


Paper Type: Original Article



Online Job Shop Scheduling and Dynamic Predictive Maintenance by Machine Learning

Haed Tavakkoli-Moghaddam¹, Seyed Hesamoddin Zegordi^{1,*} , Mohammad Reza Amin-Nasseri¹

¹ Faculty of Industrial and Systems Engineering, Tarbiat Modares University, Tehran, Iran; h.tavakkoli@modares.ac.ir; zegordi@modares.ac.ir; amin_nas@modares.ac.ir.

Citation:



Tavakkoli-Moghaddam, H., Zegordi, S. H., & Amin-Nasseri, M. R. (2022). Online job shop scheduling and dynamic predictive maintenance by machine learning. *Journal of decisions and operations research*, 7(3), 496-515.

Received: 14/10/2021

Reviewed: 09/11/2021

Revised: 04/02/2022

Accepted: 05/02/2022

Abstract

Purpose: This paper proposes several innovative approaches to model evaluation after obtaining the reinforcement learning model of scheduling with predictive maintenance. To train this model, its reward and loss function must be determined according to the conditions of the workshop environment.

Methodology: This learning model is examined in different modes of work entry into the workshop and the results obtained from other scheduling methods show better outputs.

Findings: The predictive maintenance model is evaluated by four learning methods and the quality of these models is examined. By selecting and adding the best machine failure model to the scheduling reinforcement learning model, the instant tasks entered into the workshop are assigned to the machines. By comparing the proposed method with the previous ones, the best performance is found and shown.

Originality/Value: One of the innovations of this paper is to provide a definition of the reward function for the issue.

Keywords: Real-time scheduling, Predictive maintenance, Machine learning, Reinforcement learning, Data mining.

 Corresponding Author: zegordi@modares.ac.ir

 <http://dorl.net/dor/20.1001.1.25385097.1401.7.3.8.7>




Licensee. **Journal of Decisions and Operations Research**. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0>).



نوع مقاله: پژوهشی



زمان‌بندی کار کارگاهی بلادرنگ و نگهداری و تعمیرات پیشگویانه پویا با استفاده از یادگیری ماشین

هاند نوکلی مقدم^{۱*}، سید حسام‌الدین ذگردی^{۱*} ، محمدرضا امین ناصری^۱
دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران.

چکیده

هدف: در این مقاله، پس از به دست آوردن مدل یادگیری تقویتی زمان‌بندی با در نظر گرفتن نت پیشگویانه، چندین رویکرد ابتکاری برای ارزیابی مدل مطرح شده است. برای اینکه یک مدل یادگیری تقویتی آموزش داده شود، باید تابع پاداش و زیان آن با توجه به شرایط محیط کارگاه، تعیین شود.
روش‌شناسی پژوهش: این مدل یادگیری در حالت‌های مختلف ورود کار به کارگاه مورد بررسی قرار گرفته است.
یافته‌ها: نتایج به دست آمده از روش‌های دیگر زمان‌بندی، خروجی‌های بهتری را از خود نشان می‌دهد. مدل نت پیشگویانه، با چهار روش مدل‌سازی یادگیری مورد ارزیابی و کیفیت مدل‌ها مورد بررسی قرار می‌گیرد. با انتخاب و اضافه کردن بهترین مدل خرابی ماشین به مدل یادگیری تقویتی زمان‌بندی، کارهای بلادرنگ وارد شده به کارگاه، به ماشین‌ها تخصیص داده می‌شوند. با مقایسه روش مطرح شده و روش‌های پیشین مشخص شد که بهترین عملکرد را از خود نشان داده است.
اصالت/ارزش افزوده علمی: یکی از نوآوری‌های مقاله ارائه تعریف تابع پاداش برای مسئله مورد نظر می‌باشد.

کلیدواژه‌ها: نگهداری و تعمیرات پیشگویانه، زمان‌بندی کار کارگاهی بلادرنگ، یادگیری ماشین، یادگیری تقویتی.

۱- مقدمه

برنامه‌ریزی به‌عنوان تخصیص منابع (ماشین‌ها) برای کار در دوره‌های زمانی تعریف می‌شود. هدف برنامه‌ریزی بهینه‌سازی اهداف با ایجاد یک برنامه مؤثر است و فرایند برنامه‌ریزی، برای تخصیص مجموعه‌ای مشترک از منابع مانند منابع انسانی، منابع ماشین‌ها، خرید مواد اولیه در سیستم تولید و فرآیندهای تولید استفاده می‌شود. زمان‌بندی کارها، در حوزه برنامه‌ریزی تولید، به دنبال این است که انواع کارهای موجود در سیستم را به منابع موردنظر اختصاص دهد که هزینه‌های تولید کاهش یابد. امروزه بسیاری از محققان از یادگیری ماشین برای حل مشکلات برنامه‌ریزی کارخانه‌ها استفاده کرده‌اند؛ زیرا یادگیری ماشین این قابلیت را دارد که از دانش برنامه‌ریزی برای ایجاد بهترین برنامه برای سیستم تولید استفاده کند. علاوه بر این، برنامه زمان‌بندی‌های مبتنی بر یادگیری ماشین به‌راحتی با عوامل مختلف مانند مانیتورهای حسگر و سیستم‌های تشخیصی ادغام می‌شوند. علاوه بر این به‌کارگیری از دانش به‌دست‌آمده، سیستم‌های زمان‌بندی را قادر می‌سازد تا علاوه بر پیش‌بینی، واکنش بهتری نسبت به تغییرات پویا و تصادفی محیط کارخانه نشان دهد. در سیستم زمان‌بندی با استفاده از یادگیری ماشین معمولاً از یک سیستم شبیه‌سازی برای ایجاد اتفاق‌های تصادفی و پویا مختلف سیستم تولید و انتخاب بهترین برنامه برای هر یک از اتفاق‌ها استفاده می‌کند. پس از اینکه یک اتفاق تصادفی در سیستم رخ می‌دهد، یک روش یادگیری ماشین از مجموعه داده‌ها موجود در خط تولید برای تصمیم‌گیری‌های بعدی از جمله زمان‌بندی کارگاه، برنامه‌ریزی تولید و غیره استفاده می‌کند.

* نویسنده مسئول

zegordi@modares.ac.ir

<http://dorl.net/dor/20.1001.1.25385097.1401.7.3.8.7>





با پیشرفت روزافزون تکنولوژی و حجم عظیمی از داده در مراکز صنعتی، علم داده به کاربردی‌ترین علم در این محیط‌ها تبدیل شده است. اهمیت دادن کارخانه‌های تولیدی برای دستیابی به یک هدف مشخص مانند افزایش سودآوری و کاهش اختلالات تولید، چشمگیر می‌باشد (گوو و همکاران^۱، ۲۰۱۷). در طول ۱۰۰ سال گذشته تولید، چهار انقلاب صنعتی بزرگ را پشت سر گذاشته است. هم‌اکنون در حال گذر از انقلاب صنعتی چهارم^۲ هستیم که در آن داده‌ها از ماشین‌ها، محیط کارخانه و محصولات جمع‌آوری می‌شود که به وسیله این داده‌ها می‌توان به بینشی عمیق در تولید دست‌یافت.

جمع‌آوری داده بخشی از یک رویکرد پیش‌بینی می‌باشد که در آن تمرکز بر داده‌های زمان واقعی است و به دلیل مزایای آن در بهره‌وری تولید، رخداد اختلالات (خرابی ماشین‌ها) با توجه به شرایط پویا کارخانه از اهمیت بالایی برخوردار است. اهمیت و کاربرد موضوع تحقیق در صنعت‌های مورد استفاده شده توسط شرکت‌های بزرگ تولید، می‌تواند میزان بهره‌وری و سودآوری این مراکز را با بهینه‌سازی مسئله زمان‌بندی، با توجه به تغییرات ناگهانی در روند تولید، حداکثر کند. زمان یکی از منابعی است که در محیط‌های صنعتی لحاظ می‌شود و استفاده از یک فرایندی که بتواند در کمترین زمان ممکن تصمیمی اتخاذ کند، از اهمیت بالایی برخوردار می‌شود. به همین علت استفاده از هوش مصنوعی در فرایند تصمیم‌گیری‌های صورت گرفته در سیستم‌های پویا، نتایج مناسبی را به ارمغان می‌آورد.

تحقیقات اخیر نشان می‌دهد که اجرای روش‌های نگهداری و تعمیرات (نت) پیشگویانه^۳ به‌طور گسترده در صنایع تولیدی مورد استفاده قرار گرفته است. نت پیشگویانه به دلیل توانایی پیشگویی خرابی ماشین با اجرای الگوریتم‌های یادگیری ماشین که منجر به کاهش هزینه‌های نت می‌شود، استقبال فراوانی در صنعت تولید پیدا کرده است (کالاتاس و پاپوتسیداکیس^۴، ۲۰۲۱). در تحقیقات نشان داده شده است که انتشارات مقالات نت پیشگویانه از ۰/۵٪ در سال‌های ۲۰۰۹-۲۰۱۱ به ۱۱/۳٪ در سال‌های ۲۰۱۳-۲۰۱۸ افزایش یافته است. علاوه بر این، یادگیری ماشین نیز در مابقی بنابراین پیشگویی‌های به‌دست‌آمده از روش‌های یادگیری ماشین به ارائه برنامه ریزی دقیق به مدیریت نت کمک می‌کند و نت پیشگویانه به یک ابزار جدید برای نظارت و کنترل رویدادهای نگهداری تبدیل شده است.

۲- مروری بر ادبیات موضوع

نت پیشگویانه، نوعی از نگهداری است که وضعیت دستگاه‌هایی که در خط تولید در حال انجام کار می‌باشند را کنترل می‌کند. در صنعت ۴/۰ تمامی ماشین‌های موجود در محیط کارخانه شامل حسگرهایی هستند که با استفاده از این حسگرها می‌توان وضعیت ماشین‌ها را به‌صورت لحظه‌ای مورد ارزیابی قرارداد. در این قسمت به‌مرور ادبیات این زمینه که شامل نت و مدیریت آن، فن‌آوری‌های استفاده‌شده در نت و محاسبه آن پرداخته می‌شود.

در چرخه عمر تولید یک محصول، فعالیت‌های نت نقش خود را از فقط کارهای تعمیراتی به کنترل وضعیت محصول با توجه به عمر فیزیکی و عملکردی محصول تغییر پیدا کرده است (تاکتا و همکاران^۵، ۲۰۰۴). اکثر کارخانه‌هایی که سیستم صنعتی خود را ایجاد کرده‌اند، از سرمایه‌گذاری در کارخانه‌های جدید و مدرن تا زمانی که کارخانه‌های فعلی آسوده‌خاطر سودآوری خود را دارند، خودداری می‌کنند. در نتیجه، نت به یکی از اصلی‌ترین تأثیرات در افزایش حداکثر بهره‌وری در این شرایط تبدیل شده است. ثابت شده است که عملیات نت مؤثر برای بسیاری از عملیات در کارخانه‌ها نه تنها برای کاهش زمان خرابی تجهیزات، بلکه برای بهینه‌سازی در دسترس بودن یا قابلیت اطمینان کلی سیستم‌ها و ماشین‌ها، به حداقل رساندن هزینه‌ها و بهینه‌سازی‌های چندمنظوره امری ضروری دانست (مودونی و همکاران^۶، ۲۰۱۹).

با ظهور دیجیتالی شدن، بسیاری از تحقیقات قبلی در مورد استراتژی‌های نت پیشگیرانه متمرکز شده است که به کارخانه کمک می‌کند تا قابلیت دسترسی و قابلیت اطمینان سیستم‌های تولیدی، طول عمر مفید تجهیزات و در نهایت کیفیت محصولات را افزایش دهد (گوو و همکاران، ۲۰۱۷). سه رویکرد اصلی برای نت پیشگویانه وجود دارد که شامل مدل‌های مبتنی بر دانش، مدل‌های داده محور و مدل‌های

¹ Gu

² Industry 4.0

³ Predictive Maintenance

⁴ Kalathas and Papoutsidakis

⁵ Takata et al.

⁶ Modoni et al.



مبتنی بر فیزیک سیستم می‌باشد. تحقیقات گسترده‌ای برای هر یک از این رویکردهای مدل‌سازی، انجام شده است. با این حال، برای سیستم‌های پیچیده، مدل‌های ترکیبی بر اساس ترکیب این سه رویکرد می‌تواند دقت را در حل مسائل نت افزایش دهد (جیمز و همکاران^۱، ۲۰۲۰). این مدل‌ها به صورت مدل‌های مبتنی بر دانش، مدل‌های داده‌محور، مدل‌های مبتنی بر فیزیک می‌باشند. برخی از چالش‌های نت پیشگویانه شامل هزینه راه‌اندازی اولیه (ساکیب و وویست^۲، ۲۰۱۸)، میزان درستی و دقت داده‌ها (فینک^۳، ۲۰۲۰) و روش‌های مفید و کاربردی تجزیه و تحلیل داده‌ها (کالاتاس و پاپوتسیداکیس^۴، ۲۰۲۱) می‌باشد. با توجه به این چالش‌ها، تجزیه و تحلیل داده‌های اکتشافی می‌تواند در تصمیم‌نت که گرفته می‌شود، مفید واقع شود. این اولین گام اساسی در درک انواع مجموعه داده‌های نت می‌باشد (دیگل و همکاران^۵، ۲۰۱۱). تجزیه و تحلیل داده‌های اکتشافی امکان جستجوی الگوها و روندها را از حجم عظیمی از داده‌ها فراهم می‌کند و روش‌های مصورسازی داده‌ها نقش مهمی را ایفا می‌کند؛ بنابراین، تجزیه و تحلیل داده‌های اکتشافی نیز ریشه تجزیه و تحلیل در این مقاله است.

روش داده-محور به عنوان یک رویکرد مرسوم در به دست آوردن تقریبی زمان نت و خرابی ماشین می‌باشد. رویکرد داده‌محور همان‌گونه که از اسم رویکرد مشخص است، بر اساس حجم زیادی از داده‌ها ارائه شده است. در نتیجه رشد تصاعدی و روزافزون اطلاعات و داده‌های موجود در یک سیستم تولیدی، فرآیند تصمیم‌گیری مبتنی بر داده را از اهمیت بیشتری برخوردار می‌کند. به منظور اجرای عملیاتی نت پیشگویانه در رابطه با رویکرد داده‌محور، یکی از نیازهای اساسی این رویکرد، یک سیستم نظارت بر وضعیت فعلی که دارای حسگرهای با کیفیت بالا باشد (فینک، ۲۰۲۰). ان و همکاران^۶ (۲۰۱۵) بیان کردند که رویکرد داده‌محور شامل رویکردهای آماری و رویکردهای هوش مصنوعی است. آمار و نظریه احتمال اساس مدل‌های داده‌محور است. در دهه ۹۰، برخی از رویکردهای آماری معروف، فرآیند مارکوف و روش بیزی برای مطالعه احتمال خرابی دستگاه‌ها ایجاد شده‌اند (سکیب و همکاران، ۲۰۱۸). با ارائه داده‌های استخراج شده از شرایط کارخانه، می‌توان تنوع زیادی از برنامه‌ها را به دست آورد. به طور کلی، رویکردهای مختلف مزایای خاص خود را دارند. محققان با ادغام رویکرد مدل یادگیری ماشین و رویکرد مدل آماری به مدل‌های ترکیبی دست یافتند که نتیجه نشان می‌دهد مدل‌های ترکیبی از مدل‌های سنتی بهتر عمل می‌کنند (ژنگ و همکاران^۷، ۲۰۱۹).

تیدیری و همکاران^۸ (۲۰۱۶) تشخیص خرابی در صنایع طی سال‌های اخیر به طور فعال مورد تحقیق قرار گرفته است و آن‌ها عملکرد روش‌های مبتنی بر مدل و داده‌محور را در تشخیص خرابی فرآیند مورد مطالعه قراردادند. رویکرد داده‌محور تشخیص خرابی‌ها را به عنوان وظایف طبقه‌بندی انجام می‌دهد و از هر دو روش طبقه‌بندی تحت نظارت و بدون نظارت استفاده می‌کند. همچنین این مقاله درباره استفاده از شبکه‌های بیزی و شبکه‌های عصبی مصنوعی در تشخیص خرابی را نیز مورد ارزیابی و بررسی قرار می‌دهد. بوسدکیز و همکاران^۹ (۲۰۱۹) تحقیقات مختلفی در حوزه نت انجام شده است را مورد بحث و بررسی قراردادند و شکاف تحقیق را مشخص کردند. این مقاله توصیه‌های تحقیقاتی مختلف آینده را ارائه می‌دهد که یکی از آن‌ها، توسعه مدل‌های تصمیم‌گیری که نشان‌دهنده فرآیند تصمیم‌گیری است. همچنین به ایجاد مدل‌های تصمیم‌گیری کلی که در تولید تجهیزات با استفاده از تجزیه و تحلیل تجربی، هوش مصنوعی و الگوریتم‌های یادگیری ماشین در مجموعه داده‌های مربوط به نت و تعمیرات (نت) تاریخی که قابل استفاده است، اشاره می‌کند. علاوه بر این، اهمیت تحقیق در زمینه توسعه روش‌های داده‌محور برای ساخت مدل‌های تصمیم‌گیری نیز با برجسته کردن روند فعلی تحقیقات که بر ایجاد مدل‌های تصمیم‌گیری متمرکز دارد تا با استفاده از تجزیه و تحلیل داده‌های بزرگ، مداخله کمتر انسان در تصمیم‌گیری را متذکر می‌شود.

تصمیم‌گیری در نت پیشگویانه نشان می‌دهد که توسط پیش‌بینی‌های زمان واقعی (به عنوان مثال در مورد خرابی آینده) به منظور ایجاد توصیه‌های مناسب در مورد اقدامات نت که تاثیر شکست پیش‌بینی شده را حذف یا کاهش می‌دهد، ایجاد می‌شود. مروری بر ادبیات فعلی بر الگوریتم‌های تصمیم‌گیری برای نت پیشگویانه متمرکز است. به این معنا که الگوریتم‌های تصمیم‌گیری را بررسی می‌کند که توسط پیش‌بینی‌هایی که از طریق نظارت بر شرایط به دست آمده‌اند، ایجاد می‌شوند. نظارت بر شرایط یا همان فرآیند نظارت بر وضعیت، به منظور شناسایی تغییراتی که نشان‌دهنده خطایی است که در حال افزایش است. این جزء اصلی نت پیشگویانه است (مارکز و همکاران^۹، ۲۰۱۲). طی سال‌های گذشته، به دلیل ظهور صنعت ۴/۰ و اینترنت اشیا، روش‌های نظارت بر وضعیت از بازرسی بصری و تجزیه و تحلیل دستی

¹ Jimenez et al.

² Sakib and Wuest

³ Fink

⁴ Diggle et al.

⁵ An et al.

⁶ Zhang et al.

⁷ Tidiri et al.

⁸ Bousdekis et al.

⁹ Márquez et al.

مجموعه داده‌ها به حسگرهای فرکانس بالا تبدیل شده است که داده‌های بزرگ را در زمان واقعی در مورد چندین متغیر تولید می‌کند (به‌عنوان مثال ارتعاش، دما، ترموگرافی و غیره). بر اساس این داده‌ها، روش‌های پیشرفته تجزیه و تحلیل داده‌ها را می‌توان برای کنترل عدم قطعیت ناشی از عملیات تولید تصادفی به کار گرفته شود.

الگوریتم‌های تصمیم‌گیری باید چندین محدودیت و هدف را در نظر گرفته و بهترین برنامه نت را ارائه دهد، به عبارتی دیگر برنامه‌ای که هزینه‌های نت را به حداقل برساند و عملکرد کلی فرآیند تولید را بهینه کند. نت مبتنی بر شرایط با افزایش برنامه‌ریزی دقیق فعالیت‌های نت، از افزایش کارایی مدیریت نت پشتیبانی می‌کند. در نت پیشگویانه، داده‌ها مورد تجزیه و تحلیل قرار گرفته و سپس از الگوریتم‌های مختلفی برای پیش‌بینی خرابی‌های احتمالی ماشین استفاده می‌کند. نت پیشگویانه این قابلیت را دارد که (۱) از کیفیت محصول اطمینان حاصل شود، (۲) نت به موقع انجام شود، (۳) خرابی تجهیزات به حداقل برسد و از خرابی ابزار ماشین جلوگیری شود (گاوو و همکاران^۱، ۲۰۱۵). رویکرد نت پیشگویانه مبتنی بر شرایط توسط مورترزیز^۲ (۲۰۱۵) پیشنهاد شده است.

مسئله زمان‌بندی در کف کارخانه، طبق تحقیقات مختلف که صورت گرفته است را با استفاده از قواعد توزیع، روش‌های ابتکاری، روش‌های فرا ابتکاری، روش‌های هوش مصنوعی و سیستم‌های چندعاملی می‌توان حل کرد (یاداو و جایسوال^۳، ۲۰۱۸). در کاربردهای صنعتی، برنامه‌ریزی تقریباً در شرایط پویا انجام می‌شود، به این معنا که نقطه‌ای که وظایف یا کارهای جدید در سیستم تولید وارد می‌شوند ناشناخته است. زیاده متغیرهایی مانند تقاضا، در دسترس بودن مواد اولیه و خرابی ماشین بستگی دارد؛ بنابراین، هر برنامه زمانی مورد استفاده باید انعطاف‌پذیر باشد تا با محیط تولیدی که به صورت پیوسته در حال تغییر است، سازگار باشد. در چنین شرایط پویایی، قواعد توزیع اغلب برای زمان‌بندی مورد استفاده قرار می‌گیرد و قواعد مختلف توزیع برای رسیدگی به طیف وسیعی از معیارهای برنامه‌ریزی تکامل یافته است (بوازا و همکاران^۴، ۲۰۱۹). باین حال، در صورت ارائه یک قواعد توزیع جدید، معمولاً بر اساس تعداد محدودی از معیارهای زمان‌بندی آزمایش می‌شود؛ بنابراین در زمان آنی (بلادرنگ یا لحظه‌ای) تنها با تعدادی از قواعد توزیع دیگر مقایسه می‌شود. ادبیات موجود در این زمینه فاقد مطالعاتی است که تمام قواعد توزیع موجود را با یکدیگر مقایسه کند، بنابراین تعیین نحوه مقایسه قواعد توزیع در معیارهای برنامه‌ریزی مختلف مشکل‌ساز می‌باشد. باین حال، یک مطالعه فراوان تعداد زیادی از قواعد توزیع را در نه معیار برنامه‌ریزی و چهار نوع مشکل و طیف وسیعی از ماشین‌ها و تغییرات کارها گردآوری کرده است (دوراسویچ و جکوبوویچ^۵، ۲۰۱۸).

در بخش بعدی، بیان و اهمیت مسئله و ابزارهایی مورد نیاز برای روش تحقیق پرداخته می‌شود. در بخش چهارم، نتایج محاسباتی و طراحی سیستم مورد بررسی قرار می‌گیرد و مقایسه بین الگوریتم‌های ابتکاری به کار برده شده در روش تحقیق نشان داده می‌شود؛ و در آخر به نتیجه‌گیری‌های به دست آمده از این مقاله، پاسخ سیستم و پیشنهادهای برای تحقیقات آتی پرداخته می‌شود.

۳- مسئله نت پیشگویانه پویا و زمان‌بندی کار کارگاهی بلادرنگ

یک خط تولید بهینه برای محصولات تولیدی ضروری است تا از تقاضای به موقع بازار اطمینان حاصل کند و در نتیجه رشد سازمان را تشکیل دهد. خروجی تولید در یک کارخانه در راستای عملکرد مناسب و بدون وقفه ماشین‌های درگیر در کل خط تولید است. هرگونه توقف یا خرابی ماشین‌ها در خط تولید منجر به از دست دادن زمان تولید و همچنین مشکلات اقتصادی برای کارخانه و مراکز صنعتی می‌شود.

یک مشکل زمان‌بندی در خط تولید به طور معمول از متغیرها و محدودیت‌های زیادی شامل می‌شود. لذا این مسئله زمان‌بندی به طور کلی در خانواده مسائل چندجمله‌ای نامعین سخت^۶ تلقی می‌شود؛ بنابراین، الگوریتم‌های ابتکاری و فرا ابتکاری^۷ به روشی متداول برای دستیابی به راه‌حل‌های نزدیک به بهینه برای مشکلات برنامه‌ریزی در سال‌های اخیر تبدیل شده است. باین حال، سیستم‌های تولید در

¹ Gao et al.

² Mourtziz

³ Yadav and Jayswal

⁴ Bouazza et al.

⁵ Đurasević and Jakobović

⁶ Job Shop Scheduling

⁷ Job Shop Scheduling





دنیای واقعی همیشه دارای عدم قطعیت‌های زیادی مانند تغییر زمان فرآیند و خرابی دستگاه‌های تولیدی هستند؛ بنابراین راه‌حل مطلوب در گذشته ممکن است در شرایط فعلی، نامناسب و غیرعملی باشد و برای بازسازی راه‌حل جدید به زمان زیادی نیاز خواهد بود. وضعیت یک سیستم تولیدی به‌طور مداوم تغییر می‌کند که می‌توان عملکرد سیستم را با اجرای یک سیاست زمان‌بندی درست به‌جای استفاده از یک قواعد توزیع^۱ اکتشافی واحد در یک افق برنامه‌ریزی گسترده، بهبود بخشید. این سیاست بر اساس وضعیت سیستم در هر نقطه تصمیم‌گیری، در یک سری افق‌های دوره‌ای مشخص، برنامه‌ریزی کوتاه‌مدت را انجام می‌دهد.

مسئله تعریفی به زمان‌بندی بلادرنگ^۲ (یا آتی) کارهای جدیدی که وارد فرآیند تولید کارگاه می‌شود، با در نظر گرفتن احتمال خرابی دستگاه‌ها، پرداخته می‌شود. برای تخصیص و تشخیص توالی کارها بلادرنگ به ماشین‌ها، با در نظر گرفتن احتمال خرابی هرکدام از این ماشین‌ها، نیازمند یک راه‌حل یکپارچه است. مسئله مقاله به دنبال این است که در هر لحظه که تقاضای^۳ جدید وارد محیط کارگاه می‌شود، شرایط کارگاه که شامل کارهایی که در حال حاضر بر روی دستگاه‌ها فرآیندشان انجام می‌شود و در نظر گرفتن پارامتر خرابی هرکدام از ماشین‌ها، این تقاضاهای جدید را به ماشین‌هایی که فرآیندشان تمام شده است، بدون دخالت نیروی انسانی به ماشین‌ها اختصاص دهد.

در این مسئله، هر تقاضایی که وارد سیستم می‌شود با توجه به توالی فرآیند آن بر روی دستگاه‌ها که از بدو ورود کار توالی آن مشخص شده است، یک زمانی برای پردازش می‌بایستی بگذرد. هر کار جدید که می‌رسد توالی ماشین‌های آن با کار قبلی متفاوت می‌باشد و در هر لحظه سیستم، پردازش‌هایی که بر روی کارها صورت می‌گیرد را مورد بررسی قرار می‌دهد. حالت و مکان هر یک از کارها مشخص و قابل کنترل می‌باشد. با ورود کار جدید در کارگاه، با استفاده از الگوریتم یادگیری تقویتی، یک زمان‌بندی جدید برای کارهایی که در حال پردازش هستند صادر می‌شود. از آنجایی که یادگیری تقویتی به روش پاداش و زیان سیستم خود را بهبود می‌بخشد، این سیستم برای اینکه بتواند به‌صورت بهینه تخصیص کار به ماشین‌ها در شرایط تغییر محیط کارگاه انجام دهد نیاز به مدت‌زمان برای آموزش الگوریتم تخصیص خود دارد. هر چه این یادگیری بیشتر صورت گیرد مدت‌زمانی که بتواند با تغییرات کارهای ورودی جدید تطبیق پیدا کند، کمتر خواهد بود.

روش‌هایی که در گذشته در زمان‌بندی کار کارگاهی^۴ استفاده می‌گردید از مفروضات اصلی این‌گونه بود که منابع تولید و نیازهای کاربر را ثابت در نظر می‌گرفت. با این حال، در شرایط واقعی زمان‌بندی تولید، عملیات تولید و منابع کارخانه به‌طور ناهموار توزیع می‌شود و شرایط اضطراری مانند انجام کارهای تصادفی، خرابی ماشین و کمبود مواد در هر زمان ممکن است رخ دهد؛ بنابراین، سازگاری با همچنین محیط پویا که با تغییرات زیادی همراه است، الزامی می‌باشد. نت به‌عنوان فعالیتی تلقی می‌شود که فقط در صورت خرابی دستگاه مورد ارزیابی و بررسی می‌باشد که در دنیای تکنولوژی امروزه از اهمیت بسیاری برخوردار شده است. استراتژی‌های نت منظم برنامه‌ریزی شده و پیشگیرانه با روش‌های کامپیوتری در مراکز صنعتی رواج پیدا کرده است. این بازرسی دوره‌ای از ماشین‌ها به شناسایی مشکلات اولیه کمک می‌کند تا خرابی‌ها به حداقل برسند و توقف در تولید محصول کاهش یابد.

اگر بتوان یک سیستم یکپارچه‌ای که توانایی این را داشته باشد که هم‌زمان خرابی ماشین‌هایی که در خط تولید در حال انجام کارها هستند و کارهای جدیدی که وارد خط تولید می‌شوند را در نظر بگیرد، از اهمیت بالایی برخوردار است. یک سیستمی که بتواند باگذشت زمان الگوریتم تخصیص کارها به ماشین‌ها را بهبود بخشد و سودآوری کارخانه و مراکز صنعتی را افزایش دهد. از ویژگی‌های این سیستم، توانایی پاسخگویی به تغییرات لحظه‌ای که در کارگاه به وجود می‌آید واکنش نشان داده و خود را باهدف بهبود محیط کارگاه تغییر و تطبیق می‌دهد. استفاده از الگوریتم‌های دقیق^۵ برای حل این مسئله بسیار مشکل و از نظر زمانی امکان‌پذیر نمی‌باشد. لازم به ذکر است که الگوریتم‌های فرا ابتکاری نیز کیفیت جواب را پایین آورده و شاید نتواند پاسخ خود را به زمان موردنیاز سیستمی که همواره در حال تغییر است، برساند. با استفاده از روش‌های یادگیری ماشین می‌توان سیستمی طراحی کرد که اگر در محیط کارگاه تغییراتی صورت گرفت، پاسخ سریع نسبت به شرایط به وجود آمده دهد و این امکان را فراهم می‌کند که با توجه به یادگیری تقویتی هر روز کیفیت پاسخ مسئله افزایش یابد. یک زمان‌بندی

¹ Dispatching Rule

² Online Scheduling

³ Demand

⁴ Job Shop Scheduling

⁵ Exact Algorithms

خوب می‌تواند مزایایی مانند افزایش توان کارگاه، افزایش رضایت مشتری، کاهش سطح موجودی و افزایش استفاده از منابع را ارائه دهد؛ بنابراین، نیاز زیادی به استراتژی‌های برنامه‌ریزی خوب در کارخانه‌ها احساس می‌شود.

همان‌گونه که ذکر شد، زمان‌بندی بلادرنگ نقش مهمی در عملکرد پیچیده، پویا و بسیار تصادفی محیط کارگاه دارد. هدف این مقاله طراحی مدلی یکپارچه شامل نت و زمان‌بندی محیط کارگاهی می‌باشد. یکی از مزایای این مدل افزایش بهره‌وری محیط کارگاه^۱ می‌باشد. این مدل با استفاده از حسگرهای موجود در محیط کارگاه درک جامعی از سیستم کارگاه به وجود می‌آورد و به مرور زمان فرآیند خود را بهبود می‌بخشد و بهترین قواعد عزام را برای تخصیص کارها جدید اتخاذ می‌کند. لازم به ذکر است که با پیاده‌سازی مدل نت پیشگویانه در یک محیط صنعتی دسترسی ماشین‌ها افزایش می‌یابد. این افزایش دسترسی ماشین‌ها در محقق شدن اهداف زمان‌بندی کمک شایانی می‌کند که در نتیجه زمان تحویل سفارش‌ها به حداقل می‌رسد و این خود نوعی رضایت مشتری را به همراه دارد.

۱-۳- مفروضات مسئله

مفروضات مسئله مطرح‌شده در قسمت زیر ارائه می‌شود:

- کار مستقل هستند و از توالی عملیاتی (یا مسیرهای کاری) کاملاً منظم تشکیل شده‌اند.
- همه‌ی کارها از اهمیت یکسان برخوردارند.
- حذف یا لغو عملیات مجاز نیست. هنگامی که پردازش هر عملیاتی بر روی یک ماشین شروع شد، نمی‌توان آن را قبل از اتمام کار قطع کرد و سپس در زمان بعدی از سر گرفت.
- فقط یک دستگاه از هر نوع در کارگاه وجود دارد و عملیات دو کار مختلف را نمی‌توان هم‌زمان در یک دستگاه پردازش کرد.
- عملیاتی شروع نمی‌شود مگر اینکه عملیات قبلی به پایان برسد.
- کار جدید در هر لحظه به‌صورت تصادفی وارد سیستم شود.
- سیستم از کارها جدید مطلع نیست.

۲-۳- مدل نت پیشگویانه بر اساس یادگیری ماشین


برخلاف نت تحت شرایط معمولی که از وضعیت حال حاضر کل ماشین و یا قسمتی از ماشین را مورد بررسی قرار می‌دهد، سیاست نت پیشگویانه ویژگی خرابی را مبتنی بر اطلاعات زمان واقعی و نظارت لحظه‌ای ماشین عمر مفید باقی‌مانده قطعات دستگاه را پیشگویی می‌کند. در این روش، با به دست آوردن عمر مفید باقی‌مانده اولیه یک برنامه‌نگهداری توسعه داده می‌شود و با استفاده از خروجی و سیگنال سنسورهای نصب بر روی ماشین، این عمر مفید به‌صورت آنی و زمان واقعی به‌روز می‌شوند. برنامه اقدامات مربوط به نت بر اساس آخرین تغییرات مقادیر سنسورها، باقی‌مانده عمر مفید دستگاه به‌روز می‌شود. در واقع مزایای نت پیشگویانه که شامل کمک به تعیین وضعیت تجهیزات و پیش‌بینی زمان نت می‌باشد که در کارخانه‌های بزرگ بسیار استراتژیک است. پیاده‌سازی این مدل مبتنی بر یادگیری ماشین می‌تواند منجر به صرفه‌جویی عمده در هزینه‌ها، دقت در پیش‌بینی خطا در ماشین و افزایش در دسترس بودن ماشین‌ها می‌شود.

۱-۲-۳- جنگل تصادفی

جنگل تصادفی یک الگوریتم یادگیری تحت نظارت است. جنگلی که می‌سازد، مجموعه‌ای از درختان تصمیم است که معمولاً با روش کیسه آموزش داده می‌شود. ایده کلی روش کیسه زدن این است که ترکیبی از مدل‌های یادگیری نتیجه کلی را افزایش می‌دهد. جنگل تصادفی درختان تصمیم‌گیری متعددی می‌سازد و آن‌ها را باهم ادغام می‌کند تا پیش‌بینی دقیق‌تر و پایدارتری به دست آید. یک مزیت بزرگ جنگل تصادفی این است که می‌تواند برای مشکلات طبقه‌بندی و رگرسیون که اکثر سیستم‌های یادگیری ماشین فعلی را تشکیل می‌دهند، مورد استفاده قرار گیرد. با در نظرگیری جنگل تصادفی به‌صورت طبقه‌بندی می‌باشد، زیرا طبقه‌بندی گاهی اوقات به‌عنوان بلوک



^۱ Shop Floor



اصلی یادگیری ماشین در نظر گرفته می‌شود. با توجه به اهمیت این ویژگی قادر به تصمیم‌گیری درست می‌باشد که کدام ویژگی‌ها احتمالاً حذف شوند زیرا به اندازه کافی (یا گاهی اوقات هیچ‌چیز) در فرایند پیش‌بینی کمک نمی‌کنند (عبدالکریم و عبدالعزیز^۱، ۲۰۲۱).

۲-۲-۳- مدل‌های خطی تعمیم‌یافته

مدل‌های خطی تعمیم‌یافته^۲ (GLMs) یکی از پرکاربردترین روش‌های مدل‌سازی استنباطی است. سادگی آن‌ها تفسیر آن‌ها را آسان می‌کند، بنابراین هنگام برقراری ارتباط استنباط با ذینفعان، آن‌ها یک ابزار بسیار مؤثر هستند. نظم دهی الاستیک^۳، یک روش منظم پرکاربرد، یک جفت شدن منطقی با GLM است. ویژگی‌های بی‌اهمیت و بسیار مرتبط را حذف می‌کند که می‌تواند هم به دقت و هم به نتیجه‌گیری آسیب برساند. در آمار و یادگیری ماشین، Lasso (حداقل جمع‌کننده و انتخاب مطلق اپراتور؛ همچنین Lasso) یک روش تحلیل رگرسیون است که هم انتخاب متغیر و هم منظم سازی را انجام می‌دهد تا دقت پیش‌بینی و قابلیت تفسیر مدل آماری حاصله را افزایش دهد. Lasso در ابتدا برای مدل‌های رگرسیون خطی تدوین شد. این مورد ساده مقدار قابل توجهی در مورد برآورد کننده نشان می‌دهد. این‌ها شامل رابطه آن با رگرسیون خط راسی و بهترین انتخاب زیر مجموعه و ارتباطات بین برآورد ضریب لاسو و به اصطلاح آستانه نرم است. همچنین نشان می‌دهد که (مانند رگرسیون خطی استاندارد) اگر متغیرهای خطی باشند، برآورد ضریب نیازی به منحصربه‌فرد بودن ندارد. وقتی تعداد متغیرهای بیشتر از اندازه نمونه است لاسو می‌تواند فقط تعدادی از متغیر را انتخاب کند و تمایل دارد که یک متغیر از هر مجموعه متغیرهای همبسته زیادی را انتخاب کند. شبکه الاستیک به صورت زیر می‌باشد که λ ضریب رگرسیون می‌باشد (گوریز و ساکلین^۴، ۲۰۲۰).

$$\min_{\beta^* \in \mathbb{R}^p} \left\{ \|y^* - X^* \beta^*\|_2^2 + \lambda \|\beta^*\|_1 \right\}. \quad (1)$$

$$X_{(n+p) \times p}^* = (1 + \lambda_2)^{-1/2} \begin{pmatrix} X \\ \lambda_2^{1/2} I_{p \times p} \end{pmatrix}. \quad (2)$$

$$\lambda^* = \frac{\lambda_1}{\sqrt{1 + \lambda_2}}, \quad \beta^* = \sqrt{1 + \lambda_2} \beta. \quad (3)$$

۳-۲-۳- ماشین‌های بردار پشتیبان

در یادگیری ماشین، ماشین‌های بردار پشتیبان مدل‌های یادگیری تحت نظارت با الگوریتم‌های یادگیری مرتبط هستند که داده‌ها را برای طبقه‌بندی و تحلیل رگرسیون تجزیه و تحلیل می‌کنند. در این مقاله به استفاده از ماشین‌های بردار پشتیبان می‌توان بین ماشین‌هایی که برچسب خرابی دارند را از ماشین‌هایی که به درستی در حال انجام فعالیت خود بر روی محصول هستند، تمایز قائل شد. معادله خط جداساز اصلی را معادله ابر صفحه می‌نامند. معادله ابر صفحه‌ای که نقاط را تقسیم می‌کند (برای طبقه‌بندی) اکنون می‌تواند به راحتی به صورت زیر نوشته شود:

$$H: w^T x + b = 0. \quad (4)$$

در اینجا مقدار b نشان‌دهنده سوگیری معادله ابر صفحه می‌باشد. اگر بعد مسئله D باشد، بعد ابر صفحه همیشه $D-1$ است. در مسئله نت بدیهی می‌باشد که اگر بتوان همچنین ابر صفحه‌ای که داده‌هایی با برچسب خرابی را از داده‌های با برچسب سالم جدا کند، در تولید مدل نگهداری کمک خواهد کرد. این ابر صفحه با توانایی این را داشته باشد که به بهترین شکل ممکن با حداقل خطا طبقه‌بندی را انجام دهد؛ بنابراین، برای داشتن کمترین خطا در طبقه‌بندی نقاط داده، ملزم این است که فاصله بین نقطه داده و خط جداکننده را به دست آید.

فاصله یک معادله ابر صفحه $w^T \phi(x) + b = 0$ از یک بردار $\phi(x_0)$ از طریق فرمول زیر قابل محاسبه است.

$$d_H(\phi(x_0)) = \frac{|w^T(\phi(x_0)) + b|}{\|w\|_2}. \quad (5)$$

که در این فرمول $\|w\|_2$ نرمال اقلیدسی بردار w می‌باشد.

$$\|w\|_2 = \sqrt{w_1^2 + w_2^2 + \dots + w_n^2}. \quad (6)$$

¹ Abdulkareem and Abdulazeez

² General linear models

³ Elastic net

⁴ Gorriz and Suckling



هدف بردار ماشین پشتیبان حداکثر کردن کمترین فاصله است. محصول برچسب پیش‌بینی شده و واقعی در پیش‌بینی صحیح بیشتر از صفر خواهد بود، در غیر این صورت کمتر از صفر می‌باشد. برای مجموعه داده‌های کاملاً قابل تفکیک، ابر صفحه‌ی مطلوب تمام نقاط را به‌درستی طبقه‌بندی می‌کند و مقادیر بهینه را در معادله وزن بیشتر جایگزین می‌کند. مقدار وزن بهینه از فرمول زیر به دست می‌آید.

$$w^* = \arg_w \max \left[\min_n \frac{|w^T [\phi(x_n)] + b|}{\|w\|_2} \right] \quad (7)$$

انتظار نمی‌رود که این روش بتواند چنین معادله ابر صفحه‌ای را در داده‌های واقعی که مملو از خطا و اشتباه است، به دست آورد و امکان این وجود دارد که بعضی از داده‌ها در دسته واقعی خود قرار نگیرند. درحالی‌که یک معادله ابر صفحه‌ای مطلوب است که این دسته‌بندی را به‌صورت کامل انجام دهد. روشی هست که به مدل اجازه می‌دهد در هنگام طبقه‌بندی چند داده را اشتباه دسته‌بندی کند. از این روی یک متغیر به‌عنوان مجازات برای دسته‌بندی اشتباهی که برای هر داده صورت گرفته، اضافه کرده می‌شود. اگر به‌درستی طبقه‌بندی شده باشد مقدار $\beta = 0$ و اگر اشتباه طبقه‌بندی شده باشد $\beta > I$ به‌عنوان پناهی به مدل مذکور اضافه می‌شود.

$$\min_{\omega, b, \{\beta_n\}} \frac{1}{2} \|\omega\|_2 + C \sum_n \beta_n \quad (8)$$

$$y_n [\omega^T \phi(x_n) + b] \geq 1 - \beta_n \quad \forall n; \quad (9)$$

$$\beta_n \geq 0 \quad \forall n. \quad (10)$$

اگر $C = 0$ باشد به معنای مرزهای پیچیده‌تر است، زیرا طبقه‌بندی کننده با متغیر اضافه‌شده، مجازات نمی‌شود، در نتیجه، ابر صفحه مطلوب می‌تواند از آن در هر مکانی استفاده کرده و همه طبقه‌بندی‌های اشتباه بزرگ را بپذیرد و در نتیجه، مرز تصمیم‌گیری خطی و نامناسب خواهد بود. اگر C بی‌نهایت باشد، طبقه‌بندی داده‌ها با برچسب اشتباه به‌شدت مجازات می‌شوند و مدل نمی‌تواند طبقه‌بندی نادرست انجام دهد و در نتیجه برازش بیش‌ازحد را انجام دهد؛ بنابراین پارامتر C مهم است (اچونگ و همکاران^۱، ۲۰۱۸).

۴-۲-۳- روش تقویت گرادیان^۲

تقویت گرادیان یک روش یادگیری ماشین برای رگرسیون، طبقه‌بندی و سایر وظایف است که یک مدل پیش‌بینی را در قالب مجموعه‌ای از مدل‌های پیش‌بینی ضعیف، معمولاً درخت تصمیم، تولید می‌کند. وقتی یک درخت تصمیم‌گیرنده ضعیف باشد، الگوریتم حاصله درختان گرادیان نامیده می‌شود که معمولاً از جنگل‌های تصادفی بهتر عمل می‌کند. این مدل را به روش مرحله‌ای مانند سایر روش‌های تقویت‌کننده می‌سازد و با اجازه بهینه‌سازی یک تابع ضرر قابل‌تامین دلخواه، آن‌ها را تعمیم می‌دهد. در بسیاری از مشکلات یادگیری تحت نظارت، یک متغیر خروجی y و یک بردار متغیرهای ورودی x وجود دارد که با توزیع احتمالی به یکدیگر مربوط می‌شوند. هدف این روش به دست آوردن یک تابع $\hat{F}(x)$ است که متغیر خروجی را به بهترین وجه از مقادیر متغیرهای ورودی تقریب بزند. همچنین تابع تقریبی، به کمک کمینه کردن اختلاف بین مقدار تخمین زده و مقدار واقعی به دست می‌آید. اگر یک تابع ضرر در نظر بگیریم $L(y, F(x))$ الگوریتم تقویت گرادیان به‌صورت زیر می‌باشد.

۱. ابتدا مدل را با یک مقدار ثابت به دست می‌آورد.

$$F_0(x) = \arg \min_{\gamma} \sum_{i=1}^n L(y_i, \gamma). \quad (11)$$

۲. از $m = I$ تا M :

۳. محاسبه مقدار باقی‌مانده را به‌وسیله فرمول زیر به دست می‌آورد.

$$r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{m-1}(x)} \quad (12)$$

پس از این یک مجموعه داده جدید از مقدار ورودی r_{im} به دست می‌آورد $(h(x))$.

سپس با استفاده از بهینه‌سازی رابطه زیر مقادیر γ را به دست می‌آید.

$$\gamma_m = \arg \min_{\gamma} \sum_{i=1}^n L(y_i, F_{m-1}(x_i) + \gamma h_m(x_i)). \quad (13)$$

¹ Hwang et al.

² Gradient Boosting

با به دست آوردن مقادیر γ ، مدل را به روزرسانی می‌کند.

$$F_m(x) = F_{m-1}(x) + \gamma_m h_m(x). \quad (14)$$

۴. خروجی مدل نشان داده می‌شود.^۱



۳-۳- روش‌های استفاده‌شده برای زمان‌بندی

مشکل زمان‌بندی کار کارگاهی^۲ یکی از مهم‌ترین مشکلات در صنعت تولید است. از مشکلات زمان‌بندی پویا می‌توان جریان کارگاه و زمان‌بندی در موقعیت‌های زمان واقعی، نبود اطلاع و دانش از کارهای جدید و شرایط دستگاه‌ها برای انجام پردازش محصول دانست. مسئله زمان‌بندی که عموماً مسئله سخت‌تلقی می‌شود محدودیت‌هایی مانند زمان مناسب و ظرفیت سیستم وجود دارد که عوامل بیشتری را برای برنامه‌ریزی در نظر می‌گیرد. یک استراتژی بهینه در زمان‌بندی کار کارگاهی اهدافی از جمله کاهش زمان تولید، حداکثر سود و تخصیص بهینه منابع را می‌تواند تحقق ببخشد. محققان رویکردهای متعددی را برای حل و بهینه‌سازی مشکلات زمان‌بندی کار کارگاه بررسی کرده‌اند و در هر مقطع زمانی فرایند زمان‌بندی را بهبود بخشیدند که در مرور ادبیات به آن‌ها اشاره شده است. با روش‌های مختلف توسعه‌یافته و ابزارهای بیشتر، رویکردهای حل مسائل برنامه‌ریزی را می‌توان در سه بخش طبقه‌بندی کرد: رویکردهای ابتکاری مبتنی بر تجربه، رویکردهای محاسباتی مبتنی بر شبیه‌سازی و رویکردهای مستقل مبتنی بر یادگیری ماشین.

رویکردهای ابتکاری بر اساس تجربیات واقعی برنامه‌ریزی کارخانه توسعه داده شده است. امروزه روش‌های ابتکاری به‌طور گسترده در صنعت مورد استفاده قرار می‌گیرد و این روش‌ها به‌طور کلی در این مراکز صنعتی مؤثر واقع شده‌اند. عملکردهای روش‌های ابتکاری مختلف بستگی به محیط برنامه و تنظیمات خط تولید دارد. الگوریتم‌های ابتکاری را می‌توان به‌عنوان قواعد ساده تعریف کرد مانند اولین ورود - اولین خروج^۳ (FIFO) و یا می‌توان بسیار پیچیده و مخصوص وضعیت‌های خاص طراحی کرد. در این مقاله از سه روش ابتکاری برای ارزیابی مدل نهایی یادگیری ماشین استفاده می‌کنیم که شامل FIFO، زودترین موعد تحویل^۴ (EDD) و کمترین زمان انجام کار (پردازش)^۵ (SPT) می‌باشد.

رویکرد یادگیری ماشین برای حل مشکلات برنامه‌ریزی با توسعه فناوری در کارخانه‌ها و مراکز صنعتی پیشرفته پایدار شده است. تعداد زیادی از الگوریتم یادگیری ماشین در دهه گذشته توسعه داده شده و برای استفاده آن در مسائل مختلف در دسترس قرار گرفته است. این رویکردهای یادگیری ماشین شامل یادگیری تحت نظارت، یادگیری تقویتی، یادگیری عمیق و سایر موارد می‌شود. الگوریتم‌های متعددی در گذشته برای حل مشکلات زمان‌بندی توسط محققان اتخاذ شده بود. در پژوهش‌های آن‌ها با پیاده‌سازی یادگیری ماشین بر مسئله خود عملکردهای بالاتری نسبت به رویکردهای دیگر به دست آوردند.

۳-۳-۱- روش‌های ابتکاری

قواعد توزیع مهم در ادبیات موضوع به پنج دسته تقسیم می‌شود. این دسته‌بندی شامل قواعد زمان پردازش، زمان سررسید، نه زمان پردازش و نه سررسید، شرایط واقعی محیط کارگاه و ترکیبی از دو یا چند مورد موارد، می‌باشد. تنظیمات مختلف محیط کارگاه منجر به نتایج عملکردی متفاوت می‌شود و همچنین تعداد زیادی از رویکردهای ابتکاری، فرا ابتکاری و قواعد ترکیبی وجود دارد. در این مقاله از سه روش ابتکاری پرکاربرد و مؤثر برای مقایسه با رویکرد یادگیری ماشین پیشنهادی مورد بررسی قرار گرفته است. این رویکردهای ابتکاری به‌کاربرده شده، به‌صورت است.

اولین ورودی - اولین خروجی (FIFO): اغلب به‌عنوان معیاری برای مقایسه با سایر قواعد ابتکاری و حتی سایر قواعد زمان‌بندی استفاده می‌شود. FIFO هیچ اطلاعاتی را در مورد زمان پردازش و سررسید بررسی نمی‌کند؛ بنابراین، پیاده‌سازی FIFO آسان تلقی می‌شود و می‌تواند تقریباً در تمام مشکلات برنامه‌ریزی مناسب باشد.

¹ https://en.wikipedia.org/wiki/Gradient_boosting

² Job Shop Scheduling

³ First-in-First-out

⁴ Earliest Due Date

⁵ Shortest Processing Time

زودترین موعد تحویل (*EDD*) کار را با آخرین مهلت تعیین شده انتخاب می کند، زمانی موثر است که هدف کاهش حداکثر تاخیر باشد، به همین دلیل در بسیاری از سیستم های تولیدی استفاده می شود. *EDD* هنگامی که تغییرات اعمال می شود یا وقتی با روش های ابتکاری دیگر ترکیب می شود حتی بهتر عمل می کند.

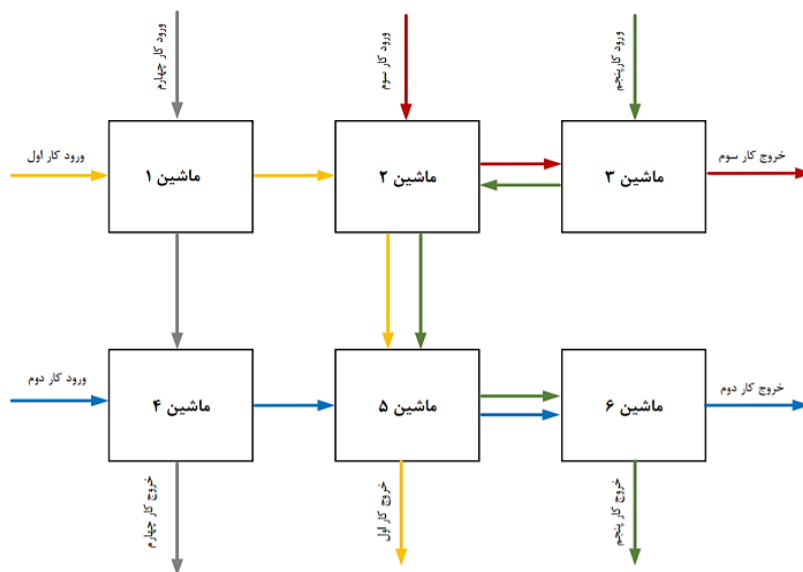
کمترین زمان پردازش (*SPT*) به دنبال این است که هنگام تصمیم گیری توزیع کارها، کار را با حداقل زمان پردازش در اولویت قرار دهد. *SPT* به عنوان قاعده ابتکاری بهینه برای به حداقل رساندن زمان جریان ساخت در نظر گرفته می شود.

۲-۳-۳- یادگیری ماشین و یادگیری تقویتی

در سیستم تولید امکان این وجود دارد که دستگاه ها خراب شوند و یا کارهای جدید وارد کارگاه شود. با توجه به قابلیت های منحصربه فرد الگوریتم های یادگیری ماشین می تواند با ورود اختلال در محیط کارگاه خود را تطبیق دهد و برنامه بهینه ساز خود را تغییر دهد. در یادگیری تقویتی به تنهایی با تابع پاداش و زیان و درک کلی از محیط و شرایط آن الگوریتم خود را بهبود بخشد. الگوریتم های یادگیری ماشین هنگام برخورد با سیستم های پیچیده دارای درجه تصادفی بالا بسیار مقرون به صرفه است و استفاده از آن منطقی می باشد.

یادگیری تقویتی با بررسی حالات محیط یاد می گیرد. یادگیری تقویتی در زمینه های مختلف کاربردهای عملی بسیار موثر واقع شده است. با این حال، کاربرد یادگیری تقویتی مبتنی بر عامل^۱ در برنامه ریزی پویا و بلادرنگ، به طور گسترده مورد بررسی قرار نگرفته است. با توجه به مرور ادبیات، سیاست های یادگیری ماشین و یادگیری تقویتی عملکرد بهتری نسبت به مدل های مختلف ریاضی نشان داده است.

در مقاله، یک مدل از یک سیستم کار کارگاهی برای شبیه سازی محیط زمان بندی ایجاد کرده می شود. این سیستم شامل چندین فرایند است که نشان دهنده فرآیندهای تولید است. هر فرآیند از چندین ماشین تشکیل شده است. گام زمانی را در مسئله به این صورت تعریف می شود که همه ماشین ها و همه فرآیندها یک با عملیات را انجام دهد. در این مدل مطرح شده، محصولات در یک سفارش باید توسط ماشین ها از تمام مراحل فرآیند بگذرد تا پردازش بر روی محصول به اتمام برسد. سفارش ها زمانی تحویل داده می شوند که کلیه محصولات سفارشی به پایان برسد. پس از آن پاداش و زیان در رویکرد یادگیری تقویتی تعیین می شود که بر اساس آن تصمیم توزیع کار بعدی را در سیستم مورد بررسی قرار می دهد. محیط کارگاه مورد نظر مقاله در شکل ۱ نشان داده شده است (ونگ و همکاران^۲، ۲۰۲۱). در این مقاله با استفاده از روش بهینه سازی سیاست تقریبی^۳ یک مسئله زمان بندی پویا در محیط کار کارگاهی حل کرده است که در این مقاله از محیط تعریف شده آن ها، برای طراحی مدل یادگیری تقویتی استفاده شده است.



شکل ۱- محیط کارگاه استفاده شده در این تحقیق.

Figure 1- Shop floor used in this research.

¹ Agent

² Wang et al.

³ Proximal Policy Optimization





در یادگیری تقویتی با عاملی روبه‌رو هستیم که از طریق سعی و خطا با محیط تعامل کرده و یاد می‌گیرد تا عملی بهینه را برای رسیدن به هدف مورد نظر انتخاب کند. یادگیری تقویتی از این‌رو مورد توجه است که راهی برای آموزش عامل‌ها برای انجام عمل مورد نظر از طریق دادن پاداش و تنبیه است، بدون اینکه لازم باشد نحوه انجام عمل را برای عامل مشخص شود. استراتژی این یادگیری با استفاده از روش‌ها آماری می‌باشد. در ادامه به توضیح مختصری از یادگیری تقویتی پرداخته می‌شود.

اگر بخواهیم مدل ابتدایی یادگیری تقویتی را توضیح دهیم به این صورت است که این مدل از یک مجموعه حالات مختلف، یک مجموعه از تصمیمات قابل اتخاذ، قواعدی برای گذر از حالات مختلف، قواعدی برای میزان پاداش به ازای هر تغییر وضعیت و قواعدی برای توصیف آنچه ماشین می‌تواند مشاهده کند، تشکیل شده است. در یادگیری تقویتی، ماشین می‌تواند در گام‌های گسسته زمانی با محیط تعامل کند. در هر لحظه از گام زمانی، ماشین یک مجموعه مشاهداتی را دریافت می‌کند که شامل پاداش نیز می‌باشد. پس از آنکه یک تصمیم را اتخاذ می‌کند، آن را به محیط ارسال می‌کند. این الگوریتم را بارها تکرار می‌کند تا به هدف مشخص شده برای یادگیری تقویتی مسئله برسد. اساس این روش از زنجیره مارکوفی تبعیت می‌کند.

ماشین‌ها و فرآیندها

در هر فرآیند از ماشین‌ها برای تولید محصول، بیکار نبودن ماشین‌ها و نبودن هزینه خرابی فرض اصلی مسئله مقاله است. همچنین ماشین‌ها تا پایان کار فعلی که بر روی آن‌ها در حال انجام پردازش است، تغییر وضعیت نمی‌دهد. ماشین‌ها از نظر قابلیت پردازش کارهای یکسان هیچ تفاوتی ندارد. برای روش یادگیری تقویتی چندعاملی^۱، هر ماشین دارای یک عامل یادگیری است؛ بنابراین، هر ماشین می‌تواند الگوریتم یادگیری خود را اعمال کرده و تصمیمات توزیع مستقلی را اتخاذ کند. ما فرض می‌کنیم که هرگونه داده برای توزیع و یادگیری توسط مدل یادگیری جمع‌آوری می‌شود. با این حال، عوامل به‌طور هم‌زمان تصمیم می‌گیرند و هنگام تصمیم‌گیری با یکدیگر ارتباط برقرار نمی‌کنند. فرآیند دارای یک بافر است که توسط تمام ماشین‌های آن به اشتراک گذاشته می‌شود. بافرها جایی هستند که کارها هنگام انتظار برای پردازش ذخیره می‌شوند. از دیگر مفروضات مسئله این است که تغییر زمانی حمل و نقل و انتقال بین ماشین‌ها معنی ندارد. سفارش‌ها به‌طور مداوم در توزیع پاسون با نرخ λ که یک عدد حقیقی می‌باشد، می‌رسند. به ترتیب نوع کار، زمان سررسید (O_D)، اندازه سفارش (OS) با گام زمانی t از توزیع‌های تصادفی یکنواخت به دست می‌آیند. تنظیمات توزیع یکنواخت تصادفی این پارامترها قابل کنترل هستند.

پارامترهای سیستم

در سیستم کار کارگاهی، پارامترهای مورد استفاده، توضیحات آن‌ها و علائم آن‌ها به اختصار در جدول ۱ فهرست شده است.

جدول ۱- پارامترهای سیستم.

Table 1- Parameters of the system.

نماد	تعریف
t	گام زمانی
E_p	یک قسمت از تغییرات سیستم که شامل ورود کارهای جدید و کارهایی بر روی ماشین‌ها در حال انجام هستند
$reward_t$	میزان پاداش گرفته شده یادگیری در هر گام زمانی
k	K امین پردازشی که بر روی ماشین انجام می‌شود
OS	اندازه سفارش
O_{max}/O_{min}	نسبت بیشینه به کمینه اندازه سفارش
OD	مدت زمان سررسید سفارش
OD_{max}/OD_{min}	نسبت بیشینه به کمینه زمان سررسید سفارش
$O_{flowtime}$	جریان زمانی پس از دریافت سفارش
$O_{Process}$	مدت زمان پردازش یک سفارش

^۱ Multi-agent

روش‌های متعددی برای ارزیابی الگوریتم‌های حل مسائل زمان‌بندی در طی سال‌ها گذشته مطرح و گسترش یافته است.

برای ارزیابی عملکرد نسبی رویکردهای الگوریتم ابتکاری و یادگیری ماشین استفاده شده در این مقاله، اندازه‌گیری عملکردی مداوم مورد نیاز است. در این مقاله از سه معیار برای ارزیابی مدل یادگیری استفاده شده است. لازم به ذکر است که روش‌هایی مانند زودکرد^۱ و زمان تکمیل کار^۲ همچنین برای ارزیابی مسئله زمان‌بندی استفاده می‌شود ولی در این تحقیق مورد استفاده قرار نگرفته است (الله وردی^۳، ۲۰۱۵). سه معیار مورد استفاده در تحقیق به صورت زیر می‌باشد.

۵۰۷

میانگین تاخیر T: این میانگین زمان تحویل کارها را که از سررسیدها محاسبه می‌شود اندازه‌گیری می‌کند. تاخیر می‌تواند از نظر ارزش مثبت یا منفی باشد. وقتی T منفی است، به این معنی است که میانگین تحویل زودتر از موعد مقرر است.

میانگین زمان جریان ساخت F: میانگین زمان جریان ساخت، میانگین مدت زمان تکمیل همه کارها را توصیف می‌کند. طبق تعریف، F باید منفی نباشد. SPT بهترین قواعد ابتکاری برای این اندازه‌گیری است.

درصد کارهای دیر کرده U: این اندازه‌گیری درصد کارها دیررس را در بین همه کارها نشان می‌دهد. هرچه این مقدار عدد کوچک‌تری باشد، نشان‌دهنده عملکرد بهتر است. در حالت سفارش، پارامترهای کنترل شده عبارت‌اند از OS ، INT و OD . هنگام انتخاب و کنترل این پارامترها، جنبه‌های زیر در نظر گرفته می‌شود. نوع کار، با توزیع تصادفی یکنواخت تولید می‌شود. هر دو اندازه سیستم عامل و فاصله ورود INT سفارش حجم تقاضای کار را تعیین می‌کنند، درحالی‌که این فاصله همچنین نوسان تقاضای سفارش را در طی مراحل زمانی تعیین می‌کند. به دلیل زمان OD زمان تحویل سفارش را تعیین می‌کند و بنابراین بر تصمیمات زمان‌بندی تأثیر می‌گذارد. علاوه بر این، حالت‌های سفارش‌ها برای در نظر گرفتن جنبه‌های تنظیمات سیستم طراحی شده است. در جدول ۲ این تنظیمات نشان داده شده است.

جدول ۲- پارامترهای کنترل شده سفارش‌ها.

Table 2- Parameters of the controlled orders.

حالت	O_{max}	O_{min}	OD_{max}	OD_{min}	INT
1	25	15	60	40	20
2	60	40	60	40	20
3	25	15	60	40	10
4	25	15	60	40	5
5	25	15	30	20	20
6	25	15	15	10	20

همچنین در این مقاله، از سه حالت دیگر برای سفارش‌ها تعیین شده است.

- حالت ۷: در این تنظیم فرض بر این است که در یک لحظه حجم $OS = 100$ از تولید کار خاص در زمان $t = 100$ وارد سیستم می‌شود.
- حالت ۸: در این تنظیم فرض بر این است که در فاصله‌ی ورود سفارش نصف می‌شود و در بازه زمان بین ۱۰۰ تا ۲۰۰ وارد سیستم می‌شود.
- حالت ۹: در این تنظیم زمان تحویل سفارش نصف می‌شود و در بازه زمانی بین ۱۰۰ تا ۲۰۰ وارد سیستم می‌شود.

برای درک بهتر عملکرد یادگیری ماشین در شرایط مختلف، سه حالت دیگر ایجاد می‌کنیم تا مواردی که حجم سفارش از ظرفیت سیستم در سطوح مختلف فراتر می‌رود را شبیه‌سازی کنیم. این حالات بر اساس تنظیم ۱ اصلاح شده و اندازه سفارش‌ها افزایش می‌یابد. این تغییرات در جدول ۳ قابل مشاهده می‌باشد.

جدول ۳- تنظیم پارامترها با اندازه سفارش‌ها بالا.

Table 3- Parameter setting with a high order size.

حالت	O_{max}	O_{min}	OD_{max}	OD_{min}	INT
10	120	100	60	40	20
11	200	180	60	40	20
12	300	280	60	40	20

¹ Total Earliness³ Allahverdi² Total Completion Time



در الگوریتم یادگیری تقویتی، باید چارچوب فرایند تصمیم‌گیری مارکوف (MDP) را با فضای حالت، فضای عمل، ماتریس انتقال و هزینه مرحله تعریف کنیم. در محدوده این مقاله، فقط در مورد طراحی فضای X و هزینه مرحله، با تمرکز بر ساختن توابع پاداش بحث می‌کنیم. فضای X در چارچوب تصمیم‌گیری مارکوف با جمع‌آوری ویژگی‌ها از سیستم ایجاد می‌شود. حالت فضای X به صورت فرمول زیر تعریف می‌شود.

$$X(t) = \{\text{reward}, \text{buffer } i, \text{kth Process}\}. \quad (15)$$

این معادله بدین معناست که برای هر گام زمانی t ، حالت فضای X پاداش دریافتی در مرحله فعلی و اندازه بافرها را برای فرایندها به عنوان ویژگی‌هایی برای تصمیم‌گیری می‌گیرد.

توابع پاداش به عنوان اهداف برای بهینه‌سازی در رویکردهای یادگیری عمل می‌کنند. عوامل یادگیری با تلاش برای دستیابی به حداکثر پاداش از طریق ویژگی‌های جمع‌آوری شده، تصمیمات خود را بهبود می‌بخشند. برای هر یک از سه اندازه‌گیری، ما توابع پاداش را با توجه به جنبه‌های اندازه‌گیری مربوطه ایجاد می‌کنیم. هر بار که یک سفارش به پایان رسید و تحویل داده شد، پاداش یا مجازات تعیین می‌کنیم. لازم به ذکر است که در تعریف توابع پاداش که به آن اشاره می‌شود پارامتر احتمال خرابی ماشین (μ_t) در گام زمانی تعیین شده، وارد می‌شود. در این مقاله، برای هر یک از انواع اندازه‌گیری‌هایی که به آن اشاره شد یک تابع پاداش و یک تابع زیان تعریف شده است که در جدول ۴ آورده شده است.

جدول ۴- تعریف تابع پاداش و زیان یادگیری تقویتی.

Table 4- Definition of the reward and loss reinforcement learning.

روش‌های اندازه‌گیری	پاداش یادگیری تقویتی	زیان یادگیری تقویتی
میانگین تاخیر	μ_t و $O_{Process}$	تعریف نشده
میانگین زمان جریان ساخت	تعریف نشده	μ_t و $O_{flowtime}$
درصد کارهای دیرکرده	0	1

برای شبیه‌سازی یک سیستم زمان‌بندی کار کارگاهی و تسهیل عوامل یادگیری که از فرایند تولید درس می‌گیرند، سیستم را در چند قسمت که شامل چندین مرحله زمانی است، در نظر می‌گیریم. عوامل یادگیری به طور مداوم یاد می‌گیرند و یادگیری را از قسمت‌های قبلی جمع‌آوری می‌کنند. در مراحل اولیه، هنگامی که عامل‌های یادگیری به مشکل نزدیک می‌شوند، عوامل انتخاب توزیع را بررسی می‌کنند و تصمیمات تصادفی می‌گیرند. برای مقایسه عملکرد واقعی و آموخته شده رویکردهای یادگیری تقویتی، هنگامی که اثر یادگیری RL ثابت باشد، روش‌ها و آزمون‌های گسترده‌ای انجام می‌شود و افزایش پاداش سیستم منجر به تثبیت یادگیری شود. نتایج نشان می‌دهد که $EP = 100$ برای عوامل یادگیری برای دستیابی به اثر یادگیری کافی است؛ بنابراین، آزمایش‌ها با $EP = 100$ انجام می‌شود.

۴- نتایج محاسباتی

در این بخش، در ابتدا به نتایج به دست آمده از مدل نت پیشگویانه پرداخته می‌شود. سپس نتایج و مقایسات مدل شبیه‌سازی شده را با سه رویکرد ابتکاری و روش یادگیری عمیق که در فصل گذشته به طور مفصل به آن اشاره شد، بررسی می‌شود. لازم به ذکر است که برای گرفتن خروجی‌ها از نرم‌افزار *Anaconda* به زبان پایتون در محیط *Jupyter Notebook* استفاده شده است.

داده‌ها شامل چندین سری زمانی چند متغیره است. داده‌ها برای آموزش مدل یادگیری پیشگویانه به زیرمجموعه‌های آموزشی و آزمایشی تقسیم می‌شود. علت تقسیم داده‌ها به این دو زیرمجموعه، برای این که بتوانیم مدل به دست آمده از روش‌های یادگیری ماشین را مورد ارزیابی قرار دهیم. نسبت این تقسیم یک به پنج می‌باشد. داده‌ها در جدول ۵ ارایه شده است.



در این مقاله، با استفاده از روش‌های یادگیری ماشین، می‌توان تعداد چرخه‌های عملیاتی باقی‌مانده قبل از خرابی ماشین، پیشگویی کرد؛ یعنی تعداد چرخه‌های عملیاتی پس از آخرین چرخه که موتور به کار خود ادامه می‌دهد. با روش‌هایی که در قسمت‌های بعدی به آن اشاره می‌شود می‌توان احتمال خرابی ماشین را تا یک ساعت بعدی تخمین زد. از این احتمال خرابی در قسمت زمان‌بندی بلادرنگ استفاده می‌شود. ماشین موردنظر شامل ۲۱ حسگر و ۳ تنظیم عملیاتی می‌باشد. در جدول ۵، ستون‌هایی که در این مجموعه داده می‌باشد شامل: چرخه عملیاتی، تنظیمات عملیاتی اول، تنظیمات عملیاتی دوم، تنظیمات عملیاتی سوم، مقدار عددی حسگر اول تا حسگر ۲۱، باقی‌مانده عمر مفید ماشین، وضعیت دستگاه (ستون وضعیت دستگاه نیز نشان‌دهنده این است که آیا ماشین خراب است یا نه؟).

برای آماده‌سازی داده‌ها، در یک مجموعه داده بعضی از ویژگی‌ها تاثیر بیشتری بر روی نوع برچسب (نسبت به دیگر ویژگی‌ها) می‌گذارند. به عبارتی دیگر این داده‌های مورد ارزیابی که دارای ۲۱ حسگر می‌باشد مقدار عددی برخی از این حسگرها تاثیر بیشتری بر روی خرابی ماشین موردنظر می‌گذارد. با استفاده از روش جنگل تصادفی این حسگرهای مؤثر بر عمر مفید باقی‌مانده، مشخص می‌شوند. در محیط برنامه مدل جنگل تصادفی بر روی مجموعه داده ساخته می‌شود. با توجه به اعداد به‌دست‌آمده حسگرهای ۲، ۳، ۲۱، ۱۵، ۱۴، ۷، ۱۲، ۴، ۹، ۱۱ به ترتیب بیشترین تاثیر را بر عمر مفید باقی‌مانده ماشین یا به عبارتی دیگر همان خرابی ماشین، می‌گذارد (شکل ۲). پس از اینکه این حسگرهای مشخص شدند، به علت بهبود مدل پیشگویانه نت، از مجموع داده حذف می‌شوند.

جدول ۵- داده‌های نت.

Table 5- Maintenance data.

Cycle	Op_setting_1	Op_setting_1	Op_setting_1	Op_setting_1	Op_setting_1
Cycle	Op_setting_1	Op_setting_1	Op_setting_1	Op_setting_1	Op_setting_1
Cycle	Op_setting_1	Op_setting_1	Op_setting_1	Op_setting_1	Op_setting_1
Cycle	Op_setting_1	Op_setting_1	Op_setting_1	Op_setting_1	Op_setting_1
Cycle	Op_setting_1	Op_setting_1	Op_setting_1	Op_setting_1	Op_setting_1
					5454545


۴-۱- روش‌های استفاده‌شده برای مدل نت پیشگویانه

در این مقاله، از چهار روش برای ایجاد مدل نت پیشگویانه که شامل رگرسیون جنگل تصادفی، *GLM Elastic Net*، ماشین بردار پشتیبانی و *Gradient Boosting* استفاده‌شده است. در ادامه خروجی‌های هر یک از این مدل‌ها نشان داده‌شده است.

۴-۱-۱- رگرسیون جنگل تصادفی

برای استخراج مدل نت پیشگویانه اولین روش مورد استفاده رگرسیون جنگل تصادفی می‌باشد. پس از این که مدل ساخته شد باید آن را مورد ارزیابی قرارداد تا کیفیت مدلی که به‌دست‌آمده است مشخص شود. برای این کار از داده آزمایشی استفاده می‌شود. مدت‌زمانی مورد نیاز برای ساخت مدل ۲/۳۲۳ دقیقه به طول می‌انجامد. مقدار خطای این مدل در تشخیص خرابی ماشین ۲۹/۸۴ می‌باشد. این مقدار را با تنظیم پارامترهای مدل می‌توان کاهش داد. برای اینکه مقدار عددی بهینه پارامترها را به دست آوریم از ماژول *GridSearch* استفاده می‌کنیم.

با تغییر پارامترهای مدل جنگل تصادفی به عدد ۸ و ۲ به خروجی جنگل تصادفی به دست می‌آید. با تغییر پارامترهای مدل، مقدار خطا به شدت کاهش یافته و مدل به خوبی می‌تواند خرابی ماشین را پیشگویی کند. البته لازم به ذکر است که امکان این نیز وجود دارد که این مدل فقط بر روی همین داده‌ها پاسخی به این خوبی از خود نشان دهد.



شکل ۳- نمودار اهمیت حسگرها.

Figure 3- Diagram of the importance of sensors.

۲-۱-۴- مدل GLM Elastic Net

در این قسمت در کتابخانه *Sklearn* با استفاده از ماژول *Elasticnet* مدل‌سازی بر روی داده‌ها انجام می‌گیرد. پس از تنظیم پارامترهای ماژول، مدل خروجی به دست می‌آید. مقدار خطا مدل زیاد می‌باشد ولی این مدل در مدت زمان ۱/۲ ثانیه ساخته می‌شود. این مدت زمان بسیار کم می‌تواند در طراحی مدل نت پیشگویانه که تغییرات ناگهانی وارد سیستم می‌شود تاثیر بسزایی داشته باشد.

۳-۱-۴- مدل ماشین بردار پشتیبانی

برای ساخت مدل ماشین بردار پشتیبانی از کتابخانه *Sklearn* و ماژول *SVR* در پایتون استفاده شده است. یکی از پارامترهای ساخت مدل انتخاب تعداد تولید مدل‌های مختلف می‌باشد. در این مقاله، پنج بار مدل ماشین بردار پشتیبانی ساخته می‌شود که بهترین مدل پیشگویانه ساخته شود و در این روش مقدار خطا مدل ۲۸۲/۳۰ می‌باشد.

۴-۱-۴- مدل Gradient Boosting

تقویت گرادیان یک روش یادگیری ماشین برای رگرسیون، طبقه‌بندی و سایر وظایف است که یک مدل پیش‌بینی را در قالب مجموعه‌ای از مدل‌های پیش‌بینی ضعیف، معمولاً درخت تصمیم، تولید می‌کند. با توجه به خروجی به دست آمده، مقدار خطا این مدل ۲۹/۹۲۱ می‌باشد. خروجی‌های مدل نت که در این مقاله استفاده شده را می‌توان در جدول ۶ خلاصه کرد.

جدول ۶- مقایسه مدل‌های نت پیشگویانه.

Table 6- Comparison of predictive maintenance models.


مدل نت	میانگین خطا مربع	میانگین خطا مطلق	r-squared
رگرسیون جنگل تصادفی	1778.024	29.843	0.625
GLM Elastic Net	2043.031	34.600	0.867
بردار ماشین پشتیبانی	1856.812	30.282	0.607
Gradient Boosting	1768.62	29.92	0.625
رگرسیون جنگل تصادفی اصلاح شده	0.016	0.034	0.749

با توجه به نتایج به دست آمده از ساخت مدل های نت رگرسیون جنگل تصادفی اصلاح شده بهترین مدل برای داده های مورد نظر می باشد. نمودار ROC و ماتریس آشفتگی جنگل تصادفی در شکل ۳ نشان می دهد.

```
Confusion Matrix:
[[3787  55]
 [ 35 250]]
Random Forest Accuracy: 97.8%
Random Forest Precision: 82.0%
Random Forest Recall: 87.7%
Classification Report:
              precision    recall  f1-score   support

     0       0.99      0.99      0.99     3842
     1       0.82      0.88      0.85      285

 accuracy         0.98     4127
 macro avg       0.91     4127
 weighted avg    0.98     4127
```



شکل ۳- نمودار ROC و ماتریس آشفتگی جنگل تصادفی.

Figure 3- Diagram of the ROC and random forest confusion matrix.

۴-۲- زمان بندی مسئله مورد مقاله و درخت تصمیم گیری

در این بخش، آزمایش ها با سه رویکرد ابتکاری پیشنهاد شده و روش یادگیری تقویتی در سیستم شبیه سازی و پیاده سازی شده است. نتایج تحت ۱۲ حالت به ترتیب با سه اندازه گیری عملکرد در جداول ۷ الی ۹ ارائه می شود. با اثبات مزیت عملکرد یادگیری عمیق، می توان زمینه را برای بحث در مورد مشارکت این مدل یادگیری تقویتی به عنوان یک استراتژی پشتیبانی تصمیم گیری ایجاد شود.

جدول ۷- خروجی میانگین تاخیر.

Table 7- Outputs of the mean tardiness.

حالت	FIFO	EDD	SPT	RL
1	-61.46	-62.63	-57.98	-63.04
2	-29.13	-37.93	-25.68	-43.31
3	-56.80	-52.46	-56.02	-57.24
4	-19.64	-20.20	-51.40	-58.46
5	-24.51	-26.50	-23.60	-28.08
6	-9.15	-9.06	-8.91	-9.84
7	-22.37	-21.04	-58.56	-64.85
8	-56.04	-50.03	-49.64	-54.27
9	-42.87	-44.76	-45.97	-36.92
10	5.11	5.36	-23.07	-39.11
11	17.62	20.91	-10.66	-14.5
12	35.69	38.09	3.57	3.57





جدول ۸- خروجی میانگین زمان جریان ساخت.

Table 8- Outputs of the mean flow time.

حالت	FIFO	EDD	SPT	RL
1	8.48	7.97	7.55	7.54
2	43.08	39.74	27.79	20.38
3	14.78	13.64	12.56	11.93
4	46.30	48.98	17.91	13.94
5	8.95	8.51	8.62	7.85
6	9.06	8.77	8.93	8.69
7	47.31	26.93	11.23	9.48
8	23.88	23.97	7.61	16.82
9	8.03	7.18	8.63	6.33
10	69.47	68.63	53.02	32.77
11	93.09	94.67	61.55	44.53
12	108.28	108.62	73.55	54.54

جدول ۹- خروجی میانگین درصد متوسط کارهای دیرکرد.

Table 9- Outputs of the average percentage of the mean tardy jobs.

حالت	FIFO	EDD	SPT	RL
1	0.00	0.00	0.00	0.00
2	18.41	16.00	9.18	9.09
3	0.46	0.18	2.38	0.09
4	25.41	26.63	5.94	4.89
5	0.00	0.00	0.00	0.00
6	17.78	28.89	29.80	13.50
7	29.31	26.00	3.21	0.00
8	5.75	4.12	9.61	5.26
9	4.57	4.06	3.13	6.67
10	39.50	40.66	27.00	26.80
11	57.30	60.33	39.00	39.66
12	65.00	67.00	44.50	43.50

همان‌طور که قبلاً ذکر شد، حالت‌های سفارش به‌گونه‌ای طراحی شده است که حجم سفارش‌ها کمتر از ظرفیت سیستم تولید است و سفارش‌ها در این مفروضات برآورده می‌شوند. نتایج نشان می‌دهد که روش یادگیری تقویتی در آزمایش‌ها بهتر از روش‌های ابتکاری عمل می‌کند. برای سفارش باحالت ۱ و ۲، اندازه سفارش یک متغیر مستقل است، جایی که اندازه سفارش در حالت ۲ بیشتر است. برای حالت ۲، یادگیری تقویتی دارای مزایای قابل توجهی نسبت به روش ابتکاری مطلوب تا ۶۸٪ در اندازه‌گیری میانگین تاخیر می‌باشد. در حالت ۱، مزایا مدل یادگیری تقویتی کمتر چشمگیر هستند، جایی که یادگیری تقویتی با ارزش کمتر از ۵٪ از بهترین روش ابتکاری بهتر عمل می‌کند.

این مجموعه مقایسه نشان می‌دهد که یادگیری تقویتی می‌تواند هنگامی که اندازه سفارش‌ها بزرگ‌تر باشد به عملکرد بهتری دست یابد. از آنجاکه ماشین‌ها فقط در هنگام اتمام سفارش‌ها قبلی کار خود را تغییر می‌دهند، اندازه سفارش‌ها بزرگ‌تر منجر به چرخه تصمیم‌گیری طولانی‌تر می‌شود. در مقابل، عوامل یادگیری تقویتی حالت‌های کلی سیستم را بررسی می‌کنند. عوامل در هر مرحله تصمیم می‌گیرند و نیازی به انتظار برای تکمیل سفارش‌ها قبلی وجود ندارد. روش یادگیری تقویتی امکان پردازش هم‌زمان چندین سفارش را فراهم می‌آورد و منجر به حداکثر پاداش می‌شود.

برای سفارش حالت ۱، ۳ و ۴، فواصل زمانی ترتیب ورود کار متغیرهای مستقل هستند. از حالت ۴ تا حالت ۳ و ۱، دو برابر سفارش‌ها مکرر نسبت به تنظیمات قبلی ایجاد می‌شود. یادگیری تقویتی همچنین در هر سه اندازه‌گیری پیش‌تاز است. باین حال، مزیت عملکرد الگوی

مشخصی ندارد. مزیت کمتر روش یادگیری تقویتی در این حالت‌ها دیده می‌شود، زیرا روش‌های ابتکاری دستورات بیشتری برای تصمیم‌گیری خواهند داشت.

برای سفارش‌ها حالت ۱، ۵ و ۶، زمان سررسید سفارش‌ها یک متغیر مستقل است. می‌توان دریافت که روش یادگیری تقویتی در همه اندازه‌گیری‌ها نتیجه بهتری می‌گیرد. مزایا نسبی به بهترین روش ابتکاری از ۵% تا ۱۰% است. این مجموعه تنظیمات نشان می‌دهد که یادگیری تقویتی دارای مزایای عملکرد ثابت و کوچک در تغییرات زمان سررسید می‌باشد.

برای سفارش حالت ۷، یادگیری تقویتی در همه اندازه‌گیری‌ها از بهترین روش‌های ابتکاری، بهتر است، به ترتیب با مزایای ۱۰، ۱۵ و ۲۵ در سه اندازه‌گیری می‌توان نام برد. این مزیت منحصر به فرد روش یادگیری ماشین را در مسئله برنامه‌ریزی نشان می‌دهد. روش‌های ابتکاری تا زمانی که سفارش بزرگ در $t = 100$ کامل نشود، به دلیل منطق ثابت تصمیم‌گیری، سفارش‌ها بعدی را اداره نمی‌کند. با این وجود، عوامل یادگیری ماشین به دنبال حداکثر پاداش هستند و آن‌ها سفارش بزرگ را به قطعات کوچک‌تر تقسیم می‌کنند و سفارش بزرگ را یک‌بار انجام نمی‌دهند. متناوباً، سایر سفارش‌ها در این بین پردازش می‌شوند؛ بنابراین، اختلال در یک سفارش بزرگ کمتر بر عملکرد کلی تأثیر می‌گذارد.

برای سفارش حالت ۸ و ۹، هیچ نتیجه‌ای وجود ندارد که نشان دهد یادگیری تقویتی می‌تواند عملکرد بهتری داشته باشد. این امر عوامل را مجبور می‌کند تا داده‌های یادگیری جدیدی را اتخاذ کرده و پیش‌بینی‌های جدیدی را در طول یک‌سوم وسط یک فرایند انجام دهند که منجر به اختلال و سردرگمی در یادگیری می‌شود. در نتیجه، عامل یادگیری قادر به پیش‌بینی مداوم نسبت به پاداش بالاتر نیست؛ بنابراین، رویکردهای یادگیری تقویتی هیچ برتری را نشان نمی‌دهند. به عنوان نکته‌ای برای حالت ۷، ۸ و ۹، رویکردهای یادگیری تقویتی رویدادهای غیرمنتظره را بهتر از روش‌های ابتکاری اداره می‌کنند، اما نسبت به تغییر طولانی مدیت سازگاری از خود نشان نمی‌دهد.

برای حالت‌های ۱۰، ۱۱ و ۱۲، عملکرد روش یادگیری تقویتی را با روش‌های ابتکاری در شرایطی که حجم سفارش‌ها بسیار زیاد است مقایسه می‌شود. اندازه سفارش‌ها از حالت ۱۰ تا حالت ۱۲ بزرگ‌تر می‌شود. رویکرد یادگیری تقویتی صلاحیت خود را در اندازه‌گیری میانگین زمان جریان ساخت نشان می‌دهد، جایی که از هر سه روش ابتکاری تحت همه تنظیمات سفارش بهتر عمل می‌کند. امتیاز عملکردی رویکرد یادگیری تقویتی با افزایش اندازه سفارش‌ها از ۶۹% به ۱% کاهش می‌یابد. در اندازه‌گیری درصد کارهای دیر هنگام، روش یادگیری تقویتی مزیتی نسبت به بهترین روش ابتکاری، SPT نشان نمی‌دهد. در این سناریو، یادگیری تقویتی تقریباً به همان نمرات عملکرد SPT دست می‌یابد.

اگرچه الگوریتم یادگیری تقویتی می‌تواند تقریباً در همه اندازه‌گیری‌ها بهترین نتایج را به دست آورند، اما می‌توان متوجه شد که عملکرد رویکرد یادگیری ماشین اغلب هنگام در نظر گرفتن سایر ویژگی‌ها به‌غیر از آن اندازه‌گیری‌ها ضعیف است. به عنوان مثال، هنگامی که در میانگین تاخیر اندازه‌گیری می‌شود، درصد سفارش‌هایی که با رویکرد یادگیری ماشین تکمیل شده‌اند در بین همه رویکردها کمترین است. قواعد توزیع به صورت درخت تصمیم در شکل ۴ ارائه شده است و شرایط تصمیم‌گیری مربوطه در جدول ۱۰ فهرست شده است.

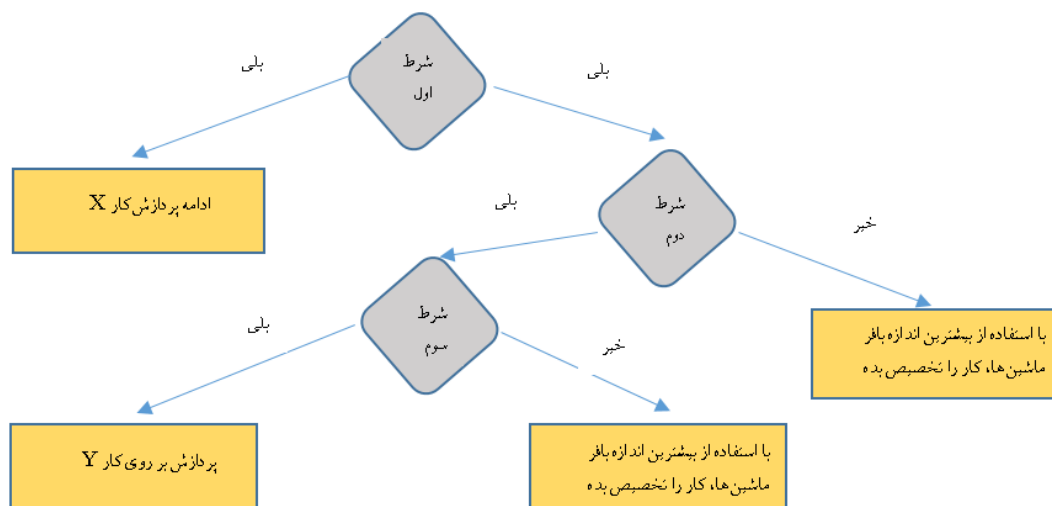
جدول ۱۰ - شرایط تصمیم‌گیری عامل.

Table 10- Agent decision conditions.

آیا ماشین M در حال پردازش k ام در گام زمانی t همچنان ماشین M در حال پردازش است؟	شرط اول
آیا مقدار تابع پاداش مثبت است؟	شرط دوم
$Range = r_{max} - r_{min}$ آیا مقدار r_t از $r_{t-1} + Range$ بیشتر است؟	شرط سوم

در درخت تصمیم‌گیری توزیع، می‌توان یک تصمیم توزیع کار را جستجو کرد که یک عامل یادگیری تقویتی با بررسی شرایط در طول شاخه‌ها، یاد می‌گیرد. برای تعیین تصمیم توزیع، ابتدا باید کارها مشخص شوند که کدام ماشین و کدام مرحله و وضعیت سیستم در مرحله زمانی در آن ماشین بازرسی شود. مرحله بعدی بررسی شرایط در هر ماشین با اطلاعات بازرسی کارها است. با بررسی شرایط، در نهایت می‌توان به تصمیم توزیع رسید. با این حال، برخلاف روش‌های توزیع ابتکاری ثابت، یک عامل آموزش دیده تضمین نمی‌کند که تصمیمات توزیع را در سناریوهای مشابه را تکرار کند؛ بنابراین تصمیمات واقعی اتخاذ شده توسط عوامل در شبیه‌سازی ممکن است هر بار نتایج یکسانی در مقایسه با استفاده از درخت توزیع‌کننده نشان ندهد.





شکل ۴- درخت تصمیم عامل یادگیری تقویتی.

Figure 4- Decision tree of the agent reinforcement learning.

تفسیر درخت توزیع بر اساس الگوهای توزیع است. با استخراج الگوها می توان یک مدل درختی مطابق الگو، با شرایط روی گره ها و توزیع تصمیمات بر روی برگ ها، ایجاد کرد. شرایط، شامل معیارهای عددی، با مشاهدات فرموله شده و با آزمایش نهایی می شود. چندین آزمایش را برای به روزرسانی و اصلاح شرایط انجام می گیرد تا شرایط بتواند رفتارهای توزیع کننده را توصیف کند.

۵- نتیجه گیری

امروزه کارخانه های مدرن قصد دارند با توسعه و به کارگیری فناوری هایی که توانایی تصمیم گیری را دارند، مداخله انسانی را در این زمینه کاهش دهند. در این پژوهش، رویکرد جدیدی را برای اجرای مدل سازی پیش بینی کننده در مشکلات کف کارخانه پیشنهاد کرده است. برای سیستم ادغامی، در این مقاله، از رویکرد یادگیری تقویتی برای مشکلات زمان بندی بلادنگ در صنعت تولیدی پیاده سازی شده است. مرور جامعی بر مطالعات موجود در حوزه نت و همچنین زمان بندی بلادنگ انجام گرفت که با استفاده از شکاف های موجود در ادبیات مسئله سیستم یکپارچه برای تصمیم گیری آتی در کف کارخانه مورد تحقیق قرار گرفت. پس از تشریح مسئله به مدل نت پیشگویانه بر اساس یادگیری ماشین پرداخته شد. از چندین رویکرد برای حل مسئله نت پیشگویانه بر اساس داده های واقعی، ارائه شد و نتایج هر یک از این روش ها مورد ارزیابی قرار گرفت. این روش ها شامل جنگل تصادفی، مدل های خطی تعمیم یافته، ماشین بردار پشتیبان و تقویت گرادیان می باشند. سپس به روش های زمان بندی و روش ارزیابی مدل زمان بندی مورد بررسی قرار گرفت. اشاره شده است که برای حل مسائل زمان بندی در کف کارخانه از روش های ابتکاری و فرا ابتکاری و یادگیری ماشین استفاده می شود. پس از ساخت انواع مدل ها میزان دقت و کیفیت مدل های به دست آمده، مقایسه و ارزیابی شد. سپس رویکردها ابتکاری و یادگیری تقویتی را در اندازه گیری های مختلف کارها در مسئله طرح شده، مقایسه شد. نتایج به دست آمده نشان می دهد که یادگیری تقویتی در حالت کلی عملکرد بهتری در اکثر آزمایش ها به دست می آورد. در گام بعدی لازم است که بتوان از یادگیری تقویتی در اعزام کارهایی که به صورت بلادنگ و آتی وارد سیستم می شوند، یک درخت تصمیمی برای عامل یادگیری تعریف شود. بررسی ادغام بیشتر قوانین اکتشافی و روش های یادگیری ماشین را می توان در تحقیقات آتی مورد بررسی مورد قرارداد. در ضمن، روش های کنترلی ارائه شده مربوط به روش های رویداد ناهم زمان است. با این وجود، مدیریت سیستم های بزرگ تنها با رویکردهای کنترل ناهم زمان بسیار پیچیده است؛ بنابراین، همچنین در تحقیقات آتی می توان روش های ترکیبی ناهم زمان و هم زمان را در نظر گرفت که امکان کنترل ترکیبی را فراهم می کند و مزایای آن ها را مورد بررسی قرارداد.

منابع

- Abdulkareem, N. M., & Abdulazeez, A. M. (2021). Machine learning classification based on Radom Forest algorithm: a review. *International journal of science and business*, 5(2), 128-142.
- Allahverdi, A. (2015). The third comprehensive survey on scheduling problems with setup times/costs. *European journal of operational research*, 246(2), 345-378. <https://doi.org/10.1016/j.ejor.2015.04.004>
- An, D., Kim, N. H., & Choi, J. H. (2015). Practical options for selecting data-driven or physics-based prognostics algorithms with reviews. *Reliability engineering & system safety*, 133, 223-236. <https://doi.org/10.1016/j.res.2014.09.014>



- Bouazza, W., Hamdadou, D., Sallez, Y., & Trentesaux, D. (2019). Effective dynamic selection of smart products scheduling rules in FMS. *Manufacturing letters*, 20, 45-48. <https://doi.org/10.1016/j.mfglet.2019.05.004>
- Bousdekis, A., Lepenioti, K., Apostolou, D., & Mentzas, G. (2019). Decision making in predictive maintenance: literature review and research agenda for industry 4.0. *IFAC-Papersonline*, 52(13), 607-612. <https://doi.org/10.1016/j.ifacol.2019.11.226>
- Diggle, P. J., Chetwynd, A. G., & Chetwynd, A. (2011). *Statistics and scientific method: an introduction for students and researchers*. Oxford University Press. <https://academic.oup.com/book/26710>
- Đurasević, M., & Jakobović, D. (2018). A survey of dispatching rules for the dynamic unrelated machines environment. *Expert systems with applications*, 113, 555-569. <https://doi.org/10.1016/j.eswa.2018.06.053>
- Fink, O. (2020). Data-driven intelligent predictive maintenance of industrial assets. In *Women in industrial and systems engineering* (pp. 589-605). Springer, Cham. https://doi.org/10.1007/978-3-030-11866-2_25
- Gao, R., Wang, L., Teti, R., Dornfeld, D., Kumara, S., Mori, M., & Helu, M. (2015). Cloud-enabled prognosis for manufacturing. *CIRP annals*, 64(2), 749-772. <https://doi.org/10.1016/j.cirp.2015.05.011>
- Márquez, F. P. G., Tobias, A. M., Pérez, J. M. P., & Papaelias, M. (2012). Condition monitoring of wind turbines: techniques and methods. *Renewable energy*, 46, 169-178. <https://doi.org/10.1016/j.renene.2012.03.003>
- Gorriz, J. M., & Suckling, J. (2020). A connection between the pattern classification problem and the General Linear Model for statistical inference. *IEEE journal of biomedical and health informatics*. DOI: [10.1109/JBHI.2021.3101662](https://doi.org/10.1109/JBHI.2021.3101662)
- Gu, C., He, Y., Han, X., & Chen, Z. (2017). Product quality oriented predictive maintenance strategy for manufacturing systems. *2017 prognostics and system health management conference (phm-harbin)* (pp. 1-7). IEEE. DOI: [10.1109/PHM.2017.8079213](https://doi.org/10.1109/PHM.2017.8079213)
- Hwang, S., Jeong, J., & Kang, Y. (2018). SVM-RBM based predictive maintenance scheme for IoT-enabled smart factory. *2018 thirteenth international conference on digital information management (ICDIM)* (pp. 162-167). IEEE. DOI: [10.1109/ICDIM.2018.8847132](https://doi.org/10.1109/ICDIM.2018.8847132)
- Kalathas, I., & Papoutsidakis, M. (2021). Predictive maintenance using machine learning and data mining: a pioneer method implemented to Greek railways. *Designs*, 5(1), 5. <https://doi.org/10.3390/designs5010005>
- Modoni, G. E., Trombetta, A., Veniero, M., Sacco, M., & Mourtzis, D. (2019). An event-driven integrative framework enabling information notification among manufacturing resources. *International journal of computer integrated manufacturing*, 32(3), 241-252. <https://doi.org/10.1080/0951192X.2019.1571232>
- Jimenez, J. J. M., Schwartz, S., Vingerhoeds, R., Grabot, B., & Salaün, M. (2020). Towards multi-model approaches to predictive maintenance: a systematic literature survey on diagnostics and prognostics. *Journal of manufacturing systems*, 56, 539-557. <https://doi.org/10.1016/j.jmsy.2020.07.008>
- Sakib, N., & Wuest, T. (2018). Challenges and opportunities of condition-based predictive maintenance: a review. *Procedia cirp*, 78, 267-272. <https://doi.org/10.1016/j.procir.2018.08.318>
- Takata, S., Kirmura, F., van Houten, F. J., Westkamper, E., Shpitalni, M., Ceglarek, D., & Lee, J. (2004). Maintenance: changing role in life cycle management. *CIRP annals*, 53(2), 643-655. [https://doi.org/10.1016/S0007-8506\(07\)60033-X](https://doi.org/10.1016/S0007-8506(07)60033-X)
- Tidriri, K., Chatti, N., Verron, S., & Tiplica, T. (2016). Bridging data-driven and model-based approaches for process fault diagnosis and health monitoring: a review of researches and future challenges. *Annual reviews in control*, 42, 63-81. <https://doi.org/10.1016/j.arcontrol.2016.09.008>
- Wang, L., Hu, X., Wang, Y., Xu, S., Ma, S., Yang, K., ... & Wang, W. (2021). Dynamic job-shop scheduling in smart manufacturing using deep reinforcement learning. *Computer networks*, 190, 107969. <https://doi.org/10.1016/j.comnet.2021.107969>
- Yadav, A., & Jayswal, S. C. (2018). Modelling of flexible manufacturing system: a review. *International journal of production research*, 56(7), 2464-2487. <https://doi.org/10.1080/00207543.2017.1387302>
- Zhang, W., Yang, D., & Wang, H. (2019). Data-driven methods for predictive maintenance of industrial equipment: a survey. *IEEE systems journal*, 13(3), 2213-2227. DOI: [10.1109/JSYST.2019.2905565](https://doi.org/10.1109/JSYST.2019.2905565)