



کاویرتایر

اولین تولیدکننده تایر در ایران

طبقه بندی و پیش بینی خرابی های دستگاه پرس پخت تایر با استفاده از یادگیری ماشین

مجید هادی، محمدامین کیانیان، صادق حسین آبادی

ایمیل: m.hadi@kavirtire.ir, شماره تماس: ۰۹۱۵۷۲۱۲۶۵۷

17th Conference And 9th Exhibition of Rubber And Related Industries

Iranmall
January 6-7 2026

۱۷ همایش و ۹ نمایشگاه لاستیک و صنایع وابسته

ایران مال
۱۸ تا ۲۱ دی ماه ۱۴۰۴


خرابی است که احتمالاً ناشی از شباهت الگوهای اولیه قبل از بروز خرابی کامل است. همچنین، نامتوازن بودن داده‌های مربوط به خرابی می‌تواند دلیل دیگری از دقت پایین‌تر برخی از خرابی‌ها باشد. برای بررسی این موضوع، در شکل ۲، نمودار یادگیری شبکه برحسب تعداد داده‌های آموزش برای مدل LightGBM نشان داده شده است. این شکل تأیید می‌کند با افزایش تعداد داده‌های آموزش خصوصاً داده‌های خرابی، می‌تواند دقت شبکه را افزایش دهد. در جدول ۲، عملکرد چهار شبکه ارائه‌شده برای طبقه‌بندی سه خرابی آورده شده است. همان‌طور که گفته شد، شبکه LightGBM عملکرد بسیار خوبی در تشخیص و پیش‌بینی خرابی به همراه دارد.

جدول ۲: مقایسه عملکرد چهار مدل ارائه‌شده در طبقه‌بندی و پیش‌بینی سه خرابی پرس پخت

مدل	عیب شیب			عیب روی تایمر نیفتادن			عیب پایین نیامدن پلاتن		
	Precision	F1-Score	Recall	Precision	F1-Score	Recall	Precision	F1-Score	Recall
LightGBM	۶۳٪	۶۶٪	۷۱٪	۸۱٪	۸۶٪	۷۷٪	۷۳٪	۷۳٪	۷۵٪
XGBoost	۶۰٪	۶۳٪	۸۲٪	۷۷٪	۸۲٪	۶۹٪	۷۱٪	۷۳٪	۷۴٪
Random Forest	۴۷٪	۵۳٪	۶۱٪	۷۹٪	۷۲٪	۶۶٪	۵۷٪	۶۱٪	۶۵٪
Extra Trees	۴۳٪	۵۰٪	۵۹٪	۸۱٪	۷۳٪	۶۴٪	۵۷٪	۵۷٪	۶۴٪

۴. نتیجه‌گیری

در این پژوهش، رویکردی برای طبقه‌بندی و پیش‌بینی خرابی‌های دستگاه پرس پخت تایر با استفاده از ۲۷ ویژگی تخصصی و چهار مدل یادگیری ماشین توسعه داده شد. مدل LightGBM با دقت ۹۸.۴٪ و F1-Score وزن‌دار ۹۸.۴٪ بهترین عملکرد را در تشخیص سه نوع خرابی (عیب شیب، روی تایمر نیفتادن، پایین نیامدن پلاتن) نشان داد. نمره AUC نزدیک به ۱ و پایداری بالا در اعتبارسنجی متقاطع نشان می‌دهد که این سیستم می‌تواند به‌عنوان ابزاری کارآمد برای نگهداری پیشگیرانه و کاهش زمان توقف تولید در صنعت تایرسازی استفاده شود.



شکل ۱: ماتریس درهم ریختگی برای مدل‌های مختلف

- مراجع:**
- [1] Susto, Gian Antonio, et al. "Machine learning for predictive maintenance: A multiple classifier approach." *IEEE transactions on industrial informatics* 11.3 (2014): 812-820.
 - [2] Carvalho, Thyago P., et al. "A systematic literature review of machine learning methods applied to predictive maintenance." *Computers & Industrial Engineering* 137 (2019): 106024.
 - [3] Saleh, Radhwan AA, et al. "Tire defect detection model using machine learning." *2022 2nd International Conference on Emerging Smart Technologies and Applications (eSmarTA)*. IEEE, 2022.
 - [4] Kuric, Ivan, et al. "Analysis of the possibilities of tire-defect inspection based on unsupervised learning and deep learning." *Sensors* 21.21 (2021): 7073.
 - [5] Yugapriya, M., Antony Kovilpillai J. Judeson, and S. Jayanthi. "Predictive maintenance of hydraulic system using machine learning algorithms." *2022 International Conference on Electronics and Renewable Systems (ICEARS)*. IEEE, 2022.

شونده به این عیب شامل موارد زیر است: خرابی و نشستی جک قفل پلاتن، نشستی جک اسکونیز، بالا نرفتن فشار اسکونیز به دلیل خرابی بوستر و پرشر ترانسسمیتر، خرابی پراکسیمیتی سونچ اسکونیز و خرابی لیمیت قفل پلاتن.

- پایین نیامدن پلاتن: پلاتن، بخشی از ساختار پرس است که قالب روی آن نصب شده و مسئولیت انتقال نیرو، توزیع حرارت و حفظ پایداری قالب را طی فرآیند پخت بر عهده دارد. این عیب مانع از بسته شدن قالب و شروع چرخه می‌شود. دلایل فنی اصلی بروز این نقص عبارتند از: خرابی سوکت یا پراکسیمیتی down بیدلیفت، بازنشستن قفل‌های پلاتن، خرابی پراکسیمیتی down سنگمت، نگرفتن سنسورهای out لودر و آنلودر.

یکی از نوآوری‌های کلیدی این پژوهش، طراحی و استخراج ۲۷ ویژگی تخصصی است که به‌طور ویژه برای تشخیص خرابی‌های دستگاه پرس پخت تایر مهندسی شده‌اند. لازم به ذکر است که بیش از ۹۰ ویژگی مختلف استخراج شده که در بررسی اهمیت ویژگی‌ها، ۲۷ ویژگی مهم و تأثیرگذار برای این پژوهش انتخاب گردید. این ویژگی‌ها در پنج دسته اصلی طبقه‌بندی می‌شوند:

دسته اول: ویژگی‌های تاریخچه خرابی: این دسته شامل هشت ویژگی است که تعداد و فراوانی خرابی‌ها را در بازه‌های زمانی مختلف (۰.۷، ۱.۴، ۳.۰، ۶.۰ و ۹.۰ روز) اندازه‌گیری می‌کنند. همچنین، تعداد تجمعی کل خرابی‌ها و نرخ تجمعی خرابی که نشان‌دهنده سطح فرسودگی دستگاه است، محاسبه می‌شود.

دسته دوم: ویژگی‌های روند زمانی: این دسته شامل شش ویژگی است که تغییرات و روندهای خرابی را در طول زمان مدل می‌کنند. شیب روند خرابی در بازه‌های مختلف (۰.۷، ۱.۴ و ۳.۰ روز) با مقایسه تعداد خرابی‌های نیمه اول و دوم محاسبه می‌شود. همچنین تنوع انواع خرابی‌ها در بازه‌های زمانی که نشان‌دهنده مشکلات چندگانه است، ارزیابی می‌گردد.

دسته سوم: شاخص‌های ریسک و پایداری: این دسته شامل شش ویژگی ترکیبی است که سطح خطر و پایداری دستگاه را کمی‌سازی می‌کنند. شاخص ریسک با ترکیب وزن‌دار تعداد خرابی‌ها و تنوع آن‌ها محاسبه می‌شود.

دسته چهارم: معیارهای زمانی: این دسته شامل پنج ویژگی است که فواصل زمانی و الگوهای زمان‌بندی خرابی‌ها را تحلیل می‌کنند، از جمله تعداد روزهای گذشته از آخرین خرابی، لگاریتم طبیعی این فاصله، تعداد روزهای متوالی با خرابی و بدون خرابی، و میانگین طول دوره‌های سالم در ۹۰ روز گذشته.

دسته پنجم: پارامترهای آماری: این دسته شامل دو ویژگی است که تغییرپذیری الگوهای خرابی را اندازه‌گیری می‌کنند، شامل انحراف معیار فواصل زمانی بین خرابی‌های متوالی و نرخ خرابی در بازه کوتاه‌مدت سه روزه.

علاوه بر این ویژگی‌ها، چهار ویژگی اصلی شامل شماره پرس، سال خرابی، میزان تولید از آخرین خرابی و تعداد روز سپری‌شده از زمان تعویض قالب نیز در مدل‌سازی استفاده می‌شوند. در نهایت، چهار الگوریتم مبتنی بر درخت شامل Random Forest (۵۰۰ درخت، عمق ۴۰)، XGBoost (۱۲۰۰ تخمین‌زن، نرخ یادگیری ۰.۱۵)، LightGBM (نرخ یادگیری ۰.۰۲، معماری Histogram-based)، و Extra Trees (۶۰۰ درخت، عمق ۳۰) برای طبقه‌بندی چندکلاسه به‌کار گرفته شدند.

۳. نتایج شبیه‌سازی و تحلیل

برای ارزیابی جامع عملکرد مدل‌های طبقه‌بندی، چهار معیار کلیدی مورد استفاده قرار گرفتند: (۱) دقت کلی: این معیار نسبت کل پیش‌بینی‌های صحیح به تعداد کل نمونه‌ها را اندازه‌گیری می‌کند یعنی $accuracy = \frac{TP+TN}{TP+TN+FP+FN}$ و F1-Score وزن‌دار: میانگین هماهنگ دقت (Precision) و بازخوانی (Recall) را برای هر کلاس محاسبه کرده و با وزن‌های متناسب با اندازه کلاس‌ها ترکیب می‌کند یعنی $F1_{weighted} = \sum_{k=1}^K \omega_k \frac{2 \cdot P_k \cdot R_k}{P_k + R_k}$ ، نمره AUC: سطح زیر منحنی ROC را با استراتژی One-vs-Rest برای مسائل چندکلاسه محاسبه می‌کند. (۴) میانگین اعتبارسنجی متقاطع: میانگین F1-Score در ۵ قسمت اعتبارسنجی متقاطع که پایداری مدل را نشان می‌دهد.

در جدول ۱، نتایج مقایسه‌ای کلی (شامل داده‌های نرمال و خرابی پرس‌ها) چهار مدل را در چهار معیار ارزیابی نمایش می‌دهد که LightGBM با دقت ۹۸.۴٪ و F1-Score وزن‌دار ۹۸.۳٪ بهترین عملکرد را به دست آورده است. XGBoost با دقت ۹۸.۲٪ در رتبه دوم و Extra Trees و Random Forest به‌ترتیب با ۹۷.۵٪ و ۹۷.۷٪ در رتبه‌های بعدی قرار دارند. همه مدل‌ها به نمره AUC تقریباً کامل ۱ دست یافته‌اند که نشان‌دهنده قدرت تفکیک عالی ویژگی‌های استخراج‌شده است. میانگین اعتبارسنجی متقاطع نیز پایداری بالای مدل‌ها را با مقادیر بالای ۰.۹۷ تأیید می‌کند، که برتری معماری‌های Gradient Boosting (LightGBM و XGBoost) در مدل‌سازی الگوهای پیچیده خرابی را نشان می‌دهد. البته عمده دقت به‌دست‌آمده به دلیل تعداد زیاد داده‌های نرمال (غیرخرابی) است و بنابراین، در ادامه به قدرت مدل‌های ارائه‌شده در بخش تشخیص خرابی پرداخته می‌شود.

جدول ۱: مقایسه چهار مدل ارائه‌شده جهت طبقه‌بندی و پیش‌بینی کلی

مدل یادگیری ماشین	دقت کلی	F1-Score	AUC Score	Cross-validation Mean
LightGBM	۰.۹۸۴	۰.۹۸۴	۰.۹۹۹	۰.۹۸۰
XGBoost	۰.۹۸۲	۰.۹۸۲	۰.۹۹۹	۰.۹۷۸
Random Forest	۰.۹۷۸	۰.۹۷۷	۰.۹۹۹	۰.۹۷۴
Extra Trees	۰.۹۷۶	۰.۹۷۵	۰.۹۹۹	۰.۹۷۱

شکل ۱ ماتریس‌های درهم‌ریختگی تفصیلی را برای شبکه‌های مختلف نمایش می‌دهد که شبکه LightGBM در شناسایی کد وضعیت نرمال با ۱۰۰٪، کد ۱ (عیب شیب) با ۶۲٪، کد ۲ (عیب روی تایمر نیفتادن) با ۸۵.۶٪، و کد ۳ (عیب پایین نیامدن پلاتن) با ۷۰.۷٪ دقت بالاترین عملکرد را دارد. این شکل نشان می‌دهد که شبکه‌های پیشنهادی عملکرد بسیار خوبی در روزهای غیرخرابی (شرایط نرمال و سالم پرس پخت) دارند و ۱۰۰ درصد روزهای نرمال را تشخیص می‌دهند. عمده اشکالات تشخیص اشتباه در روزهای خرابی و نوع

چکیده: در صنعت تایر، دستگاه‌های پرس پخت نقش حیاتی در تعیین کیفیت نهایی محصول ایفا می‌کنند و هرگونه خرابی در این تجهیزات منجر به افزایش قابل توجه نرخ اسکرپ و توقفات غیربرنامه‌ریزی شده می‌شود. این پژوهش یک چارچوب جامع مبتنی بر یادگیری ماشین برای طبقه‌بندی و پیش‌بینی سه نوع خرابی حیاتی دستگاه پرس پخت ارائه می‌دهد: عیب شیب، روی تایمر نیفتادن و پایین نیامدن پلاتن. روش پیشنهادی بر پایه مهندسی ویژگی پیشرفته شامل معیارهای تاریخچه خرابی، شاخص‌های روند زمانی، معیارهای ریسک، و پارامترهای آماری استوار است. عملکرد چهار الگوریتم یادگیری ماشین شامل LightGBM، XGBoost، Random Forest و Extra Trees مورد مقایسه قرار گرفت. نتایج تجربی نشان داد که مدل‌های مبتنی بر Ensemble Learning به‌ویژه XGBoost و LightGBM عملکرد برتری دارند. ارزیابی عملکرد مدل با استفاده از معیارهای متنوع شامل AUC-ROC، F1-Score، Precision، Recall، Accuracy انجام شد. تحلیل ماتریس درهم‌ریختگی نشان‌دهنده توانایی قابل قبول مدل در تشخیص انواع خرابی‌ها حتی در شرایط عدم توازن کلاس‌ها است. این رویکرد می‌تواند به‌عنوان یک سیستم هشدار زودهنگام در راستای نگهداری و تعمیرات پیش‌بینانه و برنامه‌ریزی تعمیرات برای کاهش عیوب پیاده‌سازی شود.

واژه‌های کلیدی: پرس پخت، یادگیری ماشین، پیش‌بینی خطا، نگهداری و تعمیرات پیش‌بینانه

محور مقاله: فناوری ماشین‌آلات و قطعات تولیدی

۱. مقدمه

صنعت تایرسازی یکی از صنایع استراتژیک و حیاتی در حوزه تولید قطعات خودرو است که کیفیت محصولات آن تأثیر مستقیم بر ایمنی و عملکرد وسایل نقلیه دارد. در فرآیند تولید تایر، مرحله پخت از اهمیت بسیار بالایی برخوردار است، زیرا در این مرحله ترکیبات شیمیایی لاستیک تحت شرایط کنترل‌شده دما و فشار به محصول نهایی تبدیل می‌شوند. دستگاه‌های پرس پخت با اعمال فشار و حرارت دقیق، شکل نهایی و خواص مکانیکی تایر را تعیین می‌کنند. خرابی‌های غیرمنتظره در دستگاه‌های پرس پخت عواقب اقتصادی و عملیاتی دارند. این خرابی‌ها منجر به تولید محصولات معیوب می‌شوند که باید به‌عنوان اسکرپ کنار گذاشته شوند. علاوه بر این، توقفات ناشی از خرابی‌ها باعث کاهش بهره‌وری خطوط تولید، افزایش هزینه‌های تعمیرات اضطراری و اختلال در برنامه‌های تولید می‌شوند.

در دهه‌های اخیر، رویکردهای مختلفی برای نگهداری و تعمیرات تجهیزات صنعتی توسعه یافته است. نگهداری واکنشی که بر اساس تعمیر پس از خرابی عمل می‌کند، به دلیل هزینه‌های بالا و توقفات طولانی دیگر مورد استقبال قرار نمی‌گیرد. نگهداری پیشگیرانه مبتنی بر زمان‌بندی ثابت نیز با وجود بهبودهایی که ارائه می‌دهد، نمی‌تواند به‌طور دقیق زمان وقوع خرابی را پیش‌بینی کند و در برخی موارد منجر به تعویض‌های غیرضروری قطعات می‌شود. ظهور فناوری‌های یادگیری ماشین و هوش مصنوعی امکان توسعه سیستم‌های نگهداری پیش‌بینانه را فراهم آورده است. این رویکرد با تحلیل داده‌های تاریخی و شناسایی الگوهای پیچیده، قادر به پیش‌بینی زمان وقوع خرابی و تشخیص نوع آن است. مطالعات متعددی در حوزه‌های مختلف صنعتی از یادگیری ماشین برای تشخیص خرابی استفاده کرده‌اند. در [۱]، از الگوریتم‌های طبقه‌بندی برای تشخیص عیوب در فرآیندهای نیمه‌هادی استفاده کردند و نشان دادند که Random Forest عملکرد بهتری نسبت به روش‌های سنتی دارد. در [۲]، یک چارچوب جامع برای نگهداری پیش‌بینانه در صنایع تولیدی ارائه دادند که ترکیبی از سنسورهای اینترنت اشیا و الگوریتم‌های یادگیری عمیق را شامل می‌شد. در [۳]، یک چارچوب هیبریدی ترکیبی از XGBoost و شبکه بیزی برای پیش‌بینی خرابی در تجهیزات نساجی توسعه دادند که دقت ۹۱٪ را با قابلیت تفسیرپذیری بالا ارائه داد. در حوزه صنعت تایر، تحقیقات محدودی انجام شده است. در [۴]، یک مدل تشخیص عیب تایر مبتنی بر یادگیری ماشین با استفاده از ماتریس هم‌رخدادی سطح خاکستری برای استخراج ویژگی ارائه دادند. در [۵]، نویسندگان امکانات بازرسی عیوب تایر براساس یادگیری بدون نظارت و یادگیری عمیق را تحلیل کردند و نشان دادند که سیستم‌های مبتنی بر یادگیری عمیق دقتی بالاتر از ۹۴٪ دارند اما در کاربردهای واقعی محدود هستند. در [۶]، نگهداری پیش‌بینانه سیستم‌های هیدرولیک را با استفاده از الگوریتم‌های یادگیری ماشین بررسی کردند که مستقیماً با سیستم هیدرولیک دستگاه‌های پرس پخت مرتبط است.

این پژوهش یک چارچوب طبقه‌بندی و پیش‌بینی چندکلاسه برای تشخیص همزمان سه نوع خرابی مهم دستگاه پرس پخت تایر (عیب شیب، روی تایمر نیفتادن و پایین نیامدن پلاتن) ارائه می‌دهد که بر پایه مهندسی ویژگی در پنج دسته (تاریخچه خرابی، روند زمانی، شاخص ریسک، معیارهای زمانی، و پارامترهای آماری) استوار است. با مقایسه سیستماتیک چهار الگوریتم یادگیری ماشین و استفاده از تکنیک‌های تفسیرپذیری، این رویکرد توانایی پیش‌بینی خرابی‌ها با دقت قابل قبولی را دارد و می‌تواند به‌عنوان یک سیستم هشدار زودهنگام در راستای کاهش نرخ اسکرپ و بهبود نگهداری و تعمیرات در صنعت تایر پیاده‌سازی شود.

۲. روش تجربی

مجموعه داده خام این پژوهش شامل رکوردهای عملکردی دستگاه‌های پرس پخت تایر از ابتدای سال ۱۳۹۹ تا اواسط ۱۴۰۴ است که از سیستم کیفیت واحد تولید کارخانه استخراج شده‌اند. هر رکورد داده شامل اطلاعات زیر است: شماره پرس، شیفت کاری، گروه کاری، کد خرابی، سمت پرس، تعداد تولید، زمان تعویض قالب و تاریخ خرابی. تمرکز این پژوهش بر طبقه‌بندی و پیش‌بینی سه دسته از خرابی‌های کلیدی و پرتکرار دستگاه پرس پخت است که به‌طور مستقیم منجر به تولید محصولات اسکرپ و افزایش ضایعات در خط تولید می‌شوند. این خرابی‌ها، که به‌عنوان متغیر هدف در مدل‌سازی در نظر گرفته شده‌اند، به شرح زیر هستند:

- عیب شیب: این عیب به بروز نقص در فرآیند شیبینگ اشاره دارد؛ مرحله‌ای که در آن تایر خام فرم اولیه خود را پیش از پخت نهایی در قالب به دست می‌آورد. تحلیل علل ریشه‌ای نشان می‌دهد که دلایل اصلی وقوع این عیب عبارتند از: خرابی شیبینگ ولو، خرابی پیستون‌ولو و سلونوئیدولو پنوماتیک M/D و A/D، خرابی پیستون‌ولو و سلونوئیدولو پنوماتیک ورودی و خرابی رگولاتور پنوماتیک تنظیم‌کننده.
- عیب روی تایمر نیفتادن: این خرابی زمانی رخ می‌دهد که علی‌رغم تکمیل مراحل اولیه و بسته شدن پلاتن‌های دستگاه پرس، چرخه خودکار پخت آغاز نمی‌شود و در نتیجه، محصول موجود در قالب به ضایعات تبدیل می‌گردد. مهم‌ترین عوامل فنی منجر