



کاربست فراترکیب (متاستز) در شناسایی روش های الگوریتم های مبتنی بر داده جهت عیب یابی فرآیند تولید پلی پروپیلین

سلیمان گل پور کنده

دانشجوی دکتری، گروه مدیریت صنعتی، واحد تهران مرکز، دانشگاه آزاد اسلامی، تهران، ایران
sgolpour@gmail.com

رضا رمضانی خورشید دوست

استادیار، گروه مهندسی صنایع و سیستم های مدیریت، دانشگاه صنعتی امیرکبیر، تهران، ایران
Email: ramazani@aut.ac.ir

محمد رضا کاباران زاده قدیم

دانشیار، گروه مدیریت، واحد تهران مرکز، دانشگاه آزاد اسلامی، تهران، ایران
Moh.kabaranzad@iauctb.ac.ir

تاریخ دریافت: ۱۴۰۲/۱۱/۰۸ * تاریخ پذیرش ۱۴۰۳/۰۲/۰۶

چکیده

این پژوهش به دنبال شناسایی روش های الگوریتم های مبتنی بر داده جهت عیب یابی فرآیند تولید پلی پروپیلین بوده است. محقق با استفاده از رویکرد مرور نظام مند و فراترکیب، به تحلیل نتایج و یافته های محققین قبلی پرداخت و با انجام گام های ۷ گانه روش ساندلوسکی و باروسو، به شناسایی عوامل مؤثر پرداخته است. از بین ۵۰۰ مقاله، ۳۴ مقاله بر اساس روش CASP انتخاب شد. در این زمینه به منظور سنجش پایایی و کنترل کیفیت، از شاخص کاپا برای ارزیابی شاخص های شناسایی شده استفاده شد که مقدار آن برای شاخص های شناسایی شده در سطح توافق عالی تشخیص داده شد. نتایج حاصل از تحلیل داده های گردآوری شده در نرم افزار ATLAS TI تحلیل شدند. بر اساس کدگذاری انجام شده، ۹ الگوریتم و تکنیک های مرتبط آنها شناسایی شدند. الگوریتم های شناسایی شده عبارتند از: مدل های ARIMA، الگوریتم های مبتنی بر دسته بندی، درختان تصمیم، شبکه های پویا بیز، مدل های هیبرید، الگوریتم های مبتنی بر نمونه، مدل های متغیر پنهان، شبکه های هوش مصنوعی و مدل های مبتنی بر قانون. حدود ۸۴ درصد از مطالعات انتخاب شده از تکنیک های یادگیری ماشین متعلق به یکی از چهار دسته استفاده کردند: درخت های تصمیم، شبکه های عصبی مصنوعی، مدل های ترکیبی و مدل های متغیر پنهان. راندمان محاسباتی نیز به عنوان یک مزیت مهم برای الگوریتم های یادگیری ماشین دیده می شود.

کلمات کلیدی: الگوریتم های مبتنی بر داده، هوش مصنوعی، عیب یابی فرآیند تولید پلی پروپیلین، متاستز (فراترکیب).

۱- مقدمه

تشخیص آنی عیوب و خرابی های مختلف در فرآیندهای صنعتی برای کاهش تلفات تولید و آسیب به تجهیزات امری ضروری است (Aldrini et al., 2023). سیستم مبتنی بر دانش حل شده و تکنیک های هوش مصنوعی، با استفاده از الگوریتم های یادگیری ماشین و شبکه های عصبی، قادر است داده های سنسورها و فرآیند را تحلیل کرده و با استفاده از مدل های پیش بینی و تشخیص، بهبودهای لازم را در فرآیندهای صنعتی اعمال کند. این سیستم قادر است با کاهش زمان های توقف و هزینه های تعمیر و نگهداری، به بهبود بهره وری و کارایی فرآیندهای صنعتی کمک کند و با استفاده از دانش حل شده و تکنیک های هوش مصنوعی، به صورت خودکار و زمان بندی شده، نظارت و کنترل بر روی فرآیندهای صنعتی را انجام دهد. این سیستم می تواند از داده های تاریخی و الگوهای فرآیندهای مشابه استفاده کرده و بهبودهای لازم را در فرآیندها پیشنهاد دهد و از وقوع مشکلات جلوگیری کند. به طور کلی، این سیستم می تواند باعث افزایش بهره وری، کاهش هزینه ها و افزایش کیفیت محصولات نهایی شود (Shen, 2023; Zhao et al., 2022).

با الگو گرفتن از تحقیق اخیر که توسط ریبریو جونیر و همکاران (۲۰۲۳) انجام شده است، در این پژوهش نیز رویکرد الگوریتم های مبتنی بر داده برای عیب یابی قواعد تشخیصی مورد بررسی قرار گرفته است. این تحقیق به بررسی عیب یابی صنعتی در فرآیند تولید پلی پروپیلن پرداخته و تأثیر آن بر زمان توقف ماشین و هزینه های تولید را مورد ارزیابی قرار داده است. این امر به طور مستقیم با توانایی شرکت های تولیدی برای رقابت از نظر هزینه، کیفیت و عملکرد مرتبط است. هدف اصلی این تحقیق عبور از تعمیر تجهیزات پس از خرابی آن بوده و به حفظ عملکرد ماشین آلات، کاهش خرابی ها و افزایش کیفیت تولید می پردازد. از این رو، عیب یابی و تشخیص آن شامل تشخیص زودهنگام خطاها می باشد (Liu et al., 2021).

در این سیستم، تحت یک برنامه عیب یابی پیش بینی کننده، با نظارت بر وضعیت واقعی ماشین آلات و شناسایی سطح معینی از خرابی، تعمیر یا تعویض قطعات انجام می شود. این رویکرد به جای انجام تعمیرات پس از وقوع خطا، اقدام به تعمیرات و تعویض قطعات می کند (Mobley, 2001; Sullivan et al., 2010). این رویکرد دارای چندین مزیت نسبت به راهبردهای عیب یابی واکنشی و پیشگیرانه است از جمله: پیشگیری از شکست های فاجعه بار، افزایش عمر مفید تجهیزات، بهینه سازی وظایف نگهداری پیشگیرانه، بهبود مدیریت موجودی تعمیر و نگهداری، بهینه سازی در دسترس بودن تجهیزات و افزایش کارایی تولید (O'Donovan et al., 2023; Naskos et al., 2019). با جلوگیری از بروز خطاهای جدی و کاهش خطاهای غیرمنتظره، تعمیر و نگهداری پیش بینی شده می تواند به حداکثر رساندن میانگین زمان بین خرابی ها (MTBF) کمک کند. این اقدام همچنین می تواند به کاهش حوادث محل کار و شدت آنها کمک کرده و تعداد تعمیرات و میانگین زمان تعمیر (MTTR) را کاهش داده و عمر مفید تجهیزات را افزایش دهد. این تحولات همه منجر به افزایش درآمد، کاهش هزینه های نگهداری و تولید، و تولید پایدارتر می شود (Ke et al., 2023).

عیب یابی پیش بینی کننده شکلی از عیب یابی مبتنی بر شرایط است که متکی بر پیش بینی و تشخیص عیب های اولیه در تجهیزات بر اساس اندازه گیری های پارامتری است که وضعیت واقعی ماشین را منعکس می کند (Linard et al., 2016). در عیب یابی مبتنی بر شرایط، تصمیم گیری توسط تکنیک های تشخیصی و پیش آگهی پشتیبانی می شود. تشخیص، که شامل انجام تشخیص و شناسایی خطا^۱ (FDI) است (Turkoglu et al., 2019) عموماً با استفاده از روش های سخت افزاری یا روش های تحلیلی انجام می شود. روش های سخت افزار شامل اندازه گیری پارامترهای یکسان با استفاده از بیش از یک حسگر و سپس مقایسه سیگنال های تکراری با استفاده از تکنیک های مختلف، مانند روش های پردازش سیگنال است (Avendano et al., 2021). روش های تحلیلی مبتنی بر مدل های ریاضی سیستم هستند و می توانند به روش های کمی یا مبتنی بر مدل و روش های کیفی یا داده محور تقسیم شوند. هر دو روش، پارامترهای پیش بینی شده یا برآورد شده را با مقادیر واقعی و اندازه گیری شده مقایسه می کنند، اما در حالی که روش های مبتنی بر مدل، پارامترهای مورد علاقه را بر اساس مدل ریاضی سیستم در

¹ Fault Detection And Identification

شرایط عملیاتی عادی تخمین می‌زنند، روش‌های مبتنی بر داده از داده‌های تاریخی و الگوریتم‌های هوش مصنوعی برای پیش‌بینی استفاده می‌کنند.

هدف پیش‌آگهی، تشخیص، شناسایی، جداسازی و دسته‌بندی عیوب در سیستم نظارت شده قبل از وقوع آنها است. به طور خاص، تکنیک‌های پیش‌آگهی برای تخمین مدت زمان برای تخمین مدت زمان - یعنی تخمین عمر مفید باقی‌مانده^۲ (RUL) - و احتمال وقوع خطا استفاده می‌شوند، اما بیشتر ادبیات پیش‌بینی ماشین بر روی نوع پیش‌بینی قبلی تمرکز دارد. هدف روش‌های تخمین RUL، که می‌توانند مبتنی بر داده نیز باشند، با پیش‌بینی مدت زمان عملکرد یک ماشین قبل از وقوع خطا است و سعی دارد پیش‌بینی نماید که آیا ماشین ممکن است در یک بازه زمانی معین از کار بیافتد. به دلیل عدم نیاز به سخت‌افزار اضافی، روش‌های افزونگی تحلیلی نسبت به روش‌های افزونگی سخت‌افزار برای پیاده‌سازی به هزینه کمتری دارند (Hwang et al., 2010). با توجه به ظهور فناوری‌های اینترنت اشیا (IoT) در محیط‌های صنعتی، اکنون می‌توان یک نمایش دیجیتال بلادرنگ از فرآیندهای تولید و وضعیت فعلی تجهیزات به دست آورد (Boyes et al., 2018)، که منجر به رشد تصاعدی حجم داده‌های صنعتی شده است (O'Donovan et al., 2015). روش‌های مبتنی بر داده، به‌ویژه تکنیک‌های یادگیری ماشین و داده‌کاوی، برای استخراج دانش از این انبوه داده‌ها مناسب هستند و در زمینه نگهداری پیش‌بینی‌کننده با موفقیت استفاده شده‌اند (Zhang et al., 2019). علاوه بر این، اگرچه روش‌های مبتنی بر مدل در صورت دقیق بودن مدل سیستم می‌توانند نتایج خوبی به همراه داشته باشند، ساخت یک مدل ریاضی دقیق از یک سیستم کار دشواری است که روش‌های مبتنی بر مدل را به گزینه‌ای کمتر برای سیستم‌های پیچیده تبدیل می‌کند (Hwang et al., 2010). مقالات مروری اخیر با تمرکز بر استفاده از تکنیک‌های یادگیری ماشین برای نگهداری، پیش‌بینی، شناسایی کرده‌اند که روش‌های متداول آنها مبتنی بر داده شامل شبکه‌های عصبی مصنوعی، (Hu et al., 2017; Mathew et al., 2017; Zhang et al., 2019; Carvalho et al., 2019)، ماشین‌های بردار پشتیبانی (Baptista et al., 2018; Susto et al., 2015)، درختان تصمیم (از جمله روش‌های مجموعه) (Canizo et al., 2017)، k-means (Uhlmann et al., 2018) و رگرسیون لجستیک (Yu, 2018) و غیره است.

تشخیص و پیش‌بینی عیوب در فرآیند تولید پلی‌پروپیلن، یک چالش است که نیازمند انتخاب دقیق روش‌های مناسب برای به دست آوردن نتایج دقیق می‌باشد. مطالعه حاضر مروری بر ادبیات سیستماتیک روش‌های یادگیری ماشینی مورد استفاده برای تشخیص عیوب مکانیکی و پیش‌آگهی عیوب در تجهیزات تولیدی در سناریوهای فرآیند تولید پلی‌پروپیلن انجام می‌دهد. این مطالعه به عنوان پایه‌ای برای اجرای سیستم‌های عیب‌یابی پیش‌بینی و کمک به شناسایی فرصت‌های تحقیقاتی آینده می‌باشد. بنابراین، این پژوهش به دنبال پاسخی برای این سؤال است که روش‌های الگوریتم‌های هوشمند جهت عیب‌یابی فرآیند تولید پلی‌پروپیلن براساس تکنیک‌های فراترکیب کدامند؟

الف) مروری بر ادبیات و پیشینه تحقیق

برای عیب‌یابی فرآیند تولید پلی‌پروپیلن، می‌توان از روش‌های مبتنی بر داده و الگوریتم‌های مختلفی استفاده کرد که در زیر به برخی از آنها اشاره شده است:

الگوریتم کنترل فرآیند چارت برای نظارت و کنترل فرآیند تولید استفاده می‌شود. این الگوریتم با استفاده از داده‌های جمع‌آوری شده در طول زمان، چارت‌های کنترل آماری رسم می‌کند (Kiangala et al., 2019). هرگونه انحراف ناهنجاری از حالت طبیعی را می‌توان با استفاده از این الگوریتم تشخیص داد. شبکه‌های عصبی مصنوعی می‌توانند برای تشخیص و پیش‌بینی عیوب در فرآیند تولید پلی‌پروپیلن مورد استفاده قرار بگیرند. این شبکه‌ها با استفاده از داده‌های آموزش داده شده، الگوهای عیب‌ها را یاد می‌گیرند و در زمان وقوع عیب‌های جدید، آنها را تشخیص می‌دهند (Xie et al., 2022). همچنین، از روش‌های کاوش داده می‌توان برای شناسایی الگوها و روابط پنهان در داده‌های فرآیند تولید پلی‌پروپیلن استفاده کرد. به عنوان مثال، الگوریتم‌های خوشه‌بندی و تحلیل عاملی می‌توانند به تحلیل و تفسیر داده‌های بزرگ کمک کنند و الگوهای ناهنجاری را

² Remaining Useful Life

شناسایی کنند. از الگوریتم های یادگیری ماشین می توان برای عیب یابی فرآیند تولید پلی پروپیلن استفاده کرد. مثلاً، الگوریتم های کلاس بندی می توانند برای تشخیص و دسته بندی عیوب استفاده شوند. همچنین، الگوریتم های تشدید کننده^۳ و الگوریتم های درخت تصمیم نیز ممکن است در عیب یابی مؤثر باشند (Chang et al., 2022).

الگوریتم های خوشه بندی برای تقسیم داده ها به گروه های مشابه بر اساس شباهت های آن ها استفاده می شوند. با استفاده از الگوریتم های خوشه بندی، می توان عیب ها را در گروه های مختلف دسته بندی کرده و الگوهای آن ها را شناسایی کرد. این فقط چند مثال از روش های الگوریتمی هستند که می توان برای عیب یابی فرآیند تولید پلی پروپیلن استفاده کرد. بر اساس ماهیت و خصوصیات داده ها و سیستم تولید، ممکن است روش ها و الگوریتم های دیگری نیز مناسب باشند. همچنین، ترکیب چندین روش و الگوریتم با یکدیگر نیز می تواند بهبود و دقت عیب یابی را افزایش دهد (Fernandes et al., 2022). در بررسی تحقیقات انجام شده در این زمینه لائو و همکاران^۴ (۲۰۱۰)، در یک شبیه سازی نشان دادند که روش پیشنهادی به طور مؤثر انواع خطاها و شدت های مختلف را تشخیص می دهد و در مقایسه با رویکرد آماری چند متغیره مرسوم بر اساس تحلیل مؤلفه های اصلی (PCA) عملکرد بهتری دارد. این روش برای نظارت در سطح کارخانه قابل استفاده است و می تواند به عنوان یک سیستم هشدار اولیه عمل کند که وظیفه آن شناسایی اختلالات فرآیندی است که می تواند عملیات فرآیند را از قبل تهدید نماید. روبریو جونیر و همکاران (۲۰۲۳)، نشان دادند تشخیص عیب در تولید پلی پروپیلن می تواند با استفاده از تکنیک های یادگیری ماشین و هوش مصنوعی صورت بگیرد. یک رویکرد متداول برای تشخیص عیب، استفاده از الگوریتم های یادگیری نظارت شده انجام می شود. در این روش، یک مدل شبکه عصبی با استفاده از داده های آموزشی که شامل ویژگی های مربوط به تولید پروپولین و برجسب های عیب می باشد، آموزش داده می شود.

شن (۲۰۲۳)، الگوریتم ژنتیک را روشی مطمئن در تشخیص عیب فرآیند تولید نشان داد. بنابراین شناسایی تکنیک های مبتنی بر داده برای تشخیص عیب در تولید پلی پروپیلن حائز اهمیت است. استفاده از روش های مبتنی بر داده در فرآیند تولید پلی پروپیلن می تواند بهبود کیفیت محصول نهایی را به دنبال داشته باشد. با تحلیل داده های مربوط به فرآیند تولید، می توان عوامل مختلفی که بر کیفیت تولید تأثیر می گذارند را شناسایی و بهینه سازی کرد. این امر شامل پارامترهای فرآیند مانند دما، فشار، زمان، نسبت های مواد و سایر عوامل مرتبط است. با کنترل و بهینه سازی این عوامل، می توان کیفیت پلی پروپیلن را بهبود بخشید و محصولات با خصوصیات مطلوب تولید کرد. همچنین استفاده از روش های مبتنی بر داده در فرآیند تولید پلی پروپیلن می تواند به کاهش هزینه ها کمک کند. با تحلیل دقیق داده های تولید، می توان به شناسایی مشکلات و عیوب در فرآیند پرداخت و آن ها را رفع کرد. این به معنای کاهش ضایعات، افزایش بازدهی، کاهش زمان تولید و بهبود کارایی فرآیند است. همچنین، با بهره گیری از تحلیل پیشرفته داده ها، می توان بهینه سازی مصرف انرژی و مواد را نیز مدنظر قرار داد. در نهایت با استفاده از روش های مبتنی بر داده، می توان عیوب و مشکلات پتانسیل در فرآیند تولید پلی پروپیلن را پیش بینی کرده و بهبود آن ها را در مراحل ابتدایی فرآیند انجام داد. با تحلیل داده های تاریخی و شناسایی الگوهای مربوطه، می توان از عیب ها پیش از وقوع آن ها آگاه شد و اقدامات پیشگیرانه انجام داد.

نوآوری تحقیق حاضر را میتوان از چند جنبه مورد توجه قرارداد: اول، روش متاستز که شامل یکپارچه سازی و ترکیب یافته ها از مطالعات متعدد برای شناسایی روش های الگوریتم های مبتنی بر داده برای رفع اشکال در فرآیند تولید پلی پروپیلن است. این رویکرد امکان درک جامع و کلانی از موضوع را با بهره گیری از یک دامنه گسترده از تحقیقات موجود فراهم می کند. دوم، تمرکز بر الگوریتم های مبتنی بر داده برای رفع اشکال در فرآیند تولید پلی پروپیلن نشان دهنده یک رویکرد نوآورانه به حل مسائل در صنعت تولید است. این نشان می دهد که گام های مهمی در این صنعت به سمت استفاده از تکنیک های پیشرفته تحلیل داده و یادگیری ماشین برای بهبود کارایی فرآیند و شناسایی مسائل پتانسیلی برداشته شده است. سوم، عیب یابی در صنعت تولید پلی پروپیلن به عنوان یک مشکل خاص و عملی در فرآیند تولید مطرح است و این تحقیق می تواند با شناسایی روش های مؤثر رفع اشکال، پتانسیل تأثیر مستقیم بر کارایی و بهره وری تولید پلی پروپیلن را فراهم نماید. همچنین تأکید بر شناسایی روش های

³ Boosting Algorithms

⁴ Lau et al.

خاص الگوریتم‌های مبتنی بر داده برای رفع اشکال به توسعه ابزارها و تکنیک‌های عملی برای کاربران صنعتی مفید است. هدف این تحقیق ارایه بینش‌ها و پیشنهادات قابل اجرا برای بهبود فرآیند رفع اشکال در تولید پلی‌پروپیلین است. به طور کلی، استفاده از روش متاستز، تمرکز بر الگوریتم‌های مبتنی بر داده و ارتباط عملی رفع اشکال در تولید پلی‌پروپیلین نشان‌دهنده نوآوری‌های این تحقیق است.

۲- روش‌شناسی پژوهش

پژوهش حاضر از نظر اینکه به دنبال شناسایی روش‌های مبتنی بر داده جهت عیب‌یابی فرآیند تولید پلی‌پروپیلین مبتنی بر رویکرد فراترکیب است. از نظر رویکرد کلی مطالعه‌ای کیفی بوده و با روش تحقیق کتابخانه‌ای، با تکنیک فراترکیب در حوزه روش‌های مبتنی بر داده صورت گرفته است. یکی از روش‌هایی که برای بررسی، ترکیب و آسیب‌شناسی پژوهش‌های قبل در چند سال گذشته معرفی شده است، فرامطالعه^۵ است. فرامطالعه شامل چهار قسمت اصلی است که عبارت‌اند از: فرا تحلیل^۶ (تحلیل کمی محتوای ابتدایی)، فراروش^۷ (تحلیل روش‌شناسی مطالعات ابتدایی)، فرا نظری^۸ (تحلیل نظریه‌های مطالعات ابتدایی) و فراترکیب (تحلیل کیفی محتوای مطالعات ابتدایی). فراترکیب یکی از انواع روش‌های زیرمجموعه فرامطالعه است که از طریق مرور نظام-مند منابع برای استخراج، ارزیابی، ترکیب و در صورت نیاز، جمع‌بندی آماری تحقیقاتی می‌پردازد که قبلاً پیرامون یک حیطه موضوعی خاص به انجام رسیده‌اند. به‌واقع در فراترکیب اطلاعات و یافته‌های استخراج شده از مطالعات دیگر با موضوع مرتبط و مشابه موردبررسی و تحلیل قرار می‌گیرد. در این زمینه داده‌های از این مطالعات به‌صورت کیفی گردآوری می‌شود. در نتیجه نمونه موردنظر براساس روش فراترکیب، انتخاب شده و ارتباط آن‌ها با سؤال پژوهش تبیین می‌شود. روش فراترکیب فقط شامل مرور یکپارچه اصول کیفی یا تجزیه‌وتحلیل داده‌های اصلی و ثانویه از مطالعات منتخب نیست، بلکه تحلیل یافته‌های این مطالعات است. به عبارتی فراترکیب، ترکیب تفسیرهای داده‌های اصلی مطالعات منتخب است. به‌منظور تحلیل داده‌ها از نرم‌افزار ATLAS TI استفاده شده است. مراحل اصلی فراترکیب برگرفته از نظر سندلوسکی و باروسو^۹ (۲۰۰۷) به شرح شکل شماره یک است:



⁵ Meta-Study

⁶ Meta-Analysis

⁷ Meta-Method

⁸ Meta-Theory

⁹ Sandelowski and Barroso

شکل شماره (۱): فرایند انجام فراترکیب

۳- بحث و نتایج

همان گونه که ذکر شد، تحلیل فراترکیب دربردارنده هفت گام است. در این بخش نتایج مربوط به هر یک از گام های این تحلیل به صورت جداگانه ارائه می شود.

(الف) مرحله اول: تنظیم سؤالات اساسی پژوهش

نخستین گام درروش سندولوسکی و باروسو، تنظیم پرسش های پژوهش است. این پرسش ها عموماً بر اساس چهار پارامتر چه چیزی، چه کسی، چه زمانی و چگونه؛ قابل تنظیم است. پس از آنکه سؤالات پژوهش بر اساس هدف پژوهش تنظیم شد مرحله بررسی نظام مند متون آغاز می شود. جدول شماره ۱ به پرسش های بنیادین و اساسی مربوط به روش فراترکیب پاسخ می دهد:

جدول شماره (۱): سؤالات اساسی پژوهش

پارامتر	پرسش پژوهش
چه چیزی (What)	شناسایی شناسایی روش های الگوریتم ژنتیک ترکیبی جدید جهت عیب یابی فرآیند تولید پلی پروپیلین براساس کلید واژه های مشخص شده
چه کسی (Who)	آثار مختلف اعم از کتاب، مقاله، گزارش در زمینه شناسایی روش های الگوریتم ژنتیک ترکیبی جدید جهت عیب یابی فرآیند تولید پلی پروپیلین
چه وقت (When)	دربگیرنده تمامی آثار در سال های ۲۰۰۰ تا ۲۰۲۳
چگونه (How)	بررسی موضوعی، شناسایی و یادداشت برداری، نکته های کلیدی، تحلیل مفاهیم

(ب) مرحله دوم: بررسی نظام مند متون

برای گردآوری داده های پژوهش از داده های ثانویه به نام اسناد و مدارک گذشته استفاده می شود. همان گونه که پیشتر بیان گردید، پایگاه های پژوهشی موردنظر در این پژوهش، دو پایگاه معتبر Scopus و Web of Science بوده که در این دو پایگاه بر مجموعه پایگاه های انتشاراتی زیر تمرکز ویژه ای گردید:

Emerald insight- Springer Link- Science Direct- Taylor & Francis Online- SAGE journals- Wiley Online Library

به علاوه در زمینه مقالات فارسی نیز پایگاه مرکز اطلاعات علمی جهاد دانشگاهی و پرتال جامع علوم انسانی موردتوجه قرار گرفت.

(ج) مرحله سوم: جستجو و انتخاب متون

در جدول ۳ گام های طی شده به منظور پالایش مقالات استخراج شده مشاهده می گردد. مبتنی بر این جدول به منظور پالایش مقالات مستخرج از ادبیات، چهار مرحله طی گردید که مرحله آخر مبتنی بر نظرات ۵ خبره ناظر در این پژوهش بود. این خبرگان به منظور سنجش کیفیت نهایی مقالات مبتنی بر رویکردی که در ادامه معرفی می گردد، نظرات خود را برای هر مقاله نهایی غربال شده ارائه نموده و مقالاتی که امتیاز پایین تری از حدنصاب اعمال شده کسب نموده بودند، از فرایند حذف شدند.

مطالعات اولیه انتخاب شده از انواع الگوریتم ها و روش های یادگیری ماشین برای انجام تشخیص عیب مکانیکی و پیش بینی خطا، از جمله ترکیبی از الگوریتم های مختلف، استفاده می کنند. اکثر مطالعات همچنین تجزیه و تحلیل های مقایسه ای بین الگوریتم های مختلف یادگیری ماشین را برای نشان دادن ارزش روش پیشنهادی یا انتخاب مناسب ترین الگوریتم انجام می دهند. در مورد دوم، تنها الگوریتم های انتخاب شده (یا بهترین عملکرد) در این بررسی توضیح داده خواهند شد. این الگوریتم ها عبارتند از: AdaBoost؛ خوشه بندی تجمعی^{۱۰} (AC)؛ رمزگذار خودکار؛ میانگین متحرک یکپارچه اتورگرسیو^{۱۱} (ARIMA)؛ شبکه عصبی پس انتشار^{۱۲} (BPNN)؛ درختان طبقه بندی و رگرسیون^{۱۳} (CART)؛ طبقه بندی بر اساس انجمن ها - الگوریتم ساخت طبقه بندی کننده^{۱۴} (CBA-CB). شبکه عصبی کانولوشن^{۱۵} (CNN)؛ شبکه عصبی عمیق^{۱۶} (DNN)؛ خوشه بندی فضایی

¹⁰ agglomerative clustering

¹¹ autoregressive integrated moving average

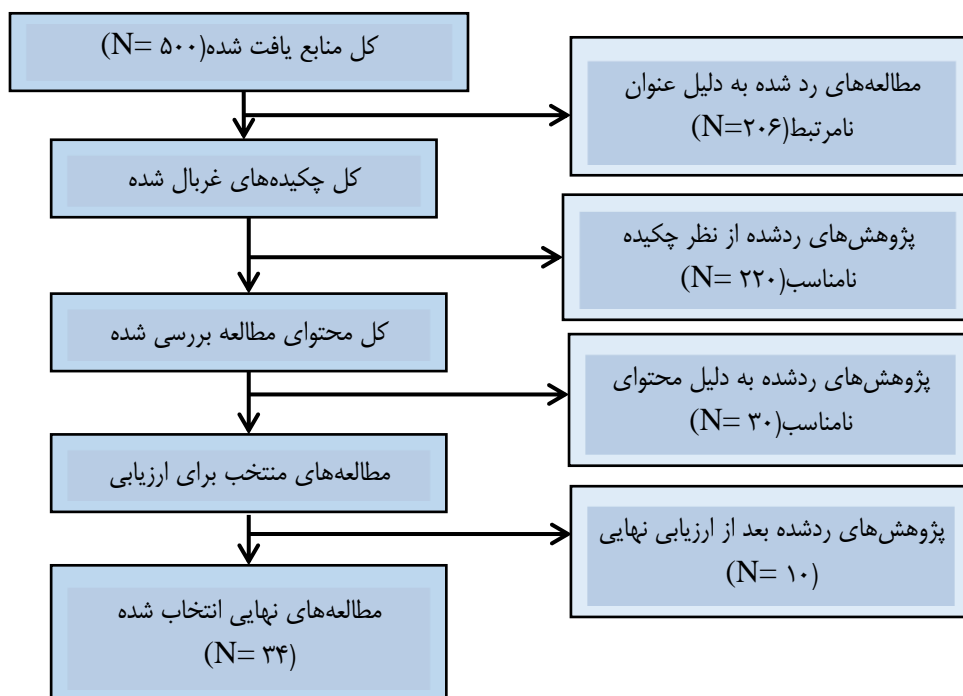
¹² back-propagation neural network

¹³ lassification and regression trees

¹⁴ classification based on associations - classifier building algorithm

مبتنی بر چگالی برنامه‌های کاربردی با نویز^{۱۷} (DBSCAN). فیلتر گسسته بیز^{۱۸} (DBF); سیستم طبقه بندی گسترده^{۱۹} (XCS); رشد الگوی مکرر^{۲۰} (FP-Growth); مدل‌های مخلوط گاوسی^{۲۱} (GMM); درختان تصمیم تقویت کننده گرادیان^{۲۲} (GBDT); مدل مارکوف پنهان^{۲۳} (HMM); خوشه بندی سلسله مراتبی^{۲۴} (HC); جنگل ایزوله^{۲۵} (IF); k-means; خوشه بندی سری‌های زمانی چند بعدی^{۲۶} k (K-MDTSC). K-نزدیک‌ترین همسایه^{۲۷} (K-NN); تجزیه مقدار مفرد^{۲۸} k (K-SVD); عامل پرت محلی^{۲۹} (LOF); رگرسیون لجستیک^{۳۰} (LR); حافظه کوتاه مدت بلند مدت^{۳۱} (LSTM); رمزگذار خودکار LSTM; حافظه کوتاه مدت بلند مدت - شبکه متخاصم مولد^{۳۲} (LSTM-GAN); خوشه بندی میانگین شیف^{۳۳} (MSC); شناسایی نقاط دورافتاده پیوسته میکرو خوشه‌ای^{۳۴} (MCOD); پرسپترون چند لایه^{۳۵} (MLP); بیز ساده^{۳۶} (NB); تجزیه و تحلیل اجزای همسایگی^{۳۷} (NCA); رگرسیون حداقل مربعات جزئی^{۳۸} (PLSR); تجزیه و تحلیل اجزای اصلی^{۳۹} (PCA); تجزیه و تحلیل تفکیک درجه دوم^{۴۰} (QDA); الگوریتم استخراج قانون انجمن کمی^{۴۱} (QARMA); جنگل تصادفی^{۴۲} (RF); جنگل بقا تصادفی^{۴۳} (RSF); شبکه عصبی مکرر^{۴۴} (RNN); رگرسیون خطی ساده خوشه بندی طیفی^{۴۵} (SC); رمزگذارهای خودکار پراکنده^{۴۶} (SSAE); ماشین‌های بردار پشتیبانی^{۴۷} (SVM).

-
- 15 convolutional neural network
 - 16 deep neural network
 - 17 density-based spatial clustering of applications with noise
 - 18 discrete Bayes filter
 - 19 eXtended classifier system
 - 20 frequent pattern growth
 - 21 Gaussian mixture models
 - 22 gradient boosting decision trees
 - 23 hidden Markov model
 - 24 hierarchical clustering
 - 25 isolation forest
 - 26 K-multi-dimensional time-series clustering
 - 27 k-nearest neighbors
 - 28 k-singular value decomposition
 - 29 local outlier factor
 - 30 logistic regression
 - 31 long short-term memory
 - 32 long short-term memory - generative adversarial network
 - 33 mean shift clustering
 - 34 micro-cluster continuous outlier detection
 - 35 multilayer perceptron
 - 36 naïve Bayes
 - 37 neighbourhood component analysis
 - 38 partial least squares regression
 - 39 principal component analysis
 - 40 quadratic discriminant analysis
 - 41 quantitative association rule mining algorithm
 - 42 random forest
 - 43 random survival forest
 - 44 recurrent neural network
 - 45 simple linear regression; spectral clustering
 - 46 stacked sparse autoencoders
 - 47 support vector machines



شکل شماره (۲): فرایند بازمینی و انتخاب

در این گام ۵۰۰ مطالعه یافت شده در گام قبل به طور دقیق طی چند مرحله مورد بازمینی قرار می گیرند تا مطالعاتی که با سؤالات پژوهش متناسب نیستند کنار گذاشته شوند و در نهایت مرتبط ترین مطالعات برای استخراج پاسخ سؤالات مشخص گردند. فرآیند بازمینی شامل بررسی عنوان، چکیده و محتوای پژوهش ها به همراه روش تحقیق مطالعات است. مراحل فرآیند بازمینی در این پژوهش به شرح زیر است:

- در این مرحله عنوان مطالعات بررسی شده و مطالعاتی که ارتباطی با سؤالات پژوهش نداشتند، کنار گذاشته شدند. با بررسی عنوان مطالعات، ۲۰۶ مطالعه به دلیل عدم ارتباط عنوانشان با سؤالات پژوهش کنار گذاشته شدند.
- در این مرحله، چکیده مطالعات بررسی شده و مطالعاتی که با سؤالات پژوهش ارتباطی نداشتند، کنار گذاشته شدند. با مطالعه چکیده مطالعات، ۲۲۰ مطالعه به دلیل عدم ارتباط چکیده با سؤالات پژوهش کنار گذاشته شدند.
- در این مرحله محتوای مطالعات بررسی شدند، به عبارتی کل پژوهش مطالعه شده و مطالعاتی که ارتباطی با سؤالات پژوهش نداشتند، کنار گذاشته شدند. با بررسی محتوای مطالعات، ۳۰ مطالعه غیر مرتبط با سؤالات پژوهش کنار گذاشته شدند.
- از آنجایی که این پژوهش قصد دارد با استفاده از ترکیب مطالعات گذشته، چارچوب تحقیق را استخراج کند، مطابق با نظر متخصصان فراترکیب مطالعات با روش تحقیق های کیفی و کمی مورد بررسی قرار می گیرند. لذا در این مرحله مطالعه ای به دلیل روش تحقیق حذف نگردیده است.

پس از حذف مطالعات نامتناسب با اهداف و سؤالات پژوهش، محقق کیفیت روش شناختی پژوهش ها را ارزیابی می نماید. هدف از این گام حذف پژوهش هایی است که محقق به یافته های ارائه شده در آنها اعتمادی ندارد. ابزاری که معمولاً برای ارزیابی کیفیت مطالعات اولیه تحقیق کیفی استفاده می شود «برنامه مهارت های ارزیابی حیاتی» است که با طرح ده سؤال کمک می کند تا دقت، اعتبار و اهمیت مطالعات کیفی تحقیق مشخص گردد. این سؤالات بر موارد زیر تمرکز دارند: ۱. اهداف تحقیق ۲. منطق روش - شناسی ۳. طرح تحقیق ۴. روش نمونه برداری ۵. جمع آوری داده ها ۶. انعکاس پذیری (که به رابطه بین محقق و مشارکت کنندگان اشاره دارد) ۷. ملاحظات اخلاقی ۸. دقت تجزیه و تحلیل داده ها ۹. بیان واضح و روشن یافته ها ۱۰. ارزش تحقیق.

جدول شماره (۲): مقالات منتخب

مجموع امتیازات	نویسنده	سال	عنوان	کد مقاله
۴۰	Shen	۲۰۲۳	Genetic algorithm based production knowledge base for mechanical fault detection model	S01
۳۵	Zhou et al	۲۰۰۱	Diagnosis Based on Genetic Algorithms and Fuzzy Logic in NPPs	S02
۳۹	Xiao et al	۲۰۱۵	Optimization scheme of genetic algorithm and its application on aeroengine fault diagnosis	S03
۴۰	Gao et al	۲۰۱۸	Intelligent methods for the process parameter determination of plastic injection molding	S04
۳۹	Zhao et al	۲۰۲۲	Recent progress in minimizing the warpage and shrinkage deformations by the optimization of process parameters in plastic injection molding: a review	S05
۴۴	Armenise et al	۲۰۲۱	Application of computational approach in plastic pyrolysis kinetic modelling: a review	S06
۳۴	Chang et al.	۲۰۲۲	Non-Dominant Genetic Algorithm for Multi-Objective Optimization Design of Unmanned Aerial Vehicle Shell Process	S07
۳۲	Tayyebi	۲۰۱۵	Multiple-Fault Diagnosing System Based on Fuzzy-Genetic Algorithm for the Production of Toluene from n-Heptane	S08
۳۳	Lau et al	۲۰۱۰	Fault diagnosis of the polypropylene production process (UNIPOL PP) using ANFIS	S09
۳۷	Zhang et al	۱۹۹۰	Fault diagnosis of a mixing process using deep qualitative knowledge representation of physical behaviour	S10
۳۷	Liu et al	۲۰۲۲	Fault Diagnosis Using Dynamic Principal Component Analysis and GA Feature Selection Modeling for Industrial Processes	S11
۳۳	PENG et al	۲۰۱۳	Study and Application of Case-based Extension Fault Diagnosis for Chemical Process	S12
۳۵	Xie et al	۲۰۲۲	Research on fault detection and identification methods of nonlinear dynamic process based on ICA for active queue management.	S13
۳۳	Ribeiro Junior et al	۲۰۲۳	On the Use of Machine Learning for Damage Assessment in Composite Structures: A Review	S14
۳۸	Ke et al	۲۰۲۳	Multi-quality prediction of injection molding parts using a hybrid machine learning model	S15
۳۹	Niknam et al	۲۰۱۷	Techniques of trend analysis in degradation-based prognostics	S16
۳۷	Srinivasan	۲۰۰۷	Artificial intelligence methodologies for agile refining: an overview	S17
۴۴	Leiviskä	۲۰۰۵	Problem Definition — From Applications to Methods	S18
۴۰	O'Donovan et al	۲۰۲۳	Ladle pouring process parameter and quality estimation using Mask R-CNN and contrast-limited adaptive histogram equalisation	S19
۳۷	Aldrini et al	۲۰۲۳	fault diagnosis and self-healing for smart manufacturing	S20
۳۸	Fernandes et al	۲۰۲۲	Machine learning techniques applied to mechanical fault diagnosis and fault prognosis in the context of real industrial manufacturing use-cases: a systematic literature review	S21
۳۵	Mobley	۲۰۱۰	Predictive Maintenance. In: Plant Engineer's Handbook	S22
۴۵	Fernandes et al	۲۰۲۰	Fault detection mechanism of a predictive maintenance system based on autoregressive integrated moving average models	S23
۳۳	Mohan et al.	۲۰۲۱	Intelligent machine learning based total productive maintenance approach for achieving zero downtime in industrial machinery	S24
۳۹	Naskos et al.	۲۰۱۹	Detecting anomalous behavior towards predictive maintenance	S25

کد مقاله	عنوان	سال	نویسنده	مجموع امتیازات
S26	Knowledge elicitation for fault diagnostics in plastic injection moulding: A case for machine-to-machine communication	۲۰۱۷	Vrabič et al.	۳۵
S27	Towards Adaptive Scheduling of Maintenance for Cyber-Physical Systems	۲۰۱۶	Linard et al	۳۳
S28	Forecasting faults of industrial equipment using machine learning classifiers	۲۰۱۸	Kolokas et al.	۴۴
S29	Application of Data Mining in Failure Estimation of Cold Forging Machines: An Industrial Research	۲۰۱۹	Turkoglu et al	۴۵
S30	A novel predictive maintenance method based on deep adversarial learning in the intelligent manufacturing system	۲۰۲۱	Liu et al	۴۳
S31	A deep learning model for predictive maintenance in cyber-physical production systems using lstm autoencoders	۲۰۲۱	Bampoula et al.	۴۳
S32	Anomaly detection and event mining in cold forming manufacturing processes	۲۰۲۱	Avendano et al.	۳۵
S33	Time Series Data for Equipment Reliability Analysis With Deep Learnin	۲۰۲۰	Chen et al	۳۹
S34	An effective predictive maintenance framework for conveyor motors using dual time-series imaging and convolutional neural network in an industry 4.0 environment	۲۰۲۰	Kiangala et al	۴۱

(د) مرحله چهارم: استخراج اطلاعات

این مرحله شامل مرور مقالات باقیمانده و استخراج متون به منظور کدگذاری در مرحله بعد است. این گام متمرکز بر تفکیک نتایج و خروجی‌ها و تفاسیر این خروجی‌ها در کنار بحث و نتیجه‌گیری نهایی پژوهشگران است. در این مرحله ۳۴ مقاله وارد نرم‌افزار TI ATLAS گردیده و به منظور بررسی اولیه به صورت پراکنده و گزینشی بخشی‌هایی از مقالات مطالعه و کدگذاری‌های تصادفی و پراکنده صورت گرفت تا مرحله آشنایی پژوهشگر با داده‌های موجود طی گردد. بدین ترتیب پژوهشگر با کلیات بحث و فضای حاکم بر آن آشنا گردید. از ۳۴ مطالعه انتخاب شده، دلایل استفاده یک الگوریتم یادگیری ماشینی خاص یا ترکیبی از الگوریتم‌ها را شرح دادند. برخی از این انگیزه‌ها به نقاط قوت ذاتی الگوریتم‌های به کار گرفته شده متکی بودند، در حالی که برخی دیگر مزایای خاصی را در نظر گرفتند که یک الگوریتم می‌تواند برای تشخیص و پیش‌بینی خطا یا برای اجرای آن در محیط‌های صنعتی مانند تولید پلی پروپیلین داشته باشد.

(ه) گام پنجم: تجزیه و تحلیل یافته‌های کیفی

در طول تجزیه و تحلیل، پژوهشگر موضوعاتی را مورد جستجو قرار می‌دهد که در میان مطالعه‌های موجود در فراترکیب پدیدار شده است. این مورد به عنوان (بررسی موضوعی) شناخته می‌شود. به محض اینکه موضوع‌ها شناسایی و مشخص شد، بررسی کننده، طبقه‌بندی‌ای را شکل می‌دهد و طبقه بندی‌های مشابه و مربوط را در موضوعی قرار می‌دهد که آن را به بهترین گونه توصیف می‌کند. موضوع‌ها اساس و پایه ایجاد توضیحات، الگوها و نظریه‌ها یا فرضیات را ارائه می‌کند. در این پژوهش، ابتدا تمام عوامل استخراج شده از مطالعه‌ها به عنوان شناسه در نظر گرفته شده و سپس با در نظر گرفتن معنای هر یک از آنها، شناسه‌ها در مفهومی مشابه تعریف شد. سپس مفاهیم مشابه در مقولات تبیین کننده دسته‌بندی گردید تا به این ترتیب محورهای تبیین کننده شاخص‌های پژوهش در قالب مؤلفه‌های اصلی و فرعی پژوهش شناسایی شود.

منبع	تکنیک	الگوریتم
S2, S3, S4, S5, S6, S7, S8, S10, S11	ARIMA	مدل‌های ARIMA
S23, S25, S26, S30, S33	MCOD	الگوریتم‌های مبتنی بر پارتیشن
S2, S4, S5, S6, S19, S20, S21, S22, S25, S27, S30, S31, S32, S33	Adaboost, CART, IF, RF, RSF, GBDT	درختان تصمیم
S12, S13, S16, S19	DBF, HMM	شبکه‌های پویا بیز
S16, S17, S20, S22, S30	ARIMA + LSTM DBSCAN + RF DBSCAN + SVM [HC / time series clustering] + RNN One-class SVM + K-Means + RF Autoencoder + Simple Linear Regression GMM + FP-Growth + CBA-CB CNN + NCA + Medium Gaussian SVM / CNN + NCA + ensemble subspace K-NN	مدل‌های هیبریدی
S3, S14, S1	K-NN	الگوریتم‌های مبتنی بر نمونه
S7, S8, S19, S20, S21, S22, S24, S25, S32, S33	PCA, GMM, K-MEANS, PLSR, K-SVD, K-MDTSC	مدل‌های متغیر پنهان
S1, S9, S14, S15, S17, S18, S19, S20, S21, S24, S27, S28, S29, S30, S31, S32, S33	ANN, BPNN, CNN, DNN, LSTM, MLP, SSAE+PBNN, SSAE+Softmax Classifier, LSTM Autoencoder, LSTM – GAN, RNN, Conditional Variational Autoencoder	شبکه‌های هوش مصنوعی
S1, S4, S5, S6, S9, S10	R4RE (“Rules 4 Rare Events” based on QARMA), XCSR	مدل‌های مبتنی بر قانون

(و) گام ششم: کنترل کیفیت خروجی‌ها

(ز) گام هفتم: جمع‌بندی نهایی

در این مرحله از روش فراترکیب، یافته‌های مراحل قبل ارائه می‌شود. در ادامه به شناسایی شاخص‌های پژوهش پرداخته می‌شود. از شاخص‌های استخراج‌شده از متون مقالات مرتبط، با حذف شاخص‌های هم‌معنی و پرتکرار و درنهایت با مقوله و دسته‌بندی شاخص‌های نهایی، ۹ الگوریتم و تکنیک‌های مرتبط حاصل گردید. در این مرحله از کدگذاری، مقوله‌های اصلی و فرعی پژوهش مشخص شدند.

پس از شناسایی شاخص‌های پژوهش براساس تحلیل فراترکیب و تعیین واحدهای تحلیل (کلمه‌ها و مضامین)، از روش آنتروپی شانون برای تحلیل داده‌ها به صورت زیر استفاده شد:

ابتدا فراوانی هر یک از مقوله های شناسایی شده براساس تحلیل محتوا مشخص گردید. ماتریس فراوانی های مورد نظر به هنجار شد. برای این منظور از روش نرمال سازی خطی استفاده گردید: رابطه شماره (۱):

$$n_{ij} = \frac{x_{ij}}{\sum x_{ij}}$$

از رابطه زیر برای محاسبه بار اطلاعاتی هر مقوله استفاده شد: رابطه شماره (۲):

$$k = \frac{1}{\ln(a)}; a = \text{تعداد گزینه ها}$$

$$E_j = -k \sum [n_{ij} \ln(n_{ij})]$$

ضریب اهمیت هر مقوله محاسبه گردید. هر مقوله که دارای بار اطلاعاتی بیشتری است، از درجه اهمیت بیشتری برخوردار است. برای این منظور از رابطه زیر استفاده گردید: رابطه شماره (۳):


$$W_j = \frac{E_j}{\sum E_j}$$

بنابراین در گام نخست ماتریس تصمیم تشکیل شده است. امتیازات بدست آمده از ماتریس تصمیم پیرامون مساله مورد نظر در جدول شماره ۵ ارائه شده است:

جدول شماره (۵): تعیین میزان اهمیت و تأکید پژوهشهای گذشته

رتبه	Wj	ضریب اهمیت	Ej	عدم اطمینان	$\sum P_{ij} \times knP_{ij}$	فراوانی	کد
۴	۰/۱۲۴۷۸۳	۰/۱۲۴۹۵۴	-۰/۲۷۳۷۶	۹	مدل های ARIMA		
۷	۰/۰۸۹۹۳۳	۰/۰۸۹۷۹۷	-۰/۱۹۷۳	۵	الگوریتم های مبتنی بر پارتیشن		
۲	۰/۱۵۰۷۳	۰/۱۵۰۵۰۲	-۰/۳۳۰۶۹	۱۴	درختان تصمیم		
۸	۰/۰۷۸۲۰۶	۰/۰۷۸۰۸۷	-۰/۱۷۱۵۷	۴	شبکه های پویا بیز		
۶	۰/۱۰۰۲۴۹	۰/۱۰۰۰۹۷	-۰/۲۱۹۹۳	۶	مدل های هیبریدی		
۹	۰/۰۶۴۷۰۶	۰/۰۶۴۶۰۸	-۰/۱۴۱۹۶	۳	الگوریتم های مبتنی بر نمونه		
۳	۰/۱۳۱۲۶	۰/۱۳۱۰۶۱	-۰/۲۸۷۹۷	۱۰	مدل های متغیر پنهان		
۱	۰/۱۵۹۸۸۴	۰/۱۵۹۶۴۲	-۰/۳۵۰۷۷	۱۷	شبکه های هوش مصنوعی		
۶	۰/۱۰۰۲۴۹	۰/۱۰۰۰۹۷	-۰/۲۱۹۹۳	۶	مدل های مبتنی بر قانون		

در نهایت براساس تحلیل های انجام شده، کدهای استخراج شده در یک مدل اولیه نشان داده شده است.



شکل شماره (۳): آنتروپی به دست آمده براساس تحقیقات گذشته

همانطور که در گام پنجم توضیح داده شد، الگوریتم‌های تشخیص عیب مشخص شدند. علاوه بر این، برخی از مطالعات نه تنها مزایای الگوریتم‌های یادگیری ماشینی مورد استفاده، بلکه روش‌های توسعه‌یافته برای رسیدگی به یک مشکل را نیز شناسایی کردند. هوش مصنوعی به عنوان یک مجموعه از تکنیک‌ها، الگوریتم‌ها و مدل‌های محاسباتی، نقش مهمی در شناسایی عیب در فرآیند تولید پلی‌پروپلین ایفا می‌کند. با استفاده از الگوریتم‌ها و مدل‌های هوش مصنوعی، می‌توان عیب‌های کوچک و ناهنجاری‌های ظریف را کشف و شناسایی کرد که ممکن است به سرعت از دست بروند یا با روش‌های سنتی قابل تشخیص نباشند. هوش مصنوعی قادر است بر روی داده‌های بزرگ و پیچیده تحلیل انجام دهد و الگوها و روابط پنهان در داده‌ها را شناسایی کند.

هدف پژوهش حاضر کاربست فراترکیب در شناسایی روش‌های الگوریتم‌های مبتنی بر داده جهت عیب‌یابی فرآیند تولید پلی‌پروپلین بوده است. بر اساس کدگذاری انجام‌شده، ۹ الگوریتم و تکنیک‌های مرتبط آنها شناسایی شدند. الگوریتم‌های شناسایی‌شده عبارت‌اند از: مدل‌های ARIMA، الگوریتم‌های مبتنی بر دسته‌بندی، درختان تصمیم، شبکه‌های پویا بیز، مدل‌های هیبریدی، الگوریتم‌های مبتنی بر نمونه، مدل‌های متغیر پنهان، شبکه‌های هوش مصنوعی و مدل‌های مبتنی بر قانون. حدود ۸۴ درصد از مطالعات انتخاب شده از تکنیک‌های یادگیری ماشینی متعلق از یکی از چهار دسته زیر استفاده کردند:

درخت‌های تصمیم؛

شبکه‌های عصبی مصنوعی؛

مدل‌های ترکیبی؛

مدل‌های متغیر پنهان.

راندمان محاسباتی نیز به عنوان یک مزیت مهم برای الگوریتم‌های یادگیری ماشینی دیده می‌شود. در حالی که الگوریتم‌های پیشرفته می‌توانند نتایج بسیار خوبی تولید کنند، از نظر منابع محاسباتی نیز می‌توانند بسیار سخت باشند. به عنوان مثال، شبکه‌های عصبی مصنوعی به قدرت پردازشی CPU و GPU زیادی نیاز دارند. آن‌ها همچنین به حافظه زیادی نیاز دارند، مانند روش‌های درختی مجموعه، و مقدار داده‌های پردازش شده بر استفاده از منابع محاسباتی نیز تأثیر می‌گذارد. علاوه بر این،

محاسبات سخت می‌تواند مصرف انرژی را تا حد زیادی افزایش دهد. به این دلایل، از جمله، توسعه یک سیستم تعمیر و نگهداری پیش‌بینی کننده نیاز به سرمایه‌گذاری قابل توجهی دارد. به این ترتیب، انتخاب الگوریتم‌های یادگیری ماشینی که از نظر محاسباتی کارآمد هستند، می‌تواند گزینه مقرون‌به‌صرفه‌تری باشد، در عین حال سازگارتر با محیط زیست، نگرانی‌ای که اهمیت و فوریت آن را نمی‌توان دست کم گرفت. با استفاده از هوش مصنوعی در عیب‌یابی فرایند تولید پلی‌پروپیلن، می‌توان بهبود کارایی و کاهش هزینه‌های مربوط به عیب‌یابی و تعمیر و نگهداری را مورد توجه قرار داد. تشخیص زودهنگام عیب‌ها، امکان ایجاد ضایعات و خرابی‌های بزرگتر را کاهش می‌دهد و بهبود عملکرد و بهره‌وری فرآیند را تحقق می‌بخشد.

با استفاده از الگوریتم‌های یادگیری ماشین و شبکه‌های عصبی مصنوعی، می‌توان الگوها و روندهای عیب‌زا را شناسایی و پیش‌بینی کرد. این امر به مدیران فرایند و کارشناسان فنی کمک می‌کند تا اقدامات پیشگیرانه و بهینه را برای جلوگیری از وقوع عیب‌ها اتخاذ کنند. با استفاده از هوش مصنوعی در عیب‌یابی، می‌توان کیفیت محصولات تولیدی را بهبود بخشید. با شناسایی و رفع عیب‌ها در مراحل زودهنگام تولید، ممکن است محصولات با کیفیت‌تری تولید شوند و نیاز به بازگشت محصولات معیوب و تعمیرات بعدی کاهش یابد. بنابراین، هوش مصنوعی در شناسایی عیب در فرایند تولید پلی‌پروپیلن بهبودهای قابل‌توجهی و اهمیتی می‌آورد که قبلاً در دسترس نبوده است. از طریق تجزیه و تحلیل داده‌های بزرگ، شناسایی الگوها و روابط پنهان در فرآیند تولید، هوش مصنوعی می‌تواند بهبودهای قابل توجهی در کیفیت و کارایی فرآیند تولید پلی‌پروپیلن ایجاد کند.

پیچیدگی ذاتی سیستم‌های تولید و ویژگی‌های متغیر زمان فرآیندهای تولید مشکل مهمی است که باید در هنگام انجام تشخیص و پیش‌آگهی عیب در صنعت تولید پلی‌پروپیلن در نظر گرفته شود. تحقیقات بیشتری برای توسعه الگوریتم‌ها و روش‌های یادگیری ماشینی مورد نیاز است که بتواند داده‌های موجود را مدیریت کند و الگوهای غیرخطی تعامل بین اجزای ماشین‌آلات را ثبت کند. رفتار تصادفی یک سیستم تولیدی و روابط پیچیده بین اجزای آن به این معنی است که این سیستم‌ها با غیرقابل پیش‌بینی بودن تعریف می‌شوند. علاوه بر این، تولید محصولات مختلف در سناریوهای دنیای واقعی، اغلب از یک خط تولید خارج می‌شوند که نیاز به تغییراتی در پیکربندی ماشین، اجزا و مواد تولید دارند. این شرایط غیر ایستا کار تشخیص و پیش‌بینی خطاها را پیچیده‌تر می‌کند. بنابراین، بسیار مهم است که الگوریتم‌های یادگیری ماشینی بتوانند الگوهای غیرخطی و پویایی را کشف کنند که این رویدادها را مشخص می‌کنند. عملکرد بالا به همان اندازه مطلوب است و به طور مستقیم با توانایی الگوریتم در مدل‌سازی سیستم مرتبط است. با این حال، هنگام شناسایی یا پیش‌بینی شکست‌ها در دنیای واقعی، تعریف عملکرد باید مبادله بین مثبت کاذب و منفی کاذب را در نظر بگیرد. بسته به الزامات کسب و کار، عدم پیش‌بینی یک خطا ممکن است عواقب جدی به دنبال داشته باشد، در این صورت مثبت کاذب به منفی کاذب ارجحیت دارد.

از آنجاییکه فرآیند تولید پلی‌پروپیلن شامل فرآیندهای شیمیایی و مکانیکی پیچیده است که می‌تواند منجر به مشکلات و چالش‌های مختلف شود، رفع این مشکلات نیازمند درک عمیقی از الگوریتم‌ها و روش‌های مبتنی بر داده است که در این فرآیند استفاده می‌شود. با این حال، ممکن است درک جامعی از روش‌ها و الگوریتم‌های مختلف مورد استفاده برای رفع مشکلات وجود نداشته باشد که باعث می‌شود رفع مشکلات تولید به صورت موثر مشکل باشد. استفاده از رویکرد مناسبتز می‌تواند در شناسایی و ترکیب روش‌ها و الگوریتم‌های مورد استفاده برای رفع مشکلات در فرآیند تولید پلی‌پروپیلن مفید باشد. این رویکرد شامل بررسی و تجزیه و تحلیل سیستماتیک ادبیات موجود، مطالعات تحقیقاتی و روش‌های صنعتی برای شناسایی و ترکیب الگوریتم‌ها و روش‌های مختلف مبتنی بر داده برای رفع مشکلات است. با این کار، درک جامعی از رویکردهای مختلف توسعه داده می‌شود که امکان حل مسائل و رفع مشکلات بهتر در فرآیند تولید را فراهم می‌کند. این امر می‌تواند در نهایت منجر به بهبود کارایی، کاهش زمان توقف و بهبود کلی نتایج تولید شود.

نتایج ملموس این تحقیق را می‌توان آرایه بینش‌ها و راه‌حل‌های کلیدی برای شناسایی عیوب در تولید پلی‌پروپیلن دانست. این تحقیق بر اهمیت شناسایی الگوریتم‌های یادگیری ماشینی کارآمد برای پاسخ‌گویی به ماهیت عیب و اشکال تأکید می‌کند و بر نیاز به کارآمدی و کارایی منابع برای کاهش هزینه‌ها تأکید می‌کند. علاوه بر این، این متن بر پتانسیل شناسایی زودهنگام و پیشگیری از بروز اشکال و عیب از طریق استفاده از الگوریتم‌های یادگیری ماشینی و شبکه‌های عصبی مصنوعی تأکید دارد که منجر به بهبود عملکرد و کارایی فرآیند می‌شود. علاوه بر این، پتانسیل بهبود کیفیت محصول از طریق پیاده‌سازی هوش

مصنوعی در شناسایی اشکال و همچنین اهمیت تحقیق و توسعه مداوم برای مدیریت پیچیدگی سیستم‌های تولید و گرفتن الگوهای غیرخطی از تعامل بین اجزاء ماشین از نتایج به دست آمده این تحقیق است. به طور خلاصه، این متن بینش‌های ارزشمندی را در مورد مزایای بهره‌برداری از یادگیری ماشینی و هوش مصنوعی برای شناسایی اشکال در تولید پلی‌پروپیلن ارائه می‌دهد.

۴- منابع

- Aldrini, J., Chihi, I., & Sidhom, L. (2023). Fault diagnosis and self-healing for smart manufacturing: a review. *Journal of Intelligent Manufacturing*, 1-33.
- Armenise, S., Wong, S., Ramírez-Velásquez, J. M., Launay, F., Wuebben, D., Nyakuma, B. B., ... & Muñoz, M. (2021). Application of computational approach in plastic pyrolysis kinetic modelling: a review. *Reaction kinetics, mechanisms and catalysis*, 134(2), 591-614. <https://doi.org/10.1007/s11144-021-02093-7>
- Bampoula, X., Siaterlis, G., Nikolakis, N., & Alexopoulos, K. (2021). A deep learning model for predictive maintenance in cyber-physical production systems using lstm autoencoders. *Sensors*, 21(3), 972.
- Baptista, M., Sankararaman, S., de Medeiros, I. P., Nascimento Jr, C., Prendinger, H., & Henriques, E. M. (2018). Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling. *Computers & Industrial Engineering*, 115, 41-53. <https://doi.org/10.1016/j.cie.2017.10.033>
- Boyes, H., Hallaq, B., Cunningham, J., & Watson, T. (2018). The industrial internet of things (IIoT): An analysis framework. *Computers in industry*, 101, 1-12.
- Canizo, M., Onieva, E., Conde, A., Charramendieta, S., & Trujillo, S. (2017). Real-time predictive maintenance for wind turbines using big data frameworks. In 2017 IEEE International Conference on Prognostics and Health Management (ICPHM) (pp. 70–77). IEEE.
- Carvalho, T. P., Soares, F. A. A. M. N., Vita, R., Francisco, R. P., Basto, J. P., & Alcalá, S. G. S. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024. <https://doi.org/10.1016/j.cie.2019.106024>
- Chang, H., Zhang, G., Sun, Y., & Lu, S. (2022). Non-dominant genetic algorithm for multi-objective optimization design of unmanned aerial vehicle shell process. *Polymers*, 14(14), 2896. <https://doi.org/10.3390/polym14142896>
- Chen, B., Liu, Y., Zhang, C., & Wang, Z. (2020). Time series data for equipment reliability analysis with deep learning. *IEEE Access*, 8, 105484–105493.
- Fernandes, M., Canito, A., Corchado, J. M., & Marreiros, G. (2019, June). Fault detection mechanism of a predictive maintenance system based on autoregressive integrated moving average models. In *International Symposium on Distributed Computing and Artificial Intelligence* (pp. 171-180). Cham: Springer International Publishing.
- Fernandes, M., Corchado, J. M., & Marreiros, G. (2022). Machine learning techniques applied to mechanical fault diagnosis and fault prognosis in the context of real industrial manufacturing use-cases: A systematic literature review. *Applied Intelligence*, 52, 14246–14280. <https://doi.org/10.1007/s10489-022-03344-3>
- Gao, H., Zhang, Y., Zhou, X., et al. (2018). Intelligent methods for the process parameter determination of plastic injection molding. *Frontiers of Mechanical Engineering*, 13, 85–95. <https://doi.org/10.1007/s11465-018-0491-0>

- Hu, H., Tang, B., Gong, X., Wei, W., & Wang, H. (2017). Intelligent fault diagnosis of the high-speed train with big data based on deep neural networks. *IEEE Transactions on Industrial Informatics*, 13(4), 2106–2116. <https://doi.org/10.1109/TII.2017.2683528>
- Hwang, I., Kim, S., Kim, Y., & Seah, C. E. (2010). A survey of fault detection, isolation, and reconfiguration methods. *IEEE Transactions on Control Systems Technology*, 18(3), 636–653. <https://doi.org/10.1109/TCST.2009.2026285>
- Ke, K. C., Wu, P. W., & Huang, M. S. (2023). Multi-quality prediction of injection molding parts using a hybrid machine learning model. *The International Journal of Advanced Manufacturing Technology*. <https://doi.org/10.1007/s00170-023-12329-6>
- Kiangala, K. S., & Wang, Z. (2020). An effective predictive maintenance framework for conveyor motors using dual time-series imaging and convolutional neural network in an industry 4.0 environment. *IEEE Access*, 1. <https://doi.org/10.1109/ACCESS.2020.3006788>
- Kolokas, N., Vafeiadis, T., Ioannidis, D., & Tzovaras, D. (2018, July). Forecasting faults of industrial equipment using machine learning classifiers. In *2018 Innovations in Intelligent Systems and Applications (INISTA)* (pp. 1-6). IEEE.
- Lau, C. K., Heng, Y. S., Hussain, M. A., & Nor, M. M. (2010). Fault diagnosis of the polypropylene production process (UNIPOL PP) using ANFIS. *ISA transactions*, 49(4), 559-566.
- Leiviskä, K. (2005). Problem Definition—From Applications to Methods. In *Do Smart Adaptive Systems Exist? Best Practice for Selection and Combination of Intelligent Methods* (pp. 19-26). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Liu, C., Bai, J., & Wu, F. (2022). Fault Diagnosis Using Dynamic Principal Component Analysis and GA Feature Selection Modeling for Industrial Processes. *Processes*, 10(12), 2570. <https://doi.org/10.3390/pr10122570>
- Liu, C., Tang, D., Zhu, H., & Nie, Q. (2021). A novel predictive maintenance method based on deep adversarial learning in the intelligent manufacturing system. *IEEE Access*, 9, 49557–49575. <https://doi.org/10.1109/ACCESS.2021.3069256>
- Mathew, V., Toby, T., Singh, V., Rao, B. M., & Kumar, M. G. (2017, December). Prediction of Remaining Useful Lifetime (RUL) of turbofan engine using machine learning. In *2017 IEEE international conference on circuits and systems (ICCS)* (pp. 306-311). IEEE.
- Mobley, R. K. (2001). Predictive Maintenance. In *Plant Engineer's Handbook* (pp. 867–888). Elsevier.
- Mohan, T. R., Roselyn, J. P., Uthra, R. A., Devaraj, D., & Umachandran, K. (2021). Intelligent machine learning based total productive maintenance approach for achieving zero downtime in industrial machinery. *Computers & Industrial Engineering*, 157, 107267. <https://doi.org/10.1016/j.cie.2021.107267>
- Naskos, A., Gounaris, A., Metaxa, I., & Köchling, D. (2019). Detecting anomalous behavior towards predictive maintenance. In *Advanced Information Systems Engineering Workshops: CAiSE 2019 International Workshops, Rome, Italy, June 3-7, 2019, Proceedings 31* (pp. 73-82). Springer International Publishing.
- Nieves Avendano, D., Caljouw, D., Deschrijver, D., & Van Hoecke, S. (2021). Anomaly detection and event mining in cold forming manufacturing processes. *The International Journal of Advanced Manufacturing Technology*, 115, 837-852.
- Niknam, S. A., Kobza, J., & Hines, J. W. (2017). Techniques of trend analysis in degradation-based prognostics. *International Journal of Advanced Manufacturing Technology*, 88, 2429–2441. <https://doi.org/10.1007/s00170-016-8909-5>
- O'Donovan, C., Popov, I., Todeschini, G., et al. (2023). Ladle pouring process parameter and quality estimation using Mask R-CNN and contrast-limited adaptive histogram

- equalisation. *International Journal of Advanced Manufacturing Technology*, 126, 1397–1416. <https://doi.org/10.1007/s00170-023-11151-4>
- O’donovan, P., Leahy, K., Bruton, K., & O’Sullivan, D. T. (2015). Big data in manufacturing: a systematic mapping study. *Journal of Big Data*, 2, 1-22. <https://doi.org/10.1186/s40537-015-0028-x>
- Peng, D., Xu, Y., & Zhu, Q. (2013). Study and Application of Case-based Extension Fault Diagnosis for Chemical Process. *Chinese Journal of Chemical Engineering*, 21(4), 366–375. doi:10.1016/s1004-9541(13)60484-x
- Ribeiro Junior, R. F., & Gomes, G. F. (2023). On the Use of Machine Learning for Damage Assessment in Composite Structures: A Review. *Applied Composite Materials*, 1-37.
- Shen, Y. (2023). Genetic algorithm based production knowledge base for mechanical fault detection model. *Journal of Computational Methods in Sciences and Engineering*, 23.
- Srinivasan, R. (2007). Artificial intelligence methodologies for agile refining: An overview. *Knowledge and Information Systems*, 12, 129–145. <https://doi.org/10.1007/s10115-006-0057-z>
- Sullivan, G., Pugh, R., Melendez, A. P., & Hunt, W. D. (2010). Operations & maintenance best practices-a guide to achieving operational efficiency (release 3). Technical Report, Pacific Northwest National Lab. (PNNL), Richland.
- Susto, G. A., Schirru, A., Pampuri, S., McLoone, S., & Beghi, A. (2015). Machine learning for predictive maintenance: A multiple classifier approach. *IEEE Transactions on Industrial Informatics*, 11(3), 812–820. <https://doi.org/10.1109/TII.2014.2349359>
- Tayyebi, S. (2015). Multiple-Fault Diagnosing System Based on Fuzzy-Genetic Algorithm for the Production of Toluene from n-Heptane. *Farayandno*, 9(48), 44-52.
- Turkoglu, B., Komesli, M., & Unluturk, M. S. (2019). Application of data mining in failure estimation of cold forging machines: An industrial research. *Stud Inf Control*, 28(1), 87-94. <https://doi.org/10.24846/v28i1y201909>
- Uhlmann, E., Pontes, R. P., Geisert, C., & Hohwieler, E. (2018). Cluster identification of sensor data for predictive maintenance in a selective laser melting machine tool. *Procedia Manuf*, 24, 60-65. <https://doi.org/10.1016/j.promfg.2018.06.009>
- Vrubic, R., Kozjek, D., & Butala, P. (2017). Knowledge elicitation for fault diagnostics in plastic injection moulding: A case for machine-to-machine communication. *CIRP Ann Manuf Technol*, 66(1), 433-436.
- Xiao, H., Xu, Z. Z., Kim, L. S., et al. (2015). Optimization scheme of genetic algorithm and its application on aeroengine fault diagnosis. *Int J Precis Eng Manuf*, 16, 735-741. <https://doi.org/10.1007/s12541-015-0097-y>
- Xie, C., Zhang, R., & Bholra, J. (2022). Research on fault detection and identification methods of nonlinear dynamic process based on ICA. *Nonlinear Engineering*, 11(1), 13-19. <https://doi.org/10.1515/nleng-2022-0003>
- Yu, J. (2018). Tool condition prognostics using logistic regression with penalization and manifold regularization. *Appl Soft Comput*, 64, 454-467. <https://doi.org/10.1016/j.asoc.2017.12.042>
- Zhang, J., Roberts, P. D., & Ellis, J. E. (1990). Fault diagnosis of a mixing process using deep qualitative knowledge representation of physical behaviour. *J Intell Robot Syst*, 3, 103-115. <https://doi.org/10.1007/BF00242159>
- Zhang, W., Yang, D., & Wang, H. (2019). Data-driven methods for predictive maintenance of industrial equipment: A survey. *IEEE Syst J*, 13(3), 2213-2227. <https://doi.org/10.1109/JSYST.2019.2905565>

- Zhao, N. Y., Lian, J. Y., Wang, P. F., et al. (2020). Recent progress in minimizing the warpage and shrinkage deformations by the optimization of process parameters in plastic injection molding: A review. *Int J Adv Manuf Technol*, 120, 85-101. <https://doi.org/10.1007/s00170-022-08859-0>
- Zhou, Y., Fang, X., & Zhao, B. (2001, June). Diagnosis based on genetic algorithms and fuzzy logic in NPPs. In *International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems* (pp. 359-366). Berlin, Heidelberg: Springer Berlin Heidelberg.

The Application of Meta-Synthesis Approach in Identifying the Methods of Data-Based Algorithms for Troubleshooting the Polypropylene Production Process

Soleiman Golpour Kandeh

PhD Candidate, Department of Industrial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran

Reza Ramazani Khorshid Doost

Assistant Professor, Department of Industrial Engineering and Management Systems, Amirkabir University of Technology, Tehran, Iran

Email: ramazani@aut.ac.ir

Mohammad Reza Kabaran Zadeh Ghadim

Associate Professor, Department of Management, Center Tehran Branch, Islamic Azad University, Tehran, Iran

Abstract

This research has sought to identify the methods of data-based algorithms for troubleshooting the polypropylene production process. The researcher analyzed the results and findings of previous researchers using a systematic and meta-composite review approach and identified the effective factors by performing the 7 steps of the Sandelovski and Barroso method. Among 500 articles, 34 articles were selected based on the CASP method. In this context, in order to measure reliability and quality control, the Kappa index was used to evaluate the identified indicators, and its value for the identified indicators was recognized at the level of excellent agreement. The results of the collected data analysis were analyzed in ATLAS TI software. Based on the done coding, 9 algorithms and their related techniques were identified. The identified algorithms are: ARIMA models, classification-based algorithms, decision trees, dynamic Bayesian networks, hybrid models, sample-based algorithms, hidden variable models, artificial intelligence networks and rule-based models. About 84% of the selected studies used machine learning techniques belonging to one of four categories: decision trees, artificial neural networks, hybrid models, and latent variable models. Computational efficiency is also seen as an important advantage for machine learning algorithms.

Keywords: Data-Based Algorithms, Artificial Intelligence, Polypropylene Production Process Troubleshooting, Metasynthesis.