

سیستم کنترل هوشمند برای نظارت بر فرایند، تشخیص خطا و کاهش نقص‌ها در ماشین‌های پخت تایر

S Smart Controlling System for Process Monitoring, Fault Diagnosis and Defect Reduction in Tire Curing Machine

چکیده:

فرایند پخت تایر آخرین مرحله در صنعت تولید تایر است. در این مرحله، تمامی مرحله‌های پیش‌تولید تایر به‌نتیجه می‌رسد. کنترل فرایندهای موجود در این مرحله، از اهمیت ویژه‌ای برخوردار است. از این‌رو جلوگیری از هرگونه اختلال و نقصان در فرایند پخت، لازم و ضروری است. ماشین‌های قدیمی پرس پخت تایر، دارای یک سیستم کنترل حلقه‌باز هستند. در این ماشین‌ها، فرایند پخت تایر به‌صورت یک جریان زمان‌بندی‌شده، کنترل می‌شود. باوجود این سیستم‌ها، تشخیص خطا در فرایند پخت، تنها توسط اپراتور یا ناظر دستگاه انجام می‌شود. این نظارت به‌صورت حضوری و از راه دیدن نمودارهای رسم شده، توسط نمایش‌گرهای موجود در پنل کنترل دستگاه انجام می‌شود. درشرایطی که فرایند پخت از شرایط تعریف‌شده استاندارد خود خارج می‌شود، تشخیص ندادن به‌موقع خطا و انجام اقدام‌های اصلاحی مناسب بر روی فرایند درحالی‌اجرا، موجب از دست رفتن محصول یا کاهش کیفیت آن می‌شود. زمانی‌که در یک خط تولید، با کنترل مجموعه‌ای از ماشین‌های پخت با فرایندهای زمانی گوناگون، روبه‌رو باشیم، مشکل‌های مطرح‌شده در فرایند پخت، به یک معضل تبدیل می‌شود.

در این مقاله، با استفاده از الگوریتم‌های خطایابی و طبقه‌بندی داده‌های مربوط به فرایند پخت سعی می‌شود در صورت بروز هرگونه اختلال و نقصان در فرایند پخت، خطای احتمالی آشکارسازی و برای جلوگیری از دست رفتن یا کاهش کیفیت محصول، فرمان‌ها و اقدام‌های اصلاحی مناسب بر روی فرایند درحالی‌اجرا ایجاد و اعمال شود. همچنین در این مقاله عملکرد الگوریتم‌های MLP, K-NN و C4.5 با استفاده از داده‌های عملی دریافتی از پرس پخت تایر، از نظر دقت مودارزیابی قرار خواهند گرفت. در این ارزیابی، دیده خواهد شد که الگوریتم C4.5، عملکرد بهتری نسبت به الگوریتم‌های MLP و K-NN از خود نشان می‌دهد. همچنین روش ارزیابی و تأیید خطای رخ داده در سیستم با استفاده از یک حافظه و پردازنده و مدارهای الکترونیکی تشریح شده خواهد شد. درنهایت، با مقایسه‌ی روش‌های خطایابی سیستم، راهکاری برای افزایش کارایی دستگاه و جلوگیری از کاهش کیفیت محصول ارائه خواهد شد.

واژه‌های کلیدی: سیستم کنترل هوشمند، تشخیص خطا، نظارت بر فرایند، ماشین پرس پخت تایر، الگوریتم‌های طبقه‌بندی MLP, K-NN و C4.5.

نوع مقاله: پژوهشی

گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران
تاریخ دریافت: ۹۶/۲/۲ تاریخ بازنگری: ۹۶/۴/۲۴ تاریخ پذیرش: ۹۶/۶/۱۷

ناصر پرهیزگار، محمدتقی دهقان خلیلی
* عهده دار مکاتبات: Parhizgar@iaushiraz.ac.ir

مقدمه:

اندازه‌های ویژه‌ی خودروهای سواری، تشخیص ندانن به موقع خطا و انجام اقدام‌های اصلاحی مناسب بر روی فرایند درحال اجرا، موجب از دست رفتن محصول یا کاهش کیفیت آن می‌شود. بنابراین کنترل پارامترهای فناورانه‌ی پخت مانند دما، فشار، زمان و ...، برای بهبود کیفیت تولید در فرایند تولید تایر بسیار مهم است [۲ و ۷].

سیستم‌های نظارت فرایند صنعتی، آشکارسازی خطا و تشخیص خطا

آشکارسازی و تشخیص خطاهای سیستم برای حفاظت از سیستم‌های کنترل فرایند در برابر نقص و آسیب‌های پایدار، بسیار ضروری‌ست. در سال‌های اخیر، استفاده از فن‌های هوش مصنوعی، جای‌گزین روش‌های سنتی نظارت و تشخیص خطا در سیستم‌های کنترل شده است. نظارت، یک کار مستمر بلادرنگ^(۱) است که به‌وسیله‌ی ثبت داده‌ها، بازشناسی و نشان دادن اشکال‌های موجود در رفتار سیستم، به تعیین شرایط یک سیستم فیزیکی می‌پردازد [۸ و ۹]. به‌عبارت‌دیگر، هدف از نظارت این است که نشان دهد آیا یک فرایند از وضعیت قابل‌پذیرش خود منحرف‌شده است یا خیر و اگر منحرف‌شده، به‌چه دلیل انحراف رخ داده است. انحراف‌ها را خطای فرایند می‌نامند. مشاهده‌ی خطا، به‌عنوان تشخیص خطا شناخته می‌شود. تشخیص خطا را می‌توان از راه‌های گوناگون انجام داد. به‌طورکلی دو رویکرد برای پردازش خطا در سیستم‌ها معرفی می‌شود [۱۰ تا ۱۲]. رویکرد اول مبتنی بر پردازش داده‌ی به‌دست‌آمده از فرایند و دیگری رویکرد مبتنی بر مدل ریاضی فرایند. در رویکرد اول، اطلاعات دریافتی ما از فرایند، وابسته به داده‌های مشاهده شده‌ی است که از حس‌گرهای به‌کاررفته در فرایند به‌دست می‌آیند. در رویکرد دوم، ساختار فیزیکی و یک رابطه‌ی شناخته‌شده‌ی پیشین بین متغیرهای فرایند، مدل پایه را برای معرفی ساختاری فرایند می‌سازد [۱۳].

تولیدکنندگان تایر باید از هر مرحله از فرایندهای تولیدشان، بیشترین بهره‌وری را به‌دست آورند. تایرهای تولیدشده باید استانداردهای لازم و مشخصه‌های موردنظر مصرف‌کننده را داشته باشد. فرایند پخت^(۱) تایر به‌عنوان آخرین مرحله از فرایند تولید تایر، دارای اهمیت بسیاری است. در این مرحله یک تایر خام^(۲) با قرار گرفتن در دستگاه پرس پخت، طی فرایندی متأثر از دما، فشار و زمان به‌شکل نهایی خود تبدیل می‌شود. به‌همین دلیل فرایند پخت نقش مهمی در رسیدن به این هدف ایفا می‌کند و بیشترین سرمایه‌گذاری کارخانه‌ها در این بخش انجام می‌شود. با توجه به اهمیت مرحله‌ی پخت تایر، بخش عمده‌ای از پژوهش‌ها در حوزه‌ی پخت تایر، به بررسی روش‌های بهینه‌ی کنترل و اصلاح فرایند پخت [۱ تا ۳]، بررسی میزان مصرف انرژی دستگاه‌های پرس پخت و بررسی اثر انتقال گرما در فرایند پخت [۴ تا ۶] اختصاص‌یافته است. هدف این مقاله ارائه‌ی یک راهکار برای بهبود کنترل فرایند پخت در خط‌های تولید تایر است. ابتدا چالش‌های موجود را بررسی کرده و سپس الگوریتم‌های به‌کار گرفته‌شده در این پژوهش معرفی می‌شوند. در پایان اقدام‌های عملی انجام‌شده در این زمینه ارائه خواهد شد.

چالش‌ها

ماشین‌های قدیمی پرس پخت تایر، دارای یک سیستم کنترل حلقه‌باز است. در این ماشین‌ها، فرایند پخت تایر به‌صورت یک جریان زمان‌بندی‌شده کنترل می‌شود. در فرایند پخت این ماشین‌ها، تشخیص رخ‌دادن خطا، تنها توسط اپراتور یا ناظر دستگاه، از راه نظارت حضوری بر نمودارهای رسم شده، توسط نمایش‌گرهای موجود در پنل کنترل دستگاه انجام می‌شود [۵ و ۶]. در این شرایط (به‌دلیل کوتاه بودن زمان اجرای فرایند پخت در بعضی اندازه‌های تایر، به‌خصوص در

1. Curing

2. Green Tire

3. Real Time

الگوریتم MLP

شبکه‌های عصبی مصنوعی پیش‌خور^(۷) معمولاً به‌عنوان طبقه‌بندی‌کننده^(۸) در رویکردهای طبقه‌بندی الگو^(۹) مورد استفاده قرار می‌گیرد که شامل پرسپترون چندلایه (MLP)^(۱۰) است [۱۶]. MLP یک شبکه‌ی عصبی مصنوعی است که شامل لایه‌های بسیار از نورون‌ها در یک معماری پیش‌خور است. یک پرسپترون چندلایه شامل ۳ یا تعداد بیشتری لایه است که در آن یک ورودی و یک خروجی با یک یا تعداد زیادی لایه مخفی می‌شود. MLP از تابع فعال‌ساز^(۱۱) غیرخطی در نورون‌ها استفاده می‌کند و هرلایه به‌طور کامل به لایه‌ی بعدی پیوند می‌خورد. چند پرسپترون به‌منظور ایجاد مرز تصمیم با استفاده از تابع‌های فعال‌ساز خطی/غیرخطی باهم ترکیب می‌شوند. هر پرسپترون یک نگاشت غیرخطی به یک بُعد جدید را فراهم می‌کند [۱۷]. با توجه به این‌که MLP یک شبکه‌ی به‌طور کامل پیوسته است که هر نورون در هر لایه به لایه‌ی بعدی با یک تابع وزن W_{ij} مشخص پیوند دارد. MLP از یک فن یادگیری نظارت‌شده^(۱۲) به‌نام پس‌انتشار^(۱۳) استفاده می‌کند. تابع وزن شبکه‌ی عصبی در طول مرحله‌ی آموزش مشخص می‌شود. روش آموزش برای MLP مبتنی بر به‌کمترین میزان رساندن تابع هزینه‌ی انتخابی است که در ابتدا توسط ورپوس^(۱۴) [۱۸] توسعه یافته است.

در شکل (۱) یک نمونه از شبکه‌ی عصبی MLP نشان داده شده است. همان‌طور که مشخص است لایه‌ی مخفی شامل S نورون و هر نورون دارای R وزن است، به‌طوری‌که می‌توان در یک ماتریس $S \times R$ بانام ماتریس، وزن ورودی I را بر اساس معادله‌ی ۱ نمایش داد. بردار P ورودی دارای R عنصر $[p_1, p_2, \dots, p_R]^T$ است که با I ضرب شده است و ماتریس نتیجه با یک بردار بایاس b_1 جمع می‌شود تا بردار n_1 بر

در این روش نیازی به دیدن داده‌های دریافتی از فرایند نیست و آگاهی ما از فرایند، توسط مدل ریاضی آن به‌دست می‌آید. در اینجا به‌دلیل دسترسی نداشتن به مدل ریاضی فرایند، رویکرد مبتنی بر داده را مورد استفاده قرار خواهیم داد.

هر طرح آشکارسازی خطا دارای بخش‌های منطقی به نام آشکارسازی و تصمیم‌گیری هستند. آشکارساز خطا، مقدارهای فعلی اندازه‌گیری شده از فرایند را به‌عنوان ورودی دریافت می‌کند و یک یا چند سیگنال شاخص خطا تولید می‌کند [۱۴] و [۱۵]. پس از فاز آشکارسازی، یک راهکار استنتاج وجود دارد که شاخص‌های خطا را به‌عنوان ورودی دریافت کرده و تصمیم‌گیری می‌کند که آیا خطایی رخ داده است یا نه.


الگوریتم‌های طبقه‌بندی^(۱)

طبقه‌بندی، اختصاص خودکار یک نمونه از مجموعه، به یکی از چند زیرمجموعه‌ی تعریف‌شده بر اساس ویژگی‌های اشیای مجموعه است. در طبقه‌بندی، مجموعه‌ی از سابقه‌ی داده‌ها، به‌عنوان داده‌های آموزش و مجموعه‌ی دیگر به‌عنوان داده‌های آزمون انتخاب می‌شود. از داده‌های آموزش برای ایجاد مدل طبقه‌بندی و از داده‌های آزمون برای اعتبارسنجی مدل طبقه‌بندی به‌دست‌آمده از داده‌های آموزش، استفاده می‌شود [۱۳]. برخی الگوریتم‌های طبقه‌بندی متداول عبارت‌اند از: شبکه‌های عصبی مصنوعی^(۷)، رگرسیون لجستیک^(۸)، k -همسایگی نزدیک^(۹)، درخت تصمیم‌گیری^(۱۰) و غیره [۱۵]. در این پژوهش، سه الگوریتم طبقه‌بندی MLP-ANN^(۲)، K -NN و C4.5 بر روی داده‌های عملی به‌دست آمده از دستگاه‌های پرس پخت، اعمال شد و نتیجه‌های آن مورد بررسی و ارزیابی قرار گرفت. در ادامه، سه الگوریتم مورد استفاده در این مقاله، به‌اختصار معرفی می‌شوند.

1. Classification	2. Artificial Neural Network	3. Logistic Regression	4. K- Nearest Neighbor
5. Decision Tree	6. Multi- layer Perceptron- Artificial Neural Network	7. Feed- Forward	8. Classifier
9. Pattern Classification	10. Multi- Layer Perceptron	11. Activation Function	12. Supervised Learning
13. Back Propagation	14. Werbos		

کلاس‌بندی‌ست که باوجود سادگی الگوریتم، بسیار خوب عمل می‌کند. طبقه‌بندی‌کنندهی KNN نیاز به یک معیار d و یک عدد صحیح مثبت k دارد. KNN، مکان نمونه‌های آموزش و طبقه‌ی آن‌ها را نگه‌داری می‌کند. زمانی‌که نیاز به تصمیم‌گیری در مورد داده‌ی جدید باشد، فاصله‌ی (d) بین داده‌ی ورودی جدید و نمونه‌های آموزش محاسبه می‌شود. بر اساس حد آستانه‌ی تعریف‌شده (مقدار K)، تعداد K نمونه با کمترین فاصله انتخاب می‌شود و کلاس دارای بیشترین نمونه، به‌عنوان نتیجه معرفی می‌شود [۱۰ و ۱۱]. فرایند یافتن نتیجه‌ی طبقه‌بندی به این‌گونه است که یک دایره به مرکزیت داده‌ی ورودی رسم می‌شود و شعاع آن تا زمانی که تعداد K نمونه درون آن قرار گیرد، افزایش می‌یابد. سپس طبقه‌ی که بیشترین تعداد از این K نمونه را در خود جای‌داده باشد، به‌عنوان نتیجه‌ی طبقه‌بندی معرفی می‌شود. در طبقه‌بندی‌کنندهی KNN، به‌طورعموم از معیار فاصله‌ی اقلیدسی برای به‌دست آوردن فاصله‌ی نمونه‌ها استفاده می‌شود [۱۹]. فاصله‌ی اقلیدسی بین دو بردار $p = [p_1 \ p_2 \ \dots \ p_n]$ و $q = [q_1 \ q_2 \ \dots \ q_n]$ از رابطه‌ی زیر محاسبه می‌شود:

$$d_E = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (7)$$

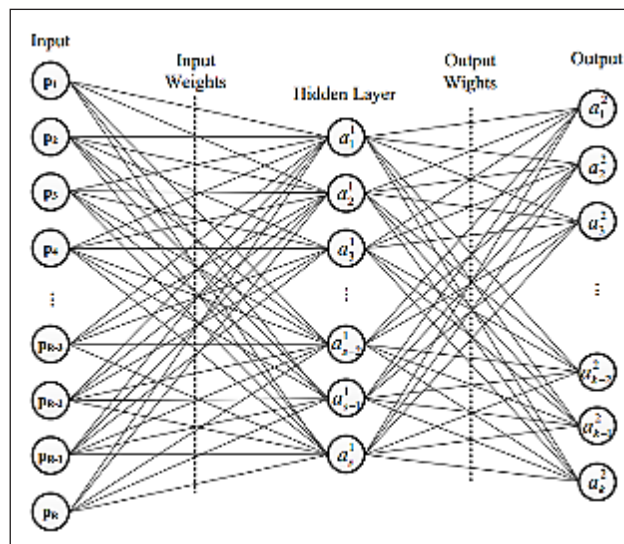


شکل ۲- نحوه‌ی محاسبه‌ی KNN

الگوریتم C4.5

C4.5 نوعی الگوریتم برای ساخت درخت تصمیم‌گیری‌ست که

اساس معادله‌ی ۲ تشکیل شود. خروجی لایه‌ی مخفی a_1 نتیجه‌ی اعمال تابع تبدیل روی n_1 است (معادله‌ی ۳).



شکل ۱- پیوندها در یک شبکه‌ی عصبی MLP

$$I = \begin{bmatrix} W_{1,1} & W_{1,2} & \dots & W_{1,R} \\ W_{2,1} & W_{2,2} & \dots & W_{2,R} \\ \vdots & \vdots & \ddots & \vdots \\ W_{S,1} & W_{S,2} & \dots & W_{S,R} \end{bmatrix} \quad (1)$$

$$n_1 = I \cdot P + b_1 \quad (2)$$

$$a_1 = f(n_1) \quad (3)$$

چنین عملیاتی بر لایه‌ی مخفی نیز اعمال می‌شود که شامل K نورون می‌شود؛ به‌طوری‌که a_1 به‌عنوان بردار ورودی استفاده می‌شود.

$$L = \begin{bmatrix} W_{1,1} & W_{1,2} & \dots & W_{1,S} \\ W_{2,1} & W_{2,2} & \dots & W_{2,S} \\ \vdots & \vdots & \ddots & \vdots \\ W_{K,1} & W_{K,2} & \dots & W_{K,S} \end{bmatrix} \quad (4)$$

$$n_2 = L \cdot a_1 + b_2 \quad (5)$$

$$a_{12} = f_2(n_2) \quad (6)$$

الگوریتم KNN

طبقه‌بندی‌کنندهی KNN، یک روش غیرپارامتری برای

در این رابطه $P_{ij} = \frac{S_{ij}}{S}$ و به معنی احتمال نمونه‌های متعلق به طبقه‌ی C_i در S_j است. بهره‌ی داده‌های^(۷) محاسبه شده از A به صورت زیر به دست می‌آید:

$$Gain(S, A) = E(S) - E(A) \quad (10)$$

مقدار داده‌ها تقسیم بر معنی آنتروپی هر مقدار از مجموعه‌ی نمونه‌ی S روی ویژگی A است. S_i مجموعه‌ی نمونه‌ی مربوط به آمین مقدار از ویژگی A است. بنابراین داده‌های تقسیم شده^(۸) برابر است با:


$$SplitInfo(S, A) = - \sum_{i=1}^v \frac{|S_i|}{|S|} \log_2 \frac{|S_i|}{|S|} \quad (11)$$

نرخ بهره‌ی داده‌ها^(۹) به عنوان نسبت بهره‌ی داده‌ها به داده‌های تقسیم شده برابر است با:

$$GainRatio(S, A) = \frac{Gain(S, A)}{SplitInfo(S, A)} \quad (11)$$

بخش داده‌های تقسیم شده، شانس انتخاب ویژگی‌هایی که شامل مقادیری زیاد و توزیع یکنواخت باشند را کاهش می‌دهد [۲۴]. انتخاب ویژگی با بزرگترین نرخ بهره به عنوان ریشه‌ی درخت تصمیم انتخاب می‌شود.

درخت‌های تصمیم‌گیری روشی برای نمایش یک سری از قانون‌ها هستند که منتهی به یک رده یا مقدار می‌شوند. مانند زمانی که خواهیم متقاضین وام را به نارنگان ریسک اعتبار خوب و بد تقسیم کنیم، شکل (۳) درخت تصمیم‌گیری را که این مسئله را حل می‌کند نشان می‌دهد و همه مؤلفه‌های اساسی یک درخت تصمیم در آن نشان داده شده است: نود تصمیم، شاخه‌ها و برگ‌ها.



شکل ۳- درخت تصمیم‌گیری

توسط راس کویینلان^(۱) بر مبنای الگوریتم ابتدایی ID3 توسعه داده شده است. این الگوریتم یک مجموعه‌ی داده‌ی برچسب خورده را به عنوان ورودی می‌گیرد و یک درخت تصمیم‌گیری را به عنوان خروجی تولید می‌کند [۲۰]. سپس درخت تصمیم به دست آمده، به وسیله‌ی داده‌های آزمون برچسب خورده‌ی جدید، آزموده می‌شود تا کمیت تعمیم آن تعیین شود. بنابراین C4.5 یک برنامه است که برای ایجاد قانون‌های طبقه‌بندی روی یک مجموعه‌ی داده شده با استفاده از درخت‌های تصمیم، مورداستفاده قرار می‌گیرد. این الگوریتم با استفاده از مفهوم آنتروپی داده‌ها، از مجموعه‌ی داده‌های آموزش، درخت‌های تصمیم را می‌سازد [۲۱ تا ۲۳].

فرض کنید S یک مجموعه‌ی دارای s داده نمونه باشد. m را به عنوان طبقه‌های متفاوت $C_i \{i=1,2,\dots,m\}$ تعریف می‌کنیم و s_i تعداد نمونه‌ها در هر طبقه C_i فرض می‌شود. P_i توسط رابطه‌ی S_i/S تخمین زده می‌شود که نشان‌دهنده‌ی احتمال هر نمونه‌ی متعلق به C_i است. در این صورت، برای یک نمونه‌ی داده شده، آنتالپی داده‌ها به صورت زیر به دست می‌آید:

$$E(S) = \sum_{i=0}^m P_i \log_2(P_i) \quad (8)$$

حال فرض کنید که ویژگی A دارای v مقدار گوناگون $\{a_1, a_2, \dots, a_v\}$ باشد و S بتواند توسط ویژگی A به v زیرمجموعه $\{S_1, S_2, \dots, S_v\}$ تقسیم شود. بنابراین S_j شامل نمونه‌هایی است که مقدار a_j در A متعلق به مجموعه S دارد. همچنین، فرض کنید S_{ij} تعداد نمونه‌های طبقه‌ی C_i باشد. بنابراین آنتروپی داده‌های زیرمجموعه که توسط ویژگی A تقسیم شده است، برابر است با:

$$E(A) = - \sum_{j=1}^v \frac{S_j}{S} \sum_{i=1}^m P_{ij} \log_2 P_i \quad (9)$$

1. Ross Quinlan

2. Information Gain

3. Split Information

4. Information Gain Ratio

مرحله‌های داده‌سازی و ارزیابی الگوریتم‌ها

نمونه‌گیری از داده‌ها

پارامترهای اندازه‌گیری شده توسط حسگرها در یک دستگاه پرس پخت سائیز سواری، از راه یک اتصال ارتباطی به یک کامپیوتر سرور مرکزی منتقل و در آنجا نخیره می‌شود. ارسال داده‌های نمونه‌برداری شده با نرخ ۱۰۰ میلی‌ثانیه صورت می‌گیرد. داده‌های دریافتی فرایند شامل دمای بلادر، دمای قالب، فشار بلادر، زمان کل فرایند، زمان هر گام از فرایند و هر گام است. برای این انجام این پژوهش داده‌های مربوط به فرایند پخت یک تایر سواری، با مدت‌زمان ۸۸۸ ثانیه، برای مدت ۴۸ ساعت، با نرخ ۱ ثانیه جمع‌آوری و سپس به نرم‌افزار اکسل منتقل شد. از میان فرایندهای ثبت‌شده، تعداد ۷۰ فرایند استاندارد، با مشورت کارشناسان پخت انتخاب شد.

کوده کردن داده‌ها به خطا و برجسب‌گذاری

برای بررسی میزان نقت الگوریتم‌های یادشده در بالا لازم است در تعدادی از داده‌های عملی به‌دست‌آمده مربوط به چهار گام فرایند پخت با تغییر داده‌ها خطا ایجاد شود. برای این کار با جمع‌آوری داده‌ها از خط تولید، درباری فرایند موردمطالعه، بسته به میزان تغییرهای دمای قالب، دمای بلدر و فشار بلادر و همچنین زمان وقوع این تغییرها را در داده‌های مربوط به هر چهار گام فرایند ایجاد می‌کنیم، بنابراین ۴ نوع خطا تعریف خواهد شد.

نتیجه‌های اجرای الگوریتم‌ها

داده‌های ایجادشده در مرحله‌ی پیش، به سه الگوریتم کلاس‌بندی KNN، MLP و C4.5 وارد شد. برای بررسی میزان نقت این الگوریتم‌ها، نتیجه‌های به‌دست‌آمده از این سه الگوریتم، از راه یک ماتریس درهم‌ریختگی^(۱) موردبررسی قرار گرفت. در الگوریتم MLP با پارامترهای نرخ یادگیری ۰/۵ و تعداد لایه‌های مخفی ۶، از مجموع ۶۴۴۱۰ داده‌ی اعمال‌شده به

الگوریتم ۶۳۷۱۲ داده را در طبقه‌بندی صحیح خود قرار داد. که این میزان ۹۸/۹۱۶۳ درصد نقت را نشان می‌دهد. نتیجه‌ها در جدول (۱) آورده شده است. در الگوریتم KNN با K برابر با ۱ و استفاده از تابع فاصله‌ی اقلیدسی، ۶۴۳۳۶ داده را طبقه‌ی در صحیح خود قرار داد که نقت آن برابر با ۹۹/۸۸۵۱ درصد است. نتیجه‌ها در جدول (۲) نشان داده‌شده است.

جدول ۱- نتیجه‌های الگوریتم MLP

خطای دمای بلادر نوع ۲	خطای دمای بلادر نوع ۱	خطای فشار بلادر	خطای دمای قالب	نرمال	پیش‌بینی واقعی
۰	۰	۹	۱	۵۵۰۴۷	نرمال
۱۳۹	۱۱۰	۱۶۴	۳۲۱۷	۵۱	خطای دمای قالب
۳	۰	۳۰۱۰	۳۲	۳	خطای فشار بلادر
۰	۱۲۳۶	۰	۷۳	۰	خطای دمای بلادر نوع ۱
۱۲۰۲	۸۳	۰	۲۷	۰	خطای دمای بلادر نوع ۲

جدول ۲- نتیجه‌های الگوریتم K-NN

خطای دمای بلادر نوع ۲	خطای دمای بلادر نوع ۱	خطای فشار بلادر	خطای دمای قالب	نرمال	پیش‌بینی واقعی
۲	۰	۱	۰	۵۵۰۵۶	نرمال
۱۹	۸	۱۳	۳۶۳۸	۳	خطای دمای قالب
۰	۰	۳۰۳۸	۸	۲	خطای فشار بلادر
۵	۱۳۰۶	۰	۱	۰	خطای دمای بلادر نوع ۱
۱۲۹۸	۱۴	۰	۰	۰	خطای دمای بلادر نوع ۲

جدول ۴ - نمونه‌ی تصمیم‌های اقدام‌های اصلاحی

شماره‌ی گام فرایند	نوع خطای دیده‌شده	عملیات اصلاحی
۱
۲
۳
۴	خطای نوع ۱	به زمان باقی‌مانده از فرایند T1 اضافه کردن زمان
	خطای نوع ۲	تبدیل گام فعلی فرایند را به گام بعدی و اضافه را به زمان باقی‌مانده از فرایند T2 کردن زمان
	خطای نوع ۳	تبدیل گام فعلی فرایند به گام پیشین و اضافه کردن به زمان باقی‌مانده فرایند T3 زمان
	خطای نوع ۴	به زمان باقی‌مانده از فرایند T4 اضافه کردن زمان
۵
.
.
.

برای انجام اقدام‌های اصلاحی، خطاهای طبقه‌بندی‌شده‌ی دریافتی از مرحله‌ی طبقه‌بندی، وارد مرحله‌ی اعتبارسنجی می‌شود. در مرحله‌ی اعتبارسنجی، به خطایی که در مرحله‌ی طبقه‌بندی تشخیص داده‌ایم، اعتباردهی می‌شود تا تصمیم‌گیری سیستم نسبت به هشدارهای کاذب^(۱) ناشی از صدای گذرا، داده‌ها، پرت یا خطای ارسال و دریافت و... دقیق‌تر شود.

در این مرحله ۱۰ نمونه‌ی پی‌درپی از سری داده‌های دریافتی به یک واحد حافظه^(۲) وارد می‌شود. سپس با ورود هر نمونه به حافظه، یک شمارنده، تعداد خطای مشابه متوالی در یک گام از فرایند را محاسبه می‌کند. در صورتی‌که مقدار این شمارنده، از حد آستانه فراتر رود، روی دادن آن نوع خطا در سیستم تأییدشده و آن نوع خطا برای انجام اقدام اصلاحی متناسب، به‌عنوان نتیجه‌ی خطای رخ‌داده‌ی سیستم اعلام می‌شود. نمایی کلی در شکل (۴) نشان داده‌شده است.

الگوریتم C4.5 نیز با قراردادن ۶۴۳۷۸ داده در طبقه‌ی صحیح خود، دقت ۹۹٫۹۵۰۳ درصد را در طبقه‌بندی نشان داد که نتیجه‌ی آن در جدول (۳) آورده شده است. بنابراین، با توجه با نتیجه‌های به‌دست‌آمده، الگوریتم C4.5 بهترین نتیجه را در شناسایی و دسته‌بندی داده‌های نرمال و خطا از خود نشان داده است.

جدول ۳ - نتیجه‌های الگوریتم C4.5

خطای دمایی بلادر نوع ۲	خطای دمایی بلادر نوع ۱	خطای فشار بلادر	خطای دمایی قالب	نرمال	پیش‌بینی واقعی
۲	۰	۰	۱	۵۵۰۵۴	نرمال
۱	۴	۴	۳۶۷۱	۱	خطای دمایی قالب
۲	۱	۳۰۴۱	۱	۳	خطای فشار بلادر
۳	۱۳۰۹	۰	۰	۰	خطای دمایی بلادر نوع ۱
۱۳۰۳	۹	۰	۰	۰	خطای دمایی بلادر نوع ۲

پیاده‌سازی عملی


گرفتن تصمیم‌های اصلاحی در برابر خطاهای طبقه‌بندی شده در سیستم

اقدام‌های اصلاحی که توسط اپراتور دستگاه‌های پرس پخت به‌کار گرفته می‌شود، بر مبنای نوع خطای رخ‌داده، دسته‌بندی می‌شود به‌طوری‌که اپراتور دستگاه با دیدن نوع خطا و مراجعه به جدول تصمیم‌های اصلاحی، فرایند پخت را اصلاح می‌کند

در اینجا نمونه‌ای از اقدام‌های اصلاحی در جدول (۴) نمایش داده‌شده است.

1. False Alarm

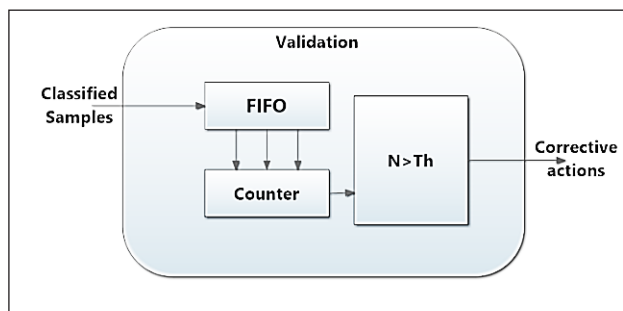
2. Memory



شکل ۵- اعمال نتیجه تصمیم به دستگاه پرس پخت

نتیجه‌گیری

در این مقاله با بررسی مشکلات کنترلی که ماشین‌های پرس پخت تایلر با آن روبه‌رو هستند، روشی برای حل این مشکل‌ها ارائه کردیم. ابتدا برخی از روش‌ها و رویکردهای خطایابی و طبقه‌بندی داده‌ها معرفی شد. سپس روش جمع‌آوری و تهیه داده‌ها برای به‌کارگیری در الگوریتم‌های طبقه‌بندی تشریح شد. نتیجه‌های الگوریتم‌های طبقه‌بندی روی داده‌های دریافتی از پرس پخت تایلر مورد ارزیابی قرار گرفت. در این ارزیابی، دیده شد که الگوریتم C4.5 عملکرد بهتری نسبت به اعمال روش‌های MLP و K-NN روی این نوع داده‌ها، از خود نشان می‌دهد. در نهایت روش ارزیابی و تأیید خطای رخ داده در سیستم، با استفاده از یک حافظه و پردازنده و مدارهای الکترونیکی تشریح شد *IRM*



شکل ۴- اتخاذ تصمیم اصلاحی

اعمال دستور اصلاحی به دستگاه

در نهایت تصمیم‌های اصلاحی که بر اساس موضوع‌های فنی و تجربه‌های کارشناسان جمع‌آوری و طبقه‌بندی شده است، درون حافظه‌ی پردازش‌گر قرار داده می‌شود. با تعیین نوع خطا در مرحله‌ی اعتبارسنجی، هویت خطای اعلام شده، به واحد پردازش‌گر منتقل می‌شود. پردازش‌گر با توجه به هویت خطا، به‌خانه‌ی حافظه‌ی متناظر با این نوع خطای سیستم، رجوع کرده و فرمان‌ها و دستورهای اصلاحی ثبت شده در آن را انتخاب و به فرایند در حال اجرا اعمال می‌کند. این رویه در شکل (۵) نمایش داده شده است.

مراجع

1. Pandya, M., R. N. Patel, and S. K. P. Amarnath, Determination of Time Delay and Rate of Temperature Change during Tyre Curing (Vulcanizing) Cycle. *Procedia Engineering*, 2013. 51: p. 828- 833.
2. Wang, Y., B. Su, and J. Wu, Simulation and optimization of giant radial tire vulcanization process. *Procedia Engineering*, 2012. 31: p. 723- 726.
3. Ghoreishy, M. H. R. and G. Naderi, Three dimensional finite element modelling of truck tyre curing process in mould. *Iranian Polymer Journal*, 2005. 14(8): p. 735- 743.
4. Guo, J. and H. Yang, A fault detection method for heat loss in a tyre vulcanization workshop using a dynamic energy consumption model and predictive baselines. *Applied Thermal Engineering*, 2015. 90: p. 711- 721.
5. Browne, A. L. and L. Wickliffe, Rubber emissivity and the thermal state of tires. *Tire Science and Technology*, 1979. 7(3): p. 71-89.

6. Schlanger, H., A one-dimensional numerical model of heat transfer in the process of tire vulcanization. *Rubber Chemistry and Technology*, 1983. 56(2): p. 304- 321.
7. Karaağaç, B., M. İnal, and V. Deniz, Predicting optimum cure time of rubber compounds by means of ANFIS. *Materials & Design*, 2012. 35: p. 833- 838.
8. Jokinen, J. and J. L. M. Lastra. Implementation of nonintrusive monitoring and fault diagnosis in industrial robot system. in 2016 IEEE 14th International Conference on Industrial Informatics (INDIN). 2016.
9. Lopez- Perez, D. and J. Antonino-Daviu, Application of infrared thermography to failure detection in industrial induction motors: case stories. *IEEE Transactions on Industry Applications*, 2017. PP(99): p. 1- 1.
10. Abdelgayed, T., W. Morsi, and T. Sidhu, A New Approach for Fault Classification in Microgrids Using Optimal Wavelet Functions Matching Pursuit. *IEEE Transactions on Smart Grid*, 2017. PP(99): p. 1- 1.
11. Ray, P., et al. Fault classification of a long transmission line using nearest neighbor algorithm and boolean indicators. in 2016 International Conference on Next Generation Intelligent Systems (ICNGIS). 2016.
12. Yu, H., S. Yin, and Y. Yunqiang. A data driven fault detection scheme design for nonlinear industrial systems. in IECON 2016- 42nd Annual Conference of the IEEE Industrial Electronics Society. 2016.
13. Isermann, R., Model-based fault-detection and diagnosis—status and applications. *Annual Reviews in control*, 2005. 29(1): p. 71- 85.
14. Castillo, I. and T. Edgar. Model Based Fault Detection and Diagnosis. in TWCCC Conference. 2008.
15. Isermann, R., Fault-diagnosis systems: an introduction from fault detection to fault tolerance. 2006: Springer Science & Business Media.
16. Jain, A.K., R. P. W. Duin, and M. Jianchang, Statistical pattern recognition: a review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000. 22(1): p. 4- 37.
17. Xia, F., et al. Research of condenser fault diagnosis method based on neural network and information fusion. in 2010 The 2nd International Conference on Computer and Automation Engineering (ICCAE). 2010.
18. Werbos, P.J., Backpropagation through time: what it does and how to do it. *Proceedings of the IEEE*, 1990. 78(10): p. 1550- 1560.
19. Oliveira- Santos, T., et al. Submersible Motor Pump Fault Diagnosis System: A Comparative Study of Classification Methods. in 2016 IEEE 28th International Conference on Tools with Artificial Intelligence (ICTAI). 2016.
20. Rajeswari, C., et al., A Gear Fault Identification using Wavelet Transform, Rough set Based GA, ANN and C4.5 Algorithm. *Procedia Engineering*, 2014. 97: p. 1831- 1841.
21. Budiman, F. N. and E.S. Wahyuni. Discrimination of particle-initiated defects in gas-insulated system using C4.5 algorithm. in 2016 3rd International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE). 2016.
22. Yasenjiang, J., et al. Fault mode prediction based on decision tree. in 2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC). 2016.
23. Lin, Y., et al. A method of satellite network fault synthetic diagnosis based on C4.5 algorithm and expert knowledge database. in 2015 International Conference on Wireless Communications & Signal Processing (WCSP). 2015.
24. Li, B., et al. A Scenario- Based Approach to Predicting Software Defects Using Compressed C4.5 Model. in 2014 IEEE 38th Annual Computer Software and Applications Conference. 2014.

S mart Controlling System for Process Monitoring, Fault Diagnosis and Defect Reduction in Tire Curing Machine

N. Parhizgar* and M.T. Dehghan-Khalili

Department of Electrical Engineering, Shiraz branch, Islamic Azad University, Shiraz, Iran

*Corresponding author Email: Parhizgar@iaushiraz.ac.ir

Received: April 2017, Revised: July 2017, Accepted: September 2017

Abstract: Curing the tire is the last manufacturing step in the tire industry. Process controlling in this step is very important. So, it is necessary to avoid any damage to the tire during curing. The old curing press machines have an open ring controlling system in which tire curing is controlled by a scheduled state. However, detecting any error during curing is possible just by the operator. This detection is done by checking the graphs drawn by the panel control of the machine. On time detection of errors may avoid material loss or reduction in material's quality. It is tried in this article to detect any possible errors by using fault finding algorithms and classification of curing process data in order not to have any loss of material or reduction in material's quality. Furthermore, the performance of K-NN, MLP and C4.5 algorithms is evaluated by using experimental data obtained from curing press machines. It was found that C4.5 algorithm has better performance than K-NN and MLP algorithms. The evaluation process and confirming the errors occurred in this system is investigated by a memory, a processor and electronic circuits. Finally, by comparing error detection systems, a solution is chosen for better performance of the machine.

Keywords: Smart control system, Fault detection, Process control, Curing press machine, K-NN, MLP and C4.5 Classification algorithms.