

زمان‌بندی تک‌ماشینه با الگوریتم فراابتکاری کرم شب‌تاب و پیش‌بینی خرابی ماشین با رویکرد داده‌کاوی

رضا کامران‌راد^{۱*}، علی قربانی^۲، یوسف ربانی^۳، پیمان فلسفی^۴

۱. استادیار گروه مهندسی صنایع، دانشکده مهندسی، دانشگاه سمنان، سمنان، ایران
۲. دانشجوی کارشناسی ارشد مهندسی صنایع، دانشکده مهندسی، دانشگاه سمنان، سمنان، ایران
۳. استادیار گروه مهندسی صنایع، دانشکده مهندسی، دانشگاه سمنان، سمنان، ایران
۴. دانشجوی کارشناسی ارشد مهندسی صنایع، دانشکده مهندسی، دانشگاه سمنان، سمنان، ایران

خلاصه

یکی از مشکلات امروزه در مسائل صنعت، پیش‌بینی اتفاقات غیرمترقبه است. ما در این مقاله، به مسأله زمان‌بندی تک‌ماشینه با در نظر گرفتن اتفاق خرابی‌ها می‌پردازیم. همچنین، به دنبال حداقل کردن جریمه‌های تحویل زودتر از موعد و دیرتر از موعد هستیم. در این پژوهش، یک مدل ریاضی برای این مسأله ارائه شده که در آن زمان‌های پردازش، بیار بودن ماشین، زمان آزادسازی، زمان خرابی و همچنین زمان در دسترس قرار گرفتن ماشین بعد از نگهداری و تعمیرات لحاظ شده است. زمان خرابی‌ها با استفاده از الگوریتم‌های یادگیری ماشین پیش‌بینی شده‌اند. نتایج نشان می‌دهد که مدل ارائه شده برای ابعاد کوچک با پارامترهای مدنظر مناسب است. اما برای حل مسأله با ابعاد بزرگ‌تر، از الگوریتم فراابتکاری استفاده شده است. این تحقیق در دو بخش به این مسأله پرداخته: بخش اول مربوط به پیش‌بینی خرابی‌ها می‌شود و بخش دوم، توالی عملیات زمان‌بندی تک‌ماشینه را دربر دارد. ابتدا، با استفاده از داده‌های گذشته، خرابی‌های ماشین‌آلات توسط الگوریتم‌های یادگیری ماشین پیش‌بینی شده و به مجموعه‌ای از قواعد برای اصلاح فرآیند رسیده‌ایم. سپس زمان‌بندی تک‌ماشینه، با استفاده از مدل برنامه‌ریزی عدد صحیح مختلط و با در نظر گرفتن این خرابی‌ها، انجام شده است.

اطلاعات مقاله

تاریخچه مقاله:

دریافت ۱۴۰۰/۵/۲۲

پذیرش ۱۴۰۰/۱۱/۳۱

(مقاله پژوهشی)

کلمات کلیدی:

خرابی ماشین‌آلات

زمان‌بندی تک‌ماشینه

داده‌کاوی

تحویل به موقع

۱. مقدمه

خرابی‌ها و یا سایر محدودیت‌های مرتبط با دسترسی ماشین ممکن است ماشین پس از مدتی به منظور نگهداری و تعمیرات و یا به دلیل خرابی‌ها متوقف شود. در این تحقیق ابتدا با استفاده از الگوریتم‌های یادگیری ماشین، پیش‌بینی می‌شود که ماشین در چه زمانی خراب می‌شود و بعد در این مدل زمان تعمیرات یا همان زمان بین خراب شدن و از دسترس خارج شدن ماشین تا زمان تعمیر و شروع به کار ماشین به صورت تصادفی و با استفاده از توزیع نمایی حاصل می‌شود زیرا این توزیع، زمانی رخ می‌دهد که خرابی تجهیزات ناشی از بروز خرابی در

امروزه مسائل توالی عملیات در بسیاری از سیستم‌های تولیدی کاربرد فراوانی یافته‌اند و مهم‌ترین تصمیم در زمان‌بندی، تخصیص منابع مورد نظر و تعیین توالی کارها می‌باشد. مهم‌ترین بخش‌های مدل‌های زمان‌بندی، کارها و ماشین‌ها هستند. اکثر مسائل زمان‌بندی فرض بر این دارند که ماشین در طول برنامه زمان‌بندی شده به طور پیوسته و مستمر کار می‌کند ولی این فرض ممکن است در برخی از حالت‌ها درست نباشد زیرا با در نظر گرفتن عواملی چون عملیات نگهداری و تعمیر،

* نویسنده مسئول: رضا کامران‌راد

تلفن: ۰۲۳-۳۱۵۳۲۳۸۱؛ پست الکترونیکی: r.kamranrad@semnan.ac.ir

پرداختیم و از الگوریتم فراابتکاری گرم شب‌تاب در این زمینه استفاده نمودیم که نتایج آن را نیز با الگوریتم ژنتیک مقایسه می‌کنیم و همچنین در مدل ریاضی مربوطه خرابی ماشین و در دسترس نبودن ماشین را لحاظ کرده‌ایم.

ما در تحقیق خود به مسأله زمان‌بندی تک‌ماشینه در فضایی که بسیار شبیه به دنیای واقعی است پرداخته‌ایم. ما داده‌های گذشته را تحلیل و بررسی کرده، عوامل ایجاد خرابی‌ها را شناسایی، و با پیش‌بینی این خرابی‌ها با استفاده از الگوریتم‌های یادگیری ماشین، به توالی عملیات در شرایط واقعی کمک می‌کنیم. هدف اصلی مسأله ما، کاهش هزینه‌ها و جریمه‌ها است. ما در این تحقیق همچنین با استفاده از مدل ریاضی زمان در دسترس نبودن ماشین‌آلات را با استفاده از پیش‌بینی‌هایی که از قبل انجام شده، ارائه می‌دهیم که مناسب فرآیند تولید با هدف حداقل کردن هزینه‌ها و همچنین تحویل به‌موقع است. یوچانگ تاسو و همکاران [۱۰] به مسأله زمان‌بندی تک‌ماشین با زمان پردازش قابل کنترل و رویکرد قیمت‌گذاری برق پرداختند. هدف آن‌ها به حداقل رساندن کل انرژی با در نظر گرفتن محدودیت‌های مالی و محیطی است. همچنین در این مقاله از رویکرد فازی با الگوریتم ژنتیک ترکیبی استفاده شده است. ووی چو و لو [۱۱] به مسأله حداقل رساندن زمان اتمام در زمان‌بندی تک‌ماشین پرداختند که نگهداری و تعمیر انعطاف‌پذیر و آزادسازی کارها را نیز در آن لحاظ کرده‌اند. آن‌ها همچنین یک مدل ریاضی برنامه‌ریزی عدد صحیح مختلط، الگوریتم ابتکاری و یک الگوریتم شاخه و کران ارائه دادند. لیو کینگ‌مینگ و همکاران [۱۲] در مقاله خود به مسأله زمان‌بندی برنامه‌ریزی تولید و برنامه‌ریزی نگهداری در فضای تک‌ماشینه پرداخته‌اند. بینگای ژائو و تائوپنگ [۱۳] در پژوهش خود مسأله زمان‌بندی تک‌ماشین که دارای محدودیت‌های موجودی غیرمنفی و زمان‌های پردازش قابل کنترل است را مورد بررسی قرار دادند. آن‌ها از یک الگوریتم دقیق و فراابتکاری برای حل این مسأله استفاده کردند. وارلا و همکاران [۱۴] در مسأله خود به حداقل رساندن هزینه کل با در نظر گرفتن تحویل به‌موقع را مدنظر قرار دادند و از روش‌هاجسون برای حل این مسأله زمان‌بندی استفاده کردند. توآت و همکاران [۱۵] به مسأله زمان‌بندی تک‌ماشین با در نظر گرفتن نگهداری و تعمیر منعطف تحت محدودیت‌های منابع انسانی با استفاده از روش‌های حل دقیق و الگوریتم‌های فراابتکاری پرداخته‌اند. آن‌ها، از الگوریتم جستجوی محلی هدایت شده^۱ برای حل مسأله در ابعاد بالا استفاده کردند. گونزالز و فرامیران [۱۶] در مسأله زمان‌بندی تک‌ماشین از روش‌های ابتکاری استفاده نمودند. آن‌ها، زمان نگهداری و تعمیر دوره‌ای را نیز در نظر گرفتند. همچنین برای حل بهینه مسأله، مدل برنامه‌ریزی خطی عدد صحیح مختلط به کار بردند. نسلو و همکاران [۱۷] نیز با استفاده از روش حل دقیق به مسأله زمان‌بندی تک‌ماشین با در نظر گرفتن زمان تعمیرات دوره‌ای و زمان‌های راه‌اندازی وابسته به توالی عملیات پرداختند. شابتای و زوفی [۱۸] در مقاله خود به مسأله توالی عملیات با یک ماشین پرداخته‌اند

یکی از قطعات تشکیل‌دهنده آن باشد و همچنین تابع توزیع نمایی بدون حافظه می‌باشد و در گام بعد زمان خرابی‌ها در مدل ریاضی ارائه شده لحاظ می‌شود تا زمان‌بندی دقیق‌تری را داشته باشیم. زمان‌بندی از مباحث مهم و قابل توجه است که باید قبل از شروع به فرآیند تولید به آن پرداخته شود و در بخش زمان‌بندی گلوگاه‌هایی وجود دارد که باید به آن‌ها توجه کرد. توالی عملیات تک‌ماشینه نیز پیچیدگی‌های خاص خود را دارد و همین پیچیدگی‌ها باعث می‌شود که در بعضی از اوقات به یک مسأله NP-hard تبدیل شود. یکی از شکاف‌هایی که در مبحث زمان‌بندی وجود دارد بحث خرابی‌های تصادفی ماشین‌آلات است که باعث می‌شود زمان‌بندی به درستی انجام نشود. این اختلالات منجر به افزایش هزینه‌هایی از قبیل هزینه تسریع کارها، هزینه نگهداری، و هزینه فروش از دست‌رفته می‌شود که بی‌اعتمادی را نیز در پی خواهد داشت. همچنین در مقالات گذشته، از داده‌کاوی، بیشتر برای کشف دانش و ارتباط برای مسأله‌های مختلف زمان‌بندی استفاده شده، و کمتر از آن برای پیش‌بینی عوامل خرابی استفاده شده است. ما در این پژوهش، از داده‌های شبیه‌سازی شده استفاده می‌کنیم که می‌تواند الگوی مناسبی برای پیاده‌سازی در صنعت تولیدی باشد.

۲. مرور ادبیات

تحقیقات زیادی در مورد مسأله زمان‌بندی تک‌ماشینه تا به حال انجام شده است و امروزه محققین در تلاش‌اند تا این مسأله را از تمام جنبه‌ها مورد آزمایش و بهبود قرار دهند که سیستم زمان‌بندی و توالی عملیات بهینه برای این مسائل را ارائه دهند. در این راستا ما به تحقیقات پیشین که در این زمینه انجام شده است می‌پردازیم. زاینودین و همکاران [۱] در مقاله خود با استفاده از شبکه عصبی مصنوعی بازگشتی به پیش‌بینی وضعیت ماشین‌ها در صنعت نفت و گاز پرداخته‌اند. گوپراس و همکاران [۲] در تحقیق خود، مسأله بهینه‌سازی برنامه‌ریزی سیستم مونتاژ دوسطحی را مورد بررسی قرار دادند. آن‌ها فرض کرده‌اند که ماشین در معرض خرابی تصادفی است و یک مدل ریاضی برای دربر گرفتن یک برنامه‌ریزی جامع برای سیستم‌های مونتاژ دوسطحی تحت زمان‌های تصادفی و خرابی ماشین ارائه داده‌اند. آن‌ها همچنین یک برنامه نگهداری و تعمیر پیش‌گیرانه برای کاهش دفعات نگهداری و تعمیر ارائه داده، و از الگوریتم ژنتیک برای نشان دادن اثربخشی مدل استفاده کرده‌اند. برخی از تحقیقات نیز به مسأله پیش‌بینی خرابی ماشین در بحث تولید، بهینه‌سازی موجودی انبار، نگهداری و تعمیر پرداختند که برای مطالعه بیشتر می‌توان به آن‌ها مراجعه کرد [۳-۸]. شکوفی و رضاییان [۹] در مقاله خود به زمان‌بندی تک‌ماشین پرداخته‌اند. آن‌ها مدل ریاضی ارائه شده را با ۱۴۴ مسأله عددی تصادفی مورد بررسی قرار داده و نتیجه گرفتند مدل ارائه شده آن‌ها می‌تواند برای تا ۶ کار، جواب بهینه دهد. ما برای ادامه این کار و با استفاده از مدل ریاضی ارائه‌شده آن‌ها، به حل آن در ابعاد بالاتر

یک الگوریتم بهینه‌سازی کلونی مورچه‌ها برای حل نمونه‌های آزمایشی با اندازه بزرگتر توسعه داده شده است. هو و همکاران [۳۱] مسأله زمان‌بندی تک‌ماشین با محدودیت‌های تعمیر و نگهداری دوره‌ای، دسترس بودن و هزینه‌های راه‌اندازی وابسته به توالی را در نظر گرفت. آن‌ها همچنین با پیشنهاد یک مدل نگهداری و تعمیر جزئی و گنجاندن آن در یک مسأله زمان‌بندی ماشین، هدفشان یافتن برنامه‌ای با استراتژی نگهداری و تعمیر مناسب برای به حداقل رساندن زمان ساخت بودند. لالویی و هلا [۳۲] از یک الگوریتم اکتشافی دوفازی استفاده کردند و سعی کردند تعداد وزنی در محیط زمان‌بندی تک‌ماشین را با توجه به دوره‌های نگهداری و تعمیر برنامه‌ریزی شده و زمان تحویل مشترک را به حداکثر برسانند. آن‌ها برای حل نمونه‌های کوچک استفاده از مسأله کوله‌پشتی چندگانه باینری را پیشنهاد دادند. وانگ و همکاران [۳۳] با استفاده از الگوریتم انشعاب و قیمت، یک مسأله زمان‌بندی ماشین واحد را که در آن کارها تدریجاً بدتر می‌شود و نگهداری و تعمیر دوره‌ای انعطاف‌پذیر در نظر گرفته شده بود، مورد مطالعه قرار داد. لو و همکاران [۳۴] شش الگوریتم اکتشافی را بر اساس اولین برزش و بهترین تناسب ارائه دادند که با مسأله زمان‌بندی تک‌ماشینی با محدودیت‌های در دسترس برای به حداقل رساندن فاصله زمانی سروکار دارد. آن‌ها در نظر گرفتند که ماشین باید پس از یک بازه زمانی دوره‌ای برای نگهداری و تعمیر متوقف شود یا بعد از این که تعداد ثابتی از کارها به‌طور هم‌زمان پردازش شدند، ابزارها را تغییر دهند. زاموری و همکاران [۳۵] یک الگوریتم جستجوی هارمونی ترکیبی با الگوریتم‌های ژنتیک پیشنهاد دادند. آن‌ها با هدف به حداقل رساندن جریمه‌های تحویل زودتر از موعد و تأخیر کلی در زمان‌بندی تک‌ماشین، مشروط به نگهداری برنامه‌ریزی شده و زمان‌های راه‌اندازی وابسته به توالی پرداختند. از بررسی و تحلیل نتایج تحقیقات پیشین می‌توان متوجه شد: تحقیق ما در راستای تکمیل تحقیقات پیشین است که به موضوع خرابی‌ها و اختلالات در زمان‌بندی تک‌ماشین و همچنین به تأثیرگذاری این اختلالات در توالی عملیات پرداخته و برای حل این مسأله در ابعاد بزرگ از الگوریتم فراابتکاری کرم شب‌تاب و ژنتیک استفاده شده است. یکی از چالش‌های مدیران تابه‌حال مسأله لحاظ کردن خرابی‌ها بوده و ما در این تحقیق سعی در پرداختن به آن به‌صورت عملی داریم تا نقشه راهی برای دیگران باشد. جدول (۱) دید کلی از تحقیقات پیشین می‌دهد.

۳. مباحث نظری

۳-۱. زمان‌بندی تک‌ماشین

زمان‌بندی تک‌ماشین یا زمان‌بندی تک‌منبعی، مسأله بهینه‌سازی‌ای می‌باشد که هدف آن تعیین توالی عملیات بهینه و همچنین حداقل کردن اهدافی از قبیل هزینه و تأخیر در تحویل کارها، است. از روش‌های حل مسأله زمان‌بندی تک‌ماشین به‌عنوان الگویی برای حل سایر مدل‌ها نیز استفاده می‌شود. توابع هدف متفاوتی برای مسائل

که در آن از زمان‌های پردازش قابل کنترل و دوره در دسترس نبودن برای به حداقل رساندن زمان اتمام کارها استفاده کردند. وانگ و همکاران [۱۹] در مقاله خود به بررسی مسأله تخصیص پنجره موعد تحویل مشترک در زمان‌بندی تک‌ماشین با جریمه‌های تعجیل/تأخیر تعمیم‌یافته پرداختند. زمان‌های پردازش کار شامل دو مورد است: یکی با مقادیر ثابت و دیگری با زمان‌های پردازش وابسته. با توجه به فعالیت نگهداری و تعمیر، زمان نگهداری را ثابت فرض کردند. هدف آن‌ها تعیین موقعیت پنجره موعد تحویل مشترک و توالی بهینه است به‌طوری که تابع هدف جریمه‌های وزنی برای مجموع تعجیل و تأخیر، تعداد وزنی تعجیل و تأخیر و پنجره زمان تحویل وزنی به حداقل برسد. چوی و پارک [۲۰] یک مسأله زمان‌بندی تک‌ماشینی را در نظر گرفتند به این ترتیب که زمان‌های تحویل به هر کار بسته به ترتیب آن اختصاص داده می‌شود و طول فواصل بین زمان‌های تحویل متوالی یکسان است. هدف این است که مجموع جریمه تحویل زود هنگام و تحویل با تأخیر هر کار را به حداقل رسانده شود. جریمه تحویل زودتر از موعد متناسب با مقدار تعجیل صورت گرفته افزایش می‌یابد، در حالی که جریمه تأخیر با توجه به تابع گام افزایش می‌یابد. مطالعه اثرات انواع مختلف نگهداری و تعمیر در زمان‌بندی ماشین‌آلات، سال‌هاست که مورد توجه قرار گرفته است. در زمینه نگهداری و تعمیر پیش‌بینی‌کننده، یادگیری ماشین در سال‌های گذشته اهمیت پیدا کرده است که تعداد فزاینده‌ای از مقالات از یادگیری ماشین در این مسأله بهره بردند و این امر به دلیل تفسیرپذیری مدل‌های یادگیری ماشین است [۲۱]. سیستم‌های پشتیبانی تصمیم‌گیری نگهداری و تعمیر^۱ که توسط اینترنت اشیاء، داده‌های بزرگ و یادگیری ماشین تقویت شده‌اند، نقش برجسته‌ای را برای اطمینان از قابلیت نگهداری و قابلیت اطمینان تجهیزات در صنایع با تبدیل مجموعه داده‌های بزرگ به دانش و نتایج مفید ایفا می‌کنند [۲۲-۲۴]. پیاده‌سازی این سیستم‌ها برای نظارت بر سلامت فرآیندهای صنعتی، بهینه‌سازی برنامه‌های نگهداری و تعمیر و دریافت هشدارهای سریع در مورد ریسک‌های عملیاتی، سازمان‌ها را قادر می‌سازد تا هزینه‌های خدمات را کاهش دهند، زمان کار را به حداکثر برسانند و بهره‌وری را بهبود بخشند [۲۵]. روش‌های متداول یادگیری ماشین برای مسأله تعمیرات و نگهداری پیش‌گیرانه ارائه شده است [۲۸-۲۶] که شامل استفاده از طبقه‌بندی‌کننده‌هایی مانند: ماشین بردار پشتیبان، درخت تصمیم، جنگل تصادفی و بیز ساده است. همچنین رویکرد نگهداری و تعمیر دوره‌ای نیز مورد استفاده قرار می‌گیرد که به‌طور گسترده توسط چن [۲۹] استفاده شده است. قهپان و همکاران [۳۰] در مقاله خود یک استراتژی پنجره زمانی برای نگهداری دوره‌ای را با پنجره‌های زمانی متفاوت و فعالیت‌های زمان‌بندی کار برای یک ماشین را در نظر گرفتند. هدف به حداقل رساندن تعداد کارهای با تأخیر از طریق ادغام برنامه‌ریزی تولید و پنجره زمانی نگهداری دوره‌ای است. یک مدل برنامه‌ریزی خطی عدد صحیح مختلط برای بهینه‌سازی نمونه‌های آزمایشی با اندازه کوچک پیشنهاد شده است. علاوه بر این،

دارند. الگوریتم‌های یادگیری ماشین در دسته‌های متفاوتی از قبیل رگرسیون، طبقه‌بندی و خوشه‌بندی قرار می‌گیرند. موضوع پیش‌بینی خرابی‌ها و تشخیص قابلیت اطمینان سیستم‌ها، مسائلی هستند که می‌توان از روش‌های داده‌کاوی برای حل آن‌ها استفاده نمود. فرمول‌هایی که برای تخمین قابلیت اطمینان در سیستم‌ها استفاده می‌شوند، بعضاً دارای هزینه محاسباتی بالایی هستند. همچنین، قابلیت اطمینان یک سیستم و یا تشخیص اختلالات، به راحتی فرمول‌پذیر نیست. با استفاده از رویکردهای طبقه‌بندی و مدل‌سازی، می‌توان مدلی سریع و محاسباتی برای تخمین مقدار احتمال خرابی، پیش‌بینی زمان خرابی آتی، پیش‌بینی نرخ و میزان خرابی و مواردی از این قبیل ساخت. برای تصمیم‌گیری مناسب، می‌توان از روش‌های طبقه‌بندی، خوشه‌بندی و یا مبتنی بر قواعد استفاده نمود. برای تخمین کمیت‌های پیوسته موجود در سیستم، امکان استفاده از رویکردهای مبتنی بر رگرسیون غیرخطی، وجود دارد.

در این مقاله از الگوریتم درخت تصمیم طبقه‌بندی کننده استفاده شده، زیرا این الگوریتم نتایج ساده و قابل فهمی دارد و همچنین قواعدی را برای ما می‌سازد.

تک‌ماشین تا به حال معرفی شده که مهم‌ترین آن‌ها عبارت‌اند از: زمان تکمیل وزن دار کل، حداکثر تأخیر، تعداد کارهای دیرتر از موعد، تأخیر کامل و تأخیر وزنی کل. به علاوه، در زمان‌بندی، اختلالاتی پیش می‌آیند که توالی کارها را دچار تغییرات کرده و تحویل محصول در موعد مقرر را با چالش مواجه می‌کند. در این پژوهش یکی از آن‌ها را در نظر خواهیم گرفت. در صنعت و تولید، خرابی‌های تصادفی شامل خرابی ماشین، لغو سفارش، خرابی ابزار، حوادث غیرمترقبه، قطعی برق، و غیره، شکل گرفته، و باعث تغییر و تحول در زمان‌بندی ماشین‌آلات می‌گردد. همچنین اختلالات می‌توانند از ورود کارهای جدید و دوباره کاری نیز ناشی شوند. ما در این مقاله اختلال در خرابی ماشین و خرابی ابزار آلات در زمان‌بندی تک‌ماشین را بررسی می‌کنیم.

۳-۲. داده‌کاوی

مجموعه‌ای از ابزارهای مهم و کاربردی است، که می‌توان از آن برای کاهش ضایعات و شناسایی و پیش‌بینی اختلالات در سیستم‌های تولیدی استفاده کرد. در داده‌کاوی از الگوریتم‌های گوناگونی استفاده می‌شود که بسته به نوع مسأله، رویکرد آن‌ها متفاوت است. روش‌های به کار رفته در داده‌کاوی با الگوریتم‌های یادگیری ماشین ارتباط قوی‌ای

جدول (۱): مرور تحقیقات پیشین

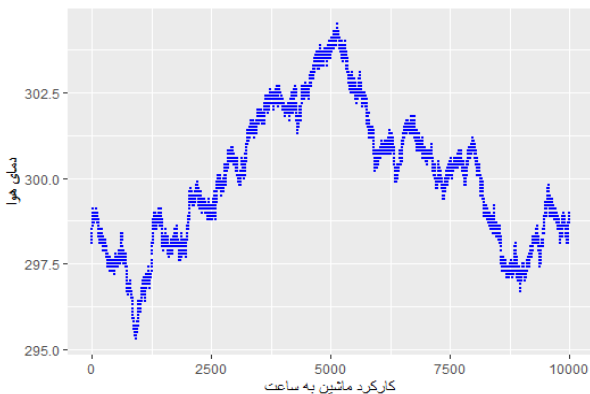
نویسندگان	مدل ریاضی	الگوریتم ابتکاری	الگوریتم فراابتکاری	داده‌کاوی
چنگ و همکاران [۱۱]	MILP چندهدفه	EDD WSPT	GNSGA III	—
زاینودین و همکاران [۱]	—	—	—	شبکه عصبی
تاسو و همکاران [۴]	MIP تک‌هدف	—	ژنتیک فازی	—
چو و لو [۵]	MIP تک‌هدف	ERD-LPT B&B	—	—
کینمینگ و همکاران [۶]	MIP تک‌هدف	—	ژنتیک	—
وارلا و همکاران [۸]	MIP تک‌هدف	هاجسون NST SPT	—	—
وانگ و لیو [۲۷]	MILP چندهدفه	—	NSGA-II	—
لیو و لی [۲۸]	MIP تک‌هدف	—	DABC	—
گونزالز و فرامینان [۱۳]	MILP تک‌هدفه	BFD FFD	PSO	—

می‌کند و در نهایت برگ با کلاسی که بیشترین مقدار به آن تعلق گرفته برچسب می‌خورد. ما در طول حل مسأله یک گراف درخت رسم می‌کنیم که گره‌های میانی آن سوال‌ها هستند و گره‌های برگ آن خروجی طبقه‌بندی را مشخص می‌کند. در این مسأله می‌خواهیم خراب شدن یا نشدن ماشین را پیش‌بینی کنیم به این صورت که در ابتدا برای ساخت مدل باید دسته‌بندی اولیه را انجام داد. از آنجایی که این الگوریتم در دسته الگوریتم‌های نظارت شده می‌باشد، بنابراین مجموعه داده باید دارای برچسب باشد. فرآیند ساختن درخت تصمیم به این صورت است


۳-۳. الگوریتم درخت تصمیم

یکی از پرکاربردترین الگوریتم‌های داده‌کاوی، الگوریتم درخت تصمیم است. در داده‌کاوی، درخت تصمیم مدلی پیش‌بینی کننده می‌باشد که می‌تواند برای هردو مدل رگرسیون و طبقه‌بندی مورد استفاده قرار گیرد. زمانی که درخت برای کارهای طبقه‌بندی استفاده می‌شود، به عنوان درخت طبقه‌بندی شناخته می‌شود. در ساختار درخت تصمیم، پیش‌بینی به دست آمده از درخت، در قالب یک سری قواعد توضیح داده می‌شود. هر مسیر از ریشه تا یک برگ درخت تصمیم، یک قانون را بیان

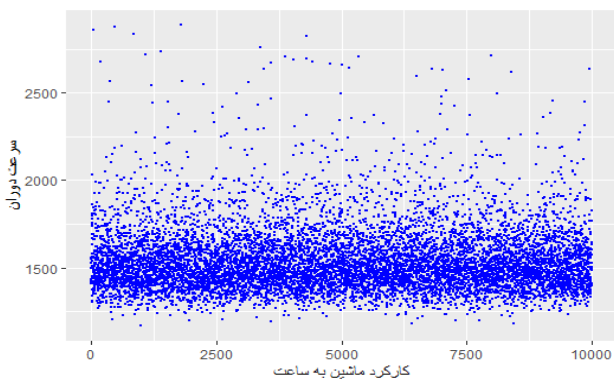
برچسب شکست ماشین روی ۱ می‌شود. در جدول (۲) برای نمونه، سه سطر از دیتاست مسأله را آورده‌ایم.




شکل (۱): نمودار پراکندگی دمای هوا



شکل (۲): نمودار پراکندگی دمای فرآیند



شکل (۳): نمودار پراکندگی سرعت دوران



شکل (۴): نمودار پراکندگی سایش ابزار

که ابتدا ویژگی یا ستونی که بیشترین آنتروپی را دارد انتخاب می‌شود. یعنی در ابتدا ویژگی را پیدا می‌کنیم که بتوانیم فقط به کمک آن طبقه‌بندی را با بیشترین دقت انجام دهیم. مرحله‌ی دوم نیز همانند مرحله‌ی اول می‌باشد و فرآیند پیدا کردن ویژگی با بیشترین آنتروپی را دوباره برای مجموعه داده انجام می‌دهیم. فرآیند را برای دیتاست موجود تا زمانی ادامه می‌دهیم که یا دیگر ویژگی با بیشترین آنتروپی خوب وجود نداشته باشد و یا این که دیگر ویژگی جدیدی وجود نداشته باشد و همه ویژگی‌ها را بررسی کرده باشیم. همچنین مقادیر جینی و آنتروپی از روابط زیر به دست می‌آید که در آن P_i احتمال کلاس مربوطه می‌باشد.

$$\text{Gain}(X,A) = \text{entropy}(X) - \text{entropy}(X,A) \quad (1)$$

$$\text{entropy}(X) = -\sum_{i=1}^n P_i \log_2(P_i) \quad (2)$$

$$\text{entropy}(X,A) = \sum_{i=0}^m \frac{|X_i|}{|X|} \text{entropy}(X_i) \quad (3)$$

$$\text{Gain-Rate}(X,A) = \frac{\text{gain}(X,A)}{\text{entropy}(X,A)} \quad (4)$$

۳-۴. دیتاست

یکی از مراحل مهم داده‌کاوی، وارد کردن داده‌ها و پیش‌پردازش داده‌ها است که این دیتاست از سایت

(<https://archive.ics.uci.edu/ml/datasets>) دریافت شده است و

شامل اطلاعات مربوطه ویژگی‌های عددی، رسته‌ای و تاریخی مشاهده می‌شود که شامل ۱۰۰۰۰ مشاهده می‌باشد که ما از ۸۰ درصد داده‌ها

به‌عنوان داده‌های آموزش و ۲۰ درصد داده‌ها را نیز به‌عنوان داده‌های آزمایش مورد استفاده قرار داده‌ایم. در این مشاهدات خرابی‌ها را

به‌صورت صفر و یک نمایش می‌دهیم که ۱ به معنای خرابی و ۰ به معنای عدم خرابی می‌باشد و همچنین پنج ویژگی دمای هوا، دمای

فرآیند، سرعت چرخش، گشتاور و سایش ابزار نیز موجود می‌باشند که نمودار پراکندگی هر کدام از ویژگی‌ها در شکل (۱) تا (۵) نشان داده

شده است.

خرابی ماشین در این دیتاست از ۴ حالت مستقل تشکیل می‌شود که اولین مورد خرابی ناشی از ابزار است که اگر پارامتر سایش ابزار بین

۲۰۰ تا ۲۴۰ دقیقه باشد به احتمال زیاد دستگاه خراب می‌شود و ابزار باید تعویض شود. اگر اختلاف بین دمای هوا و دمای فرآیند کمتر از

۶/۸ کلوین باشد و سرعت چرخش ابزار نیز زیر ۱۳۸۰ دور در دقیقه باشد باعث خرابی ماشین می‌شود که به آن خرابی ناشی از اتلاف حرارت

می‌گویند. یکی دیگر از عوامل خرابی، قطع برق می‌باشد که یعنی اگر حاصل ضرب گشتاور و سرعت چرخش برابر با توان مورد نیاز برای

فرآیند نباشد، فرآیند با شکست مواجه می‌شود. یعنی اگر توان کمتر از ۳۵۰۰ وات یا بیشتر از ۹۰۰۰ وات باشد ماشین دچار قطعی برق و

خرابی می‌شود. آخرین پارامتری که ما در این پژوهش در نظر گرفته‌ایم فشار بیش‌ازحد می‌باشد که باعث خرابی و شکست می‌شود که اگر

حاصل جمع پارامترهای سایش ابزار و گشتاور بیشتر از ۱۱۰۰۰ دقیقه بر نیوتون متر باشد، فرآیند دچار خرابی می‌شود. در هر حال، اگر

هر کدام از این عوامل اتفاق بیافتد باعث خرابی ماشین و در نتیجه تنظیم

اجرای این الگوریتمها در نرم افزار پایتون و با کتابخانه sklearn و سیستم با رام ۸ و پردازنده Core i7 انجام شده است.

جدول (۳): نتایج طبقه بندی

نام مدل	دقت	زمان (ثانیه)	زمان/دقت
K نزدیکترین همسایه	۹۷ درصد	۰/۱۱۸۹	۲۸۱/۲۳۹
رگرسیون لجستیک	۹۷/۳ درصد	۰/۶۵	۱۲۰/۲۰۵
درخت تصمیم	۹۷/۹۵ درصد	۰/۲۶	۱۹۰/۲۹۱
جنگل تصادفی	۹۶/۹ درصد	۱/۳۵	۸۳/۲۳۹
ماشین بردار پشتیبان	۹۶/۹۵ درصد	۷/۰۸	۳۶/۴۱۳
بیز ساده	۹۶/۱ درصد	۰/۰۳	۵۲۳/۱۸۵


همان طور که از نتایج جدول (۳) مشخص است، الگوریتم درخت تصمیم در پیش بینی خرابیها عملکرد بهتری داشته است. اجرای این الگوریتم به زمان کمی به نسبت سایر الگوریتمها نیاز دارد و همان طور که در جدول (۴) نشان داده شده، درصد تشخیص درست خرابیها توسط این الگوریتم برابر با ۹۸/۸ درصد است. همین طور خراب نشدن ماشین را نیز در ۹۸/۸۶ درصد از موارد به درستی پیش بینی کرده، که در کل عملکرد بهتری نسب به سایر الگوریتمها می باشد.

جدول (۴): نتایج پیش بینی

نام مدل	پیش بینی صحیح خراب نشدن (درصد)	پیش بینی نادرست خرابی (درصد)	پیش بینی صحیح خرابی (درصد)
K نزدیکترین همسایه	۹۹/۱	۸۴/۳	۷/۲۵
رگرسیون لجستیک	۹۹/۵۹	۷۳/۰۲	۲۶/۹۸
درخت تصمیم	۹۸/۸۶	۳۰/۱۶	۶۹/۸۴
جنگل تصادفی	۱۰۰	۹۸/۴۱	۱/۵۹
ماشین بردار پشتیبان	۱۰۰	۹۶/۸۳	۳/۱۷
بیز ساده	۹۸/۶۱	۸۰/۹۵	۱۹/۰۵

کارایی الگوریتمهای طبقه بندی معمولاً توسط شاخص های جدول (۳) و (۴) سنجیده می شود. البته، در نمودار مشخصه عملکرد، از ترکیب دو شاخص صحت و دقت استفاده شده و به صورت یک منحنی نمایش داده می شود که در شکل (۷) آمده است.

مقدار عددی AUROC عددی بین صفر و یک است و قدرت تشخیص یا درستی نتایج یک آزمون را نشان می دهد. درستی نتایج آزمون به این بستگی دارد که روش آزمون، چقدر توانایی تفاوت گذاری درست بین نتایج مثبت صحیح و منفی صحیح را داشته باشد. اگر این عدد به یک نزدیک باشد، به معنای آن است که داده ها عموماً در بالای




شکل (۵): نمودار پراکندگی گشتاور

جدول (۲): دیتاست مسأله

خرابی ماشین	سایز ابزار	گشتاور	سرعت چرخش	دمای فرآیند	دمای هوا
0	135	53/9	1425	309/2	298/8
0	140	44/1	1412	309/2	298/8
1	143	4/6	2861	309/1	298/8

در شکل (۶) نیز نمونه ای از رابطه بین متغیرهای سرعت دوران و گشتاور با خرابی ماشین را نشان داده ایم که با افزایش سرعت دوران و کاهش گشتاور، ماشین خراب می شود. همچنین با افزایش گشتاور و کاهش سرعت دوران، ماشین خراب می شود.



شکل (۶): نمودار پراکندگی سرعت دوران و گشتاور


۴. طبقه بندی خرابیها

در این تحلیل برای صحت و مقایسه نتایج از ۶ الگوریتم طبقه بندی کننده، استفاده شده که عبارتند از: رگرسیون لجستیک^۱، درخت تصمیم^۲، جنگل تصادفی^۳، ماشین بردار پشتیبان^۴، بیز ساده^۵ و k نزدیکترین همسایه^۶. نتایج طبقه بندی نیز در جدول (۳) آمده است.

4. Support vector machine (SVM)
5. Naïve bayes
6. k nearest neighbor (KNN)

1. Logistic regression
2. Decision Tree
3. Random forest

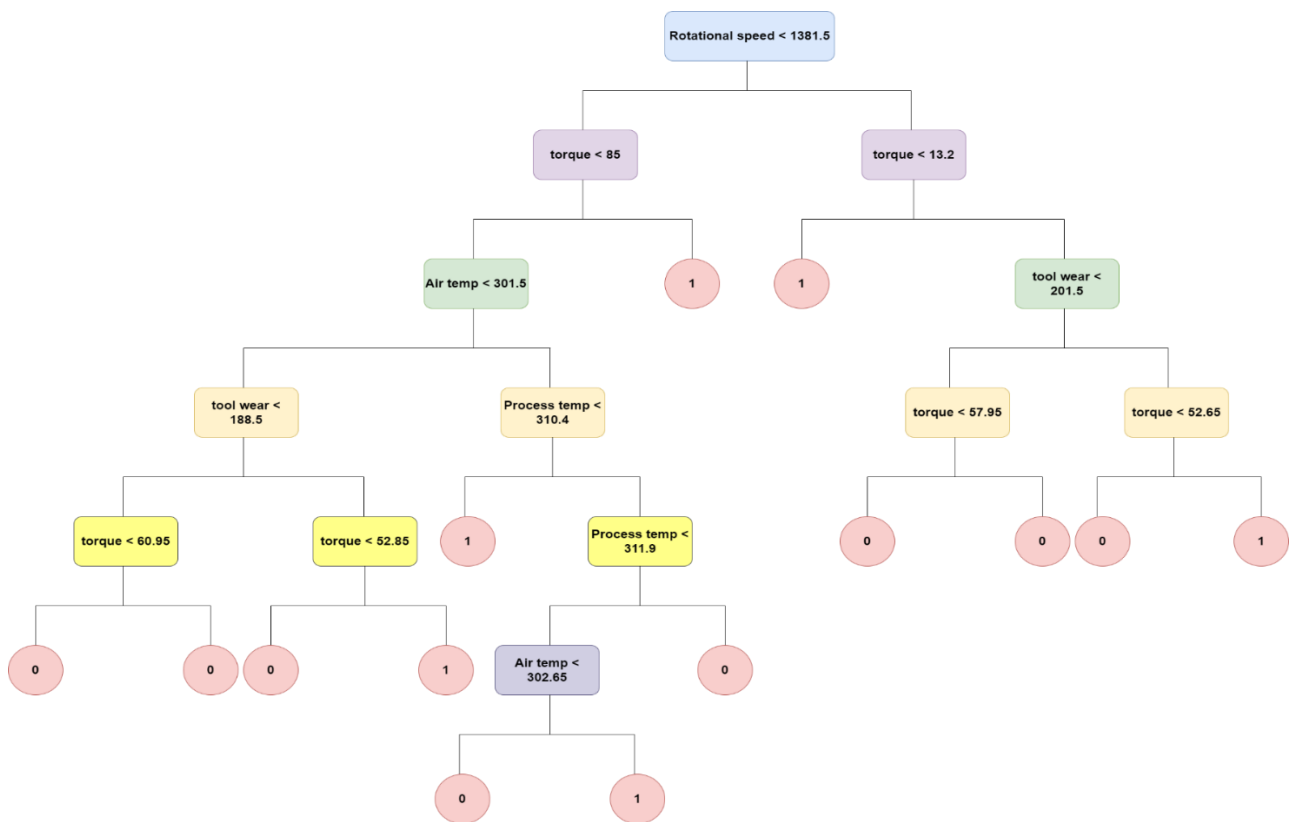
خط نیم‌ساز قرار گرفته‌اند و میزان نرخ مثبت صحیح بالا است و روش آزمون قدرت تشخیص یا درستی مناسبی دارد، که در مدل ما نیز به همین صورت است. همچنین برای تنظیم کردن درخت تصمیم از ۵ متغیر استفاده شده که تعداد گره‌های پایانی یا برگ‌های درخت برابر با ۱۴، انحراف میانگین باقی‌مانده و میزان خطای طبقه‌بندی به ترتیب برابر با ۰/۱۰۱۲ و ۰/۱۶۳۸ است. در شکل (۸) به صورت گرافیکی درخت را نمایش داده‌ایم.



شکل (۷): نمودار مشخصه عملکرد الگوریتم طبقه‌بندی درخت تصمیم

برخی از نتایج الگوریتم درخت تصمیم به صورت زیر می‌باشد:
 سرعت چرخش > ۱۳۸۱/۵ ← گشتاور > ۱۳/۲ ← سایش ابزار > ۲۰/۱/۵ ← ۵۲/۶۵ < گشتاور < ۵۷/۹۵ و
 سرعت چرخش > ۱۳۸۱/۵ ← گشتاور > ۶۵ ← دمای هوا > ۳۰/۱/۵۵ ← دمای فرآیند > ۳۱۰/۴ و
 سایش ابزار > ۱۸۸/۵ ← ۵۲/۸۵ < گشتاور < ۶۰/۹۵

برای مثال، قواعد حاصل از الگوریتم درخت تصمیم نشان می‌دهند که اگر سرعت چرخش کمتر از ۱۳۸۱/۵، و مقدار سایش ابزار کمتر از ۲۰/۱/۵، و مقدار گشتاور کمتر از ۵۷/۹۵ باشد، به احتمال بالایی ماشین خراب نمی‌شود. به علاوه، یکی از مشکلات رایج درختان طبقه‌بندی over fit شدن مدل است. رویکردی که برای کاهش این مشکل استفاده می‌شود، رویکرد اعتبارسنجی متقاطع می‌باشد. به این صورت که مدل را تنظیم می‌کنیم و مشاهده می‌نماییم که درخت با استفاده از چه پارامترهایی بهترین نتایج را نشان می‌دهد. در این مسأله، اعتبارسنجی متقاطع را با استفاده از معیارهای انحراف و نرخ طبقه‌بندی اشتباه حل نموده‌ایم. پس از مشاهده نتایج و مقایسه آن‌ها در کنار یکدیگر، (شکل (۹)) خط رسم شده نشان می‌دهد که حداقل تفاوت بین انحراف و طبقه‌بندی اشتباه رخ داده است. از آنجایی که طبقه‌بندی اشتباه و انحراف اعتبارسنجی متقاطع شده هر دو به حداقل تعداد شاخه‌های درخت طبقه‌بندی به دست آمده در مرحله قبل می‌رسند، پس هرس این درخت بیش از این نتیجه‌ای نخواهد داشت.



شکل (۸) نمایش گرافیکی درخت

آمده است.

جدول (۵): تعداد خرابی در هر دوره

شماره دوره	تعداد خرابی	شماره دوره	تعداد خرابی
۱	۱۳	۱۴	۲۴
۲	۵	۱۵	۸
۳	۹	۱۶	۷
۴	۱۳	۱۷	۹
۵	۱۰	۱۸	۹
۶	۶	۱۹	۷
۷	۹	۲۰	۶
۸	۸	۲۱	۹
۹	۶	۲۲	۹
۱۰	۸	۲۳	۸
۱۱	۱۵	۲۴	۶
۱۲	۵۴	۲۵	۷
۱۳	۵۷	۲۶	۱۷

جدول (۶): نتایج برآورد بیشینه درست نمایی

حداقل	1367.031
مقدار تخمینی	12.22713
گرادینان	7.438332×10^{-8}
تعداد تکرار برای حل	11

بنابراین، طبق نتایج جدول (۶) می توان متوجه شد که تقریباً بعداز هر ۳۰ ساعت، ماشین دچار شکست می شود. و متوسط زمان تعمیر^۳ به صورت زیر محاسبه می شود:


$$MTTR = \frac{1}{\lambda}$$

در یک مسأله نگهداری و تعمیر ماشین، مهم است که در آن ماشین به صورت منظم خدمت رسانی کند. به طور خاص، ما علاقه مندیم بدانیم چگونه چرخه های نگهداری و تعمیر ماشین ها را می توان آغاز کرد تا تمام نیازهای سرویس برآورده شود. بنابراین با داشتن متوسط زمان تعمیر می توان در مدل ریاضی مربوطه به محاسبه دقیق تر زمان بندی پرداخت و زمان های دردسترس نبودن ماشین را تخمین زد. در ادامه به تعریف مجموعه ها و اندیس ها، پارامترها، متغیرهای تصمیم، و روابط مدل ریاضی می پردازیم.

جدول (۷): مجموعه ها و اندیس ها

n	تعداد کارها
M	تعداد وضعیت ها
i	اندیس کارها
k	اندیس وضعیت

جدول (۸): پارامترها



شکل (۹): نتایج اعتبارسنجی متقاطع

۵. تعریف مسأله

در این بخش، یک مدل ریاضی غیرخطی برای مسأله زمان بندی تک ماشین فرموله شده است. در این مدل، قطع کار، زمان آزادسازی، و زمان بی کاری ماشین مجاز است. در ابتدا به تعریف پارامترها و متغیرهای تصمیم پرداخته و سپس به مدل برنامه ریزی عدد صحیح مختلط برای زمان بندی تک ماشین با در نظر گرفتن خرابی ها می پردازیم تا مجموع جریمه ها کاهش پیدا کند. در این مدل، زمان تعمیرات یا همان زمان بین خراب شدن و از دسترس خارج شدن ماشین تا زمان تعمیر و شروع به کار ماشین، به صورت تصادفی و با استفاده از توزیع نمایی حاصل می شود. زیرا این توزیع زمانی رخ می دهد که خرابی تجهیز ناشی از بروز خرابی در یکی از قطعات تشکیل دهنده آن باشد. همچنین تابع توزیع نمایی بدون حافظه است که کمک بزرگی به استفاده از آن، در هر کجای مسأله می کند. به زمان لازم جهت تعمیر یا سرویس دستگاه ها یا قطعات تعمیر پذیری سیستم یا قابلیت تعمیر^۱ می گویند. همان طور که مدت زمانی که طول می کشد تا دستگاه دچار خرابی شود یک متغیر تصادفی است، زمان تعمیر را هم می توان متغیر تصادفی در نظر گرفت. اگر فرض کنیم زمان تعمیر از تابع چگالی نمایی پیروی کند، در این صورت نرخ تعمیر ثابت بوده و تابع چگالی آن برابر است با:

$$f(x) = \lambda e^{-\lambda x} \quad x \geq 0$$

λ متوسط تعداد تعمیرهای ارائه شده در واحد زمان است و $\frac{1}{\lambda}$ متوسط طول زمان تعمیر می باشد. برای محاسبه λ از روش برآورد بیشینه تابع درست نمایی^۲ استفاده می کنیم، تا برآوردی از مقدار λ داشته باشیم. داده های مربوط به تعداد خرابی ماشین در سیستم، در جدول (۵)، آمده است. با فرض مستقل بودن خرابی ها از یکدیگر، توزیع نمایی برای این داده ها برازش شده و مقدار λ آن تخمین زده می شود. تعداد خرابی در هر دوره در جدول (۵) آمده است. در این جدول، هر دوره مربوط به ۴۵ روز است که هر روز دارای ۸ ساعت کارکرد دستگاه می باشد.

نتایج حاصل از روش برآورد بیشینه تابع درست نمایی در جدول (۶)

3. Medium Time to Repair (MTTR)

1. Maintainability
2. Maximum Likelihood Estimation (MLE)

$$T_i \geq C_i - d_i \quad i = 1, 2, \dots, n \quad (۱۴)$$

$$E_i \geq d_i - P_i - S_i \quad i = 1, 2, \dots, n \quad (۱۵)$$

$$T_i \geq 0 \quad (۱۶)$$

$$E_i \geq 0 \quad (۱۷)$$

$$u_{ik}, y_{ik} \in 0, 1 \quad (۱۸)$$

تابع هدف، تحویل زودتر از موعد و تأخیر کل را به‌طور هم‌زمان به حداقل می‌رساند. محدودیت (۲) ایجاب می‌کند که در هر موقعیت فقط یک قسمت قطع شده از یک کار قابل انجام باشد. محدودیت (۳) تضمین می‌کند که طول هر بخش قطع شده از یک کار که در ترتیب تخصیص داده می‌شود بزرگتر از واحد زمان، و کوچکتر از زمان پردازش آن باشد. این محدودیت تضمین می‌کند که طول هر قسمت قطع شده یک متغیر پیوسته بین کران پایین و بالایی آن باشد. محدودیت (۴) تضمین می‌کند که طول کل قطعات منقطع یک کار برابر با زمان پردازش آن باشد. محدودیت (۵) و (۶) زمان تکمیل موقعیت K ام را باتوجه به زمان آزادسازی کارها محاسبه می‌کند. زمانی که قطع کار مجاز باشد، می‌توان یک کار را قطع کرد و بعداً ادامه داد. بنابراین، یک کار می‌تواند چندین بار قطع شود. محدودیت (۷) زمان تکمیل هر کار را با مشخص کردن زمان تکمیل آخرین قسمت قطع شده هر کار محاسبه می‌کند. محدودیت (۸) زمان شروع اولین قسمت قطع شده هر کار را از موقعیت ۲ تا k تعیین می‌کند. محدودیت (۹) در صورت وجود، زمان شروع قسمت قطع شده هر کار را در موقعیت اول محاسبه می‌کند. درنهایت، محدودیت (۱۰) زمان شروع واقعی هر کار را براساس نتایج محاسبات قیود (۸) و (۹) نشان می‌دهد. محدودیت‌های (۱۲) و (۱۳) نیز تضمین می‌کنند که پایان یک کار باید قبل از شروع به‌کار دستگاه یا شروع کار پس‌از تعمیر و نگهداری (یعنی پس از شناسایی خرابی‌ها و راه‌اندازی مجدد) باشد. محدودیت‌های (۱۴) و (۱۵) به‌ترتیب هزینه‌های تحویل زودتر از موعد و دیرتر از موعد را برای هر کار محاسبه می‌کنند. همان‌طور که قبلاً ذکر شد، در اینجا، هزینه زود هنگام به زمان شروع گره خورده است، در حالی که هزینه‌های تأخیر همچنان به تکمیل کارها وابسته است. محدودیت (۱۸) نیازهای منطقی باینری و غیرمنفی را برای متغیرهای تصمیم فراهم می‌کند.

۲-۵. تفسیر مدل

در این بخش به مدل ریاضی می‌پردازیم. در این پژوهش تصمیم گرفتیم برای زمان بی‌کاری بین اجرای کارها، از جریمه ناشی از تحویل زودتر از موعد و یا تحویل دیرتر از موعد استفاده کنیم که به‌ترتیب طبق این روابط زیر اثبات می‌شوند:

$$E_i = \max(0, d_i - P_i - S_i)$$

$$T_i = \max(0, C_i - d_i)$$

در این روش، بعد از پیش‌بینی خرابی‌ها، به زمان‌بندی ماشین و کار می‌پردازیم. در این قسمت برای اطمینان از رویکرد مدنظر، به مقایسه نتایج پیش‌بینی خرابی توسط الگوریتم درخت تصمیم و توزیع نمای برآزش شده بر روی داده‌ها می‌پردازیم. برای این بخش در جدول (۱۰)، قسمتی از نتایج شروع خرابی‌ها در حالت واقعی و پیش‌بینی شده را با در نظر گرفتن توزیع نمای نشان داده‌ایم. این داده‌ها بعد از ۵۰ ساعت

p_i زمان نرمال پردازش قطعه i

r_i زمان آزادسازی قطعه i

α_i جریمه تحویل زودتر از موعد

β_i جریمه تأخیر در تحویل

d_i موعد تحویل کارها

M عدد بزرگ مثبت

SPM_k زمان شروع در دسترس نبودن ماشین

FPM_k پایان زمان در دسترس نبودن ماشین

جدول (۹): متغیرهای تصمیم

C_i	زمان اتمام کار قطعه i
y_{ik}	۱ می‌شود اگر قطعه i در K امین وضعیت زمان‌بندی شود و در غیر این صورت ۰
E_i	زمان تحویل زودتر از موعد هر قطعه
T_i	زمان تأخیر در تحویل هر قطعه
X_{ik}	طول منقطع وضعیت k ام قطعه i ام
S_i	زمان شروع کار قطعه i
S_i'', S_i'	متغیر کمکی محاسبه زمان شروع پردازش قطعه i
c_k	زمان تکمیل قطعه در وضعیت k ام
u_{ik}	اگر کار قطعه i قبل از دوره در دسترس نبودن ماشین در وضعیت k شروع شود یک می‌شود در غیر این صورت صفر

۵-۱. مدل ریاضی

$$Z = \min (\sum_{i=1}^n (\alpha_i E_i + \beta_i T_i)) \quad (۱)$$

$$\sum_{i=1}^n Y_{ik} \leq 1 \quad K = 1, 2, \dots, m \quad (۲)$$

$$Y_{ik} \leq X_{ik} \leq p_i \cdot Y_{ik} \quad i = 1, 2, \dots, n \quad k = 1, 2, \dots, m \quad (۳)$$

$$\sum_{k=1}^m X_{ik} = p_i \quad i = 1, 2, \dots, n \quad (۴)$$

$$S_i + P_i = X_{ik} - d_i \leq T_i \quad j = 1, 2, \dots, n \quad k = 1, 2, \dots, m \quad (۵)$$

$$c_k \geq c_{k-1} + \sum_{i=1}^n X_{ik} \quad k = 2, \dots, m \quad (۶)$$

$$c_k \geq \sum_{i=1}^n X_{ik} + Y_{ik} \cdot r_i \quad k = 1, \dots, m \quad (۷)$$

$$C_i = \max_{k=1}^m (Y_{ik} \cdot c_k) \quad i = 1, 2, \dots, n \quad (۸)$$

$$S_i' = \min_{k=2}^m (c_{k-1} \cdot M(1 - Y_{ik})) \quad i = 1, 2, \dots, n \quad (۹)$$

$$S_i'' = r_i + M(1 - Y_{ik}) \quad i = 1, 2, \dots, n, \quad k = 1 \quad (۱۰)$$

$$S_i' = \min(S_i', S_i) \quad i = 1, 2, \dots, n \quad (۱۱)$$

$$S_i + P_i = X_{ik} \leq SPM_k + M(1 - u_{ik}) \quad i = 1, 2, \dots, n \quad k = 1, 2, \dots, m \quad (۱۲)$$

$$S_i \geq FPM_k - M u_{ik} \quad i = 1, 2, \dots, n \quad k = 1, 2, \dots, m \quad (۱۳)$$

کارکرد توسط ماشین می باشد. زمان بندی مورد نظر برای مقایسه نتایج، اطلاعات پارامترها در جدول (۱۱) آمده است. برای پنج کار و یک ماشین در شکل (۱۰) نشان داده شده است.

جدول (۱۰): مقادیر نتایج شروع خرابی ها

مقدار واقعی	درخت تصمیم	توزیع نمایی	ساعت شروع خرابی	مقدار واقعی	درخت تصمیم	توزیع نمایی	ساعت شروع خرابی
۰	۰	۰	۱۱	۰	۰	۰	۱
۰	۰	۱	۱۲	۱	۰	۰	۲
۰	۰	۰	۱۳	۰	۱	۰	۳
۰	۰	۰	۱۴	۰	۰	۰	۴
۰	۰	۰	۱۵	۰	۰	۰	۵
۰	۰	۰	۱۶	۰	۰	۰	۶
۰	۰	۰	۱۷	۰	۰	۰	۷
۰	۰	۰	۱۸	۰	۰	۰	۸
۰	۰	۰	۱۹	۰	۰	۰	۹
۰	۰	۰	۲۰	۰	۰	۰	۱۰


می کنیم که نتایج نشان دهنده بهبود بوده و در قسمت بعد به آن پرداخته شده است.

جدول (۱۱): مقادیر پارامترها

کارها	p_i	r_i	α_i	β_i	d_i	Z^1	Z^2
کار ۲							
۱	۱	۳	۱	۲	۴	۰	۰
۲	۲	۱	۳	۱	۳		
کار ۵							
۱	۵	۴	۳	۲	۹		
۲	۳	۱	۲	۲	۵		
۳	۶	۷	۲	۲	۱۶	۴	۱۰
۴	۳	۱۷	۳	۲	۲۰		
۵	۲	۱۴	۲	۲	۱۸		
کار ۷							
۱	۵	۴	۳	۲	۹		
۲	۳	۱	۲	۲	۵		
۳	۶	۷	۲	۲	۱۶		
۴	۳	۱۷	۳	۲	۲۰	۲۷	۴۳
۵	۲	۱۴	۲	۲	۱۸		
۶	۳	۱۸	۳	۳	۲۴		
۷	۵	۲۰	۳	۳	۲۸		

۳-۵. الگوریتم فراابتکاری گرم شب تاب

این الگوریتم برگرفته از طبیعت است و عوامل متعددی در آن تأثیرگذار است. همچنین این الگوریتم الهام گرفته از الگوریتم چشمک زن کرم های شب تاب استوایی و الگوریتم جستجوی فاخته می باشد.



شکل (۱۰): توالی عملیات ۵ کار

همان طور که در شکل (۱۰) مشخص است، حالت (a) مربوط به زمان بندی با در نظر گرفتن زمان شروع خرابی براساس توزیع نمایی برازش شده بر داده ها است. حالت (b) مربوط به زمان بندی با در نظر گرفتن شروع خرابی ها براساس نتایج الگوریتم درخت تصمیم می باشد. در حالت (a) خرابی دوم در مدل اعمال شد، در صورتی که خرابی به وقوع نپیوست و باعث شد تا در کارها تأخیر به وجود بیاید و خرابی اول که در ساعت ۲ بوده است را نیز پیش بینی نکرده است که حتی این امر می تواند باعث وارد شدن هزینه ساخت مجدد قطعه یا دوباره کاری شود. ولی در حالت (a) هزینه کمتری به سیستم وارد می شود و تحویل به موقع را نیز خواهیم داشت. می توان نتیجه گرفت که روش پیشنهادی عملکرد واقع گرایانه تری برای مدل مسأله خواهد داشت تا بتوان از هزینه های کل کم کرد. همچنین از آنجایی که این مسأله زمان بندی در ابعاد بالا NP-hard می شود، شکوفی و رضاییان [۳] پیشنهاد داده اند برای توسعه کار از الگوریتم های فراابتکاری استفاده شود. ما نیز برای حل مسأله در ابعاد بالا از الگوریتم فراابتکاری گرم شب تاب، استفاده

شبه‌کد الگوریتم کرم شب‌تاب

```

Objective function  $f(x)$ ,  $x=(x_1, x_2, \dots, x_d)^T$ 
Generata initial population of fireflies  $x_i$ 
( $i = 1, 2, \dots, n$ )
Light intensity  $I_i$  at  $X_i$  is determined by  $f(X_i)$ 
Define light absorption coefficient  $\gamma$  While ( $t < \text{Max Generation}$ )
for  $i=1:n$  all  $n$  fireflies
    for  $j=1:n$  all  $n$  fireflies (inner loops)
        if ( $I_i < I_j$ ), Move firefly  $i$  towards  $j$ ; end if
        Vary attractiveness with distance  $\gamma$  via  $\exp[-\gamma r]$ 
        Evaluate new solution and update light intensity
    End for  $j$ 
End for  $i$ 
Rank the fireflies and find the current global best  $g^*$ 
End while
Postprocess results and visualization.
    
```

الگوریتم اولین بار توسط زین شی یانگ در دانشگاه کمبریج توسعه یافت [۳۶, ۳۷]. الگوریتم برای مناسبت که هرچه فاصله بین کرم شب‌تاب با کرم‌های شب‌تاب اطراف خود کمتر باشد راحت‌تر آن‌ها را جذب می‌کند. هرچه این فاصله بیشتر باشد اثر جذب کمتر می‌شود و این مفهوم از قوانین فیزیک نور برگرفته می‌شود که هرچه فاصله بیشتر شود، شدت نور کمتر می‌شود. سه قانون مهمی که این الگوریتم بهینه‌سازی از آن پیروی می‌کند عبارت است از:

- (۱) عامل جنسیت در کرم شب‌تاب برای جذب سایر کرم‌های شب‌تاب تأثیر ندارد.
- (۲) هرچه فاصله کمتر باشد، میزان جذب کرم‌های شب‌تاب بیشتر است.
- (۳) میزان روشنایی آن‌ها به واسطه مقدار تابع هدف مشخص می‌شود. مراحل اجرای این الگوریتم نیز به صورت زیر می‌باشد:

- (۱) تولید پاسخ‌های اولیه و ارزیابی آن‌ها
- (۲) به‌ازای هر کرم شب‌تاب مانند i ، به‌ازای هر کرم شب‌تاب مانند j ، اگر I_i کمتر از I_j باشد (j بهتر از i است).
- (۳) طبق فرمول جذب X' را تولید می‌کنیم که در آن γ ضریب جذب نور و β مقدار جذابیت می‌باشد. β_0 نیز مقدار جذابیت پایه‌ای می‌باشد و r فاصله بین دو منبع نور است و E بردار تصادفی‌ای می‌باشد که مؤلفه‌های این بردار می‌تواند دارای توزیع یکنواخت، گوسی و یا ... باشد. α هم ضریب این بردار است. همچنین I شدت نور دریافتی است که I_0 شدت نور پایه آن می‌باشد و فرمول محاسبه به صورت زیر است:

$$I = I_0 \cdot e^{-\gamma r^m}$$

$$X' = X_i + \beta(X_j - X_i) + \alpha E_i$$

$$\beta = \beta_0 e^{-\gamma r^m}$$

- (۴) ارزیابی کرم‌های شب‌تاب جدید
- (۵) تعیین بهترین پاسخ‌یافته شده
- (۶) تکرار از مرحله ۲ در صورت برآورده نشدن شرایط خاتمه. همچنین برای تغییر ضریب جهش α می‌توان از سه رویکرد متفاوت استفاده کرد که منجر به همگرایی آن می‌شود که α_0 مقدار اولیه و α_∞ مقدار آن بعد از بی‌نهایت تکرار می‌باشد که نحوه محاسبه هر کدام از این رویکردها در زیر آمده است:

الف: تغییر خطی

$$\alpha(t) = \alpha_0 + (\alpha_\infty - \alpha_0) \frac{t}{T}$$

ب: تغییر نمایی

$$\alpha(t) = \alpha_\infty + (\alpha_0 - \alpha_\infty) e^{-Kt}$$

ج: حالت خاص ($\alpha_\infty = 0$)

$$\alpha(t) = \alpha_0 (e^{-k})^t$$

به دلیل کم شدن α ، منجر به این می‌شود که همگرایی رخ دهد یا می‌توان برای رخ دادن همگرایی ضریب جذب نور را به مراتب بزرگتر کرد. در زیر شبه‌کد فرآیند الگوریتم کرم شب‌تاب را نشان داده‌ایم.

۶. نتایج

در این تحقیق ضرایب جریمه تحویل زودتر از موعد و تأخیر در تحویل به صورت تصادفی در نظر گرفته شده است. همچنین هزینه فشرده‌سازی و گسترش کارها نیز به صورت تصادفی لحاظ می‌شود. پارامتر SPM زمان شروع در دسترس نبودن ماشین است که توسط پیش‌بینی حاصل می‌شود و FPM نیز بعد از تعمیرات لازم و یا تعویض ابزارآلات با استفاده از توزیع نمایی تخمین زده می‌شود (که چه زمانی ماشین در دسترس می‌باشد). زمان پردازش و زمان موعد تحویل کار نیز به صورت پیش‌فرض لحاظ شده است. نتایج الگوریتم فراابتکاری کرم شب‌تاب با الگوریتم ژنتیک مقایسه شده که مقادیر آن‌ها در جدول (۱۲) به نمایش درآمده است. برای حل الگوریتم فراابتکاری نیز از نرم‌افزار متلب با رم ۸ و CPU Core I 7 استفاده شده است.

جدول شماره (۱۲): نتایج الگوریتم فراابتکاری

کرم شب‌تاب		ژنتیک	
RPD	زمان	تابع هدف	RPD
۰٪	۰	۰	۰
۰٪	۰/۰۲۷	۰/۰۱۵	۶
۰٪	۲/۵۳	۴/۱۱	۱۷
۰٪	۴/۴۶۷	۴/۱۵۶۲	۴۸۱
۰٪	۱۷/۳۸۵	۱۴/۱۰۹	۱۶۳۳

نتایج، نشان‌دهنده عملکرد مناسب الگوریتم کرم شب‌تاب در مقایسه با الگوریتم ژنتیک است. زیرا مقادیر محاسبه‌شده برای تابع هدف کمتر می‌باشد. همچنین برای مقایسه نتایج الگوریتم‌های

کمتری را برای حل نیاز دارد، اما مقادیر تابع هدف بیشتری را نسبت به الگوریتم گرم شب تاب دارا می باشد.

جدول (۱۳): نتایج آزمون t برای مقایسه الگوریتمها

مقدار P	مقدار t	خطای استاندارد میانگین	انحراف معیار استاندارد	میانگین الگوریتم	نوع
۰/۱۶۰۸	-۰/۵۶	۳/۲۴	۷/۲۳	۴/۹۲	FA
۰/۷۹۱	۰/۴۴	۰/۷۹۱	۱/۷۶۸	-۰/۴۴	تفاوت
۰/۱۷۸	۱/۶۳	۳۱۵	۷۰۴	۴۲۷	GA
۰/۱۷۸	۱/۶۳	۳۱۲	۶۹۹	۴۲۲	FA
۳/۰۷	۳/۰۷	۳/۰۷	۶/۸۶	۵	تفاوت
۰/۵۲	۰/۵۲	۰/۵۲	۱/۱۶۲	۰/۶۹۶	GA
۱/۳۴	۱/۳۴	۱/۳۴	۰	۰	FA
۰/۲۵۱	۰/۲۵۱	۰/۲۵۱	۱/۱۶۲	۰/۶۹۶	تفاوت

جدول (۱۴): نتایج آزمون ویلکاکسون برای مقایسه الگوریتمها

وضعیت	حد بالا فاصله اطمینان	حد پایین فاصله اطمینان	میان تخمینی	الگوریتم	نوع
+۱	۲/۲۶۸	۰	۰/۴	GA	زمان
-۱	۰	۰	۰	FA	زمان
-۱	۱۶۳۳	۰	۲۴۴	GA	تابع هدف
+۱	۱۶۲۰	۰	۲۳۸	FA	تابع هدف
-۱	۱۴/۱	۰	۰/۴	GA	RPD
+۱	۱۷/۴	۰	۲/۵	FA	RPD


۷. جمع بندی

در این مقاله تلاش کردیم با استفاده از الگوریتم درخت تصمیم به مجموعه ای از قواعد برای پیش بینی خرابی های ماشین آلات دست پیدا کنیم که در شکل (۸) نشان داده ایم. همچنین الگوریتم درخت تصمیم در ۶۹/۸ درصد مواقع پیش بینی درستی از خراب شدن ماشین داشته است که عملکرد بهتری را نسبت به الگوریتم های دیگر نشان داد. سپس با استفاده از مدل ریاضی، و اعمال این زمان خرابی در آن، به توالی عملیات بهینه دست پیدا کردیم. از آنجایی که این مسأله در ابعاد بالا NP-hard می شود، از دو الگوریتم بهینه سازی گرم شب تاب و ژنتیک استفاده نمودیم که مقایسه آماری نتایج این دو الگوریتم در جدول های (۱۲) و (۱۳) آورده شده است. در نهایت به این نتیجه رسیدیم که الگوریتم گرم شب تاب عملکرد بهتری نسبت به الگوریتم ژنتیک در این مسأله دارد. همچنین مقادیر تابع هدف در اجرای این الگوریتم کمتر از مقادیر تابع هدف در الگوریتم ژنتیک است. به علاوه، درصد انحراف نسبی اجرای الگوریتم گرم شب تاب نیز به نسبت الگوریتم ژنتیک کمتر است. همچنین برای کارهای آینده پیشنهاد می شود از این نوع رویکرد برای انواع زمان بندی های دیگر از جمله زمان بندی ماشین های موازی و


اعمال شده از درصد انحراف نسبی برای این مسأله استفاده شده است. هرچه میزان این انحراف کمتر باشد، عملکرد الگوریتم و کیفیت جواب بهتر است. میزان درصد انحراف نسبی از رابطه زیر به دست می آید:

$$RPD = \frac{sol - min_{sol}}{min_{sol}}$$

که در آن مقدار sol برابر با جواب مسأله در یک اجرا است و مقدار min_sol نیز برابر با کمترین مقدار جواب در بین تمام اجراها است. نتایج آن ها نیز در جدول (۱۲) ذکر شده است و در شکل های (۱۱) و (۱۲) نیز نمودار مستطیلی مربوط به زمان حل الگوریتمها و مقدار تابع هدف به نمایش درآمده است.



شکل (۱۱): نمودار مستطیلی مقدار زمان حل الگوریتمها



شکل (۱۲): نمودار مستطیلی مقدار تابع هدف

همچنین، برای بررسی نتایج الگوریتم های فرا ابتکاری از آزمون های ناپارامتری ویلکاکسون و همچنین از آزمون t برای مقایسه نتایج استفاده می کنیم. در جدول های (۱۳) و (۱۴) نتایج از لحاظ مقدار تابع هدف، زمان حل و مقدار RPD براساس این دو آزمون در سطح اطمینان ۹۵ درصد مورد بررسی قرار گرفته است. نتایج آزمون ویلکاکسون نشان دهنده عملکرد مناسب الگوریتم گرم شب تاب از نظر تابع هدف و RPD است و در جدول (۱۴) نشان داده شده است. همچنین زمان حل الگوریتم ژنتیک کمتر از زمان حل توسط الگوریتم گرم شب تاب است ولی با این که الگوریتم ژنتیک زمان

جریان کارگاهی استفاده کرد.

مراجع

- [16] Perez-Gonzalez, P. and J.M. Framinan, Single machine scheduling with periodic machine availability. *Computers & Industrial Engineering*, 2018. 123: p. 180-188.
- [17] Nesello, V., et al., Exact solution of the single-machine scheduling problem with periodic maintenances and sequence-dependent setup times. *European Journal of Operational Research*, 2018. 266(2): p. 498-507.
- [18] Shabtay, D. and M. Zofi, Single machine scheduling with controllable processing times and an unavailability period to minimize the makespan. *International Journal of Production Economics*, 2019. 198: p. 191-200.
- [19] Wang, J.-B., Y. Hu, and B. Zhang, Common due-window assignment for single-machine scheduling with generalized earliness/tardiness penalties and a rate-modifying activity. *Engineering Optimization*, 2021. 53(3): p. 496-512.
- [20] Choi, B.-C. and M.-J. Park, Single-machine scheduling with periodic due dates to minimize the total earliness and tardy penalty. *Journal of Combinatorial Optimization*, 2021. 41(4): p. 781-793.
- [21] Vollert, S., M. Atzmueller, and A. Theissler. Interpretable Machine Learning: A brief survey from the predictive maintenance perspective. in 2021 26th IEEE international conference on emerging technologies and factory automation (ETFA). 2021. IEEE.
- [22] Ayvaz, S. and K. Alpay, Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time. *Expert Systems with Applications*, 2021. 173: p. 114598.
- [23] Chen, C., et al., Predictive maintenance using cox proportional hazard deep learning. *Advanced Engineering Informatics*, 2020. 44: p. 101054.
- [24] Schmitt, J., et al., Predictive model-based quality inspection using Machine Learning and Edge Cloud Computing. *Advanced engineering informatics*, 2020. 45: p. 101101.
- [25] Schwendemann, S., Z. Amjad, and A. Sikora, A survey of machine-learning techniques for condition monitoring and predictive maintenance of bearings in grinding machines. *Computers in Industry*, 2021. 125: p. 103380.
- [26] Bilski, P., Application of support vector machines to the induction motor parameters identification. *Measurement*, 2014. 51: p. 377-386.
- [27] Calabrese, M., et al., SOPHIA: An event-based IoT and machine learning architecture for predictive maintenance in industry 4.0. *Information*, 2020. 11(4): p. 202.
- [28] Schmidt, B. and L. Wang, Predictive maintenance of machine tool linear axes: A case from manufacturing industry. *Procedia manufacturing*, 2018. 17: p. 118-125.
- [29] Chen, W.-J., Minimizing number of tardy jobs on a single machine subject to periodic maintenance. *Omega*, 2009. 37(3): p. 591-599.
- [30] Qamhan, A.A., et al., An exact method and ant colony optimization for single machine scheduling problem with time window periodic maintenance. *IEEE Access*, 2020. 8: p. 44836-44845.
- [31] Hou, Y.-T., et al., A single-machine scheduling problem with a deterioration model and partial maintenance. *Journal of Statistics and Management Systems*, 2018. 21(8): p. 1501-1511.
- [32] Laalaoui, Y. and R. M'Hallah, A binary multiple knapsack model for single machine scheduling with machine unavailability. *Computers & Operations Research*, 2016. 72: p. 71-82.
- [33] Wang, T., et al., A branch-and-price algorithm for scheduling of deteriorating jobs and flexible periodic maintenance on a single machine. *European Journal of Operational Research*, 2018. 271(3): p. 826-838.
- [34] Low, C., et al., Minimizing the makespan in a single machine scheduling problem with flexible periodic maintenance. *Journal of Manufacturing Systems*, 2019. 53: p. 104904.
- [1] Zainuddin, Z., P.A. EA, and M. Hasan, Predicting machine failure using recurrent neural network-gated recurrent unit (RNN-GRU) through time series data. *Bulletin of Electrical Engineering and Informatics*, 2021. 10(2): p. 870-878.
- [2] Guiras, Z., et al., Optimal maintenance plan for two-level assembly system and risk study of machine failure. *International Journal of Production Research*, 2019. 57(8): p. 2446-2463.
- [3] Mokhtari, H. and M. Dadgar, Scheduling optimization of a stochastic flexible job-shop system with time-varying machine failure rate. *Computers & Operations Research*, 2015. 61: p. 31-45.
- [4] Riazi, M., et al. Detecting the onset of machine failure using anomaly detection methods. in *International Conference on Big Data Analytics and Knowledge Discovery*. 2019. Springer.
- [5] Paprocka, I., Evaluation of the effects of a machine failure on the robustness of a job shop system—Proactive approaches. *Sustainability*, 2019. 11(1): p. 65.
- [6] Wang, Z., C.K. Pang, and T.S. Ng, Robust scheduling optimization for flexible manufacturing systems with replenishment under uncertain machine failure disruptions. *Control Engineering Practice*, 2019. 92: p. 104094.
- [7] SobASzek, Ł., A. Goła, and A. Świć, Time-based machine failure prediction in multi-machine manufacturing systems. *Eksploatacja i Niezawodność*, 2020. 22(1): p. 1-10.
- [8] Smadi, H.J. and A.K. Kamrani, PRODUCT QUALITY-BASED METHODOLOGY FOR MACHINE FAILURE ANALYSIS AND PREDICTION. *International Journal of Industrial Engineering*, 2011. 18(1): p. 1-10.
- [9] Shokoufi, K. and J. Rezaeian, An exact solution approach using a novel concept for single machine preemptive scheduling problem in the just-in-time production system. *Journal of Industrial and Production Engineering*, 2020. 37(5): p. 215-228.
- [10] Tsao, Y.-C., V.-V. Thanh, and F.-J. Hwang, Energy-efficient single-machine scheduling problem with controllable job processing times under differential electricity pricing. *Resources, Conservation and Recycling*, 2020. 161: p. 104902.
- [11] Cui, W.-W. and Z. Lu, Minimizing the makespan on a single machine with flexible maintenances and jobs' release dates. *Computers & Operations Research*, 2017. 80: p. 11-22.
- [12] Liu, Q., M. Dong, and F. Chen, Single-machine-based joint optimization of predictive maintenance planning and production scheduling. *Robotics and Computer-Integrated Manufacturing*, 2018. 51: p. 238-247.
- [13] Zhou, B. and T. Peng, New single machine scheduling with nonnegative inventory constraints and discretely controllable processing times. *Optimization Letters*, 2019. 13(5): p. 1111-1121.
- [14] Varela, M.L., et al., Collaborative paradigm for single-machine scheduling under just-in-time principles: total holding-tardiness cost problem. *Management and Production Engineering Review*, 2018. 9: p. 1-10.
- [15] Touat, M., F. Benbouzid, and B. Benhamou, Exact and metaheuristic approaches for the single-machine scheduling problem with flexible maintenance under human resource constraints. *International Journal of Manufacturing Research*, 2021. 12(1): p. 1-10.

- Engineering, 2014. 76: p. 333-346.
- [36] Yang, X.-S. and N.-I.M. Algorithms, Luniver press. Beckington, UK, 2008: p. 242-246.
- [37] Yang, X.-S. Firefly algorithms for multimodal optimization. in International symposium on stochastic algorithms. 2009. Springer.
- machine scheduling problems with flexible and periodic maintenance. Applied Mathematical Modelling, 2010. 34(2): p. 334-342.
- [35] Zammori, F., M. Braglia, and D. Castellano, Harmony search algorithm for single-machine scheduling problem with planned maintenance. Computers & Industrial



DOI: 10.22084/IER.2022.26080.2080

Single Machine Scheduling with Firefly Algorithm and Machine Failure Prediction with Data Mining Approach

R. Kamranrad^{1*}, A. Qorbani², Y. Rabani³, P. Falsafi⁴

¹. Assistant Professor, Department of Industrial Engineering, Faculty of Engineering, Semnan University, Semnan, Iran

². M. A. student in Industrial Engineering, Faculty of Engineering, Semnan University, Semnan, Iran

³. Assistant Professor, Department of Industrial Engineering, Faculty of Engineering, Semnan University, Semnan, Iran

⁴. M. A. student in Industrial Engineering, Faculty of Engineering, Semnan University, Semnan, Iran

ARTICLE INFO

Article history:

Received 13 August 2021

Accepted 20 February 2022

Keywords:

Machine Failure
Single Machine Scheduling
Data Mining
Just in Time

ABSTRACT

One of the problems in the industry is the forecast of unexpected events, and in this article we consider the single machine scheduling problem with considering to machine failure, and also looking for the minimizing tardiness and earliness penalties. In this research, a mathematical model for this problem is presented in which the processing times, idle time, release time and failure time as well as the availability time of the machine after repairs and maintenance are taken into article that failure times are predicted using machine learning algorithms. The results show that the proposed model is suitable for small dimensions with the desired parameters and to solve this problem in larger dimensions, the meta-heuristic algorithm has been used in this research. This research presents this problem in two parts: the first part is related to failure prediction and the second part is the sequence of single machine scheduling operations. In the first part, after receiving the previous data, we predict machine failures using machine learning algorithms and achieve a set of rules for process modification, and in the second part, we use the number programming model. Correctly mixed and considering these breakdowns and lack of access to machines in a single machine schedule.

* Corresponding author. Reza Kamranrad

Tel.:023-31532381; E-mail address: r.kamranrad@semnan.ac.ir