



## Online Job Shop Scheduling and Dynamic Predictive Maintenance by Machine Learning

Haed Tavakkoli-Moghaddam<sup>1</sup>, Seyed Hesamoddin Zegordi<sup>2</sup>,  
Mohammad Reza Amin-Nasseri<sup>3</sup>

<sup>1</sup> M.Sc., Faculty of Industrial and Systems Engineering, Tarbiat Modares University,  
Tehran, Iran

<sup>2</sup> Professor, Faculty of Industrial and Systems Engineering, Tarbiat Modares University,  
Tehran, Iran

<sup>3</sup> Professor, Faculty of Industrial and Systems Engineering, Tarbiat Modares University,  
Tehran, Iran

### Abstract

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

**Keywords:** Real-time scheduling, Predictive Maintenance, Machine Learning, Reinforcement Learning, Data Mining.

### Original Article

Receive:

Review:

Revise:

Accept:

### Citation:

\* Corresponding Author

Email Address: zegordi@modares.ac.ir

DOI: <http://dx.doi.org/10.22105/dmor.2022.310377.1504>



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

هاند توکلی مقدم<sup>۱</sup>، سید حسام‌الدین ذگردی<sup>۲</sup>، محمدرضا امین ناصری<sup>۳</sup>

<sup>۱</sup> دانش آموخته کارشناسی ارشد، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران

<sup>۲</sup> استاد، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران

<sup>۳</sup> استاد، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران

### چکیده

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. یکی از نوآوری‌های مقاله ارائه تعریف تابع پاداش برای مسئله مورد نظر می‌باشد. این مدل یادگیری در حالت‌های مختلف ورود کار به کارگاه مورد بررسی قرار گرفته و 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.

**واژه‌های کلیدی:** نگهداری و تعمیرات پیشگویانه؛ زمانبندی کار کارگاهی بلادرنگ؛ یادگیری ماشین؛ یادگیری تقویتی.

### نوع مقاله: پژوهشی

اصلاح:

دریافت:

داوری:

پذیرش: ۱۴۰۲/۰۱/۲۲

### ۱- مقدمه

برنامه‌ریزی به عنوان 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 مورد نظر 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 به راحتی با عوامل مختلف مانند مانیتورهای حسگر و سیستم‌های تشخیصی ادغام می‌شوند. علاوه بر این به کارگیری از دانش به دست آمده، 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

\* نویسنده مسئول

آدرس رایانامه: zegordi@modares.ac.ir

شناسه دیجیتال: <http://dx.doi.org/10.22105/dmor.2022.310377.1504>

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.

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

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<sup>۳</sup> به طور گسترده در صنایع تولیدی مورد استفاده قرار گرفته‌است. 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 کرده‌است (کالاتاس<sup>۴</sup> و پاپوتسیداکیس، ۲۰۲۱). در تحقیقات نشان داده شده‌است که انتشارات مقالات نت پیشگویانه از ۰٫۷ درصد در سال‌های ۲۰۰۹-۲۰۱۱ به ۱۱٫۳ درصد در سال‌های ۲۰۱۳-۲۰۱۸ افزایش یافته‌است. علاوه بر این، یادگیری ماشین نیز در مابقی بنابراین پیشگویی‌های به دست آمده از روش‌های یادگیری ماشین به ارائه برنامه‌ریزی دقیق به مدیریت نت کمک می‌کند و نت پیشگویانه به یک ابزار جدید برای نظارت و کنترل رویدادهای نگهداری تبدیل شده‌است.

## 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 به صورت لحظه‌ای مورد ارزیابی قرار داد. در این قسمت به مرور ادبیات این زمینه که شامل نت و مدیریت آن، فن‌آوری‌های استفاده شده 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 کرده‌است (تاکاتا<sup>۵</sup> و همکاران، ۲۰۰۴). اکثر کارخانه‌هایی که سیستم صنعتی خود را ایجاد کرده‌اند، از سرمایه‌گذاری در کارخانه‌های جدید و مدرن تا زمانی که کارخانه‌های فعلی آسوده خاطر سودآوری خود را دارند، خودداری می‌کنند. در نتیجه، نت به یکی از اصلی‌ترین تأثیرات در افزایش حداکثر بهره‌وری در این شرایط تبدیل شده‌است. ثابت شده‌است 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 چند منظوره امری ضروری دانست (مودونی<sup>۶</sup> و همکاران، ۲۰۱۹).

با ظهور دیجیتالی شدن، بسیاری از تحقیقات قبلی در مورد استراتژی‌های نت پیشگیرانه متمرکز شده‌است 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 مبتنی بر فیزیک سیستم می‌باشد. تحقیقات گسترده‌ای برای هر یک از این رویکردهای مدل‌سازی، انجام شده‌است. با این حال، برای سیستم‌های پیچیده، مدل‌های ترکیبی بر اساس ترکیب این سه رویکرد می‌تواند دقت را در حل مسائل نت افزایش دهد (جیمنز<sup>۷</sup> و همکاران، ۲۰۲۰). این مدل‌ها به صورت مدل‌های مبتنی بر دانش، مدل‌های داده محور، مدل‌های مبتنی بر فیزیک می‌باشند. برخی از چالش‌های نت پیشگویانه شامل هزینه راه‌اندازی اولیه (ساکیب<sup>۸</sup> و وویست، ۲۰۱۸)، میزان درستی و دقت داده‌ها (فینک<sup>۹</sup>، ۲۰۲۰) و روش‌های مفید و

<sup>1</sup> Gu

<sup>2</sup> Industry 4.0

<sup>3</sup> Predictive Maintenance

<sup>4</sup> Kalathas

<sup>5</sup> Takata

<sup>6</sup> Modoni

<sup>7</sup> Jimenez

<sup>8</sup> Sakib

<sup>9</sup> Fink



کاربرد تجزیه و تحلیل داده‌ها (کالاتاس<sup>۱۰</sup> و پاپوتسیداکیس، 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<sup>۱۱</sup> و چتویند، ۲۰۱۳). 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 داده محور 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 داده محور، یکی از نیازهای اساسی این رویکرد، یک سیستم نظارت بر وضعیت فعلی که دارای حسگرهای با کیفیت بالا باشد (فینک<sup>۱۲</sup>، ۲۰۲۰). ان<sup>۱۳</sup> و همکاران (۲۰۱۵) بیان کردند که رویکرد داده محور شامل رویکردهای آماری و رویکردهای هوش مصنوعی است. آمار و نظریه احتمال اساس مدل‌های داده محور است. در دهه ۹۰، برخی از رویکردهای آماری معروف، فرآیند مارکوف و روش بیزی برای مطالعه احتمال خرابی دستگاه‌ها ایجاد شده‌اند (سکیب<sup>۱۴</sup> و همکاران، ۲۰۱۸). با ارائه داده‌های استخراج شده از شرایط کارخانه، می‌توان تنوع زیادی از برنامه‌ها را بدست 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<sup>۱۵</sup> و وو، ۲۰۱۹).

تیدیری<sup>۱۶</sup> و همکاران (۲۰۱۶) تشخیص خرابی در صنایع طی سال‌های اخیر به طور فعال مورد تحقیق قرار گرفته است و آنها عملکرد روش‌های مبتنی بر مدل و داده محور را در تشخیص خرابی فرآیند مورد مطالعه قرار دادند. رویکرد داده محور تشخیص خرابی‌ها را به عنوان وظایف طبقه‌بندی انجام می‌دهد و از هر دو روش طبقه بندی 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<sup>۱۷</sup> و همکاران (۲۰۱۹) تحقیقات مختلفی در حوزه نت انجام شده است، را مورد بحث و بررسی قرار دادند 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 داده محور 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<sup>۱۸</sup> و همکاران، 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 مجموعه داده‌ها به حسگرهای فرکانس بالا تبدیل شده است که داده‌های بزرگ را در زمان واقعی در مورد چندین

<sup>10</sup> Kalathas

<sup>11</sup> Diggle

<sup>12</sup> Fink

<sup>13</sup> An

<sup>14</sup> Sakib

<sup>15</sup> Zhang

<sup>16</sup> Tidiri

<sup>17</sup> Bousdekis

<sup>18</sup> Márquez

متغیر تولید می‌کند (به عنوان 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 برنامه‌ریزی 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<sup>۱۹</sup> و همکاران، ۲۰۱۵). رویکرد نت پیشگیرانه مبتنی بر شرایط توسط مورتزیز<sup>۲۰</sup> (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 فراابتکاری، روش‌های هوش مصنوعی و سیستم‌های چند عاملی می‌توان حل کرد (یاداو<sup>۲۱</sup> و جاییسوال، 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. زیرا به 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 (بواز<sup>۲۲</sup> و همکاران، ۲۰۱۹). با این 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. با این 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 (دوراسویج<sup>۲۳</sup> و جکوبویج، 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 مسایل چند جمله‌ای نامعین سخت<sup>۲۴</sup> تلقی می‌شود. بنابراین، الگوریتم‌های ابتکاری و فراابتکاری<sup>۲۵</sup> به روشی متداول برای دستیابی به راه‌حل‌های نزدیک به بهینه برای مشکلات برنامه‌ریزی در سال‌های اخیر تبدیل شده است. با این حال، سیستم‌های تولید در دنیای واقعی همیشه دارای عدم قطعیت‌های زیادی مانند تغییر زمان فرآیند و خرابی دستگاه‌های تولیدی هستند. بنابراین راه حل مطلوب در گذشته ممکن است در شرایط فعلی، نامناسب و غیرعملی باشد و برای بازسازی راه حل جدید به زمان زیادی نیاز خواهد بود. وضعیت یک سیستم تولیدی به طور مداوم تغییر می‌کند که می‌توان عملکرد سیستم را با اجرای یک سیاست زمانبندی درست به جای استفاده از یک قواعد توزیع<sup>۲۶</sup> 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 کوتاه مدت را انجام می‌دهد.

مسئله تعریفی به زمانبندی بلادرنگ<sup>۲۷</sup> (یا آنی) 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 هر کدام از این ماشین‌ها، نیازمند یک راه‌حل یکپارچه است. مسئله مقاله به دنبال

<sup>19</sup> Gao

<sup>20</sup> Mourtziz

<sup>21</sup> Yadav

<sup>22</sup> Bouazzaa

<sup>23</sup> Durasevic

<sup>24</sup> Job Shop Scheduling

<sup>25</sup> Job Shop Scheduling

<sup>26</sup> Dispatching Rule

<sup>27</sup> Online Scheduling



این است که در هر لحظه که تقاضای<sup>۲۸</sup> 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 هر کدام 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 به صورت بهینه تخصیص کار به ماشین را در شرایط تغییر محیط کارگاه انجام دهد نیاز به مدت زمان برای آموزش الگوریتم تخصیص خود دارد. هرچه این یادگیری بیشتر صورت گیرد مدت زمانی که بتواند با تغییرات کارهای ورودی جدید تطبیق پیدا کند، کمتر خواهد بود.

روش‌هایی که در گذشته در زمانبندی کار کارگاهی<sup>۲۹</sup> 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 به طور 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 به عنوان 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 با گذشت 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 با هدف بهبود محیط کارگاه تغییر و تطبیق می‌دهد. استفاده از الگوریتم‌های دقیق<sup>۳۰</sup> برای حل این مسئله بسیار مشکل و از نظر زمانی امکان‌پذیر نمی‌باشد. لازم به ذکر است که الگوریتم‌های فراابتکاری نیز کیفیت جواب را پایین آورده و شاید نتواند پاسخ خود را به زمان مورد نیاز 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 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 بالادرنگ 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<sup>۳۱</sup> 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 پیاده سازی 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 سفارشات به حداقل می‌رسد و این خود نوعی رضایت مشتری را به همراه دارد.

### ۱-۳- مفروضات مسئله

مفروضات مسئله مطرح شده در قسمت زیر ارائه می‌شود:

- کار مستقل هستند و از توالی عملیاتی (یا مسیرهای کاری) کاملاً منظم تشکیل شده اند.
- همه‌ی کارها از اهمیت یکسان برخوردارند.

<sup>28</sup> Demand

<sup>29</sup> Job Shop Scheduling

<sup>30</sup> Exact Algorithms

<sup>31</sup> Shop Floor

- 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 به صورت تصادفی وارد سیستم شود.
- سیستم از کارها جدید مطلع نیست.

### ۳-۲-۳- 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 باقی مانده قطعات دستگاه را پیشگویی می‌کند. در این روش، با به دست آوردن عمر مفید باقی مانده اولیه یک برنامه نگهداری توسعه داده می‌شود و با استفاده از خروجی و سیگنال سنسورهای نصب بر روی ماشین، این عمر مفید به صورت آنی و زمان واقعی به‌روز می‌شوند. برنامه اقدامات مربوط به نت بر اساس آخرین تغییرات مقادیر سنسورها، باقی مانده 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 صرفه-جویی عمده در هزینه‌ها، دقت در پیش‌بینی خطا در ماشین و افزایش در دسترس بودن ماشین‌ها می‌شود.

### ۳-۲-۱- 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 با هم 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 نظر گرفتن جنگل تصادفی به صورت طبقه‌بندی می‌باشد، زیرا طبقه‌بندی گاهی اوقات به عنوان بلوک 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 هیچ چیز) در فرایند پیش‌بینی کمک نمی‌کنند (عبدالکریم<sup>۳۲</sup> و عبدالعزیز، ۲۰۲۱).

### ۳-۲-۲- مدل‌های خطی تعمیم یافته

مدل‌های خطی تعمیم یافته<sup>۳۳</sup> (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<sup>۳۴</sup>، یک روش منظم‌شده 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 منظم‌سازی 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 زیرمجموعه 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 منحصر به فرد 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  $\lambda$  ضریب رگرسیون می‌باشد (گوریز<sup>۳۵</sup> و ساکلین، ۲۰۲۰).

$$\min_{\beta^* \in \mathbb{R}^p} \{ \|y^* - X^* \beta^*\|_2^2 + \lambda^* \|\beta^*\|_1 \} \quad (۱)$$

$$X_{(n+p) \times p}^* = (1 + \lambda_2)^{-1/2} \begin{pmatrix} X \\ \lambda_2^{1/2} I_{p \times p} \end{pmatrix} \quad (۲)$$

<sup>32</sup> Abdulkareem

<sup>33</sup> General Linear Models

<sup>34</sup> Elastic Net

<sup>35</sup> Gorriz

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

### ۳-۲-۳- ماشین های بردار پشتیبان

در یادگیری ماشین، ماشین های بردار پشتیبان مدل های یادگیری تحت نظارت با الگوریتم های یادگیری مرتبط هستند که داده ها را برای طبقه بندی و تحلیل رگرسیون تجزیه و تحلیل می کنند. در این مقاله با استفاده از ماشین های بردار پشتیبان می توان بین ماشین هایی که برچسب خرابی دارند را از ماشین هایی که به درستی در حال انجام فعالیت خود بر روی محصول هستند، تمایز قائل شد. معادله خط جداساز اصلی را معادله ابرصفحه می نامند. معادله ابرصفحه ای که نقاط را تقسیم می کند (برای طبقه بندی) اکنون می تواند به راحتی به صورت زیر نوشته شود:

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

در اینجا مقدار  $b$  نشان دهنده سوگیری معادله ابرصفحه می باشد. اگر بعد مسئله  $D$  باشد، بعد ابرصفحه همیشه  $D-1$  است. در مسئله نت بدیهی می باشد که اگر بتوان همچین ابرصفحه ای که داده هایی با برچسب خرابی را از داده های با برچسب سالم جدا کند، در تولید مدل نگهداری کمک خواهد کرد. این ابرصفحه با توانایی این را داشته باشد که به بهترین شکل ممکن با حداقل خطا طبقه بندی را انجام دهد. بنابراین، برای داشتن کمترین خطا در طبقه بندی نقاط داده، ملزم این است که فاصله بین نقطه داده و خط جدا کننده را به دست آید. فاصله یک معادله ابرصفحه  $w^T \phi(x) + b = 0$  از یک بردار  $\phi(x_0)$  از طریق فرمول زیر قابل محاسبه است.

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

که در این فرمول  $\|w\|_2$  نرمال اقلیدوسی بردار  $w$  می باشد.

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

هدف بردار ماشین پشتیبان حداکثر کردن کمترین فاصله است. محصول برچسب پیش بینی شده و واقعی در پیش بینی صحیح بیشتر از صفر خواهد بود، در غیر این صورت کمتر از صفر می باشد. برای مجموعه داده های کاملاً قابل تفکیک، ابرصفحه ای مطلوب تمام نقاط را به درستی طبقه بندی می کند و مقادیر بهینه را در معادله وزن بیشتر جایگزین می کند. مقدار وزن بهینه از فرمول زیر به دست می آید.

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

انتظار نمی رود که این روش بتواند چنین معادله ابرصفحه ای، را در داده های واقعی که مملو از خطا و اشتباه است، به دست آورد و امکان این وجود دارد که بعضی از داده ها در دسته واقعی خود قرار نگیرند. در حالی که یک معادله ابرصفحه ای مطلوب است که این دسته بندی را به صورت کامل انجام دهد. روشی هست که به مدل اجازه می دهد در هنگام طبقه بندی چند داده را اشتباه دسته بندی کند. از این روی یک متغیر به عنوان مجازات برای دسته بندی اشتباهی که برای هر داده صورت گرفته، اضافه کرده می شود. اگر به درستی طبقه بندی شده باشد مقدار  $\beta = 0$  و اگر اشتباه طبقه بندی شده باشد  $\beta > 1$  به عنوان پنالتی به مدل مذکور اضافه می شود.

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

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

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

اگر  $C = 0$  باشد به معنای مرزهای پیچیده تر است، زیرا طبقه بندی کننده با متغیر اضافه شده، مجازات نمی شود، در نتیجه، ابرصفحه مطلوب می تواند از آن در هر مکانی استفاده کرده و همه طبقه بندی های اشتباه بزرگ را بپذیرد و در نتیجه، مرز تصمیم گیری خطی و نامناسب خواهد بود.





اگر  $C$  بی نهایت باشد، طبقه‌بندی داده‌ها با برچسب اشتباه به شدت مجازات می‌شوند و مدل نمی‌تواند طبقه‌بندی نادرست انجام دهد و در نتیجه برازش بیش از حد را انجام دهد. بنابراین پارامتر  $C$  مهم است (اچونگ<sup>۳۶</sup> و همکاران، ۲۰۱۸).

#### ۳-۲-۴- روش تقویت گرادیان<sup>۳۷</sup>

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 تصمیم گیرنده 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 تقویت کننده می‌سازد و با اجازه بهینه‌سازی یک تابع ضرر قابل تمایز 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 به صورت زیر می‌باشد.

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

$$F_0(x) = \operatorname{argmin}_{\gamma} \sum_{i=1}^n L(y_i, \gamma) \quad (11)$$

۲. از  $m = 1$  تا  $M$ :

محاسبه مقدار باقی مانده را به وسیله 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 مقادیر ورودی و  $r_{im}$  به دست می‌آورد  $(h(x))$ . سپس با استفاده از بهینه‌سازی رابطه زیر مقادیر  $\gamma$  را به دست می‌آید.

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

با به دست آوردن مقادیر  $\gamma$ ، مدل را به روز رسانی می‌کند.

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

۳. خروجی مدل نشان داده می‌شود<sup>۳۸</sup>.

#### ۳-۳- روش‌های استفاده شده برای زمانبندی

مشکل زمانبندی کار کارگاهی<sup>۳۹</sup> 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 سخت تلقی 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 توسعه یافته و ابزارهای بیشتر، رویکردهای

<sup>36</sup> Hwang

<sup>37</sup> Gradient Boosting

<sup>38</sup> [https://en.wikipedia.org/wiki/Gradient\\_boosting](https://en.wikipedia.org/wiki/Gradient_boosting)

<sup>39</sup> Job Shop Scheduling

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 به طور گسترده در صنعت مورد استفاده قرار می‌گیرد و این روش‌ها به طور 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 به عنوان قواعد ساده تعریف کرد مانند اولین ورود - اولین خروج<sup>۴۰</sup> (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<sup>۴۱</sup> (EDD) و کمترین زمان انجام کار (پردازش)<sup>۴۲</sup> (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 شد 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 رویکرد های دیگر به دست آوردند.

### ۱-۳-۳- روش‌های ابتکاری

قواعد توزیع مهم در ادبیات موضوع به پنج دسته تقسیم می‌شود. این دسته بندی 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، فرآینک‌های 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 به کار برده شده، به صورت است.

- **اولین ورودی - اولین خروجی (FIFO):** اغلب به عنوان 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، پیاده سازی FIFO آسان تلقی می‌شود و می‌تواند تقریباً در تمام مشکلات برنامه ریزی مناسب باشد.
- **زودترین موعد تحویل (EDD):** کار را با آخرین مهلت تعیین شده انتخاب می‌کند، زمانی مؤثر است که هدف کاهش حداکثر تاخیر باشد، به همین دلیل در بسیاری از سیستم‌های تولیدی استفاده می‌شود. EDD هنگامی که تغییرات اعمال می‌شود یا وقتی با روش‌های ابتکاری دیگر ترکیب می‌شود حتی بهتر عمل می‌کند.
- **کمترین زمان پردازش (SPT):** به دنبال این است که هنگام تصمیم‌گیری 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 می‌شود.

### ۲-۳-۳- یادگیری ماشین و یادگیری تقویتی

در سیستم تولید امکان این وجود دارد که دستگاه‌ها خراب شوند و یا کارهای جدید وارد کارگاه شود. با توجه به قابلیت‌های منحصر به فرد الگوریتم‌های یادگیری ماشین می‌تواند با ورود اختلال در محیط کارگاه خود را تطبیق دهد و برنامه بهینه‌ساز 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. الگوریتم‌های یادگیری ماشین هنگام برخورد با سیستم‌های پیچیده دارای درجه تصادفی بالا بسیار مقرون به صرفه است و استفاده از آن منطقی می‌باشد.

یادگیری تقویتی با بررسی حالات محیط یاد می‌گیرد. یادگیری تقویتی در زمینه‌های مختلف کاربردهای عملی بسیار مؤثر واقع شده است. با این حال، کاربرد یادگیری تقویتی مبتنی بر عامل<sup>۴۳</sup> در برنامه‌ریزی پویا و بلادرنگ، به طور گسترده مورد بررسی قرار نگرفته است. با توجه به مرور ادبیات، سیاست‌های یادگیری ماشین و یادگیری تقویتی عملکرد بهتری نسبت به مدل‌های مختلف ریاضی نشان داده است.

<sup>40</sup> First-in-First-out

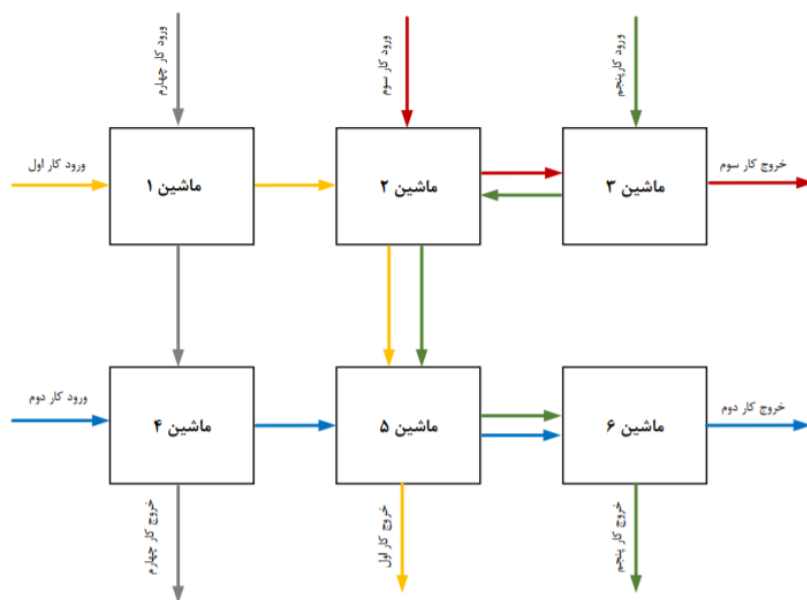
<sup>41</sup> Earliest Due Date

<sup>42</sup> Shortest Processing Time

<sup>43</sup> Agent



در مقاله، یک مدل از یک سیستم کار کارگاهی برای شبیه سازی محیط زمانبندی 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. سفارشات 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، ۲۰۲۱). در این مقاله با استفاده از روش بهینه سازی سیاست تقریبی<sup>۴۴</sup> یک مسئله زمانبندی پویا در محیط 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

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 این رو مورد توجه است که راهی برای آموزش عامل ها 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 روش 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 که ماشین می‌تواند مشاهده کند، تشکیل شده است. در یادگیری تقویتی، ماشین می‌تواند در گام های 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.

### ۱-۲-۳- ماشین ها و فرآیندها

در هر فرآیند از ماشین ها برای تولید محصول، بیکار نبودن ماشین ها و نبودن هزینه خرابی فرض اصلی مسئله مقاله است. همچنین ماشین ها تا پایان کار فعلی که بر روی آن ها در حال انجام پردازش است، تغییر وضعیت نمی‌دهد. ماشین ها از نظر قابلیت پردازش کارهای یکسان هیچ تفاوتی ندارد. برای روش یادگیری تقویتی چند عاملی<sup>۴۵</sup>، 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 جمع آوری می‌شود. با این حال، عوامل به طور همزمان تصمیم می‌گیرند و هنگام تصمیم‌گیری با یکدیگر ارتباط برقرار نمی‌کنند. هر 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. سفارشات به طور مداوم در توزیع پواسون با نرخ  $\lambda$  که یک

<sup>44</sup> Proximal Policy Optimization

<sup>45</sup> Multi-agent

عدد حقیقی می‌باشد، می‌رسند. به ترتیب نوع کار، زمان سررسید ( $OD$ )، اندازه سفارش ( $OS$ ) با گام زمانی  $t$  از توزیع‌های تصادفی یکنواخت به دست می‌آیند. تنظیمات توزیع یکنواخت تصادفی این پارامترها قابل کنترل هستند.

### ۲-۳-۳- 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
$Ep$	یک قسمت از تغییرات سیستم که شامل ورود کارهای جدید و کارهایی بر روی ماشین‌ها در حال انجام هستند
$rewardt$	میزان پاداش گرفته شده یادگیری در هر گام زمانی
$k$	$K$ امین پردازشی که بر روی ماشین انجام می‌شود
$OS$	اندازه سفارش
$Omax/Omin$	نسبت بیشینه به کمینه اندازه سفارش
$OD$	مدت زمان سررسید سفارش
$ODmax/ODmin$	نسبت بیشینه به کمینه زمان سررسید سفارش
$Oflowtime$	جریان زمانی پس از دریافت سفارش
$OProcess$	مدت زمان پردازش یک سفارش

### ۳-۳-۳- معیارهای ارزیابی

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<sup>۴۶</sup> و زمان تکمیل کار<sup>۴۷</sup> همچنین برای ارزیابی مسئله زمانبندی استفاده می‌شود ولی در این تحقیق مورد استفاده قرار نگرفته است (الله‌وردی<sup>۴۸</sup>، ۲۰۱۵). سه معیار مورد استفاده در تحقیق به صورت زیر می‌باشد.

- **میانگین تاخیر  $\bar{T}$** : 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  $\bar{F}$** : 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 عبارتند از  $INT$ ،  $OS$  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، در حالی که این فاصله همچنین نوسان تقاضای سفارش را در طی مراحل زمانی تعیین می‌کند. به دلیل زمان،  $OD$  زمان تحویل سفارش را تعیین

<sup>46</sup> Total Earliness

<sup>47</sup> Total Completion Time

<sup>48</sup> Allahverdi



می‌کند و بنابراین بر تصمیمات زمانبندی تأثیر می‌گذارد. علاوه بر این، حالت‌های سفارشات برای در نظر گرفتن جنبه‌های تنظیمات سیستم طراحی شده است. در جدول ۲ این تنظیمات نشان داده شده است.

جدول ۲- پارامترهای کنترل شده سفارشات  
Table 2- Parameters of the controlled orders

حالت	$O_{max}$	$O_{min}$	$OD_{max}$	$OD_{min}$	$INT$
۱	۲۵	۱۵	۶۰	۴۰	۲۰
۲	۶۰	۴۰	۶۰	۴۰	۲۰
۳	۲۵	۱۵	۶۰	۴۰	۱۰
۴	۲۵	۱۵	۶۰	۴۰	۵
۵	۲۵	۱۵	۳۰	۲۰	۲۰

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

۱. 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.

۲. 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.

۳. 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 سفارشات افزایش می‌یابد. این تغییرات در جدول ۳ قابل مشاهده می‌باشد.

جدول ۳- تنظیم پارامترها با اندازه سفارشات بالا

Table 3- Parameter setting with a high order size

حالت	$O_{max}$	$O_{min}$	$OD_{max}$	$OD_{min}$	$INT$
۱۰	۱۲۰	۱۰۰	۶۰	۴۰	۲۰
۱۱	۲۰۰	۱۸۰	۶۰	۴۰	۲۰
۱۲	۳۰۰	۲۸۰	۶۰	۴۰	۲۰

### ۳-۳-۴- تنظیمات یادگیری تقویتی

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 جمع آوری ویژگی‌ها از سیستم ایجاد می‌شود. حالت فضای  $X$  به صورت فرمول زیر تعریف می‌شود.

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

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 جمع آوری 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 ( $\mu_i$ ) 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.

Table 4- Definition of the reward and loss reinforcement learning

زیان یادگیری تقویتی	پاداش یادگیری تقویتی	روش های اندازه گیری
تعریف نشده	$\mu_t$ و $O_{Process}$	میانگین تاخیر
$\mu_t$ و $O_{flowtime}$	تعریف نشده	میانگین زمان جریان ساخت
۱	۰	درصد کارهای دیرکرده

برای شبیه سازی یک سیستم زمان بندی کار کارگاهی و تسهیل عوامل یادگیری که از فرایند تولید درس می گیرند، سیستم را در چند قسمت، که شامل چندین مرحله زمانی است، در نظر می گیریم. عوامل یادگیری به طور مداوم یاد می گیرند و یادگیری را از قسمت های قبلی جمع آوری می کنند. در مراحل اولیه، هنگامی که عامل های یادگیری به مشکل نزدیک می شوند، عوامل انتخاب توزیع را بررسی می کنند و تصمیمات تصادفی می گیرند. برای مقایسه عملکرد واقعی و آموخته شده رویکردهای یادگیری تقویتی، هنگامی که اثر یادگیری RL ثابت باشد، روش ها و آزمون های گسترده ای انجام می شود و افزایش پاداش سیستم منجر به تثبیت یادگیری شود. نتایج نشان می دهد که  $EP = 100$  برای عوامل یادگیری برای دستیابی به اثر یادگیری کافی است. بنابراین، آزمایشات با  $EP = 100$  انجام می شود.

#### ۴- نتایج محاسباتی

در این بخش، در ابتدا به نتایج به دست آمده از مدل نت پیشگویانه پرداخته می شود. سپس نتایج و مقایسات مدل شبیه سازی شده را با سه رویکرد ابتکاری و روش یادگیری عمیق که در فصل گذشته به طور مفصل به آن اشاره شد، بررسی می شود. لازم به ذکر است که برای گرفتن خروجی ها از نرم افزار Anaconda به زبان پایتون در محیط Jupyter Notebook استفاده شده است.

داده ها شامل چندین سری زمانی چند متغیره است. داده ها برای آموزش مدل یادگیری پیشگویانه به زیر مجموعه های آموزشی و آزمایشی تقسیم می شود. علت تقسیم داده ها به این دو زیر مجموعه، برای این که بتوانیم مدل به دست آمده از روش های یادگیری ماشین را مورد ارزیابی قرار دهیم. نسبت این تقسیم یک به پنج می باشد

در این مقاله، با استفاده از روش های یادگیری ماشین، می توان تعداد چرخه های عملیاتی باقی مانده قبل از خرابی ماشین، پیشگویی کرد. یعنی تعداد چرخه های عملیاتی پس از آخرین چرخه که موتور به کار خود ادامه می دهد. با روش هایی که در قسمت های بعدی به آن اشاره می شود می توان احتمال خرابی ماشین را تا یک ساعت بعدی تخمین زد. از این احتمال خرابی در قسمت زمان بندی بلادرنگ استفاده می شود. ماشین مورد نظر شامل ۲۱ حسگر و ۳ تنظیم عملیاتی می باشد. در جدول ۵، ستون هایی که در این مجموعه داده می باشد شامل: چرخه عملیاتی، تنظیمات عملیاتی اول، تنظیمات عملیاتی دوم، تنظیمات عملیاتی سوم، مقدار عددی حسگر اول تا حسگر ۲۱، باقی مانده عمر مفید ماشین، وضعیت دستگاه (ستون وضعیت دستگاه نیز نشان دهنده این است که آیا ماشین خراب است یا نه؟).


برای آماده سازی داده ها، در یک مجموعه داده بعضی از ویژگی ها تاثیر بیشتری بر روی نوع برجسب (نسبت به دیگر ویژگی ها) می گذارند. به عبارتی دیگر این داده های مورد ارزیابی که دارای ۲۱ حسگر می باشد مقدار عددی برخی از این حسگر ها تاثیر بیشتری بر روی خرابی ماشین مورد نظر می گذارد. با استفاده از روش جنگل تصادفی این حسگر های مؤثر بر عمر مفید باقی مانده، مشخص می شوند. در محیط برنامه مدل جنگل تصادفی بر روی مجموعه داده ساخته می شود. با توجه به اعداد به دست آمده حسگر های ۲، ۳، ۲۱، ۱۵، ۱۴، ۷، ۱۲، ۴، ۹، ۱۱ به ترتیب بیشترین تاثیر را بر عمر مفید باقی مانده ماشین یا به عبارتی دیگر همان خرابی ماشین، می گذارد (شکل ۲). پس از اینکه این حسگر های مشخص شدند، به علت بهبود مدل پیشگویانه نت، از مجموع داده حذف می شوند.



Table 5- Maintenance data

Cycle	Op_Setting_1	Op_Setting_2	Op_Setting_3	Sensor_1	Sensor_2	Sensor_3	Sensor_4	Sensor_5
1	-0.0007	-0.0004	100.0	518.67	641.82	1589.70	1400.60	14.62
2	0.0019	-0.0003	100.0	518.67	642.15	1591.82	1403.14	14.62
3	-0.0043	0.0003	100.0	518.67	642.35	1587.99	1404.20	14.62
4	0.0007	0.0000	100.0	518.67	642.35	1582.79	1401.87	14.62
5	-0.0019	-0.0002	100.0	518.67	642.37	1582.85	1406.22	14.62

Sensor_13	Sensor_14	Sensor_15	Sensor_16	Sensor_17	Sensor_18	Sensor_19	Sensor_20	Sensor_21	Target_Remaining_Useful_Life
2388.02	8138.62	8.4195	0.03	392	2388	100.0	39.06	23.4190	191
2388.07	8131.49	8.4318	0.03	392	2388	100.0	39.00	23.4236	190
2388.03	8133.23	8.4178	0.03	390	2388	100.0	38.95	23.3442	189
2388.08	8133.83	8.3682	0.03	392	2388	100.0	38.88	23.3739	188
2388.04	8133.80	8.4294	0.03	393	2388	100.0	38.90	23.4044	187



```

Sensor_11    0.483372
Sensor_9     0.135095
Sensor_4     0.097162
Sensor_12    0.044909
Sensor_7     0.034436
Sensor_14    0.033587
Sensor_15    0.030271
Sensor_21    0.027977
Sensor_3     0.024597
Sensor_2     0.023624
dtype: float64

```

شکل ۳- نمودار اهمیت حسگرها

Figure 3- Diagram of the importance of sensors

#### ۴-۱- روش های استفاده شده 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 استفاده شده است. در ادامه خروجی های هر یک از این مدل ها نشان داده شده است.

##### ۴-۱-۱- رگرسیون جنگل تصادفی

برای استخراج مدل نت پیشگویانه اولین روش مورد استفاده رگرسیون جنگل تصادفی می باشد. پس از این که مدل ساخته شد باید آن را مورد ارزیابی قرار داد تا کیفیت مدلی که به دست آمده است مشخص شود. برای این کار از داده آزمایشی استفاده می شود. مدت زمانی مورد نیاز برای ساخت مدل ۲/۳۲۳ دقیقه به طول می انجامد. مقدار خطای این مدل در تشخیص خرابی ماشین ۲۹/۸۴ می باشد. این مقدار را با تنظیم پارامترهای مدل می توان کاهش داد. برای اینکه مقدار عددی بهینه پارامترها را به دست آوریم از ماژول GridSearch استفاده می کنیم.

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

#### ۲-۱-۴- مدل GLM Elastic Net

در این قسمت در کتابخانه Sklearn با استفاده از ماژول Elasticnet مدل سازی 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، طبقه بندی و سایر وظایف است که یک مدل پیش بینی را در قالب مجموعه ای از مدل‌های پیش بینی ضعیف، معمولاً درخت تصمیم، تولید می‌کند. با توجه به خروجی به دست آمده، مقدار خطا این مدل ۹۲۱/۲۹ می‌باشد. خروجی های مدل نت که در این مقاله استفاده شده، را می توان 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	۱۷۷۸۰۰۲۴	۲۹۰۸۴۳	۰،۶۲۵
GLM Elastic Net	۲۰۴۳،۰۳۱	۳۴،۶۰۰	۰،۸۶۷
بردار ماشین پشتیبانی	۱۸۵۶،۸۱۲	۳۰،۲۸۲	۰،۶۰۷
Gradient Boosting	۱۷۶۸،۶۲	۲۹،۹۲	۰،۶۲۵
رگرسیون جنگل تصادفی اصلاح شده	۰،۰۱۶	۰،۰۳۴	۰،۷۴۹

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

#### ۲-۲- زمانبندی مسئله مورد مقاله و درخت تصمیم گیری


در این بخش، آزمایشات 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 می‌شود. با اثبات مزیت عملکرد یادگیری عمیق، می‌توان زمینه را برای بحث در مورد مشارکت این مدل یادگیری تقویتی به عنوان یک استراتژی پشتیبانی تصمیم‌گیری ایجاد شود.





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	0.93	0.92	4127
weighted avg	0.98	0.98	0.98	4127



شکل ۳- نمودار ROC و ماتریس آشفستگی جنگل تصادفی

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

جدول ۷- خروجی میانگین تاخیر

Table 7- Outputs of the mean tardiness

حالت	FIFO	EDD	SPT	RL
۱	-۶۱،۴۶	-۶۲،۶۳	-۵۷،۹۸	-۶۳،۰۴
۲	-۲۹،۱۳	-۳۷،۹۳	-۲۵،۶۸	-۴۳،۳۱
۳	-۵۶،۸۰	-۵۲،۴۶	-۵۶،۰۲	-۵۷،۲۴
۴	-۱۹،۶۴	-۲۰،۲۱	-۵۱،۴۰	-۵۸،۴۶
۵	-۲۴،۵۱	-۲۶،۵۰	-۲۳،۶۰	-۲۸،۰۸
۶	-۹،۱۵	-۹،۰۶	-۸،۹۱	-۹،۸۴
۷	-۲۲،۳۷	-۲۱،۰۴	-۵۸،۵۶	-۶۴،۸۵
۸	-۵۶،۰۴	-۵۰،۰۳	-۴۹،۶۴	-۵۴،۲۷
۹	-۴۲،۸۷	-۴۴،۷۶	-۴۵،۹۷	-۳۶،۹۲
۱۰	۵،۱۱	۵،۳۶	-۲۳،۰۷	-۳۹،۱۱

Table 8- Outputs of the mean flow time

حالت	FIFO	EDD	SPT	RL
۱	۸،۴۸	۷،۹۷	۷،۵۵	۷،۵۴
۲	۴۳،۰۸	۳۹،۷۴	۲۷،۷۹	۲۰،۳۸
۳	۱۴،۷۸	۱۳،۶۴	۱۲،۵۶	۱۱،۹۳
۴	۴۶،۳۰	۴۸،۹۸	۱۷،۹۱	۱۳،۹۴
۵	۸،۹۵	۸،۵۱	۸،۶۲	۷،۸۵
۶	۹،۰۶	۸،۷۷	۸،۹۳	۸،۶۹
۷	۴۷،۳۱	۲۶،۹۳	۱۱،۲۳	۹،۴۸
۸	۲۳،۸۸	۲۳،۹۷	۷،۶۱	۱۶،۸۲
۹	۸،۰۳	۷،۱۸	۸،۶۳	۶،۳۳
۱۰	۶۹،۴۷	۶۸،۶۳	۵۳،۰۲	۳۲،۷۷

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

حالت	FIFO	EDD	SPT	RL
۱	۰،۰۰	۰،۰۰	۰،۰۰	۰،۰۰
۲	۱۸،۴۱	۱۶،۰۰	۹،۱۸	۹،۰۹
۳	۰،۴۶	۰،۱۸	۲،۳۸	۰،۰۹
۴	۲۵،۴۱	۲۶،۶۳	۵،۹۴	۴،۸۹
۵	۰،۰۰	۰،۰۰	۰،۰۰	۰،۰۰
۶	۱۷،۷۸	۲۸،۸۹	۲۹،۸۰	۱۳،۵۰
۷	۲۹،۳۱	۲۶،۰۰	۳،۲۱	۰،۰۰
۸	۵،۷۵	۴،۱۲	۹،۶۱	۵،۲۶
۹	۴،۵۷	۴،۰۶	۳،۱۳	۶،۶۷
۱۰	۳۹،۵۰	۴۰،۶۶	۲۷،۰۰	۲۶،۸۰

همانطور که قبلاً ذکر شد، حالت‌های سفارش به گونه‌ای طراحی شده‌است که حجم سفارشات کمتر از ظرفیت سیستم تولید است و سفارشات در این مفروضات برآورده می‌شوند. نتایج نشان می‌دهد که روش یادگیری تقویتی در آزمایش‌ها بهتر از روش‌های ابتکاری عمل می‌کند. برای سفارش با حالت 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 اندازه گیری 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 سفارشات بزرگتر باشد به عملکرد بهتری دست یابد. از آنجا که ماشین‌ها فقط در هنگام اتمام سفارشات قبلی کار خود را تغییر می‌دهند، اندازه سفارشات 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 سفارشات 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 سفارشات مکرر نسبت به تنظیمات قبلی ایجاد می‌شود. یادگیری تقویتی همچنین در هر سه اندازه‌گیری پیش‌تاز است. با این 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 سفارشات حالت ۱، ۵ و ۶، زمان سررسید سفارشات یک متغیر مستقل است. می توان دریافت که روش یادگیری تقویتی در همه اندازه گیری ها نتیجه بهتری می گیرد. مزایا نسبی به بهترین روش ابتکاری از ۵ تا ۱۰ درصد است. این مجموعه تنظیمات نشان می دهد که یادگیری تقویتی دارای مزایای عملکرد ثابت و کوچک در تغییرات زمان سررسید می باشد.

برای سفارش حالت ۷، یادگیری تقویتی در همه اندازه گیری ها از بهترین روش های ابتکاری، بهتر است، به ترتیب با مزایای ۱۰، ۱۵ و ۲۵ در سه اندازه گیری می توان نام برد. این مزیت منحصر به فرد روش یادگیری ماشین را در مسئله برنامه ریزی نشان می دهد. روش های ابتکاری تا زمانی که سفارش بزرگ در  $t = 100$  کامل نشود، به دلیل منطق ثابت تصمیم گیری، سفارشات بعدی را اداره نمی کند. با این وجود، عوامل یادگیری ماشین به دنبال حداکثر پاداش هستند و آنها سفارش بزرگ را به قطعات کوچکتر تقسیم می کنند و سفارش بزرگ را یکبار انجام نمی دهند. متناوباً، سایر سفارشات در این بین پردازش می شوند. بنابراین، اختلال در یک سفارش بزرگ کمتر بر عملکرد کلی تأثیر می گذارد.

برای سفارش حالت ۸ و ۹، هیچ نتیجه ای وجود ندارد که نشان دهد یادگیری تقویتی می تواند عملکرد بهتری داشته باشد. این امر عوامل را مجبور می کند تا داده های یادگیری جدیدی را اتخاذ کرده و پیشبینی های جدیدی را در طول یک سوم وسط یک فرایند انجام دهند، که منجر به اختلال و سردرگمی در یادگیری می شود. در نتیجه، عامل یادگیری قادر به پیشبینی مداوم نسبت به پاداش بالاتر نیست. بنابراین، رویکردهای یادگیری تقویتی هیچ برتری را نشان نمی دهند. به عنوان نکته ای برای حالت ۷، ۸ و ۹، رویکردهای یادگیری تقویتی روی داده های غیر منتظره را بهتر از روش های ابتکاری اداره می کنند، اما نسبت به تغییر طولانی مدیت سازگاری از خود نشان نمی دهد.

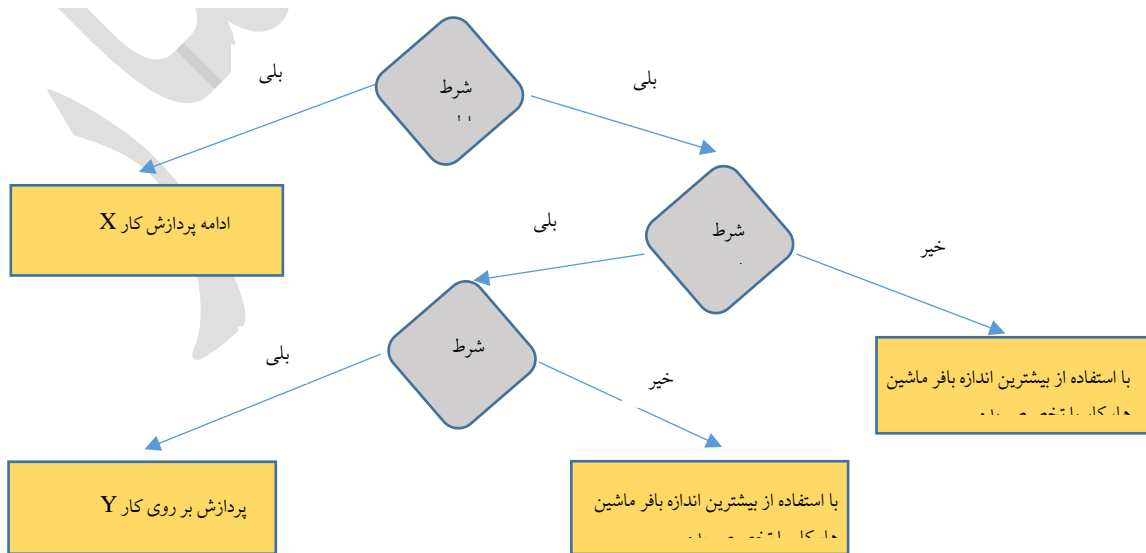
برای حالت های ۱۱، ۱۰ و ۱۲، عملکرد روش یادگیری تقویتی را با روش های ابتکاری در شرایطی که حجم سفارشات بسیار زیاد است مقایسه می شود. اندازه سفارشات از حالت ۱۰ تا حالت ۱۲ بزرگتر می شود. رویکرد یادگیری تقویتی صلاحیت خود را در اندازه گیری میانگین زمان جریان ساخت نشان می دهد، جایی که از هر سه روش ابتکاری تحت همه تنظیمات سفارش بهتر عمل می کند. امتیاز عملکردی رویکرد یادگیری تقویتی با افزایش اندازه سفارشات از ۶۹٪ به ۱٪ کاهش می یابد. در اندازه گیری درصد کارهای دیر هنگام، روش یادگیری تقویتی مزیتی نسبت به بهترین روش ابتکاری، SPT نشان نمی دهد. در این سناریو، یادگیری تقویتی تقریباً به همان نمرات عملکرد SPT دست می یابد.

اگرچه الگوریتم یادگیری تقویتی می تواند تقریباً در همه اندازه گیری ها بهترین نتایج را بدست آورند، اما می توان متوجه شد که عملکرد رویکرد یادگیری ماشین اغلب هنگام در نظر گرفتن سایر ویژگی ها به غیر از آن اندازه گیری ها ضعیف است. به عنوان مثال، هنگامی که در میانگین تاخیر اندازه گیری می شود، درصد سفارشات که با رویکرد یادگیری ماشین تکمیل شده اند در بین همه رویکردها کمترین است. قواعد توزیع به صورت درخت تصمیم در شکل ۴ ارائه شده است و شرایط تصمیم گیری مربوطه در جدول ۱۰ فهرست شده است.

جدول ۱۰- شرایط تصمیم گیری عامل

Table 10- Agent decision conditions

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



شکل ۴- درخت تصمیم عامل یادگیری تقویتی

Figure 3- Decision tree of the agent reinforcement learning



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، بر خلاف 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 هربار نتایج یکسانی در مقایسه با استفاده از درخت توزیع کننده نشان ندهد.

تفسیر درخت توزیع بر اساس الگوهای توزیع است. با استخراج الگوها می‌توان یک مدل درختی مطابق الگو، با شرایط روی گره‌ها و توزیع تصمیمات بر روی برگ‌ها، ایجاد کرد. شرایط، شامل معیارهای عددی، با مشاهدات فرموله شده و با آزمایش نهایی می‌شود. چندین آزمایش را برای به روزرسانی و اصلاح شرایط انجام می‌گیرد تا شرایط بتواند رفتارهای توزیع کننده را توصیف کند.

## ۵- نتیجه‌گیری

امروزه کارخانه‌های مدرن قصد دارند با توسعه و به کارگیری فناوری‌هایی که توانایی تصمیم‌گیری 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 زمانبندی بلادنگ در صنعت تولیدی پیاده‌سازی شده است. مرور جامعی بر مطالعات موجود در حوزه نت و همچنین زمانبندی بلادنگ انجام گرفت که با استفاده از شکاف‌های موجود در ادبیات مسئله سیستم یکپارچه برای تصمیم‌گیری 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 داده‌های واقعی، ارائه شد و نتایج هر یک از این روش‌ها مورد ارزیابی قرار گرفت. این روش‌ها شامل جنگل تصادفی، مدل‌های خطی تعمیم‌یافته، ماشین بردار پشتیبان و تقویت گرادیان می‌باشند. سپس به روش‌های زمانبندی و روش ارزیابی مدل زمانبندی مورد بررسی قرار گرفت. اشاره شده است که برای حل مسائل زمانبندی در کف کارخانه از روش‌های ابتکاری و فرآینتکاری و یادگیری ماشین استفاده می‌شود. پس از ساخت انواع مدل‌ها میزان دقت و کیفیت مدل‌های به دست آمده، مقایسه و ارزیابی شد. سپس رویکرد‌ها ابتکاری و یادگیری تقویتی را در اندازه‌گیری‌های مختلف کارها در مسئله طرح شده، مقایسه شد. نتایج به دست آمده نشان می‌دهد که یادگیری تقویتی در حالت کلی عملکرد بهتری در اکثر آزمایش‌ها به دست می‌آورد. در گام بعدی لازم است که بتوان از یادگیری تقویتی در اعزام کارهایی که به صورت بلادرنگ و آتی وارد سیستم می‌شوند، یک درخت تصمیمی برای عامل یادگیری تعریف شود. بررسی ادغام بیشتر قوانین اکتشافی و روش‌های یادگیری ماشین را می‌توان در تحقیقات آتی مورد بررسی قرار داد. در ضمن، روش‌های کنترلی ارائه شده مربوط به روش‌های رویداد ناهمزمان است. با این وجود، مدیریت سیستم‌های بزرگ تنها با رویکردهای کنترل ناهمزمان بسیار پیچیده است. بنابراین، همچنین در تحقیقات آتی می‌توان روش‌های ترکیبی ناهمزمان و همزمان را در نظر گرفت که امکان کنترل ترکیبی را فراهم می‌کند و مزایای آنها را مورد بررسی قرار داد.

## ۶- مراجع

پدیداران مقدم، فرهنگ و سالاریان، رویا، (۱۳۹۵). مروری بر روش‌های زمانبندی در سیستم‌های بلادرنگ، دومین همایش ملی علوم و فناوری‌های نوین ایران، تهران، انجمن توسعه و ترویج علوم و فنون بنیادین.  
فرامرزیان، حسین (۱۳۹۴). بررسی تأثیر نگهداری و تعمیرات پیشگویانه بر نگهداری و تعمیرات پیشگیرانه با استفاده از تکنیک داده کاوی، کنفرانس بین المللی پژوهش‌های نوین در مدیریت، اقتصاد و حسابداری، موسسه سرآمد همایش کارین، ۲۵ اسفند ۱۳۹۴.

Abdulkareem, N. M., & Abdulazeez, A. M. (2021). Machine Learning Classification Based on Random 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.

An, D., Kim, N. H., & Choi, J. H. (2015). Practical options for selecting data-driven or physics-based prognostics algorithms with reviews. *Reliability Engineering and System Safety*, 133, 223-236.

Bouazza, W., Hamdadou, D., Sallez, Y., Trentesaux, D. (2019). Effective dynamic selection of smart products scheduling rules in FMS, *Manufacturing Letters*, 20, 45-48.

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, 607-612.

- Diggle, P. J., & Chetwynd, A. G. (2013). *Statistics and scientific method: An introduction for students and researchers*, Oxford University Press, UK.
- Đurasević, M., & Jakobović, D. (2018). A survey of dispatching rules for the dynamic unrelated machines environment. *Expert Systems with Applications*, 113, 555-569.
- Fink, O. (2020). *Data-Driven Intelligent Predictive Maintenance of Industrial Assets*, Springer.
- Gao, R., Wang, L., Teti, R., Dornfeld, D., Kumara, S., Mori, M., & Helu, M. (2015). Cloud-enabled prognosis for manufacturing. *CIRP Annals - Manufacturing Technology*, 64(2), 749-772.
- García Márquez, F. P., Tobias, A. M., Pinar Pérez, J. M., & Papaelias, M. (2012). Condition monitoring of wind turbines: Techniques and methods. *Renewable Energy*, 46, 169-178.
- Gorritz, J. M., & Suckling, J. (2020). A connection between the pattern classification problem and the General Linear Model for statistical inference. arXiv preprint arXiv:2012.08903.
- Gu, C., He, Y., Han, X., Chen, Z. (2017). Product Quality Oriented Predictive Maintenance Strategy for Manufacturing Systems, *Proc. of the 2017 Prognostics and System Health Management Conference*, Harbin, China, 9-12 July 2017.
- Hwang, S., Jeong, J., & Kang, Y. (2018). SVM-RBM based predictive maintenance scheme for IoT-enabled smart factory. *International Conference on Digital Information Management*, 162-167
- Kalathas, I., & Papoutsidakis, M. (2021). Predictive maintenance using machine learning and data mining: A pioneer method implemented to greek railways. *Designs*, 5(1), 2021.
- Krüger, J., Wang, L., Verl, A., Bauernhansl, T., Carpanzano, E., Makris, S., Fleischer, J., Reinhart, G., Franke, J., & Pellegrinelli, S. (2017). Innovative control of assembly systems and lines. *CIRP Annals*, 66(2), 707-730.
- 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.
- Montero Jimenez, J.J., 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, 2020.
- Mourtzis, D., Vlachou, E., Xanthopoulos, N., Givehchi, M., & Wang, L. (2016). Cloud-based adaptive process planning considering availability and capabilities of machine tools. *Journal of Manufacturing Systems*, 39, 1-18.
- Sakib, N., & Wuest, T. (2018). Challenges and opportunities of condition-based predictive maintenance: A review. *Procedia CIRP*, 78, 267-272.
- Takata, S., Kimura, F., Van Houten, F. J. A. M., Westkämper, E., Shpitalni, M., Ceglarek, D., & Lee, J. (2004). Maintenance: Changing role in life cycle management. *CIRP Annals - Manufacturing Technology*, 53(2), 643-655.
- 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.
- Wang, L., Hu, X., Wang, Y., Xu, S., Ma, S., Yang, K., Liu, Z., & Wang, W. (2021). Dynamic job-shop scheduling in smart manufacturing using deep reinforcement learning. *Computer Networks*, 190, 107969.
- Yadav, A., & Jayswal, S. C. (2018). Modelling of flexible manufacturing system: a review. In *International Journal of Production Research*, 56(7), 2464-2487.
- 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.