YOLOv3 آغاز شد و در نسخه‌های بعدی تکامل یافت. شکل 1 معماری آشکارسازهای جدید را در سه بخش Backbone، Neck و Head نشان می‌دهد. در شکل 2 نیز نمونه‌هایی از وظایف بینایی ماشین نمایش داده شده است؛ از جمله کارگری که کلاه ایمنی ندارد (no_hardhat) و در بخش تشخیص شیء با جعبه قرمز مشخص شده است. این مدل‌ها برای آموزش از ترکیب توابع زیان مکان‌یابی، اطمینان و طبقه‌بندی استفاده می‌کنند. پیشرفت‌هایی مانند CIoU و DIoU در محاسبه زیان، همگرایی و دقت تشخیص را بهبود داده‌اند.

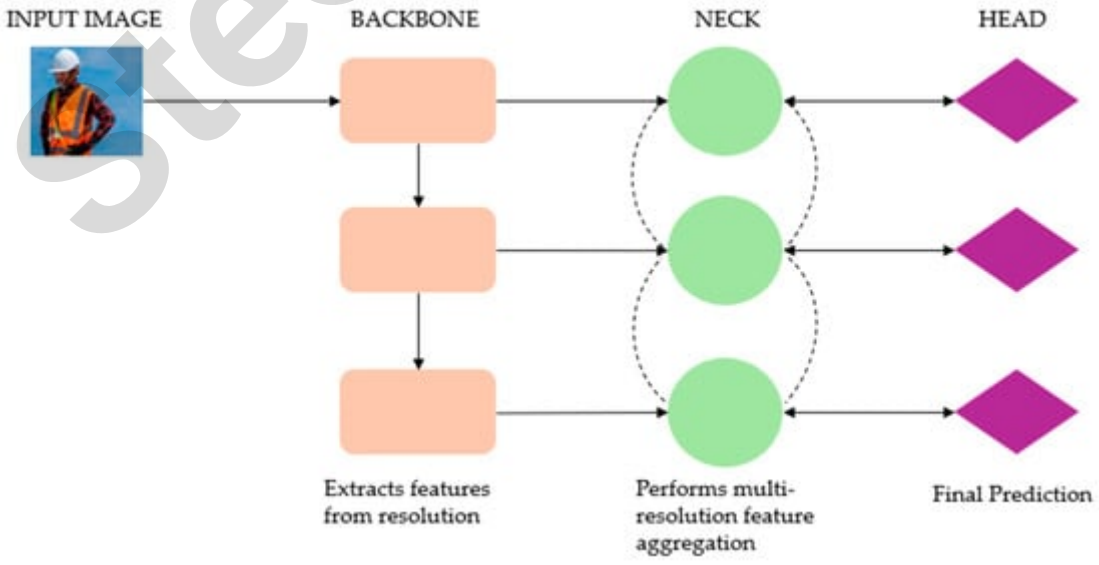

شکل 1. معماری آشکارسازهای پیشرفته با سه بخش ستون فقرات (Backbone)، گردن (Neck) و سر (Head). منبع: Awolusi، Lan و Cai، *AI* (2024)، DOI: 10.3390/ai5030058؛ مجوز CC BY 4.0.

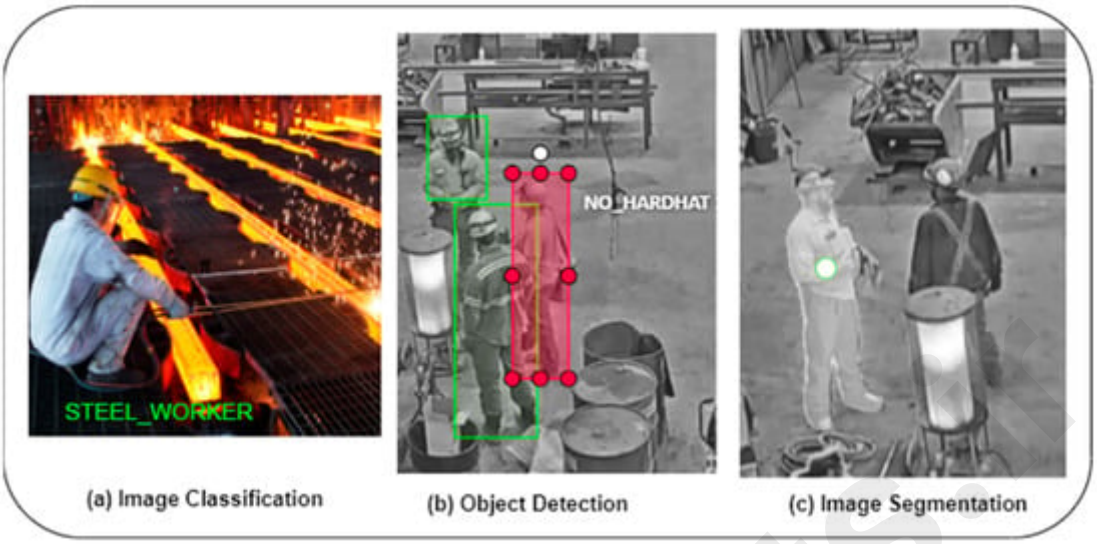

شکل 2. نمونه‌هایی از وظایف بینایی ماشین (CV). منبع: Lan، Awolusi و Cai، *AI* (2024)، DOI: 10.3390/ai5030058؛ مجوز CC BY 4.0.

شبکه‌های YOLO در حوزه‌های مختلف به‌کار رفته‌اند و انعطاف‌پذیری خود را نشان داده‌اند. در خودروهای خودران، این مدل‌ها برای تشخیص بلادرنگ عابران، خودروها، تابلوهای راهنمایی و موانع استفاده می‌شوند [39]. در حفاظت و نظارت تصویری، پایش و شناسایی تهدید را تسهیل می‌کنند [40]. در سلامت و تصویربرداری پزشکی، برای تشخیص تومور، قطعه‌بندی اندام‌ها و مکان‌یابی ابزار جراحی کاربرد دارند [41]. در کشاورزی نیز برای پایش محصول، تشخیص آفت و برآورد عملکرد به کار می‌روند و به کشاورزی دقیق کمک می‌کنند [42]. جدول 1 نمونه‌هایی از کاربرد YOLO در حوزه‌های دیگر را مرور می‌کند.

جدول 1. نمونه‌هایی از کاربرد مدل‌های YOLO در حوزه‌های مختلف

کاربرد	بخش صنعتی	تعداد کلاس‌ها	نسخه YOLO	تعداد تصاویر	عملکرد گزارش‌شده	منبع
تشخیص تجهیزات ساخت‌وساز	ساختمان	4	YOLOv5 و YOLOv8	4800	mAP@0.5 = 0.951	[43]
تشخیص ترک پیاده‌رو	ساختمان	4	YOLOv2، YOLOv3 و YOLOv4-tiny	4000	Accuracy = 0.94	[44]
تشخیص میوه گیلاس	کشاورزی	3	YOLOv4	400	F1-score = 0.947	[45]
بازرسی اتصال حرارتی قطعات	خودروسازی	3	YOLOv5	3000	mAP@0.95 = 0.95	[46]
شناسایی قطعات مونتاژی	هوافضا	150	YOLOv5	9450	mAP@0.5 = 0.99	[47]
تشخیص عیوب سطح فولاد	فولاد	6	YOLOv3	4057	mAP@0.95 = 0.72	[48]

کاربرد	بخش صنعتی	تعداد کلاس‌ها	نسخه YOLO	تعداد تصاویر	عملکرد گزارش‌شده	منبع
تشخیص ربات انبار	لجستیک	2	YOLOv8	335	mAP@0.95 = 0.86	[49]

۲.۵. ضرورت انجام پژوهش

کاربرد سامانه‌های بینایی ماشین در فولادسازی، به‌ویژه برای مدیریت ایمنی، هنوز در پژوهش‌های موجود به‌اندازه کافی بررسی نشده است. بیشتر تحقیقات بر افزایش بهره‌وری از طریق کنترل کیفیت، پایش ریخته‌گری مداوم، تشخیص عیوب سطح فولاد و پیش‌بینی وقوع پارگی پوسته در ریخته‌گری تمرکز داشته‌اند [50–52]. این کارها ارزشمندند، اما مستقیماً به مدیریت ایمنی کارخانه‌های فولاد نمی‌پردازند. پویایی عملیات و تنوع مخاطرات این صنعت نشان می‌دهد بررسی اختصاصی ظرفیت بینایی ماشین برای ارتقای ایمنی ضروری است. مقاله حاضر می‌کوشد این خلأ را پر کند و پایه‌ای برای توسعه پژوهش‌های آینده در زمینه کاربرد بینایی ماشین در ایمنی فولادسازی فراهم سازد.

یکی از دستاوردهای پژوهش حاضر، ارزیابی محصولات تجاری بینایی ماشین است که امکان استفاده در مدیریت ایمنی کارخانه فولاد را دارند. یافته‌ها تصویری جامع از سامانه‌های قابل‌استفاده و الگویی برای تولیدکنندگان علاقه‌مند به افزودن بینایی ماشین به دستورالعمل‌های ایمنی ارائه می‌کنند. افزون بر این، مقاله با یک مطالعه موردی درباره شناسایی کلاه ایمنی، کاربرد عملی تشخیص تجهیزات حفاظت فردی (PPE) را در محیط فولادسازی نشان می‌دهد و امکان‌پذیری این رویکرد را می‌آزماید.

۳. مواد و روش‌ها

هدف این تحقیق آزمودن امکان استفاده از بینایی ماشین برای مدیریت ایمنی در فولادسازی است. برای این کار، یک مطالعه پایلوت طراحی شد تا با یادگیری عمیق، استفاده کارکنان فولاد از کلاه ایمنی به‌صورت خودکار تشخیص داده شود. ابتدا مخاطراتی که ظرفیت پایش تصویری دارند شناسایی و طبقه‌بندی شدند؛ سپس با یک روش تصمیم‌گیری چندمعیاره، سامانه‌ای تجاری برای اجرای آزمایش انتخاب شد. مراحل تحقیق در شکل 3 آمده است.

SteelExperts.ir

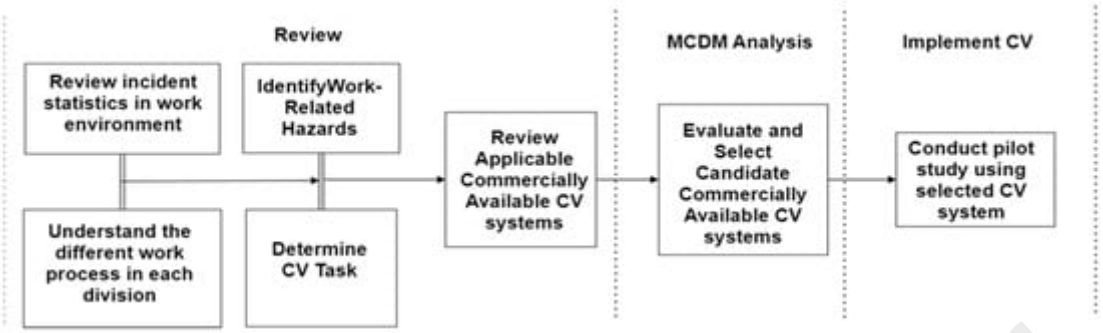

شکل 3. مراحل اجرای پژوهش. منبع: Lan، Awolusi و Cai، *AI* (2024)، DOI: 10.3390/ai5030058؛ مجوز CC BY 4.0.

۳.۱. شناسایی کاربردهای بینایی ماشین در ایمنی فولادسازی

برای تعیین کاربردهای مناسب بینایی ماشین در مدیریت ایمنی فولادسازی، به‌ویژه در یک مینی‌میل، لازم بود فرایندهای کاری این نوع کارخانه به‌خوبی شناخته شوند. پژوهش در سه مرحله «مرور منابع»، «مشاهده میدانی» و «توصیف و طبقه‌بندی خطرات» پیش رفت. در مرحله نخست، گروه تحقیق گزارش‌ها و مقاله‌های مربوط به فعالیت مینی‌میل‌ها را مطالعه کرد و استانداردهای بهره‌برداری، انواع تجهیزات، شیوه‌های کار و شاخص‌های مهم ایمنی، مانند LTIFR و FFR، را بررسی کرد. ابزار تصویری Steel Wheel متعلق به انجمن فناوری آهن و فولاد (AIST) نیز در این مرحله بسیار مفید بود؛ زیرا تصویری نظام‌مند از عملیات معمول مینی‌میل ارائه می‌کرد و درک اولیه پژوهشگران را از زنجیره فرایندها بهبود می‌داد.

پژوهشگران برای تکمیل شناخت حاصل از منابع مکتوب، یک مینی‌میل واقعی را از نزدیک بازدید کردند. مدیران کارخانه آن‌ها را از بخش‌ها و فرایندهای مختلف عبور دادند و جزئیات عملیات را توضیح دادند. در ادامه، مطابق رویکرد Bolderston [53]، مصاحبه گروهی درباره مخاطرات فعلی، اقدامات ایمنی موجود و کاستی‌های آن‌ها انجام شد. این گفت‌وگوی تقریباً 70 دقیقه‌ای با مشارکت اعضای گروه، ثبت یادداشت‌ها و مشخص‌کردن نکات کلیدی پیش رفت؛ روشی همسو با پیشنهاد Guest [54]. بازدید یک‌روزه همراه با مرور اولیه منابع، پایه‌ای مناسب برای شناخت فعالیت‌های مینی‌میل و خطراتی که کارکنان با آن روبه‌رو هستند فراهم کرد. سپس برای هر خطر، وظیفه بینایی ماشین متناسب با آن تعیین شد.

۳.۲. ارزیابی و انتخاب سامانه‌های تجاری بینایی ماشین برای ایمنی

برای اجرای مطالعه پایلوت درباره رعایت الزام استفاده از کلاه ایمنی در مینی‌میل، ابتدا باید سامانه بینایی ماشینِ مناسب برای انجام تشخیص انتخاب می‌شد.

۳.۲.۱. جست‌وجوی سامانه‌های بینایی ماشین

گروه تحقیق برای شناسایی سامانه‌های تجاری بینایی ماشین مناسبِ پایش ایمنی در فولادسازی، جست‌وجوی اینترنتی گسترده‌ای انجام داد. عبارت‌هایی مانند «شرکت‌های بینایی ماشین»، «هوش مصنوعی در سلامت و ایمنی»، «شرکت‌های عرضه‌کننده تشخیص شیء» و «هوش مصنوعی و ایمنی محیط کار» در Google جست‌وجو شدند. پس از دستیابی به گزینه‌های فراوان، تنها سامانه‌هایی بررسی شدند که برای کاربرد ایمنی ظرفیت واقعی داشتند. همچنین مطابق رویکرد Creswell [55]، از متخصصان صنعت نظرخواهی شد تا نتایج جست‌وجو کامل‌تر و مرتبط‌تر شود. ترکیب بررسی بازار و مشورت با خبرگان، امکان شناسایی محصولاتی را فراهم کرد که هم به‌صورت تجاری عرضه می‌شدند و هم با دامنه پژوهش و نیازهای ایمنی محیط کار تناسب داشتند.

۳.۲.۲. ارزیابی و انتخاب سامانه

در نهایت هشت سامانه آماده‌به‌کار بینایی ماشین برای کاربردهای ایمنی صنعت فولاد شناسایی شد. انتخاب گزینه مناسب از میان آن‌ها با روش تصمیم‌گیری چندمعیاره (MCDM) انجام گرفت. این روش‌ها به تصمیم‌گیرنده کمک می‌کنند گزینه‌ها را بر اساس چند معیار متفاوت مقایسه کند. از روش‌های شناخته‌شده می‌توان به فرایند تحلیل سلسله‌مراتبی (AHP)، فرایند تحلیل شبکه‌ای (ANP)، بهینه‌سازی چندهدفه بر پایه تحلیل نسبت‌ها (MOORA) و تکنیک ترجیح گزینه‌ها بر اساس شباهت به راه‌حل ایده‌آل (TOPSIS) اشاره کرد. انتخاب روش به هدف‌ها و ترجیح‌های تصمیم‌گیرنده بستگی دارد [56].

در این پژوهش از TOPSIS استفاده شد؛ روشی نسبتاً ساده، قابل‌فهم و کارآمد که تفاوت گزینه‌ها را با مقادیر نرمال‌شده آشکار می‌کند [57، 58]. این روش نخستین بار در سال 1981 توسط Hwang و Yoon ارائه و بعداً اصلاح شد. منطق آن مقایسه فاصله اقلیدسی هر گزینه با دو مرجع است: راه‌حل ایده‌آل مثبت (PIS) و راه‌حل ایده‌آل منفی (NIS). بهترین گزینه باید کمترین فاصله را با PIS و بیشترین فاصله را از NIS داشته باشد. شکل 4 گردش‌کار این مدل را برای انتخاب سامانه مناسب مطالعه پایلوت فولاد نشان می‌دهد.

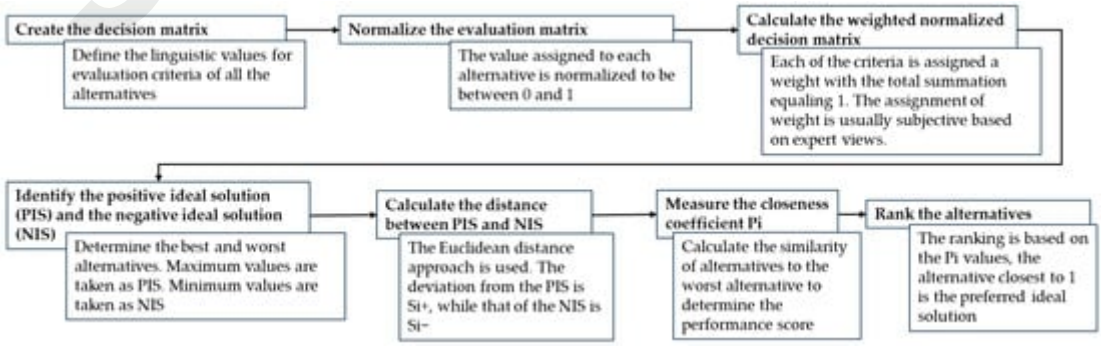

شکل 4. گردش‌کار TOPSIS برای ارزیابی سامانه‌های آماده‌به‌کار بینایی ماشین. منبع: Awolusi، Lan و Cai، *AI* (2024)، DOI: 10.3390/ai5030058؛ مجوز CC BY 4.0.

مراحل اجرای TOPSIS در این تحقیق به شرح زیر است:

گام 1 ـ تشکیل ماتریس تصمیم: هشت سامانه تجاری بینایی ماشین به‌عنوان گزینه‌ها و قابلیت‌هایی مانند تشخیص PPE، حفاظت از حریم خصوصی داده‌ها، تشخیص نزدیکی به تجهیزات سنگین، لغزش، سکندری و سقوط به‌عنوان معیارها در نظر گرفته شدند. برای هر معیار وزن اهمیت تعیین شد و وضعیت قابلیت‌ها با مقادیر زبانی «موجود» یا «ناموجود» بیان شد.

ماتریس تصمیم با $X = [x$ و بردار وزن معیارها با $W = [w , w , w , ..., w$ نمایش داده می‌شود. مجموع وزن‌ها برابر یک است.

$$w_1 + w_2 + w_3 + \cdots + w_n = 1$$

گام 2 ـ نرمال‌سازی ماتریس ارزیابی.

نرمال‌سازی باعث می‌شود مقادیر معیارها مقیاسی قابل‌مقایسه پیدا کنند. روابط (1) تا (3) روش‌های محاسبه مقدار نرمال‌شده n را نشان می‌دهند [56، 59، 60].

$$(n_{ij} = x_{ij} / \sqrt{(\Sigma_{i=1}^{m} x_{ij}^2)}) \quad (1$$

$$(n_{ij} = x_{ij} / \max_i(x_{ij})) \quad (2$$

$$(n_{ij} = (\max_i x_{ij} - x_{ij}) / (\max_i x_{ij} - \min_i x_{ij})) \text{ [هزینه]} \quad (3) \quad (n_{ij} = (x_{ij} - \min_i x_{ij}) / (\max_i x_{ij} - \min_i x_{ij})) \text{ [منفعت]؛}$$

گام 3 ـ محاسبه ماتریس نرمال‌شده وزنی.

با ضرب هر مقدار نرمال‌شده در وزن معیار مربوط، درایه‌های ماتریس وزنی به دست می‌آیند؛ مطابق رابطه (4) [56، 59، 60].

$$(v_{ij} = w_j \times n_{ij}) \quad (4$$

در این روابط $i = 1,...,m$ و $j = 1,...,n$ است. معیارها می‌توانند از نوع هزینه یا منفعت باشند؛ در این تحقیق «در دسترس بودن یک قابلیت» معیار منفعت است و مقدار بیشتر آن گزینه بهتری را نشان می‌دهد.

گام 4 ـ تعیین راه‌حل ایده‌آل مثبت و منفی. برای هر معیار، بهترین و بدترین مقدار میان همه سامانه‌های بینایی ماشین مشخص می‌شود؛ یعنی مقادیر بیشینه و کمینه معیارها تعیین می‌شوند.

راه‌حل ایده‌آل مثبت با V نمایش داده می‌شود و طبق رابطه (5) محاسبه می‌گردد [56، 59، 60].

$$(V^+ = (v_1^+, ..., v_n) \text{؛ } v_j^+ = \max_i(v_{ij}) \text{ برای معیار منفعت و } \min_i(v_{ij}) \text{ برای معیار هزینه}) \quad (5$$

راه‌حل ایده‌آل منفی با V مشخص می‌شود و تعریف آن در رابطه (6) آمده است.

$$(V^- = (v_1^-, ..., v_n) \text{؛ } v_j^- = \min_i(v_{ij}) \text{ برای معیار منفعت و } \max_i(v_{ij}) \text{ برای معیار هزینه}) \quad (6$$

گام 5 ـ محاسبه فاصله تا PIS و NIS.

فاصله اقلیدسی هر گزینه از راه‌حل ایده‌آل مثبت با S و از راه‌حل ایده‌آل منفی با S نمایش داده می‌شود. روابط (7) و (8) این دو فاصله را تعریف می‌کنند [56، 59، 60].

$$S_i^+ = \sqrt{[\Sigma_{j=1}^{n} (v_{ij} - v_j^+)^2]} \quad (7)$$

$$S_i^- = \sqrt{[\Sigma_{j=1}^{n} (v_{ij} - v_j^-)^2]} \quad (8)$$

گام 6 ـ محاسبه ضریب نزدیکی p.

گزینه‌ها بر اساس ضریب نزدیکی p رتبه‌بندی می‌شوند؛ گزینه‌ای که مقدار p آن به یک نزدیک‌تر است، انتخاب بهتری خواهد بود. رابطه (9) نحوه محاسبه این ضریب را نشان می‌دهد [56، 59، 60].

$$p_i = S_i^- / (S_i^- + S_i^+) \quad (9)$$

۳.۳. مطالعه پایلوت تشخیص کلاه ایمنی

۳.۳.۱. بستر اجرای مطالعه

مرور ادبیات نشان می‌دهد که کاربرد بینایی ماشین در صنایع مختلف گسترده شده، اما پژوهش‌های اختصاصی درباره مدیریت ایمنی فولادسازی همچنان اندک است. این کمبود به‌دلیل ویژگی‌های خاص صنعت فولاد، از جمله شرایط متغیر و دشوار کار، کمبود داده آموزشی و حساسیت ذی‌نفعان نسبت به حریم خصوصی داده‌ها اهمیت بیشتری پیدا می‌کند. این تحقیق به‌عنوان یک مطالعه پایلوت اولیه می‌کوشد امکان استفاده عملی از بینایی ماشین را در مدیریت ایمنی فولادسازی بسنجد. تمرکز اصلی، اثبات امکان اجرا و کاربردپذیری سامانه است، نه صرفاً بیشینه‌کردن شاخص‌های عملکرد. سامانه منتخب با تحلیل MCDM برگزیده شد و مسئله مشخص آزمایش، تشخیص استفاده از کلاه ایمنی توسط کارکنان بود. ارزیابی کمی سامانه انتخابی می‌تواند تصویری اولیه از توان فناوری و آمادگی آن برای محیط واقعی فولادسازی فراهم کند و مبنایی برای مطالعات دقیق‌تر و عملکردمحور آینده باشد.

۳.۳.۲. مدل‌های تشخیص

برای تشخیص کلاه ایمنی در فولادسازی، سه نسخه از پیش‌آموزش‌دیده YOLOv8m، YOLOv5m و YOLOv9c با یکدیگر مقایسه شدند. YOLOv5m به توازن سرعت و دقت معروف است و از CSPNet برای جریان مؤثر گرادیان، PANet برای ادغام ویژگی‌ها در چند مقیاس و SPPF برای استخراج بهتر ویژگی استفاده می‌کند. YOLOv8m با ستون فقرات CSPDarknet53، ترکیب PANet و FPN و روش‌های افزایش داده مانند MixUp و CutMix به دنبال تشخیص بهتر در چند مقیاس و تعمیم‌پذیری بالاتر است. در YOLOv9c نیز

CSPResNeXt برای استخراج مقاوم ویژگی‌ها، BiFPN برای ادغام کارآمد ویژگی و روش‌های تشخیص انطباقی برای مکان‌یابی بهتر و کاهش مثبت کاذب به‌کار رفته‌اند. این مدل‌ها به‌دلیل سرعت، دقت و استحکام، گزینه‌های مناسبی برای کاربردهای ایمنی بلادرنگ در محیط صنعتی‌اند. مقایسه معماری سه مدل در جدول 2 آمده است.

جدول 2. مقایسه معماری نسخه‌های YOLO [37]

ویژگی	YOLOv5	YOLOv8	YOLOv9
نوع شبکه	تمام‌متصل	تمام‌متصل	تمام‌متصل
ستون فقرات استخراج ویژگی	CSPDarknet53	CSPDarknet53 اختصاصی با اتصال جزئی بین مراحل	شبکه تجمیع کارآمد لایه‌ها (GLEAN)
بخش میانی (Neck)	شبکه تجمیع مسیر (PANet)	شبکه تجمیع مسیر (PANet)	اطلاعات گرادیان برنامه‌پذیر (PGI)
بخش خروجی (Head)	سر YOLOv5 با سه لایه تشخیص	سر YOLOv8 بدون لنگرِ بهبودیافته	سر YOLOv8 بدون لنگرِ انطباقی

۳.۳.۳. گردآوری و پردازش مجموعه‌داده

برای تحلیل کمی، از مجموعه‌داده‌ای متشکل از 703 تصویر با برچسب‌گذاری دقیق استفاده شد. این تصاویر از پنج ساعت فیلم دوربین مداربسته (CCTV) ناحیه تعمیرات (maint) یک مینی‌میل فولاد استخراج شدند؛ ناحیه‌ای که انبار را نیز در بر می‌گیرد. به‌دلیل تردد زیاد کارکنان، این محل برای گردآوری داده در بازه محدود مشاهده مناسب بود. برچسب‌گذاری تصاویر با ابزار تعاملی حاشیه‌نویسی تصویر و ویدئو CVAT انجام شد.

برای بررسی اثر تنظیم دقیق مدل تشخیص شیء ازپیش‌آموزش‌دیده، مدل با همین مجموعه 703 تصویری که کوچک اما متنوع بود دوباره آموزش داده شد. تنوع داده‌ها با چرخش تصویر، وارونگی افقی و تغییر روشنایی و اشباع تصویر خاکستری افزایش یافت؛ اقدامی ضروری برای جلوگیری از بیش‌برازش مدل. چون موارد واقعی نقض الزام کلاه ایمنی در تصاویر CCTV کم بود، تصاویر مصنوعیِ نشان‌دهنده این تخلف نیز ساخته شدند. برای این کار از روش درون‌نقاشی مبتنی بر Stable Diffusion که Rombach و همکاران شرح داده‌اند استفاده شد [61]؛ نمونه آن در شکل 5 دیده می‌شود. برای افزایش استحکام ارزیابی، اعتبارسنجی K بخشی با K = 5 به کار رفت و در هر مرحله 80 درصد داده‌ها برای آموزش و 20 درصد برای اعتبارسنجی تخصیص یافت. شکل 6 نمونه‌ای از تصاویر آموزشی را نشان می‌دهد.

SteelExperts.ir



شکل 5. نمایش افزایش داده با درون‌نقاشی (Stable Diffusion: (A داده اصلی، (B) داده افزوده‌شده، (C) داده اصلی و (D) داده افزوده‌شده.
منبع: Lan، Awolusi و Cai، *AI* (2024)، DOI: 10.3390/ai5030058؛ مجوز CC BY 4.0.



شکل 6. نمونه تصاویر مجموعه‌داده آموزشی ثبت‌شده در مینی‌میل فولاد. منبع: Lan، Awolusi و Cai، *AI* (2024)، DOI: 10.3390/ai5030058؛ مجوز CC BY 4.0.

۳.۳.۴. شاخص‌های ارزیابی

عملکرد مدل‌های تشخیص شیء با شاخص‌های دقت مثبت (Precision)، یادآوری (Recall)، امتیاز F1، دقت متوسط (AP)، ویژگی (Specificity) و سطح زیر منحنی (AUC) سنجیده شد [62، 63]. برای تشخیص رعایت الزام کلاه ایمنی، «نداشتن کلاه ایمنی» کلاس مثبت در نظر گرفته شد. بنابراین TP یعنی تشخیص درست فرد

بدون کلاه، FP یعنی پیش‌بینی نادرستِ نداشتن کلاه برای فردی که کلاه دارد، و FN یعنی تشخیص‌ندادن فردی که کلاه ندارد. برای تعیین این وضعیت‌ها در ماتریس درهم‌ریختگی، آستانه اشتراک بر اجتماع (IoU) برابر 0.5 انتخاب شد.

۴. نتایج و بحث

نتایج پژوهش در بخش‌های بعدی و مطابق ترتیب روش تحقیق ارائه می‌شوند. ابتدا دسته‌بندی مخاطرات، سپس کاربرد TOPSIS و در نهایت تحلیل داده‌های مطالعه پایلوت شرح داده خواهد شد. این ترتیب، مسیر یافته‌ها را از شناسایی و طبقه‌بندی خطر تا ارزیابی گزینه‌ها و نتیجه‌های تجربی روشن می‌کند.

۴.۱. طبقه‌بندی مخاطرات ایمنی و تحلیل TOPSIS

۴.۱.۱. شناسایی مخاطرات برای کاربرد بینایی ماشین در فولادسازی

در این مطالعه خطرات هر مرحله از تولید فولاد در مینی‌میل به‌دقت شناسایی شده و نشان داده می‌شود که بینایی ماشین چگونه می‌تواند برای پایش هدفمند آن‌ها به کار رود. هدف، ایجاد هشدار زودهنگام و کاهش احتمال آسیب، بیماری و مرگ‌ومیر است. بررسی از محوطه خردایش قراضه آغاز می‌شود؛ جایی که فلزات قراضه فرآوری و مواد آهنی از غیرآهنی جدا می‌شوند. همه مینی‌میل‌ها مرحله خردایش ندارند، اما برای جامع‌بودن بررسی، این بخش نیز لحاظ شده است. سپس مواد آهنی برای ذوب به کوره قوس الکتریکی (EAF) منتقل می‌شوند. در مرحله بعد، فولاد مذاب در ایستگاه متالورژی پاتیل (LMS) تصفیه می‌شود و در ماشین ریخته‌گری مداوم به محصولات نیمه‌نهایی مانند بیلت، اسلب یا بلوم تبدیل می‌گردد. این محصولات در نورد و فرایندهای تکمیلی، از جمله بازپخت، شکل‌دهی گرم، نورد سرد، اسیدشویی، گالوانیزه، پوشش‌دهی و رنگ‌آمیزی به محصول نهایی تبدیل می‌شوند. چرخه با تکمیل محصول و حمل آن پایان می‌یابد.

جدول 3 ارتباط میان مخاطرات شناسایی‌شده در هر مرحله مینی‌میل، وظایف قابل‌انجام با بینایی ماشین و نحوه پیاده‌سازی آن‌ها را به‌تفصیل نشان می‌دهد. هدف، دستیابی به چارچوبی است که بتوان در آن خطرات را به‌شکل مؤثر ردیابی، شناسایی یا پایش کرد. شکل 7 نیز جریان کلی تولید فولاد و جایگاه بینایی ماشین در تقویت ایمنی مراحل مختلف را به تصویر می‌کشد. تطبیق وظایف CV با مخاطرات هر ایستگاه، رویکردی عملی برای افزایش ایمنی در محیط پویای مینی‌میل فراهم می‌آورد.

جدول 3. شناسایی مخاطرات ایمنی و کاربردهای بینایی ماشین در فولادسازی

مخاطره	وظیفه بینایی ماشین	تجهیز گردآوری داده	نمونه موقعیت خطر	کاربرد بینایی ماشین	منبع
برخورد جسم یا تجهیز با فرد	ردیابی و تشخیص شیء	دوربین RGB، دوربین RGB-D، دوربین دید استریو	(1) پرتاب مواد هنگام خردکردن قراضه در واحدهای دارای شردر؛ (2) احتمال برخورد دامپ‌تراک یا جرثقیل دروازه‌ای متحرک با کارکنان؛ (6) برخورد محصولات نهایی، قیچی، میلگرد خم‌شده یا کامیون بارگیری با فرد.	ردیابی بلادرنگ کارکنان و صدور هشدار هنگام نزدیک‌شدن به ناحیه خطر برخورد.	[64]
گرفتارشدن میان اجسام	ردیابی و تشخیص شیء	دوربین RGB، RGB-D و استریو	(1) گرفتارشدن میان تجهیزات، شردر و قراضه در محوطه خردایش؛ (2) گرفتارشدن میان بار در شعاع گردش جرثقیل و اجسام ثابت یا متحرکِ فولادسازی؛ (6) گرفتارشدن میان کامیون‌ها و محصول انباشته، مانند میلگرد.	شناسایی، طبقه‌بندی و ردیابی انسان و تجهیزات و هشدار در صورت نزدیک‌شدن به موقعیت‌های خطرناک.	[65]
آتش‌سوزی	تشخیص و طبقه‌بندی شیء	دوربین RGB، RGB-D، فروسرخ و Flash LiDAR	(2) خطر بالای حریق در نزدیکی کوره با فولاد مذاب در دمای بالاتر از 2800 درجه فارنهایت؛ (3) خطر در LMS و عملیات تصفیه، آلیاژسازی، گوگردزدایی و گاززدایی فولاد مذاب؛ (4) خطر حریق هنگام انجماد مذاب در دماهای بالا.	شناسایی حریق در مراحل اولیه، گاه زودتر از آشکارساز دود، با روش‌های یادگیری عمیق.	[66]
ریزش یا پاشش مذاب	طبقه‌بندی، قطعه‌بندی و تشخیص شیء	دوربین RGB و RGB-D	(2) پاشش فولاد مذاب نزدیک کوره؛ (3) احتمال پاشش هنگام تخلیه از EAF به ایستگاه تصفیه؛ (4) احتمال ریزش هنگام انتقال مذاب از پاتیل به تاندیش.	تشخیص پاشش با قطعه‌بندی تصویر و هشدار به کارکنان در محدوده نزدیک.	[67]
لغزش، سکندری و سقوط	تشخیص شیء و تشخیص رفتار	دوربین RGB و RGB-D	(2) خطر بالا در اطراف کوره به‌دلیل عملیات و دید محدود؛ (5) احتمال لغزش کارکنان در نورد به‌دلیل چیدمان نامناسب تجهیزات؛ (6) خطر لغزش و سقوط هنگام تکمیل و حمل، از جمله نزدیکی میلگردهای انباشته.	تشخیص نزدیکی افراد به موقعیت‌های لغزش و سقوط و شناسایی خودِ سقوط در زمان واقعی؛ امکان یکپارچگی با حسگرهای جلیقه، ساعت یا کلاه هوشمند.	[68]
وضعیت نامناسب بدن کارکنان	برآورد وضعیت بدن و تشخیص رفتار	دوربین RGB، RGB-D و استریو	وضعیت بدنی نامناسب در همه مراحل حضور کارکنان ممکن است دیده شود؛ باید تعامل فرد با ابزار، تجهیزات و محیط در همه فرایندها بررسی شود.	تحلیل تصویر و ویدئو برای تشخیص وضعیت بدن و هشدار هنگام ایجاد خطر ارگونومیک.	[69]
استفاده‌نکردن از PPE	طبقه‌بندی و تشخیص شیء	دوربین RGB و RGB-D	تجهیزات حفاظت فردی در تمام بخش‌های مینی‌میل لازم است و کارکنان باید در هر محل کاری از پوشش مقرر استفاده کنند.	تشخیص افراد فاقد کلاه ایمنی، جلیقه، دستکش و در برخی بخش‌ها عینک ایمنی.	[70]
دمای بسیار بالا	طبقه‌بندی، قطعه‌بندی و تشخیص شیء	دوربین فروسرخ (IR)	کل زنجیره مینی‌میل کارکنان را در معرض گرمای شدید قرار می‌دهد و پایش آن ضروری است.	استفاده از نگاشت حرارتی و تصاویر چهره برای شناسایی نشانه‌های تنش گرمایی کارکنان بر اساس کدهای رنگی.	[71]

SteelExperts.ir

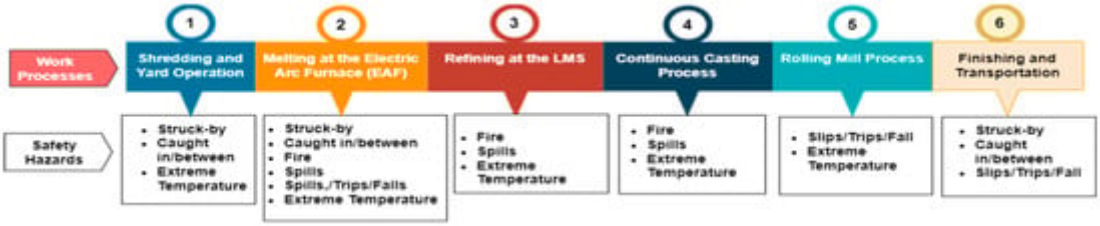

شکل 7. مخاطرات شناسایی‌شده در مراحل مختلف تولید فولاد در مینی‌میل. منبع: Lan، Awolusi و Cai، *AI* (2024)، DOI: 10.3390/ai5030058؛ مجوز CC BY 4.0.

۴.۱.۲. تحلیل TOPSIS

پس از شناسایی و دسته‌بندی مخاطرات، انتخاب سامانه‌ای برای اجرای پایلوت ضرورت پیدا کرد. مطابق روش تحقیق، تکنیک TOPSIS برای مقایسه هشت محصول بینایی ماشین به کار رفت: Everguard، Intenseye، Kogniz، Chooch، Rhyton، Protex، Cogniac و Matroid. این محصولات بر اساس یازده معیار ارزیابی شدند که قابلیت تشخیص PPE، حریم خصوصی داده‌ها، ارگونومی، سلامت، حصار مجازی (Geofencing)، نزدیکی به تجهیزات سنگین، لغزش/سکندری/سقوط، کاربرد در فولادسازی، پردازش بلادرنگ، سهولت استفاده از رابط گرافیکی (GUI) و انعطاف‌پذیری در دیگر کاربردها را در بر می‌گرفت. معیارها بر مبنای مرور منابع و میزان تأثیرشان بر مدیریت مطلوب ایمنی صنعت فولاد انتخاب شدند. جدول‌های 4 تا 8 نتایج ارزیابی TOPSIS را نشان می‌دهند: جدول 4 مقادیر زبانی معیارها را تعریف می‌کند که در آن 1 به معنای «غیرقابل‌ارائه» و 2 به معنای «قابل‌ارائه» است؛ جدول 5 ماتریس ارتباط معیارها و گزینه‌ها و وزن‌های مربوط را نمایش می‌دهد. وزن‌ها بر اساس تجربه ایمنی گروه پژوهش و تأثیر هر معیار بر هدف مطالعه، به‌صورت قضاوتی تعیین شدند. جدول 6 مقادیر نرمال‌شده و جدول 7 مقادیر وزن‌دار همراه با راه‌حل‌های ایده‌آل مثبت و منفی را ارائه می‌کنند.

جدول 4. تعریف مقادیر زبانی برای معیارهای ارزیابی

مقدار زبانی	PPED	DP	OA	EG	H	GF	PHE	STF	AS	RT	GUI
موجود = 2	2	2	2	2	2	2	2	2	2	2	2
ناموجود = 1	1	1	1	1	1	1	1	1	1	1	1

PPED: تشخیص تجهیزات حفاظت فردی؛ DP: حریم خصوصی داده؛ OA: کاربردهای دیگر؛ EG: ارگونومی؛ H: سلامت؛ GF: حصار مجازی؛ PHE: نزدیکی به تجهیزات سنگین؛ STF: لغزش، سکندری و سقوط؛ AS: کاربرد در فولادسازی؛ RT: پردازش بلادرنگ؛ GUI: سهولت استفاده از رابط گرافیکی.

جدول 5. مؤلفه‌های ماتریس ارزیابی

GUI	RT	AS	STF	PHE	GF	H	EG	OA	DP	PPED	سامانه CV
2	2	2	2	2	2	2	2	1	2	2	Everguard
2	2	1	2	2	1	1	2	1	2	2	Intenseye
2	2	1	1	1	1	1	1	2	2	2	Cogniac
2	2	1	1	1	1	1	1	1	2	2	Protex
1	1	1	1	2	1	1	2	1	1	2	Rhyton
2	2	1	1	2	2	1	1	2	2	2	Chooch
2	2	1	2	2	1	1	1	2	1	2	Kogniz
2	2	1	1	1	2	1	1	2	2	2	Matroid
0.05	0.1	0.15	0.1	0.1	0.1	0.05	0.1	0.1	0.05	0.1	وزن معیارها

PPED: تشخیص تجهیزات حفاظت فردی؛ DP: حریم خصوصی داده؛ OA: کاربردهای دیگر؛ EG: ارگونومی؛ H: سلامت؛ GF: حصار مجازی؛ PHE: نزدیکی به تجهیزات سنگین؛ STF: لغزش، سکندری و سقوط؛ AS: کاربرد در فولادسازی؛ RT: پردازش بلادرنگ؛ GUI: سهولت استفاده از رابط گرافیکی.

جدول 6. مقادیر نرمال‌شده ماتریس ارزیابی

GUI	RT	AS	STF	PHE	GF	H	EG	OA	DP	PPED	سامانه CV
0.371	0.371	0.603	0.485	0.417	0.485	0.603	0.485	0.224	0.392	0.354	Everguard
0.371	0.371	0.302	0.485	0.417	0.243	0.302	0.485	0.224	0.392	0.354	Intenseye
0.371	0.371	0.302	0.243	0.209	0.243	0.302	0.243	0.447	0.392	0.354	Cogniac
0.371	0.371	0.302	0.243	0.209	0.243	0.302	0.243	0.224	0.392	0.354	Protex
0.186	0.186	0.302	0.243	0.417	0.243	0.302	0.485	0.224	0.196	0.354	Rhyton
0.371	0.371	0.302	0.243	0.417	0.485	0.302	0.243	0.447	0.392	0.354	Chooch
0.371	0.371	0.302	0.485	0.417	0.243	0.302	0.243	0.447	0.196	0.354	Kogniz
0.371	0.371	0.302	0.243	0.209	0.485	0.302	0.243	0.447	0.392	0.354	Matroid

PPED: تشخیص تجهیزات حفاظت فردی؛ DP: حریم خصوصی داده؛ OA: کاربردهای دیگر؛ EG: ارگونومی؛ H: سلامت؛ GF: حصار مجازی؛ PHE: نزدیکی به تجهیزات سنگین؛ STF: لغزش، سکندری و سقوط؛ AS: کاربرد در فولادسازی؛ RT: پردازش بلادرنگ؛ GUI: سهولت استفاده از رابط گرافیکی.

جدول 7. مقادیر وزن‌دار ماتریس ارزیابی همراه با PIS و NIS

سامانه CV	PPED	DP	OA	EG	H	GF	PHE	STF	AS	RT	GUI
Everguard	0.035	0.020	0.022	0.049	0.030	0.049	0.042	0.049	0.090	0.037	0.019
Intenseye	0.035	0.020	0.022	0.049	0.015	0.024	0.042	0.049	0.045	0.037	0.019
Cogniac	0.035	0.020	0.045	0.024	0.015	0.024	0.021	0.024	0.045	0.037	0.019
Protex	0.035	0.020	0.022	0.024	0.015	0.024	0.021	0.024	0.045	0.037	0.019
Rhyton	0.035	0.010	0.022	0.049	0.015	0.024	0.042	0.024	0.045	0.019	0.009
Chooch	0.035	0.020	0.045	0.024	0.015	0.049	0.042	0.024	0.045	0.037	0.019
Kogniz	0.035	0.010	0.045	0.024	0.015	0.024	0.042	0.049	0.045	0.037	0.019
Matroid	0.035	0.020	0.045	0.024	0.015	0.049	0.021	0.024	0.045	0.037	0.019
V	0.035	0.020	0.045	0.049	0.030	0.049	0.042	0.049	0.090	0.037	0.019
V	0.035	0.010	0.022	0.024	0.015	0.024	0.021	0.024	0.045	0.019	0.009

PPED: تشخیص تجهیزات حفاظت فردی؛ DP: حریم خصوصی داده؛ OA: کاربردهای دیگر؛ EG: ارگونومی؛ H: سلامت؛ GF: حصار مجازی؛ PHE: نزدیکی به تجهیزات سنگین؛ STF: لغزش، سکندری و سقوط؛ AS: کاربرد در فولادسازی؛ RT: پردازش بلادرنگ؛ GUI: سهولت استفاده از رابط گرافیکی.

جدول 8. فاصله از راه‌حل‌های ایده‌آل، ضریب نزدیکی و رتبه گزینه‌ها

سامانه CV	S	S	ضریب نزدیکی p	رتبه
Everguard	0.022	0.071	0.760	1
Intenseye	0.058	0.046	0.444	2
Cogniac	0.067	0.032	0.324	6
Protex	0.071	0.023	0.246	8
Rhyton	0.067	0.032	0.323	7
Chooch	0.059	0.045	0.435	3
Kogniz	0.060	0.044	0.426	4
Matroid	0.062	0.040	0.392	5

در جدول 8 فاصله هر گزینه از راه‌حل ایده‌آل مثبت (PIS) و منفی (NIS)، ضریب نزدیکی و رتبه نهایی آمده

است. انتخاب بر اساس ضریب نزدیکی به PIS انجام شد. از میان هشت سامانه، Everguard با ضریب 0.760 در رتبه اول، Intenseye با 0.444 در رتبه دوم و Chooch با 0.435 در رتبه سوم قرار گرفتند. بنابراین، بر اساس معیارهای مطالعه، Everguard به‌عنوان گزینه منتخب برای کاربردهای ایمنی فولادسازی و اجرای پایلوت تعیین شد.

۴.۲. نتایج مطالعه پایلوت تشخیص کلاه ایمنی با سامانه منتخب

۴.۲.۱. محیط آزمایش

مدل شبکه با زبان Python و کتابخانه یادگیری عمیق PyTorch پیاده‌سازی شد. PyTorch ورود داده‌های برچسب‌گذاری‌شده، به‌روزرسانی وزن‌ها و محاسبات لازم را امکان‌پذیر کرد. جزئیات GPU، CPU و کتابخانه‌ها و ابزارهای محیط اجرا در جدول 9 آمده است. همه تصاویر آموزشی به اندازه ورودی 640 تغییر مقیاس داده شدند. آموزش در 50 دوره (Epoch) با اندازه دسته 16 و نرخ یادگیری 0.001 انجام شد. مقادیر تکانه (Momentum)، ضریب زیان جعبه و نوع بهینه‌ساز ثابت نگه داشته شدند. بهینه‌ساز گرادیان کاهشی تصادفی (SGD) با تکانه 0.937 انتخاب شد. Gupta و همکاران [72] اشاره کرده‌اند که هرچند همگرایی SGD کندتر و گرادیان‌های آن به‌طور یکنواخت مقیاس‌بندی می‌شوند، خطای آموزشی پایین‌تر می‌تواند به تعمیم‌پذیری بهتر بر داده‌های آزمون کمک کند. آموزش با یک پردازنده گرافیکی NVIDIA 4090 اجرا شد؛ این پیکربندی پردازش مناسب وظیفه تشخیص شیء را ممکن ساخت.

جدول 9. پیکربندی سامانه مدل‌سازی و محیط اجرا

پارامتر	پیکربندی
پردازنده مرکزی (CPU)	Intel i9-13900K ×1
پردازنده گرافیکی (GPU)	NVIDIA 4090 ×1
حافظه RAM	64 GB
زبان برنامه‌نویسی	Python
سیستم‌عامل	Ubuntu 22.04

۴.۲.۲. نتایج تشخیص مدل‌ها

نتایج Precision، Recall، F1 و mAP

برای ارزیابی قابل‌اتکای عملکرد و توان تعمیم مدل‌ها به داده‌های دیده‌نشده، از اعتبارسنجی متقاطع پنج‌بخشی استفاده شد. سه نسخه پیشرفته YOLOv8m، YOLOv5m و YOLOv9c روی مجموعه 703 تصویر برچسب‌گذاری‌شده از کارخانه فولاد آزمایش شدند.

مجموعه‌داده به پنج زیرمجموعه تقریباً مساوی تقسیم شد. در هر تکرار، یکی از زیرمجموعه‌ها برای آزمون و بقیه برای آموزش استفاده شدند؛ این فرایند پنج بار ادامه یافت تا همه تصاویر در ارزیابی نوبتی حضور داشته باشند. میانگین شاخص‌های هر تکرار به‌عنوان برآورد عملکرد کلی گزارش شد. شکل 8 پیش‌بینی مدل‌ها را در کنار برچسب‌های مرجع واقعی (Ground Truth) نشان می‌دهد. برچسب‌ها شامل «دارای کلاه ایمنی» (in_hardhat)، «فاقد کلاه ایمنی» (no_hardhat) و «نامرئی/خارج از دید» (invisible) هستند. در نمونه‌های نمایش‌داده‌شده، امتیاز اطمینان بالا در چند مدل دیده می‌شود و توانایی آن‌ها در پیش‌بینی را نشان می‌دهد.

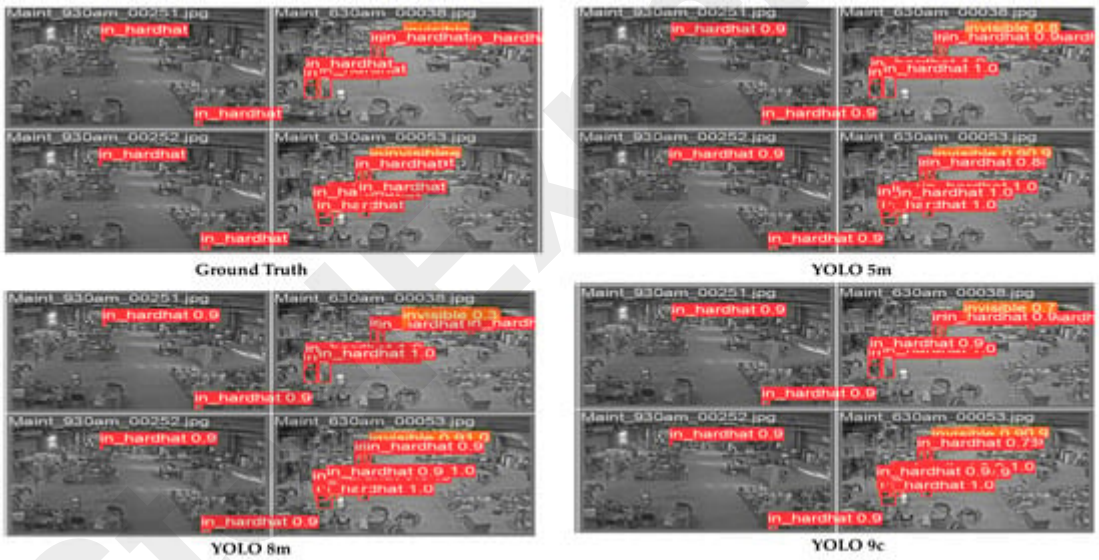

شکل 8. مقایسه برچسب‌های مرجع واقعی (Ground Truth) با جعبه‌های پیش‌بینی‌شده توسط مدل‌ها. منبع: Lan، Awolusi و Cai، *AI*، DOI: 10.3390/ai5030058 (2024)؛ مجوز CC BY 4.0.

جدول 10 خلاصه نتایج اعتبارسنجی متقاطع را برای سه مدل در چهار شاخص کلیدی دقت مثبت (Precision)، یادآوری، F1 و میانگین دقت متوسط (mAP) ارائه می‌کند. دقت مثبت بالا یعنی مدل افراد متخلف را درست تشخیص می‌دهد و هشدارهای مثبت کاذب کمترند. یادآوری بالا نشان‌دهنده شناسایی بیشتر موارد تخلف و کاهش موارد ازدست‌رفته است. F1 توازن دقت مثبت و یادآوری را می‌سنجد و mAP کارایی تشخیص را در سطوح مختلف یادآوری و کلاس‌های متفاوت جمع‌بندی می‌کند. YOLOv5m در پنج بخش، میانگین Precision برابر 0.976 داشت و مقدار هر بخش بین 0.96 تا 0.98 بود. میانگین Recall آن 0.974 گزارش شد که توانایی خوب شناسایی موارد مثبت واقعی را نشان می‌دهد. بااین‌حال، F1 با میانگین 0.956 نوسان بیشتری داشت؛

یعنی توازن بین Precision و Recall در تکرارها کاملاً ثابت نبود. میانگین mAP این مدل 0.940 بود که با وجود مقداری نوسان، قابلیت تشخیص قابل‌قبولی را در کلاس‌های مختلف نشان می‌دهد.

جدول 10. نتایج اعتبارسنجی پنج‌بخشی مدل‌های YOLO

بخش	YOLOv5m / Precision	YOLOv8m / Precision	YOLOv9c / Precision	YOLOv5m / Recall	YOLOv8m / Recall	YOLOv9c / Recall	YOLOv5m / F1	YOLOv8m / F1	YOLOv9c / F1	YOLOv5m / mAP	YOLOv8m / mAP	YOLOv9c / mAP
1	0.96	0.97	0.94	0.96	0.98	0.98	0.97	0.97	0.98	0.93	0.93	0.94
2	0.97	0.98	0.98	0.99	0.98	0.97	0.958	0.98	0.97	0.94	0.92	0.94
3	0.99	0.98	0.98	0.98	0.97	0.98	0.94	0.98	0.98	0.95	0.95	0.95
4	0.98	0.98	0.99	0.97	0.97	0.97	0.98	0.98	0.98	0.95	0.94	0.95
5	0.98	0.98	0.98	0.98	0.98	0.98	0.93	0.98	0.98	0.93	0.94	0.95
میانگین	0.976	0.978	0.974	0.976	0.976	0.976	0.9556	0.982	0.978	0.938	0.936	0.944

یادداشت ویرایشی: چند میانگین در متن توضیحی مقاله با اعداد ردیف «میانگین» این جدول یکسان نیست؛ همه مقادیر جدول عیناً از PDF اصلی حفظ شده‌اند.

در مقابل، YOLOv8m در همه شاخص‌ها یکنواختی بیشتری داشت. میانگین Precision آن 0.978 و تغییراتش میان بخش‌ها اندک بود. میانگین Recall برابر 0.974، مانند YOLOv5m، اما با نوسان کمتر بود. امتیاز F1 نیز با میانگین 0.978 بالا و پایدار ماند و توازن خوب میان دقت مثبت و یادآوری را نشان داد. میانگین mAP برابر 0.938 بود؛ یعنی مدل با وجود اختلاف‌های جزئی میان کلاس‌ها، عملکرد بالایی را حفظ کرد.

YOLOv9c نیز مقادیر Precision و Recall بالایی داشت که به‌ترتیب میانگین آن‌ها 0.974 و 0.976 بود. میانگین F1 این مدل با مقدار 0.982 از دو مدل دیگر بیشتر بود و بهترین توازن دقت و یادآوری را نشان داد. میانگین mAP برابر 0.944 نیز بالاترین مقدار میان سه مدل بود و کارایی مناسب آن را در تشخیص کلاس‌های مختلف نشان می‌داد.

در مجموع، قرارگرفتن شاخص‌های اصلی همه مدل‌ها بالاتر از 0.93، امکان استفاده از این نسخه‌های YOLO برای تشخیص کلاه ایمنی در فولادسازی را تأیید می‌کند. مقدار بالای یادآوری از نظر ایمنی اهمیت ویژه‌ای دارد، زیرا به معنی احتمال کمترِ ازقلم‌افتادن کارکنان فاقد کلاه است. در عین حال، تفاوت‌های جزئی عملکرد نشان می‌دهد انتخاب مدل باید متناسب با نیاز عملیاتی باشد: اگر کاهش هشدار کاذب اولویت داشته باشد، YOLOv8m به‌دلیل دقت بالا و پایدار گزینه مناسبی است؛ اگر سازگاری با شرایط گوناگون اهمیت بیشتری داشته باشد، YOLOv9c با mAP بهتر می‌تواند ارجح باشد.

نمودارهای جعبه‌ای شکل 9 عملکرد YOLOv5m، YOLOv8m و YOLOv9c را در شاخص‌های Precision، Recall، F1 و mAP مقایسه می‌کنند. نمودار Precision نشان می‌دهد پراکندگی YOLOv5m از دو مدل دیگر

بیشتر است؛ یعنی دقت آن بین بخش‌های اعتبارسنجی تغییر بیشتری می‌کند. میانه Precision در YOLOv5m اندکی کمتر است، درحالی‌که YOLOv8m و YOLOv9c مقدارهای نزدیک به هم و پایدارتری دارند؛ دامنه بین‌چارکی باریک و تعداد کم داده پرت مؤید این موضوع است.

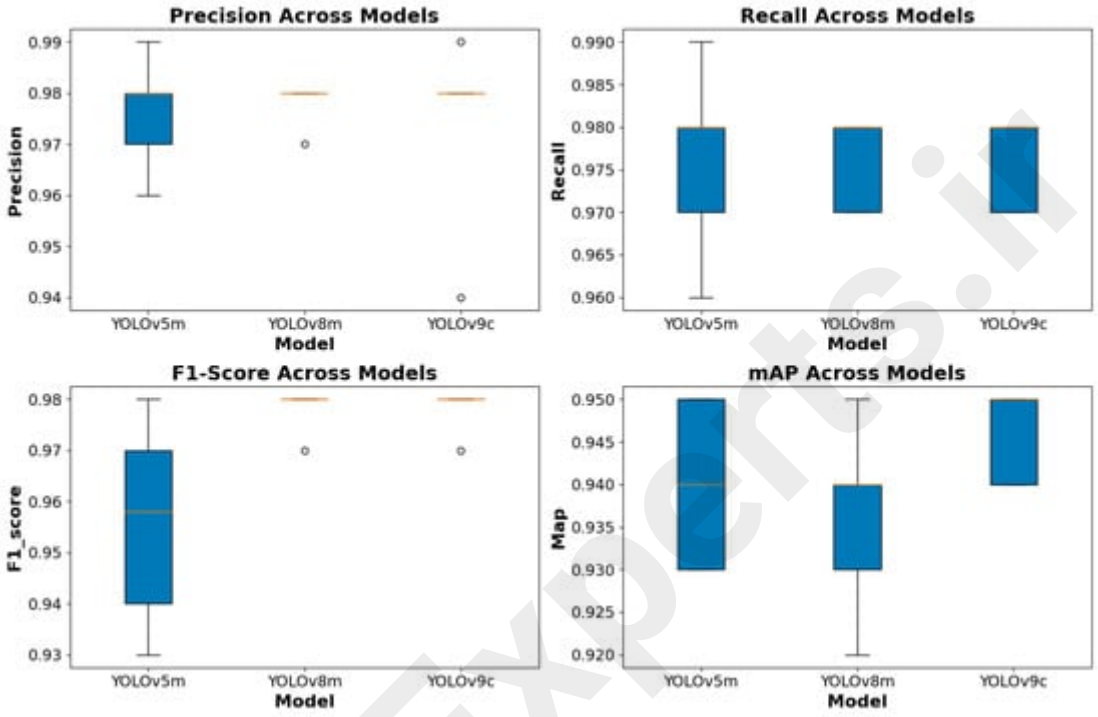

شکل 9. نمودارهای جعبه‌ای شاخص‌های عملکرد مدل‌های مختلف. منبع: Awolusi، Lan و Cai، *AI* (2024)، DOI: 10.3390/ai5030058؛ مجوز CC BY 4.0.

در نمودار Recall نیز YOLOv5m نوسان بیشتری از دو مدل دیگر دارد؛ در مقابل، میانه و دامنه بین‌چارکی YOLOv8m و YOLOv9c بسیار نزدیک است و پایداری آن‌ها را در شناسایی موارد مثبت واقعی نشان می‌دهد. نمودار F1 برای YOLOv5m دامنه بین‌چارکی گسترده‌تر و چند مقدار پرت را نشان می‌دهد؛ یعنی توازن دقت و یادآوری در پنج تکرار نوسان داشته است. F1 دو مدل دیگر، با دامنه‌های باریک و داده پرت اندک، پایدارتر بوده است. در نمودار mAP نیز پراکندگی YOLOv5m اندکی بیشتر است، هرچند میانه آن با دو مدل دیگر قابل‌مقایسه است. YOLOv8m در mAP تغییرات قابل‌توجهی دارد که می‌تواند از تفاوت عملکرد بین کلاس‌ها ناشی شده باشد؛ درحالی‌که YOLOv9c با دامنه بین‌چارکی محدود و نبود داده پرت، mAP بالا و پایداری ارائه می‌کند.

بالابودن شاخص‌های اصلی هر سه مدل از 0.93، امکان کاربرد آن‌ها در تشخیص کلاه ایمنی صنعت فولاد را تقویت می‌کند. یادآوری پایدار و بالا برای سامانه ایمنی بسیار ارزشمند است، زیرا احتمال دیده‌نشدن تخلفات را کاهش می‌دهد. بااین‌حال، انتخاب مدل باید تابع نیاز همان محل باشد. در کاربردهایی که کم‌شدن هشدار کاذب اهمیت زیادی دارد، YOLOv8m با Precision و F1 بالا و پایدار مناسب‌تر است. در محیط‌هایی با شرایط

متنوع یا زمانی که عملکرد کلی تشخیص اولویت دارد، YOLOv9c به‌دلیل mAP بیشتر می‌تواند انتخاب بهتری باشد. اگر منابع پردازشی محدود باشند و توازن میان پیچیدگی و عملکرد اهمیت داشته باشد، YOLOv5m نیز گزینه‌ای قابل‌استفاده است.

نتایج Specificity و AUC

تحلیل AUC و ویژگی (Specificity) در شکل 10، تفاوت‌های ظریف عملکرد سه مدل را آشکار کرد؛ تفاوت‌هایی که ماهیت خاکستری فیلم‌های منبع تشخیص را دشوارتر کرده بود. برای کلاس in_hardhat، همه مدل‌ها AUC بالاتر از 0.7 داشتند و YOLOv9c با مقدار حدود 0.75 اندکی بهتر بود. این نتیجه نشان می‌دهد تشخیص استفاده صحیح از کلاه حتی بدون اطلاعات رنگ، نسبتاً قابل‌اعتماد است. اما کلاس no_hardhat دشوارتر بود و AUC هر سه مدل کاهش یافت: حدود 0.38 برای YOLOv5m و بهترین نتیجه، حدود 0.6، برای YOLOv9c ثبت شد. علت احتمالی این اختلاف، نامتوازن‌بودن کلاس‌ها در داده آموزشی، محدودیت افزایش داده مصنوعی و کاهش اطلاعات ویژگی در تصاویر خاکستری است. تصاویر سیاه‌وسفید، به‌خصوص در نواحی کم‌نور کارخانه، تشخیص تفاوت‌های ظریف میان کلاه ایمنی، پس‌زمینه و پوشش‌های دیگر سر را سخت‌تر می‌کنند.

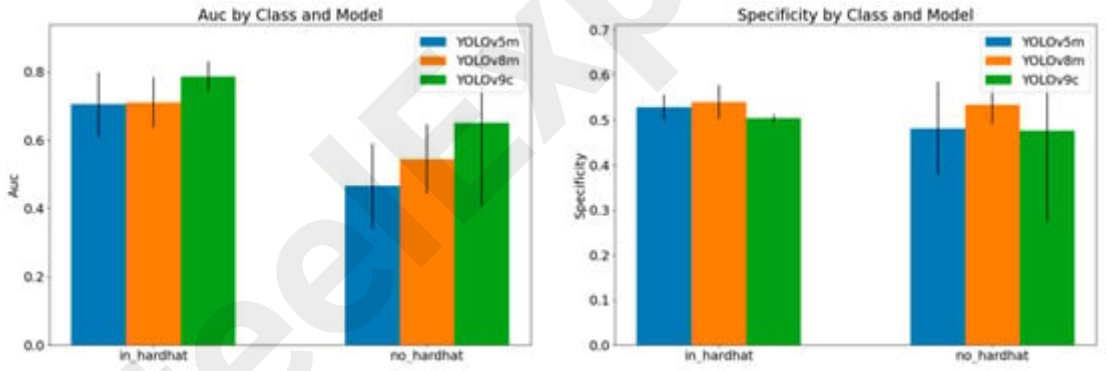

شکل 10. نمودارهای میله‌ای شاخص‌های عملکرد مدل‌ها همراه با میله‌های خطا. منبع: Lan، Awolusi و Cai، *AI* (2024)، DOI: 10.3390/ai5030058؛ مجوز CC BY 4.0.

تحلیل Specificity این تفاوت‌ها را روشن‌تر کرد. برای کلاس in_hardhat، YOLOv8m با مقدار حدود 0.54 بالاترین ویژگی را داشت که نشان‌دهنده کنترل بهتر مثبت کاذب، حتی در تصویر خاکستری، است. برای کلاس no_hardhat، YOLOv9c با مقدار حدود 0.55 بهترین ویژگی را به دست آورد، هرچند بین تکرارها تغییرپذیری بیشتری داشت. این یافته‌ها بر ضرورت اصلاح هدفمند معماری و راهبرد آموزش، به‌ویژه برای ورودی‌های خاکستری، تأکید دارند. پژوهش‌های آینده باید با روش‌های پیشرفته‌تر افزایش داده، ویژگی‌های مقاوم به تغییر روشنایی و شاید استفاده هم‌زمان از چند نوع داده، مشکل عدم‌توازن کلاس‌ها و کمبود اطلاعات تصویر خاکستری را کاهش دهند. هرچند YOLOv9c برای استقرار واقعی در نظارت ایمنی فولاد، به‌ویژه تشخیص تخلف، امیدوارکننده‌تر است، برای تشخیص مطمئنِ نبود کلاه ایمنی در تصاویر دشوار و کم‌نور هنوز به بهبود نیاز

دارد.

۵. دستاوردها و محدودیت‌های پژوهش

این مطالعه مخاطرات خاص صنعت فولاد را به‌تفصیل شناسایی و بررسی می‌کند که بینایی ماشین چگونه می‌تواند احتمال وقوع آن‌ها را کاهش دهد. نگاشت عوامل خطر به وظایف CV یک چارچوب راهبردی برای افزایش ایمنی محل کار فراهم می‌آورد؛ چارچوبی که در پژوهش‌های پیشین کمتر به این شکل ارائه شده است. از دستاوردهای اصلی این پایلوت، آزمودن مدل‌های پیشرفته YOLOv8m، YOLOv5m و YOLOv9c برای مدیریت ایمنی، به‌خصوص تشخیص کلاه ایمنی، در محیط واقعی فولادسازی است؛ موضوعی که هم در ادبیات علمی و هم در عمل صنعتی کم‌تر بررسی شده بود. پژوهش همچنین عملکرد این مدل‌ها را بر تصاویر خاکستری تحلیل می‌کند؛ نوع تصویری که در دوربین‌های مداربسته صنعتی متداول است، اما در تحقیقات بینایی ماشین کمتر مورد توجه قرار گرفته است. مقایسه جامع شاخص‌های Specificity، mAP، F1، Recall، Precision و AUC در کلاس‌های no_hardhat، in_hardhat و invisible، نقاط قوت و ضعف هر مدل را در این محیط روشن می‌کند. افزون بر این، دشواری‌هایی مانند نورپردازی شدید یا نامناسب و پویایی محیط تولید مشخص شده و مبنایی برای ارزیابی‌های بعدی به دست آمده است.

با وجود این دستاوردها، محدودیت‌های مهمی هم وجود دارد. مجموعه‌داده پژوهش نسبتاً کوچک بود و تنها 703 تصویر از یک بخش مشخصِ مینی‌میل را در بر داشت؛ بنابراین تعمیم نتایج به همه محیط‌های فولادسازی باید با احتیاط انجام شود. کمبود نمونه‌های no_hardhat موجب استفاده از تصاویر مصنوعی برای افزایش داده شد؛ تصاویری که شاید تمام پیچیدگی‌های دنیای واقعی را بازنمایی نکنند. همچنین تمرکز صرف بر کلاه ایمنی، دامنه گسترده تجهیزات حفاظت فردی موردنیاز صنعت فولاد را پوشش نمی‌دهد.

بااین‌حال، عملکرد بالای مدل‌های YOLO در تشخیص کلاه ایمنی، به‌ویژه در F1، Recall، Precision و mAP، ظرفیت بینایی ماشین برای بهبود پایش ایمنی فولادسازی را نشان می‌دهد. با بهینه‌سازی بیشتر، چنین سامانه‌هایی می‌توانند رعایت مقررات ایمنی را تقویت و احتمال حوادث را کاهش دهند. گام‌های بعدی باید شامل گسترش مجموعه‌داده به موقعیت‌های متنوع‌تر، بهبود تشخیص تخلف و مدیریت انسداد دید، سنجش عملکرد بلادرنگ و افزودن تجهیزات حفاظت فردی دیگر باشد. پیشنهادهای مشخص پژوهشگران عبارت‌اند از: (الف) جمع‌آوری داده بیشتر از محیط‌های متنوع فولادسازی؛ (ب) توسعه افزایش داده پیشرفته برای رفع عدم‌توازن کلاس‌ها؛ (ج) بررسی آرایش چنددوربینه برای کاهش مشکل پوشیدگی افراد؛ و (د) گسترش تشخیص به عینک ایمنی، دستکش و پوشاک حفاظتی.

این پایلوت با کنار هم گذاشتن نتایج امیدوارکننده و محدودیت‌های آشکار، اطلاعات مهمی برای مسیر تحقیق و توسعه ایمنی صنعتی فراهم می‌کند. رفع این موانع در پژوهش‌های آینده می‌تواند کاربردپذیری و اعتمادپذیری سامانه‌های بینایی ماشین را در کارخانه‌های فولاد بیشتر کند.

۶. نتیجه‌گیری

ایمنی کارکنان در کارخانه‌های فولاد چنان اهمیتی دارد که پایش مستمر رفتارهای ناایمن و شناسایی پیش‌دستانه خطرات را ضروری می‌کند. این تحقیق از طریق مطالعه پایلوت تشخیص خودکار کلاه ایمنی کارکنان با یادگیری عمیق و بینایی ماشین، امکان استفاده از این فناوری در مدیریت ایمنی صنعت فولاد را بررسی کرده است.

پژوهش با مروری جامع برای شناسایی و توصیف مخاطرات تولید فولاد و راه‌های کنترل آن‌ها به کمک بینایی ماشین آغاز شد. سپس مدل تصمیم‌گیری چندمعیاره TOPSIS برای انتخاب یک سامانه تجاری مناسب به‌کار رفت. خطرات مینی‌میل با بررسی گزارش‌های کارخانه، مشاهده میدانی و مشورت با ذی‌نفعان تحلیل شدند. این کار امکان تطبیق دقیق خطرات با قابلیت‌های بینایی ماشین را فراهم کرد و کاربرد این فناوری برای تشخیص خودکار خطر و پایش فعال محیط کار را نشان داد. از میان هشت محصول تجاری شناسایی‌شده در بررسی بازار، Everguard مناسب‌ترین گزینه مطالعه پایلوت تشخیص داده شد.

مطالعه پایلوت امکان به‌کارگیری بینایی ماشین برای تشخیص کلاه ایمنی در فولادسازی را تأیید کرد. سه مدل YOLOv8m، YOLOv5m و YOLOv9c با 703 تصویر خاکستری از یک مینی‌میل ارزیابی شدند. مقایسه آن‌ها بر اساس Specificity، mAP، F1، Recall، Precision و AUC، نقاط قوت و ضعف هر مدل را روشن کرد. همه مدل‌ها به‌ویژه برای کلاس in_hardhat عملکرد امیدوارکننده‌ای داشتند و AUC بالاتر از 0.7 ثبت کردند؛ YOLOv9c اندکی بهتر از بقیه بود. اما در کلاس no_hardhat، AUC کاهش محسوسی داشت و YOLOv5m ضعیف‌ترین عملکرد را نشان داد. YOLOv9c در شناسایی نقض الزام ایمنی بهترین نتیجه را به دست آورد. خاکستری‌بودن فیلم‌ها نیز پیچیدگی بیشتری ایجاد کرد، زیرا در نقاط کم‌نور کارخانه تشخیص اختلاف‌های جزئی شدت روشنایی دشوار است.

هرچند پژوهش امکان استفاده از یادگیری عمیق مبتنی بر بینایی ماشین را در مدیریت ایمنی فولادسازی نشان می‌دهد، موانعی مانند عدم‌توازن کلاس‌ها، محدودیت تصاویر مصنوعی و اطلاعات ویژگی کمتر در تصویر خاکستری باقی است. مطالعات آینده باید با روش‌های پیشرفته‌تر افزایش داده، استخراج ویژگی‌های مقاوم به تغییر نور و بررسی رویکردهای چندوجهی، این ضعف‌ها را برطرف کنند.

این روش در آینده می‌تواند علاوه بر کلاه ایمنی، تشخیص جلیقه، دستکش و عینک حفاظتی و نیز پایش وضعیت بدن کارکنان و فاصله آن‌ها از ماشین‌آلات سنگین را پشتیبانی کند. این موضوع‌ها مسیرهای ارزشمندی برای ادامه پژوهش و ارتقای مستمر ایمنی کار در فولادسازی هستند.

در جمع‌بندی، این پایلوت با ارائه نتایج امیدوارکننده و درعین‌حال شناخت روشن محدودیت‌ها و زمینه‌های بهبود، راهنمایی برای پژوهش و توسعه آینده در ایمنی صنعتی فراهم می‌کند. برطرف‌شدن چالش‌ها می‌تواند قابلیت استفاده و اطمینان‌پذیری سامانه‌های بینایی ماشین را در مدیریت ایمنی صنایع، به‌ویژه محیط پیچیده و پویای تولید فولاد، افزایش دهد.

مشارکت نویسندگان

طراحی مفهوم پژوهش: I.A. و J.C.؛ روش‌شناسی: R.L. و I.A.؛ تحلیل رسمی: R.L.؛ تهیه پیش‌نویس اولیه: R.L.؛ بازبینی و ویرایش: I.A. و J.C.؛ نظارت: I.A.؛ مدیریت پروژه: I.A.؛ جذب حمایت مالی: I.A. و J.C. همه نویسندگان نسخه منتشرشده مقاله را مطالعه و تأیید کرده‌اند.

تأمین مالی

هزینه این پژوهش از محل کمک‌هزینه «فناوری‌های دیجیتال برای تولید فولاد» (DTSM) بنیاد انجمن فناوری آهن و فولاد (AIST) تأمین شده است.

بیانیه کمیته اخلاق پژوهش

موضوعیت ندارد.

بیانیه رضایت آگاهانه

موضوعیت ندارد.

SteelExperts.ir

دسترسی به داده‌ها

داده‌های ارائه‌شده در این مطالعه با درخواست منطقی و موجه از نویسنده مسئول قابل دریافت‌اند.

قدردانی

نویسندگان از بنیاد انجمن فناوری آهن و فولاد (AIST) بابت تأمین مالی این پژوهش از طریق کمک‌هزینه DTSM سپاسگزاری می‌کنند. همچنین از شرکای صنعتی، به‌ویژه Yong Wu، Paul Thurber و گروه Everguard، برای حمایت از مطالعه پایلوت این پروژه قدردانی می‌شود.

تعارض منافع

نویسندگان اعلام کرده‌اند که تعارض منافعی ندارند.

منابع علمی

1. Khahro, S.H.; Khahro, Q.H.; Ali, T.H.; Memon, Z.A. Industrial Accidents and Key Causes: A Case Study of the Steel Industry. ACM Int. Conf. Proceeding Ser. 2023 , 66–70. [ ] DOI / CrossRef
2. Sacks, R.; Perlman, A.; Barak, R. Construction safety training using immersive virtual reality. Constr. Manag. Econ. 2013 , 31 , 1005–1017. [ ] DOI / CrossRef
3. Zhang, S.; Sulankivi, K.; Kiviniemi, M.; Romo, I.; Eastman, C.M.; Teizer, J. BIM-based fall hazard identification and prevention in construction safety planning. Saf. Sci. 2015 , 72 , 31–45. [ ] DOI / CrossRef
4. Nordlöf, H.; Wiitavaara, B.; Winblad, U.; Wijk, K.; Westerling, R. Safety culture and reasons for risk-taking at a large steel-manufacturing company: Investigating the worker perspective. Saf. Sci. 2015 , 73 , 126–135. [ ] DOI / CrossRef
5. Zhou, D.; Xu, K.; Lv, Z.; Yang, J.; Li, M.; He, F.; Xu, G. Intelligent Manufacturing

SteelExperts.ir

Technology in the Steel Industry of China: A Review. Sensors 2022 , 22 , 8194. [ ] [ ] DOI / CrossRef

.6 Chai, J.; Zeng, H.; Li, A.; Ngai, E.W.T. Deep learning in computer vision: A critical review of emerging techniques and application scenarios. Mach. Learn. Appl. 2021 , 6 , 100134. [ ] DOI / CrossRef

.7 Feng, X.; Jiang, Y.; Yang, X.; Du, M.; Li, X. Computer vision algorithms and hardware implementations: A survey. Integration 2019 , 69 , 309–320. [ ] DOI / CrossRef

.8 Lan, R.; Awolusi, I.; Cai, J. Digital computer vision for safety management in steel manufacturing. In Proceedings of the Iron & Steel Technology Conference, Detroit, .MI, USA, 8–11 May 2023; pp. 31–42

.9 Marks, E.D.; Teizer, J. Method for testing proximity detection and alert technology for safe construction equipment operation. Constr. Manag. Econ. 2013 , 31 , 636–646. [ ] DOI / CrossRef

.10 Awolusi, I.; Song, S.; Marks, E. Forklift safety: Sensing the dangers with technology. .Prof. Saf. 2017 , 62 , 36–39

.11 Kursunoglu, N.; Onder, S.; Onder, M. The Evaluation of Personal Protective Equipment Usage Habit of Mining Employees Using Structural Equation Modeling. Saf. Health Work. 2022 , 13 , 180–186. [ ] DOI / CrossRef

.12 Zhang, M.; Cao, Z.; Yang, Z.; Zhao, X. Utilizing Computer Vision and Fuzzy Inference to Evaluate Level of Collision Safety for Workers and Equipment in a Dynamic Environment. J. Constr. Eng. Manag. 2020 , 146 , 04020051. [ ] DOI / CrossRef

.13 Ghosh, A.; Chatterjee, A. Ironmaking and Steelmaking: Theory and Practice ; PHI .Learn. Priv. Ltd.: Delhi, India, 2008

.14 Xu, Z.J.; Zheng, Z.; Gao, X.Q. Operation optimization of the steel manufacturing process: A brief review. Int. J. Miner. Metall. Mater. 2021 , 28 , 1274–1287. [ ] DOI / CrossRef

.15 Bae, J.; Li, Y.; Ståhl, N.; Mathiason, G.; Kojola, N. Using Machine Learning for Robust Target Prediction in a Basic Oxygen Furnace System. Metall. Mater. Trans.

B 2020 , 51 , 1632–1645. [ ] DOI / CrossRef

16. Nutting, J.; Edward, F.; Wondris, E. Steel. Encyclopedia Britannica. Available online: ((accessed on 4 October 2022).

17. Burchart-Korol, D. Life cycle assessment of steel production in Poland: A case study. J. Clean. Prod. 2013 , 54 , 235–243. [ ] DOI / CrossRef

18. Nair, A.T.; Mathew, A.; Archana, A.R.; Akbar, M.A. Use of hazardous electric arc furnace dust in the construction industry: A cleaner production approach. J. Clean. Prod. 2022 , 377 , 134282. [ ] DOI / CrossRef

19. World Steel Association. Safety and Health in the Steel Industry: Data Report 2023. (2023. Available online: (accessed on 18 November 2023).

20. Ali, M.X.M.; Arifin, K.; Abas, A.; Ahmad, M.A.; Khairil, M.; Cyio, M.B.; Samad, M.A.; Lampe, I.; Mahfudz, M.; Ali, M.N. Systematic Literature Review on Indicators Use in Safety Management Practices among Utility Industries. Int. J. Environ. Res. Public Health 2022 , 19 , 6198. [ ] [ ] DOI / CrossRef

21. Tang, B.; Chen, L.; Sun, W.; Lin, Z.K. Review of surface defect detection of steel products based on machine vision. IET Image Process 2022 , 17 , 303–322. [ ] DOI / CrossRef

22. International Labour Organization. Sectoral Activities Programme. In Proceedings of the Code of Practice on Safety and Health in the Iron and Steel Industry: Meeting of Experts to Develop a Revised Code of Practice on Safety and Health in the Iron and Steel Industry, Geneva, Switzerland, 1–9 February 2005.

23. Kifle, M.; Engdaw, D.; Alemu, K.; Sharma, H.R.; Amsalu, S.; Feleke, A.; Worku, W. Work related injuries and associated risk factors among iron and steel industries workers in Addis Ababa, Ethiopia. Saf. Sci. 2014 , 63 , 211–216. [ ] DOI / CrossRef

24. National Institute for Occupational Safety and Health. Hierarchy of Controls. CDC. (2015. Available online: (accessed on 20 November 2023).

25. Houette, B.; Mueller-Hirth, N. Practices, preferences, and understandings of rewarding to improve safety in high-risk industries. J. Saf. Res. 2022 , 80 ,

302–310. [ ] DOI / CrossRef

26. Berhan, E. Prevalence of occupational accident; and injuries and their associated factors in iron, steel and metal manufacturing industries in Addis Ababa. Cogent Eng. 2020 , 7 , 1723211. [ ] DOI / CrossRef

27. Awolusi, I.; Marks, E.; Hallowell, M. Wearable technology for personalized construction safety monitoring and trending: Review of applicable devices. Autom. Constr. 2018 , 85 , 96–106. [ ] DOI / CrossRef

28. Márquez-Sánchez, S.; Campero-Jurado, I.; Herrera-Santos, J.; Rodríguez, S.; Corchado, J.M. Intelligent platform based on smart ppe for safety in workplaces. Sensors 2021 , 21 , 4652. [ ] DOI / CrossRef

29. Nnaji, C.; Awolusi, I.; Park, J.W.; Albert, A. Wearable sensing devices: Towards the development of a personalized system for construction safety and health risk mitigation. Sensors 2021 , 21 , 682. [ ] DOI / CrossRef

30. Hong, X.; Lv, B. Application of Training Simulation Software and Virtual Reality Technology in Civil Engineering. In Proceedings of the 2022 IEEE International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA), Changchun, China, 25–27 February 2022; pp. 520–524.

31. Velev, D.; Zlateva, P. Virtual Reality Challenges in Education and Training. Int. J. Learn. 2017 , 3 , 33–37. [ ] DOI / CrossRef

32. Chai, X.; Lee, B.G.; Pike, M.; Wu, R.; Chieng, D.; Chung, W.Y. Pre-impact Firefighter Fall Detection Using Machine Learning on the Edge. IEEE Sens. J. 2023 , 23 , 14997–15009. [ ] DOI / CrossRef

33. Zhou, L.; Zhang, L.; Konz, N. Computer Vision Techniques in Manufacturing. IEEE Trans. Syst. Man. Cybern. Syst. 2022 , 53 , 105–117. [ ] DOI / CrossRef

34. Redmon, J.; Divvala, S.; Girshick, R.; Farhadi, A. You Only Look Once: Unified, Real-Time Object Detection. arXiv 2015 , arXiv:1506.02640.

35. Redmon, J.; Farhadi, A. YOLO9000: Better, faster, stronger. In Proceedings of the 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017,

Honolulu, HI, USA, 21–26 November 2017; pp. 6517–6525. [ ] DOI / CrossRef

36. Bochkovskiy, A.; Wang, C.-Y.; Liao, H.-Y.M. YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv 2020 , arXiv:2004.10934.

37. Terven, J.; Córdova-Esparza, D.M.; Romero-González, J.A. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. Mach. Learn. Knowl. Extr. 2023 , 5 , 1680–1716. [ ] DOI / CrossRef

38. Jiang, P.; Ergu, D.; Liu, F.; Cai, Y.; Ma, B. A Review of Yolo Algorithm Developments. Procedia Comput. Sci. 2021 , 199 , 1066–1073. [ ] DOI / CrossRef

39. Li, Y.; Wang, H.; Dang, L.M.; Nguyen, T.N.; Han, D.; Lee, A.; Jang, I.; Moon, H. A deep learning-based hybrid framework for object detection and recognition in autonomous driving. IEEE Access 2020 , 8 , 194228–194239. [ ] DOI / CrossRef

40. Narejo, S.; Pandey, B.; Vargas, D.E.; Rodriguez, C.; Anjum, M.R. Weapon Detection Using YOLO V3 for Smart Surveillance System. Math. Probl. Eng. 2021 , 2021 , 9975700. [ ] DOI / CrossRef

41. Ragab, M.G.; Abdulkader, S.J.; Muneer, A.; Alqushaibi, A.; Sumiea, E.H.; Qureshi, R.; Al-Selwi, S.M.; Alhussian, H. A Comprehensive Systematic Review of YOLO for Medical Object Detection (2018 to 2023). IEEE Access 2024 , 12 , 57815–57836. [ ] DOI / CrossRef

42. Lippi, M.; Bonucci, N.; Carpio, R.F.; Contarini, M.; Speranza, S.; Gasparri, A. A YOLO-based pest detection system for precision agriculture. In Proceedings of the 2021 29th Mediterranean Conference on Control and Automation, MED 2021, Puglia, Italy, 22–25 June 2021; pp. 342–347. [ ] DOI / CrossRef

43. Kim, K.; Kim, K.; Jeong, S. Application of YOLO v5 and v8 for Recognition of Safety Risk Factors at Construction Sites. Sustainability 2023 , 15 , 15179. [ ] DOI / CrossRef

44. Qiu, Q.; Lau, D. Real-time detection of cracks in tiled sidewalks using YOLO-based method applied to unmanned aerial vehicle (UAV) images. Autom. Constr. 2023 , 147 , 104745. [ ] DOI / CrossRef

.45 Gai, R.; Chen, N.; Yuan, H. A detection algorithm for cherry fruits based on the improved YOLO-v4 model. Neural Comput. Appl. 2023 , 35 , 13895–13906. [ ] DOI / CrossRef

.46 Jung, H.; Rhee, J. Application of YOLO and ResNet in Heat Staking Process Inspection. Sustainability 2022 , 14 , 15892. [ ] DOI / CrossRef

.47 Mushtaq, F.; Ramesh, K.; Deshmukh, S.; Ray, T.; Parimi, C.; Tandon, P.; Jha, P.K. YOLO-v5 and image processing based component identification system. Eng. Appl. Artif. Intell. 2023 , 118 , 105665. [ ] DOI / CrossRef

.48 Kou, X.; Liu, S.; Cheng, K.; Qian, Y. Development of a YOLO-V3-based model for detecting defects on steel strip surface. Measurement 2021 , 182 , 109454. [ ] DOI / CrossRef

.49 Pitts, H. Warehouse Robot Detection for Human Safety Using YOLOv8. In Proceedings of the SoutheastCon 2024, Atlanta, GA, USA, 15–24 March 2024; pp. 1184–1188. [ ] DOI / CrossRef

.50 Hao, Z.; Wang, Z.; Bai, D.; Tao, B.; Tong, X.; Chen, B. Intelligent Detection of Steel Defects Based on Improved Split Attention Networks. Front. Bioeng. Biotechnol. .2022 , 9 , 810876

.51 Martins, L.A.O.; Pádua, F.L.C.; Almeida, P.E.M. Automatic detection of surface defects on rolled steel using Computer Vision and Artificial Neural Networks. In Proceedings of the IECON 2010-36th Annual Conference on IEEE Industrial .Electronics Society, Glendale, AZ, USA, 7–10 November 2010; pp. 1081–1086

.52 Sizyakin, R.; Voronin, V.; Gapon, N.; Zelensky, A.; Pižurica, A. Automatic detection of welding defects using the convolutional neural network. In Automated Visual .Inspection and Machine Vision III ; SPIE: Philadelphia, PA, USA, 2019

.53 Bolderston, A. Conducting a research interview. J. Med. Imaging Radiat. Sci. 2012 , 43 , 66–76. [ ] DOI / CrossRef

.54 Guest, G.; Namey, E.; Taylor, J.; Eley, N.; McKenna, K. Comparing focus groups and individual interviews: Findings from a randomized study. Int. J. Soc. Res. Methodol.

2017 , 20 , 693–708. [ ] DOI / CrossRef

.55 Creswell, J.W. Editorial: Mapping the field of mixed methods research. J. Mix. Methods Res. 2009 , 3 , 95–108. [ ] DOI / CrossRef

.56 Çelikbilek, Y.; Tüysüz, F. An in-depth review of theory of the TOPSIS method: An experimental analysis. J. Manag. Anal. 2020 , 7 , 281–300. [ ] DOI / CrossRef

.57 Kraujalienė, L. Comparative Analysis of Multicriteria Decision-Making Methods Evaluating the Efficiency of Technology Transfer. Bus. Manag. Educ. 2019 , 17 , 72–93. [ ] DOI / CrossRef

.58 Olson, D.L. Comparison of weights in TOPSIS models. Math. Comput. Model. 2004 , 40 , 721–727. [ ] DOI / CrossRef

.59 Chakraborty, S. TOPSIS and Modified TOPSIS: A comparative analysis. Decis. Anal. J. 2022 , 2 , 100021. [ ] DOI / CrossRef

.60 Yahya, M.N.; Gökçekuş, H.; Ozsahin, D.U.; Uzun, B. Evaluation of wastewater treatment technologies using topsis. Desalin. Water Treat. 2020 , 177 , 416–422. [ ] DOI / CrossRef

.61 Rombach, R.; Blattmann, A.; Lorenz, D.; Esser, P.; Ommer, B. High-Resolution Image Synthesis with Latent Diffusion Models. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, New Orleans, LA, USA, .18–24 June 2022

.62 Tharwat, A. Classification assessment methods. Appl. Comput. Inform. 2018 , 17 , 168–192. [ ] DOI / CrossRef

.63 Obi, J.C. A comparative study of several classification metrics and their performances on data. World J. Adv. Eng. Technol. Sci. 2023 , 8 , 308–314. [ ] DOI / CrossRef

.64 Yan, X.; Zhang, H.; Li, H. Computer vision-based recognition of 3D relationship between construction entities for monitoring struck-by accidents. Comput. Aided Civ. Infrastruct. Eng. 2020 , 35 , 1023–1038. [ ] DOI / CrossRef

SteelExperts.ir

65. Anwar, Q.; Hanif, M.; Shimotoku, D.; Kobayashi, H.H. Driver awareness collision/proximity detection system for heavy vehicles based on deep neural network. J. Phys. Conf. Ser. 2022 , 2330 , 012001. [ ] DOI / CrossRef

66. Wu, H.; Wu, D.; Zhao, J. An intelligent fire detection approach through cameras based on computer vision methods. Process Saf. Environ. Prot. 2019 , 127 , 245–256. [ ] DOI / CrossRef

67. Krestenitis, M.; Orfanidis, G.; Ioannidis, K.; Avgerinakis, K.; Vrochidis, S.; Kompatsiaris, I. Oil spill identification from satellite images using deep neural networks. Remote Sens. 2019 , 11 , 1762. [ ] DOI / CrossRef

68. Lee, H.; Lee, G.; Lee, S.H.; Ahn, C.R. Assessing exposure to slip, trip, and fall hazards based on abnormal gait patterns predicted from confidence interval estimation. Autom. Constr. 2022 , 139 , 104253. [ ] DOI / CrossRef

69. Luo, H.; Wang, M.; Wong, P.K.Y.; Cheng, J.C.P. Full body pose estimation of construction equipment using computer vision and deep learning techniques. Autom. Constr. 2020 , 110 , 103016. [ ] DOI / CrossRef

70. Balakreshnan, B.; Richards, G.; Nanda, G.; Mao, H.; Athinarayanan, R.; Zaccaria, J. PPE compliance detection using artificial intelligence in learning factories. Procedia Manuf. 2020 , 45 , 277–282. [ ] DOI / CrossRef

71. Abd El-Rahiem, B.; Sedik, A.; El Banby, G.M.; Ibrahem, H.M.; Amin, M.; Song, O.Y.; Khalaf, A.A.M.; Abd El-Samie, F.E. An efficient deep learning model for classification of thermal face images. J. Enterp. Inf. Manag. 2020 , 36 , 706–717. [ ] DOI / CrossRef

72. Gupta, A.; Ramanath, R.; Shi, J.; Keerthi, S.S. Adam vs. SGD: Closing the generalization gap on image classification. In Proceedings of the OPT2021: 13th .Annual Workshop on Optimization for Machine Learning, Virtual, 22 October 2021

یادداشت ناشر: مطالب، دیدگاه‌ها و داده‌های منتشرشده فقط بیانگر نظر نویسندگان و مشارکت‌کنندگان هر اثر هستند و لزوماً دیدگاه MDPI یا سردبیران آن نیستند. ناشر و سردبیران مسئولیتی در قبال آسیب به افراد یا

اموال ناشی از ایده‌ها، روش‌ها، دستورالعمل‌ها یا محصولات مطرح‌شده در مقاله نمی‌پذیرند.

مشخصات اثر اصلی و حقوق انتشار

مقاله اصلی: Computer Vision for Safety Management in the Steel Industry؛ نویسندگان: Roy Lan، Ibukun Awolusi و Jiannan Cai؛ نشریه *AI*، جلد 5، شماره 3، صفحات 1192–1215، سال 2024. تاریخ انتشار: 19 ژوئیه 2024.

لینک مقاله اصلی: https://www.mdpi.com/2673-2688/5/3/58 | DOI: 10.3390/ai5030058.

مجوز متن و تصاویر: Creative Commons Attribution 4.0 International (CC BY 4.0). این نسخه ترجمه فارسی متن انگلیسی است؛ تصاویر اصلی بدون بازترسیم یا جایگزینی حفظ شده‌اند. اعتبار علمی و حقوق تصاویر متعلق به پدیدآورندگان اصلی است.

نسخه آنلاین مقاله: https://landing.steelexperts.ir/2026/10/27/sx-r044-computer-vision-steel-safety/