



چکیده

صنعت تولید لاستیک با چالش های متعددی از جمله ضایعات تولید(scrap) ، نقص های کیفی و هزینه های بازگشتی مواجه است که هم بار اقتصادی و هم زیست محیطی قابل توجهی ایجاد می‌کند. هوش مصنوعی (AI) و یادگیری ماشینی امکانات نوینی برای تشخیص زودهنگام عیوب، پیش بینی رخداد های منجر به ضایعات و بهینه سازی فرایند های تولید فراهم کرده اند. این مقاله مروری-کاربردی است که تأثیر روش های بینایی ماشین، شبکه های عمیق، مدل های پیش بینی مبتنی بر داده و تحلیل پیشگویانه را بر کاهش ضایعات در خطوط تولید لاستیک بررسی می کند. در بخش تجربی، یک مطالعه عملی از کاربرد شبکه Xception با تکنیک های Explainable AI برای شناسایی اجسام خارجی و عیوب در تصاویر رادیوگرافی تایر ارائه شده؛ در این مطالعه مدل با مجموعه داده ای شامل ۳۳۰۳ نمونه معیوب و ۴۹۱۹۸ نمونه سالم آموزش‌دیده و دقت، بازیابی و معیار F1 به ترتیب ۹۹٫۱۹٪، ۹۸٫۷۵٪ و ۹۹٫۰۵٪ گزارش شده است. همچنین یک پیاده سازی صنعتی از راهکار بینایی ماشین (Shanghai DeepSight) با ابزار(OpenVINO) که دقت تشخیص را تا بیش از ۹۹٫۹٪ ارتقاء داده و سرعتِ بازرسی را به کمتر از یک ثانیه رسانده و ضایعات و هزینه های نیروی انسانی را کاهش داده، بررسی می شود. مقاله مراحل پیاده سازی، نیازهای داده ای، چالش های عملی و پیشنهادات مدیریتی و تکنیکی برای استقرار راهکارهای AI در کارخانجات لاستیک سازی را بیان می‌کند و نشان میدهد ترکیب بینایی ماشین، حسگرهای خطی و مدل های پیش بینی می تواند کاهش ملموسی در نرخ ضایعات به همراه داشته باشد .

واژگان کلیدی:

هوش مصنوعی، یادگیری عمیق، بازرسی بصری، پیش بینی ضایعات، تولید لاستیک، کیفیت، Explainable AI

مقدمه

صنعت تولید لاستیک یکی از صنایع پایه ای و پر حجم در اقتصاد جهانی است؛ هم زمان با رشد تقاضای خودرو و حمل و نقل، تولیدکنندگان برای حفظ کیفیت، کاهش هزینه و رعایت استانداردهای زیست محیطی تحت فشار قرار دارند. یکی از مسائل کلیدی در این صنعت، ضایعات تولیدی شامل تایرهای معیوب، قطعات دورریز و محصولات بازگشتی است که می تواند تا چند درصد از تولید را تشکیل دهد و هزینه های مستقیم و غیرمستقیم قابل توجهی به دنبال داشته باشد. دلایل ایجاد ضایعات متنوع اند: ورود اجسام خارجی در فرایند، خطاهای فرمولاسیون مواد اولیه، تنظیمات نامناسب ماشین آلات، خطا در فرآیند آتشفشانی (vulcanization) یا سایر فرایند های تولیدی. روش های سنتی کنترل کیفیت عموماً مبتنی بر بازرسی بصری انسانی یا آزمون های نمونه ای است که هم پرهزینه اند و هم حساس به خستگی و خطای انسانی.

در سال های اخیر، پیشرفت در حسگر ها، دوربین های صنعتی، محاسبات لبه ای (edge computing) و الگوریتم های یادگیری ماشینی باعث شده است تا راهکارهای خودکار و داده محور برای بازرسی و پیش بینی در کارخانه ها معرفی شوند. بینایی ماشین (computer vision) و شبکه های عصبی کانولوشنی (CNN) قادرند نقص های سطحی، ناخالصی ها و الگوهای غیرطبیعی در تصاویر تایر را با دقت بالا تشخیص دهند؛ همچنین مدل های پیش بینی مبتنی بر داده خط تولید و پارامترهای فرایندی می توانند وقوع شرایط منجر به ضایعات را پیش بینی کرده و مداخله پیشگیرانه را فعال کنند. مجموعه ای از مطالعات و پیاده سازی های صنعتی نشان داده اند که دقت تشخیص عیوب با روش های عمیق معمولاً بالای ۹۴٪ است و در مواردی تا حدود ۹۹٪ نیز گزارش شده؛این سطح دقت می‌تواند نرخ بازگشت محصول و هزینه های مرتبط با آن را به طور معنی داری کاهش دهد. همچنین استفاده از رویکرد های Explainable AI(توضیح‌پذیر) برای شفاف سازی دلایل تشخیص مدل، موجب اعتماد بیشتر اپراتورها و تسهیل فرایندهای بهینه سازی شده است .

بخش تجربی

۱ .انتخاب مطالعه موردی و توجیه

برای بخش تجربی، مطالعه «Explainable AI-Powered Foreign Object Defect Detection with Xception Networks and Grad-CAM» برای مطالعه کاربردی روی داده های رادیوگرافی تایر) انتخاب شد؛ این مقاله یک نمونه کامل از یک پیاده سازی یادگیری عمیق در تشخیص عیوب تولیدی با داده های واقعی است و شامل

نقش هوش مصنوعی در پیش بینی و کاهش ضایعات در تولید لاستیک

۱ – مسلم حسن پور سرپرست اداره تولید

۲– سجاد زنگی آبادی ، مدیر شیفت

شامل ارقام عملکردی مشخص) دقت، بازیابی، معیار (F1 و توضیحاتی درباره نحوه مقابله با عدم توازن داده هاست. استفاده از این مطالعه امکان شرح جزئی مراحل از آماده‌سازی داده تا استقرار را فراهم می آورد و نتایج عددی قابل استناد برای نشان دادن تأثیر AI بر کاهش ضایعات در اختیار می گذارد.

۲ .شرح کامل داده ها و پیش پردازش

۱– استاندارد سازی اندازه و رزولوشن: همه تصاویر به یک اندازه ثابت) مثلاً ۲۹۹×۲۹۹ پیکسل برای (Xception تغییر مقیاس شدند تا با معماری مدل سازگار باشند.

۲ – نرمال‌سازی شدت پیکسل ها: مقادیر پیکسل ها به بازه [۰،۱] یا استاندارد Z-score تبدیل شدند تا همگرایی آموزش سریع تر شود.

۳ – افزایش داده : (Data Augmentation) به دلیل عدم توازن شدید کلاس ها، روش های افزایشی شامل چرخش های کوچک، برش تصادفی، تغییر روشنایی و تکنیک های بیشتر اختصاصی برای تصاویر رادیوگرافی (مثلاً نویز اضافه، تغییر کنتراست) به کار رفت تا کلاس معیوب غنی تر شود. مؤلفین مطالعه یک روش augmentation سفارشی برای افزایش نمونه های معیوب استفاده کردند. افزون بر این، از تکنیک های oversampling برای متعادل سازی داده ها در فاز آموزش بهره گرفته شد .

۳ .معیارهای ارزیابی

معیارهایی که در گزارش مطالعه موردی به‌کار رفته اند عبارت اند از: دقت(accuracy) ، بازیابی(recall) ، دقت مثبت پیش بینی‌شده (precision) و . F1-score. این معیارها به ویژه در مجموعه داده های نامتوازن اهمیت دارند؛ زیرا دقت تنها می تواند به خاطر فراوانی کلاس سالم گمراه‌کننده باشد. در مطالعه انتخاب شده مقادیر زیر گزارش شده اند: دقت ۹۹٫۱۹٪، بازیابی ۹۸٫۷۵٪، دقت ۹۹٫۳۴٪ و F1 برابر ۹۹٫۰۵٪. این اعداد نشان دهنده توان بالای مدل در تشخیص اجسام خارجی و کاهش احتمال خروج محصول معیوب از خط تولید است .

۳ .معیارهای ارزیابی

معیارهایی که در گزارش مطالعه موردی به‌کار رفته اند عبارت اند از: دقت(accuracy) ، بازیابی(recall) ، دقت مثبت پیش بینی‌شده (precision) و . F1-score. این معیارها به ویژه در مجموعه داده های نامتوازن اهمیت دارند؛ زیرا دقت تنها می تواند به خاطر فراوانی کلاس سالم گمراه‌کننده باشد. در مطالعه انتخاب شده مقادیر زیر گزارش شده اند: دقت ۹۹٫۱۹٪، بازیابی ۹۸٫۷۵٪، دقت ۹۹٫۳۴٪ و F1 برابر ۹۹٫۰۵٪. این اعداد نشان دهنده توان بالای مدل در تشخیص اجسام خارجی و کاهش احتمال خروج محصول معیوب از خط تولید است .

۵ .مراحل پیاده سازی فنی (گام به گام)

گام ۱ — جمع‌آوری و ذخیره‌سازی داده: تجهیز نقاط بازرسی با دستگاه های رادیوگرافی/دوربین مناسب و ذخیره تصویر با شناسه تولید(batch ID ، timestamp ، sensor ID).

گام ۲ — برچسب گذاری و تضمین کیفیت داده: ایجاد رابط برچسب گذاری برای اپراتورهای متخصص. بازیینی تصادفی و چندنفره برای کنترل صحت برچسب ها. مستند سازی انواع عیوب و استاندارد نام گذاری.

گام ۳ — پیش پردازش و افزایش داده: ذخیره نسخه های تولیدشده به صورت مجزا یا تولید در زمان اجرا

گام ۴ — طراحی و آموزش مدل: بارگذاری مدل از پیش‌آموزش‌دیده. استفاده از class weights یا تکنیک های oversampling/SMOTE برای متوازنی.

گام ۵ — بررسی تبیینی(Explainability) : استفاده از روش هایی مانند Grad-CAM برای تولید نقشه های گرما (heatmaps)که نشان می‌دهد مدل بر روی کدام بخش های تصویر تکیه کرده تا تصمیم‌گیری کند؛ این کار به افزایش اعتماد اپراتور و یافتن خطاهای احتمالی مدل کمک می‌کند.

گام ۶ —استقرار در لبه(Edge Deployment) : تبدیل مدل برای اجرا بر روی سخت افزار صنعتی) مثلاً با OpenVINO برای پردازنده های Intel یا ابزارهای مشابه



گام ۷ — یکپارچه سازی با سیستم های تولید(MES/SCADA) : ارسال خودکار نتایج به سیستم کنترل تولید و فعال سازی اقدامات اصلاحی (مثلاً توقف خط، برچسب گذاری دسته تولید مشکل دار، هشدار به تیم تعمیرات).

گام ۸ — چرخه یادگیری مداوم: ذخیره داده های جدید (تصاویر و متادیتا) برای بازآموزی دوره ای مدل، به خصوص نمونه هایی که مدل پیش بینی غلط داشت. تنظیم مدل و pipeline بر اساس توالی خطاهای واقعی و تغییرات در تجهیزات.

۶ .نتایج عددی و تحلیل آماری (نمونه گزارش و تفسیر)

مطالعه انتخاب شده عملکرد بسیار بالایی گزارش کرده است: دقت ۹۹٫۱۹٪، precision۹۹٫۳۴٪، recall۹۸٫۷۵٪ و F1 ۹۹٫۰۵٪. که نشان می دهد مدل قادر است با نرخ کم خطا اجسام خارجی را در تصاویر X-ray پیدا کند. این نتایج اگر در شرایط خط تولید واقعی استقرار یابند، می تواند به کاهش چشمگیر ضایعات منجر شود؛ مطالعات صنعتی گزارش کرده اند راهکارهای بینایی ماشین و استقرار آن ها می تواند نرخ ضایعات را کاهش داده و هزینه های مرتبط با برگشتی ها و نیروی انسانی را به طور قابل توجهی کم کند .

۷ .چالش ها، محدودیت ها و راه حل های پیشنهادی

عدم توازن داده: ناپایداری عملکرد با تغییر شرایط خط؛ نیاز به پردازش در زمان واقعی

مسائل سازمانی: لازم است مدیریت کیفیت و تیم فناوری اطلاعات با هم همکاری کنند؛ تدوین سیاست های حفظ داده، استانداردسازی جمع آوری و برچسب گذاری و برنامه آموزش پرسنل برای پذیرفتن نتایج مدل از اهمیت بالایی برخوردار است.

نتیجه گیری

هوش مصنوعی و به ویژه روش های بینایی ماشین و یادگیری عمیق، ظرفیت بالایی برای کاهش ضایعات و بهبود کیفیت در تولید لاستیک دارند. شواهد تجربی از مطالعات آزمایشگاهی و پیاده سازی های صنعتی نشان می دهد که مدل های مناسب می توانند درصد قابل توجهی از عیوب را با دقت بالا تشخیص دهند) نمونه ها: دقت ۹۹٫۱۹٪ در مطالعه Xception و افزایش دقت به بیش از ۹۹٫۹٪ در پیاده سازی صنعتی . این بهبود در تشخیص نه تنها از خروج محصول معیوب به بازار جلوگیری می‌کند، بلکه امکان مداخله زودهنگام در خط تولید را فراهم می آورد و به تبع آن هزینه های بازگشتی، تعمیرات اضطراری و اثرات زیست محیطی ضایعات کاهش می یابد .

از منظر مدیریتی، توصیه می شود پروژه های کاهش ضایعات مبتنی بر AI به صورت مرحله ای اجرا شوند؛ ابتدا یک فاز آزمایشی (pilot) برای جمع آوری داده و ارزیابی مدل، سپس فاز توسعه برای بهینه سازی و مقیاس پذیری، و در نهایت فاز استقرار کامل که شامل آموزش نیروی انسانی و تنظیمات عملیاتی است. معیار سنجش موفقیت باید شامل کاهش درصد ضایعات) مثلاً کاهش نرخ بازگشت یا(scrap rate ، بهبود KPI های تولید (افزایش throughput یا کاهش توقفات) و بازگشت سرمایه (ROI) بر اساس کاهش هزینه های بازگشتی و نیروی انسانی باشد.

به‌طور خلاصه، ترکیب بینایی ماشین با داده های فرایندی و سیاست های مدیریتی مناسب می تواند کاهش معنی داری در ضایعات تولید لاستیک ایجاد کند و در بلندمدت به صرفه جویی اقتصادی و کاهش اثرات زیست محیطی منجر شود. مسیر پیاده سازی باید تدریجی، شفاف و مبتنی بر داده باشد تا نتایج قابل اتکا و پایدار حاصل گردد.

منابع :

1. R. A. A. Saleh, et al., Advancing Tire Safety: Explainable Artificial Intelligence-Powered Foreign Object Defect Detection with Xception Networks and Grad-CAM Interpretation, Applied Sciences, 2024.

2. I. Kuric, et al., Analysis of the Possibilities of Tire-Defect Inspection Based on Unsupervised Learning and Deep Learning, Sensors, 2021.

3. Intel (DeepSight case), DeepSight and Intel Help Tire Manufacturer Speed Up Flaw Detection (industry case study / customer spotlight).

4. M. Tamborski, I. Rojek, D. Mikołajewski, Revolutionizing Tire Quality Control: AI’s Impact on Research, Development, and Real-Life Applications (review).

1397-RIERCO