

مروری بر یادگیری ماشین و داده‌کاوی در صنعت تولید

حمزه شیخ شعاعی

دانشجوی سیاستگذاری علم و فناوری دانشگاه شهید بهشتی

فارغ التحصیل مهندسی نرم افزار دانشگاه آزاد اسلامی قم

hamzeh.sheikh.shoaei@gmail.com

چکیده

سازمان‌ها و شرکت‌های تولیدی، برای تحقق اهداف اصلی خود، نیازمند استفاده از شیوه‌ها و ابزارهای گوناگونی هستند. استفاده از فناوری و ابزارهای یادگیری ماشین و داده‌کاوی، می‌تواند برای مقابله با چالش‌های تولید بسیار مفید باشد. پژوهش حاضر، با مرور ادبیات در این زمینه، یک نمای کلی از چگونگی استفاده از شیوه‌های یادگیری ماشین برای تحقق سازوکارهای تولید مبتنی بر اقدامات هوشمند ارائه می‌دهد. هدف پژوهش حاضر، ارائه یک درک کامل از رویکردها و الگوریتم‌های اصلی مورد استفاده برای بهبود فرآیندهای تولید در دو دهه گذشته است. پژوهش‌های پیشین در زمینه یادگیری ماشین و پیشرفت‌های تولید را می‌توان در چهار موضوع اصلی دسته‌بندی نمود: برنامه‌ریزی، نظارت، کیفیت و شکست. این دسته‌بندی، راه‌حل‌های موجود در تولید را با توجه به جنبه‌های گوناگونی از جمله وظایف (مانند خوشه‌بندی، دیسکه‌بندی و رگرسیون)، الگوریتم‌ها (مانند ماشین بردار پشتیبان و شبکه عصبی)، انواع یادگیری (مانند یادگیری گروهی و یادگیری عمیق) و معیارهای عملکرد (مانند دقت و میانگین خطای مطلق)، مورد بررسی قرار می‌دهد. همچنین در این پژوهش، مراحل اصلی کشف دانش در پایگاه‌های داده، که در برنامه‌های کاربردی تولید دنبال می‌شوند، به تفصیل بیان شده‌اند. علاوه بر این، ضمن اشاره به برخی از آمارها در مورد وضعیت کنونی، مزایای استفاده از شیوه‌های یادگیری ماشین در تولید بیان شده و راه‌های غلبه بر چالش‌های خاص در زمینه یادگیری ماشین و داده‌کاوی بیان شده‌اند. مباحث ارائه شده، مسیر پژوهش‌های احتمالی آینده را روشن تر می‌سازد.

کلمات کلیدی: یادگیری ماشین، داده‌کاوی، تولید، طبقه‌بندی، خوشه‌بندی

۱. مقدمه

یادگیری ماشین^۱ یک زمینه پژوهشی مهم در هوش مصنوعی است که رایانه‌ها را قادر می‌سازد تا مدل‌سازی مبتنی بر تجربیات و پیش‌بینی دقیق رویدادهای آینده را انجام دهند (شیخ شعاعی، ۱۴۰۰ ب). رویکردهای اصلی یادگیری ماشین را می‌توان به دو دسته اصلی طبقه‌بندی نمود: یادگیری تحت نظارت (پروین، علینژاد رکنی، مینایی بیدگلی و پروین، ۲۰۱۳) و یادگیری بدون نظارت (مینایی بیدگلی، پروین، علی نژاد رکنی، علیزاده و پانچ، ۲۰۱۴). یک مشکل معمولی در یادگیری تحت نظارت، طبقه‌بندی است (روکاچ^۲، ۲۰۱۰)، در حالی که یادگیری بدون نظارت، در مسائل خوشه‌بندی نسبتاً رایج است (احمدی نیا، میبیدی، اثنا عشری و علینژاد رکنی، ۲۰۱۳). شیوه‌های رایج در طبقه‌بندی، شامل شبکه‌های عصبی، ماشین‌های بردار پشتیبان و درخت‌های تصمیم بوده (پروین، میرزینی بابلی و علی نژاد رکنی، ۲۰۱۵) و پرکاربردترین شیوه خوشه‌بندی، کی-

¹ Machine learning

² Rokach

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

میانگین^۳ است (احمد و دی،^۴ ۲۰۰۷). شیوه‌های یادگیری ماشین به طور گسترده و با موفقیت در بسیاری از زمینه‌های گوناگون مانند بهداشت (شیخ شعاعی، ۱۴۰۰ الف؛ شیخ شعاعی، ۱۴۰۰ ج)، آموزش (سیدآقایی، راحتی، علینژاد رکنی و روحی، ۲۰۱۳؛ شیخ شعاعی، ۱۴۰۰ د)، شبکه‌های حسگر بی‌سیم (احمدی نیا، علینژاد رکنی و آهنگری کیاساری، ۲۰۱۴)، امور مالی و روابط بین‌المللی (شیخ شعاعی، ۱۴۰۰ ه) استفاده شده است. پژوهش حاضر، مروری بر استفاده از شیوه‌های یادگیری ماشین در تولید، ارائه می‌دهد.

کارخانه‌های نوین، از سیستم‌های قدرتمند جمع‌آوری داده‌ها برای گردآوری و انتقال الکترونیکی داده‌ها از تقریباً تمام فرآیندهای تولید استفاده می‌کنند. بسیاری از متغیرهای تولید، به طور مداوم در مراحل مختلف، اندازه‌گیری شده و مقادیر آنها در پایگاه داده ذخیره می‌شود. این داده‌ها ممکن است به ویژگی‌های محصولات، ماشین‌آلات، خط تولید (مانند اینکه هر ماشین با چه مقداریری راه‌اندازی شده است)، منابع انسانی در خط تولید (مانند سطح تجربه کارگر، نوبت کاری)، مواد اولیه مورد استفاده در فرآیند تولید، محیط (رطوبت، دما و غیره)، حسگرهای متصل به ماشین‌آلات (ارتعاش، نیرو، فشار، کشش و غیره)، خرابی یا تعمیر و نگهداری ماشین، کیفیت محصول و سایر عوامل مهم تولید مرتبط باشند.

در پی پیشرفت‌های فناوری، هر روز حجم عظیمی از داده‌های خام در صنعت تولید به وجود می‌آید. این حجم از داده‌های در دسترس، اهمیت پژوهش در مفهوم یادگیری ماشین را آشکار می‌سازد. برنامه‌های کاربردی یادگیری ماشین و داده‌کاوی^۵ طی دو دهه پیش، برای حل مشکلات بخش تولید به وجود آمده‌اند. سیستم‌های هوشمند پشتیبان تصمیم‌گیری مؤثر (چنگ و همکاران،^۶ ۲۰۱۸؛ کوجاوینسکا، روگالوویچ، موجوفسکی و استانکوفسکا،^۷ ۲۰۱۸)، برنامه‌های مدیریت خط تولید (پریور، پونته، پونته و گومز،^۸ ۲۰۱۸) و برنامه‌های نگهداری ماشین‌آلات (گاندی، اشمیت و نگ،^۹ ۲۰۱۸؛ ژانگ و رن،^{۱۰} ۲۰۱۵) را می‌توان به عنوان نمونه‌هایی از کاربرد یادگیری ماشین در صنایع تولیدی ذکر کرد. همچنین نمونه‌های خاص دیگر، عبارتند از برنامه‌های پیش‌بینی شکست (ندلکوسکی و استوجانوفسکی،^{۱۱} ۲۰۱۷؛ پاولیشنکو،^{۱۲} ۲۰۱۶)، تخمین مصرف انرژی ماشین‌ها (کاپک، زببیسکی، زونبرگ و درونیاک،^{۱۳} ۲۰۱۸)، ارزیابی کیفیت محصول (رستمی، دانتان و حمیری،^{۱۴} ۲۰۱۵) و تشخیص عیب (هوانگ، پان، لین و گوو،^{۱۵} ۲۰۱۸؛ وانگ،^{۱۶} ۲۰۱۳) در تولید.

راهکارهای یادگیری عمیق^{۱۷} یادگیری گروهی^{۱۸} پروین، علینژاد رکنی و پروین،^{۱۹} ۲۰۱۳؛ پروین، مینایی بیدگلی، علینژاد رکنی و پانچ،^{۲۰} ۲۰۱۳) و یادگیری پیوندی^۹ (پروین، حلمی، مینایی بیدگلی، علینژاد رکنی و شیرگاهی،^{۲۱} ۲۰۱۱؛ پرژوونچک و

³ K-Means

⁴ Ahmad & Dey

⁵ Data Mining

⁶ Cheng et al.

⁷ Kujawinska, Rogalewicz, Muchowski, & Stankowska

⁸ Priore, Ponte, Puente, & Gómez

⁹ Gandhi, Schmidt, & Ng

¹ Zhang & Ren

¹ Nedelkoski & Stojanovski

¹ Pavlyshenko

¹ Cupek, Ziebinski, Zonenberg, & Drewniak

¹ Rostami, Dantan, & Homri

¹ Huang, Pan, Lin, & Guo

¹ Wang

¹ Deep learning

¹ Ensemble learning

¹ Linkage learning

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

کومارنیچکی،^{۲۰۲۰}، از امیدوارکننده ترین پیشرفت‌های یادگیری ماشین در حوزه تولید می‌باشند. یادگیری ماشین، کاربردهای گوناگونی در این حوزه دارد که از خودروسازی (سیافرودین، آلفیان، فیتریانی و ری،^{۲۰۱۸}) تا صنعت پوشاک (لی، چوی، هو، چین، لاو و تسه،^{۲۰۱۳}) و از صنعت نیمه‌هادی (لینگیتز و همکاران،^{۲۰۱۸}) تا بسیاری از زمینه‌های دیگر علوم و مهندسی گسترده‌اند. پژوهش‌های فراوانی در زمینه یادگیری ماشین بر دسته‌بندی متمرکز شده‌اند، که وظیفه تخصیص یک شیء به یکی از دسته‌های از پیش تعریف شده را بر عهده دارد. از سوی دیگر، برخی از مشکلات تولید، مربوط به خوشه‌بندی است که وظیفه آن، تقسیم اشیاء به گروه‌هایی به نام خوشه و بر اساس شباهت بین آنها است.

به تازگی پژوهش‌هایی در مورد کاربرد یادگیری ماشین و داده‌کاوی در صنعت تولید صورت گرفته است. با این حال، برخی از آنها تنها بر یک زمینه خاص از تولید مانند صنعت الکترونیک (لو، کیم، ژنگ و جین،^{۲۰۱۸})، تولید افزودنی^۵ (تولید اشیاء سه بعدی با رسوب مواد) (علابی، نیکسون و بوتف،^{۲۰۱۸}) یا ساخت نیمه‌هادی‌ها (استانیساویلیویچ و اسپیتزر،^{۲۰۱۶}) تمرکز کرده‌اند. همچنین برخی از آنها تنها بر یک موضوع مانند ارزیابی کیفیت (رستمی، دانتان و حمزی،^{۲۰۱۵})؛ کوکسال، باتماز و تستیک،^{۲۰۱۱} و برخی دیگر، تنها به داده‌کاوی (وانگ،^{۲۰۰۷}) پرداخته‌اند، بدون توجه به یادگیری ماشین. برخی از آنها (هاردینگ، شهباز، سرنیواس و کوسیاک،^{۲۰۰۵})؛ وانگ، تانگ و اینارد،^{۲۰۰۷} جامع نیستند و برخی از آنها (فام و آفیفی،^{۲۰۰۵})؛ چوداری، هاردینگ و تیواری،^{۲۰۰۹} سابق هستند. پژوهش حاضر، با مرور یادگیری ماشین و داده‌کاوی در صنعت تولید، مزایا و چالش‌های خاص حوزه تولید را آشکار ساخته و چشم‌اندازهای جدیدی را برای کاربردهای آینده ارائه می‌نماید.

نوآوری‌های پژوهش حاضر، بررسی راه‌حل‌های موجود در صنعت تولید با توجه به جنبه‌های گوناگون، از جمله وظایف (خوشه بندی، طبقه بندی، استخراج قوانین مرتبط و غیره)، الگوریتم‌ها (کی-نزدیک‌ترین همسایگی،^۳ شبکه عصبی و غیره) و معیارهای عملکرد (دقت و میانگین خطای مطلق)^۴، بررسی مزایای استفاده از شیوه‌های یادگیری ماشین، چالش‌ها و راه‌های غلبه بر آنها در صنعت تولید و همچنین ارائه برخی از مسیرهای پژوهشی آینده است که می‌تواند به آشکار کردن کاربردهای احتمالی یادگیری ماشین در آینده صنعت تولید کمک کند.

در ادامه، در بخش ۲، اطلاعاتی در مورد رابطه بین رشته‌های مختلف مرتبط با صنعت تولید، ارائه می‌شود. همچنین به پژوهش‌های معتبر دو دهه اخیر در حوزه صنعت تولید اشاره شده است. علاوه بر این، متغیرهای مورد استفاده در پژوهش‌های یادگیری ماشین در صنعت تولید ارائه شده است. ابزارهای رایج پردازش داده، کتابخانه‌ها و موتورهای معرفی شده و مجموعه

2	Przewozniczek & Komarnicki	0
2	Syafrudin, Alfian, Fitriyani, & Rhee	1
2	Lee, Choy, Ho, Chin, Law, & Tse	2
2	Lingitz et al.	3
2	Lv, Kim, Zheng, & Jin	4
2	Additive manufacturing	5
2	Alabi, Nixon, & Botef	6
2	Stanisavljevic & Spitzer	7
2	Köksal, Batmaz, & Testik	8
2	Harding, Shahbaz, Srinivas, & Kusiak	9
3	Wang, Tong, & Eynard	0
3	Pham & Afify	1
3	Choudhary, Harding, & Tiwari	2
3	K-nearest neighbor	3
3	Mean absolute error	4

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

داده‌های پرکاربرد مربوط به تولید ارائه شده‌اند. بخش ۳، مراحل حیاتی متوالی را بیان می‌کند که باید برای کشف دانش مفید در یک محیط تولیدی دنبال شوند. همچنین ترتیب عملیات لازم در این فرآیند را بیان کرده و چگونگی جریان داده‌ها را توضیح می‌دهد. در بخش ۴، برنامه‌های کاربردی تولید به زیر گروه‌هایی تقسیم می‌شوند که تحت نظارت، بدون نظارت، یادگیری قانون وابستگی^{۳۵}، مجموعه^{۳۶} و مطالعات مبتنی بر یادگیری عمیق است. بخش ۵ به بیان اثرات و مزایای رویکردهای یادگیری ماشین و داده‌کاوی در صنعت تولید اشاره می‌کند. برخی از مشکلات صنعت تولید در بخش ۶ مورد تأکید قرار گرفته‌اند. در نهایت بخش ۷، تلاش‌های علمی و عملی احتمالی آینده را برای بهبود کارایی در اقدامات تولیدی پیشنهاد می‌کند.

۲. مرور ادبیات

یادگیری ماشین، کارآمدتر از مدل‌های ریاضی و آماری سنتی در تولید است، زیرا آنها قادر به درک روابط پیچیده بین ویژگی‌های داده‌ها و پیش‌بینی مقادیر ویژگی‌های ناشناخته یک نمونه جدید نیستند. به همین سبب، شیوه‌های یادگیری ماشین که در طیف وسیعی از رشته‌های علمی به کار می‌روند، در سال‌های اخیر در صنعت تولید نیز مورد استفاده قرار گرفته‌اند.

استفاده از شیوه‌های یادگیری ماشین و داده‌کاوی در تولید، به خوبی تثبیت شده است زیرا داده‌های تحلیل شده به شیوه هوشمند، منبع ارزشمندی برای دستیابی به بینش‌های جدید بوده و می‌تواند مزیت رقابتی قابل توجهی ایجاد کند. ویژگی‌ها و ساختارهای مهم، با تجزیه و تحلیل داده‌ها مشخص می‌شوند، دانش ضمنی، قوانین و الگوهای مربوط به داده‌ها، با داده‌کاوی کشف می‌شوند و مدل‌های موثر توسط یادگیری ماشین برای آموزش رفتار یک سیستم تولیدی ایجاد می‌شوند. تجزیه و تحلیل داده‌ها، نقش مهمی در تصمیم‌گیری (پشتیبان تصمیم‌گیری)^{۳۷} در صنعت تولید داشته است (جه، سونگ، دینگ و هوانگ،^{۳۸} ۲۰۱۷). برنامه‌ریزی، نظارت، ارزیابی کیفیت و تشخیص شکست، رایج‌ترین زمینه‌های استفاده از شیوه‌های یادگیری ماشین و داده‌کاوی در صنعت تولید هستند. علاوه بر این، سایر زمینه‌های تولیدی که از قابلیت‌های یادگیری ماشین بهره می‌برند، برنامه‌ریزی چیدمان^{۳۹} (کلار، گلات و اوریش،^{۴۰} ۲۰۲۱)، پیش‌بینی فروش^{۴۱} (پاکیانادر، دیویس، هارادن، سومان و وایت،^{۴۲} ۲۰۱۷) و استخراج فرآیند^{۴۳} (پوسپیسیل، بارتیک و هروسکا،^{۴۴} ۲۰۱۶) هستند. علاوه بر این، شیوه‌های یادگیری ماشین برای بسیاری از کارهای تولیدی دیگر مانند طراحی محصول (توتونی و همکاران،^{۴۵} ۲۰۱۷)، پیش‌بینی زمان-هزینه (میدان، لرنر، رابینوویتز و حسون،^{۴۶} ۲۰۱۱)، پیش‌بینی بازده، تشخیص ناهنجاری (ریوتی، بوسنل و گال،^{۴۷} ۲۰۱۷)؛ سوستو، ترزی و بگی،^{۴۸} ۲۰۱۷) و پیش‌بینی مصرف انرژی ماشین‌ها (کاپک، زیبینسکی، زونبرگ و درونیاک، ۲۰۱۸) استفاده شده‌اند.

3 Association rule mining (ARM)	5
3 Ensemble	6
3 Decision-support	7
3 Ge, Song, Ding, & Huang	8
3 Layout planning	9
4 Klar, Glatt, & Aurich	0
4 Sales forecasting	1
4 Packianather, Davies, Harraden, Soman, & White	2
4 Process mining	3
4 Pospisil, Bartik, & Hruska	4
4 Tootooni et al.	5
4 Meidan, Lerner, Rabinowitz, & Hassoun	6
4 Rivetti, Busnel, & Gal	7
4 Susto, Terzi, & Beghi	8

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

پژوهش‌های یادگیری ماشین و داده‌کاوی در صنعت تولید را می‌توان در چهار موضوع اصلی گروه بندی کرد:

- زمان‌بندی، از جمله پردازش سفارش، زمان‌بندی فروشگاه (جونگ، روبریکو، آدچی، ناکامورا و اوتا؛ ۲۰۱۷^۴)، ترتیب‌بندی (اسماعیل، عثمان و ابوبکر؛ ۲۰۱۳^۵)، تخصیص منابع، زمان‌بندی فعالیت (برگمن، فلدکمپ و استراس؛ ۲۰۱۷) و برنامه‌ریزی در تولید (واشنک و همکاران؛ ۲۰۱۸^۲).
- نظارت، از جمله سیستم‌های پشتیبان تصمیم^۳ و نظارت بر فرآیند^۴ (سیافرودین، آلفیان، فیتربانی و ری، ۲۰۱۸) برای جلوگیری از انحرافات ارزش شاخص کلیدی عملکرد^۵ و افزایش دید سیستم‌های تولیدی.
- کیفیت، از جمله پیش‌بینی کیفیت محصولات (بای، لی، سان و چن؛ ۲۰۱۸^۶؛ محمدی و وانگ؛ ۲۰۱۶^۷؛ عارف، سورینا و حسین؛ ۲۰۱۳^۸)، بهبود کیفیت در یک فرآیند بزرگ و پیچیده (کامسو فوگم، ریگال و ماژه؛ ۲۰۱۳^۹)، نظارت، کنترل، تشخیص کیفیت و تشخیص عیب در تولید (داس، پال و بگ؛ ۲۰۱۷^{۱۰}).
- شکست، از جمله تشخیص موقعیت‌های غیرعادی (عیوب) (مانگل و کومار؛ ۲۰۱۶^{۱۱}؛ ناکاتا، اوریهارا، میزوکا و تاکاگی؛ ۲۰۱۷^{۱۲})، تعمیر و نگهداری ماشین (جلول، ساری و سیدیبه؛ ۲۰۱۸^{۱۳})، پیش‌بینی شکست (لیم، کیم و کیم؛ ۲۰۱۷^{۱۴})، نظارت بر تجهیزات (ژائو و همکاران؛ ۲۰۱۹^{۱۵})، خرابی تجهیزات و تجزیه و تحلیل سیستماتیک اطلاعات مربوط به خرابی تجهیزات.

ویجرت و همکارانش^۶ (۲۰۱۹) داده‌های تولیدی مورد استفاده در یادگیری ماشین را به شرح زیر دسته‌بندی کردند: داده‌های کیفی در مقابل داده‌های کمی، داده‌های سری زمانی در مقابل داده‌های موقعیتی^۷، داده‌های قابل کنترل در مقابل داده‌های غیرقابل کنترل، داده‌های کنونی در مقابل داده‌های تاریخی، داده‌های اندازه‌گیری شده در مقابل داده‌های شبیه‌سازی شده و داده‌های قابل مشاهده در مقابل داده‌های مربوط به متغیرهای شرایط کاری. همچنین وانگ (۲۰۰۷) متغیرهای تولیدی را که اغلب در یادگیری ماشین استفاده می‌شوند، به متغیرهای منبع^۸، متغیرهای ماشین^۹ و متغیرهای شرایط کاری^{۱۰} طبقه بندی کرد. متغیرهای تولیدی که اغلب در یادگیری ماشین استفاده می‌شوند، بر اساس انواعشان به شرح زیر دسته‌بندی می‌شوند:

4 Jong, Rubrico, Adachi, Nakamura, & Ota	9
5 Ismail, Othman, & Abu Bakar	0
5 Bergmann, Feldkamp, & Strassburger	1
5 Waschneck et al.	2
5 Decision support systems	3
5 Process monitoring	4
5 Key Performance Indicator (KPI)	5
5 Bai, Li, Sun, & Chen	6
5 Mohammadi & Wang	7
5 Arif, Suryana, & Hussin	8
5 KamsuFoguem, Rigal, & Mauget	9
6 Das, Pal, & Bag	0
6 Mangal & Kumar	1
6 Nakata, Orihara, Mizuoka, & Takagi	2
6 Djelloul, Sari, & Sidibe	3
6 Lim, Kim, & Kim	4
6 Zhao et al.	5
6 Weichert et al.	6
6 Workpiece-related data	7
6 Resource variables	8
6 Machining variables	9



دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

- متغیرهای محصول، از جمله ویژگی‌های محصولات مانند رنگ، اندازه و شکل.
- متغیرهای ماشین، از جمله ویژگی‌های ماشین‌ها مانند سرعت، نیرو، ارتعاش، فشار، دما، ولتاژ، روان کننده‌ها، خنک کننده‌ها، انرژی و تعمیر و نگهداری.
- متغیرهای فرآیند ساخت، مانند آهنگری، ریخته‌گری، تمیز کردن، بسته‌بندی، اکستروژن^{۷۱}، مهرزنی، مونتاژ و سیگنال‌های جاری.
- متغیرهای مواد خام، از جمله ویژگی‌های مواد که در فرآیند تولید استفاده می‌شوند، مانند چگالی، اندازه ذرات، ترکیب شیمیایی، ضخامت لایه، ویژگی‌های نقشه‌برداری سطح، رسانایی و ضخامت.
- متغیرهای محیطی مانند رطوبت و دما.
- متغیرهای عامل، مانند جنسیت، سن، سطح تجربه، تیم وضعیت روانی و سلامت.
- متغیرهای خط تولید، مانند پارامترهای راه اندازی ماشین، جابجایی، تعداد کارکنان، خرابی‌ها، نرخ تولید و حوادث.
- متغیرهای زمان‌بندی، مانند تقاضای محصول و اولویت سفارشات.
- متغیرهای کنترل کیفیت، مانند خلوص، وضعیت سطح، ظاهر، غلظت و سطح ناخالصی.
- متغیرهای خدمات، مانند عنوان خدمت، ارائه دهنده خدمات، هزینه خدمات و وضعیت اجرایی.
- متغیرهای زنجیره تامین، مانند زمان تحویل، ظرفیت تولید، نرخ نیروی کار، سطح موجودی، سطوح عقب‌ماندگی، وضعیت تحویل و حامیان.
- متغیرهای هدف، مانند بازده، کیفیت، شاخص عملکرد و بهره‌وری.

این متغیرها عمدتاً توسط سیستم‌های اطلاعاتی مانند سیستم نظارت بر کنترل و اکتساب داده‌ها^{۷۲}، سیستم طراحی و تولید به کمک رایانه^{۷۳}، واحد کنترل منطقی قابل برنامه‌ریزی^{۷۴}، برنامه‌ریزی منابع سازمانی^{۷۵}، مدیریت ارتباط با مشتری^{۷۶}، مدیریت داده‌های محصول^{۷۷} و سیستم‌های مدیریت چرخه عمر محصول^{۷۸} جمع‌آوری می‌شوند.

شکل ۱ و جدول ۱ گروه‌بندی پژوهش‌های یادگیری ماشین و داده‌کاوی مبتنی بر وظایف تولید را آنها نشان می‌دهند. اگرچه هر عملیات تولیدی وابستگی به شرایط کاری خود دارد، اما می‌توان آنها را تحت این گروه‌های اصلی مشخص کرد. این وظایف با عنوان: طراحی محصول، پشتیبانی تصمیم، تولید، فرآیند، نظارت، کیفیت، نقص، خرابی یا عیب، زمان‌بندی، برنامه‌ریزی چیدمان، فروش و انرژی بیان شده‌اند.

6

⁷ Working condition variables	0
⁷ Extrusions	1
⁷ Supervisory control and data acquisition (SCADA)	2
⁷ Computer-aided manufacturing/Computer-aided design (CAM/CAD)	3
⁷ Programmable logic controller (PLC)	4
⁷ Enterprise resource planning (ERP)	5
⁷ Customer relationship management (CRM)	6
⁷ Product data management (PDM)	7
⁷ Product lifecycle management systems	8

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران



شکل ۱: گروه بندی پژوهش های یادگیری ماشین و داده کاوی مبتنی بر وظایف تولید.

جدول ۱: گروه بندی پژوهش های یادگیری ماشین و داده کاوی مبتنی بر وظایف تولید

7

طراحی محصول	توتونی و همکاران، ۲۰۱۷؛ وانگ، ۲۰۰۷
پشتیبانی تصمیم	چنگ و همکاران، ۲۰۱۸؛ گاندی، اشمیت و نگ، ۲۰۱۸
تولید	لینگیتز و همکاران، ۲۰۱۸؛ ریوتی، بوسنل و گال، ۲۰۱۷؛ سوستو، ترزی و بگی، ۲۰۱۷؛ کو، لی، چو، چو، لی و لی، ۲۰۱۷ ^۹
فرآیند	کیم، اوه، یونگ و کیم، ۲۰۱۸ ^۸ ؛ مولداوی، سیوآرا، آنگل و سالومی، ۲۰۱۷ ^۸ ؛ ژانگ، رن، لیو و سی، ۲۰۱۷؛ جه، سونگ، دینگ و هوانگ، ۲۰۱۷ ^۳ ؛ ژو، لی، وانگ، نیو و زو، ۲۰۱۷ ^۴ ؛ سند، کونز، هابرت و فرانکه، ۲۰۱۶ ^۵ ؛ پوسیسیل، بارتیک و هروسکا، ۲۰۱۶
نظارت	ژائو و همکاران، ۲۰۱۹؛ رن، سان، کوی و ژانگ، ۲۰۱۸ ^۶ ؛ سیافرویدین، آلفیان، فیتیرانی و ری، ۲۰۱۸؛ لی، بو و کان، ۲۰۱۷ ^۷ ؛ ناکاتا، اوربهارا، میزوکا و تاکاگی، ۲۰۱۷
کیفیت	بوستیلو، اوربیکاین، پرز، پیرا و د لاکال، ۲۰۱۸ ^۸ ؛ لی، نو، کیم و کانگ، ۲۰۱۸ ^۹ ؛ بای، لی، سان و چن، ۲۰۱۸؛ کائو، هسیه، چن و لی، ۲۰۱۷ ^۹ ؛ لی، کیم و کیم، ۲۰۱۶ ^۹ ؛ محمدی و وانگ، ۲۰۱۶؛ دجاتنا و آلیتو، ۲۰۱۵ ^۲

7 Ko, Lee, Cho, Cho, Lee, & Lee	9
8 Kim, Oh, Jung, & Kim	0
8 Moldovan, Cioara, Anghel, & Salomie	1
8 Zhang, Ren, Liu, & Si	2
8 Ge, Song, Ding, & Huang	3
8 Zhou, Li, Wang, Niu, & Xu	4
8 Sand, Kunz, Hubbert, & Franke	5
8 Ren, Sun, Cui, & Zhang	6
8 Lei, Bo, & Kun	7
8 Bustillo, Urbikain, Perez, Pereira, & de Lacalle	8
8 Lee, Noh, Kim, & Kang	9
9 Kao, Hsieh, Chen, & Lee	0

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

لیوکونن و هیلتونن ^۹ ؛ هوانگ، پان، لین و گوو، ۲۰۱۸؛ هو، ژو، ژیانگ و فنگ ^۹ ؛ ۲۰۱۸؛ داس، پال و بگ، ۲۰۱۷؛ زیدک، ماکسیم، پیتل و هوسوفسکی ^۹ ؛ ۲۰۱۶؛ وانگ، ۲۰۱۳؛ لی، چوی، هو، چین، لاو و تسه، ۲۰۱۳	نقص
جلول، ساری و سیدیبه، ۲۰۱۸؛ لیم، کیم و کیم، ۲۰۱۷؛ لی، کیم و کیم، ۲۰۱۶؛ شائو، سان، یان، وانگ و گائو، ۲۰۱۷؛ کیم، هان و لی ^۹ ؛ ۲۰۱۷؛ پاولیشنکو، ۲۰۱۶	خرابی یا عیب
دولگی، بختادزه، پیاتتسکی، سابیتوف، اسمیرنوا، الپاشف، زاخاروف ^۹ ؛ ۲۰۱۸؛ پریور، پونته، پونته و گومز، ۲۰۱۸؛ جونگ، روبریکو، آداجی، ناکامورا و اوتا، ۲۰۱۷؛ برگمن، فلدکمپ و استراس، ۲۰۱۷	زمان بندی
کلار، گلات و اوریش، ۲۰۲۱	برنامه ریزی چیدمان
پاکیانانتر، دیویس، هارادن، سومان و وایت، ۲۰۱۷	فروش
کاپک، زبیینسکی، زونبرگ و درونیاک، ۲۰۱۸؛ وانگ، وانگ، هوانگ و ژو ^۹ ؛ ۲۰۱۹	انرژی

ابزارهای پردازش داده زیادی وجود دارد که بر اساس شیوه‌های یادگیری ماشین، قابلیت‌های مدل‌سازی و پیش‌بینی را ارائه می‌دهند. چندین پژوهش، اجرای ابزارهای پردازش داده در تولید را بررسی می‌کنند (ناگورنی، لیما مونتیرو، باراتا و کلمبو^{۱۰}؛ ۲۰۱۷). در پژوهش‌های حوزه تولید، پرکاربردترین ابزارهای پردازش داده رایگان و یا منبع باز عبارتند از: R، Weka، Orange، KNIME، RapidMiner، Mallet، Tanagra، Elki، KEEL و این ابزارها امکان استفاده آسان و تنظیم پارامترها را برای افزایش دقت مدل‌ها فراهم می‌سازند. کتابخانه‌های پایتون مانند Keras، Theanos، TensorFlow، Caffe و Scikit-Learn، برای سهولت برنامه نویسی یادگیری ماشین در دسترس هستند. برخی از رایج‌ترین موتورهای پردازش داده منبع باز عبارتند از Hadoop، Spark، Samza، Flink و Storm. شیوه‌های یادگیری ماشین عموماً برای بررسی کلان‌داده‌ها به کار می‌روند، به همین سبب، آنها باید بتوانند مجموعه داده‌های بزرگ (مجموعه داده دارای بیش از ۲۰ ویژگی) را پردازش کنند. برخی از نمونه‌های چارچوب‌های یادگیری ماشین توزیع‌شده در مقیاس بزرگ، در حال حاضر موجود هستند، مانند: MLlib، Mahout، H2O، SAMOA و MLbase.

در پژوهش‌های علمی، از مجموعه داده‌های معیار برای نشان دادن قابلیت رویکرد ارائه شده و مقایسه عملکرد الگوریتم‌ها استفاده می‌شود. یکی از پرکاربردترین مجموعه داده‌های معیار مربوط به صنعت تولید، SECOM است (کیم، هان و لی، ۲۰۱۶؛ کردراسوپ و کردراسوپ^{۱۰}؛ ۲۰۱۱؛ منیراتینام و رامادوس^{۱۰}؛ ۲۰۱۶) که از فرآیند تولید نیمه‌هادی به دست آمده است. بنابراین، این مجموعه داده متشکل از متغیرهای فرآیند تولید است. دیگر مجموعه داده تولیدی معروف، به نام "گسل‌های

⁹ Lee, Kim, & Kim	1
⁹ Djatna & Alitu	2
⁹ Liukkonen & Hiltunen	3
⁹ Hu, Zhou, Xiang, & Feng	4
⁹ Zidek, Maxim, Pitel, & Hosovsky	5
⁹ Shao, Sun, Yan, Wang, & Gao	6
⁹ Kim, Han, & Lee	7
⁹ Dolgui, Bakhtadze, Pyatetsky, Sabitov, Smirnova, Elpashev, Zakharov	8
⁹ Wang, Wang, Wang, Huang, & Xue	9
¹ Nagorny, Lima-Monteiro, Barata, & Colombo	0
¹ Kerdrasop & Kerdrasop	0
¹ Munirathinam & Ramadoss	0

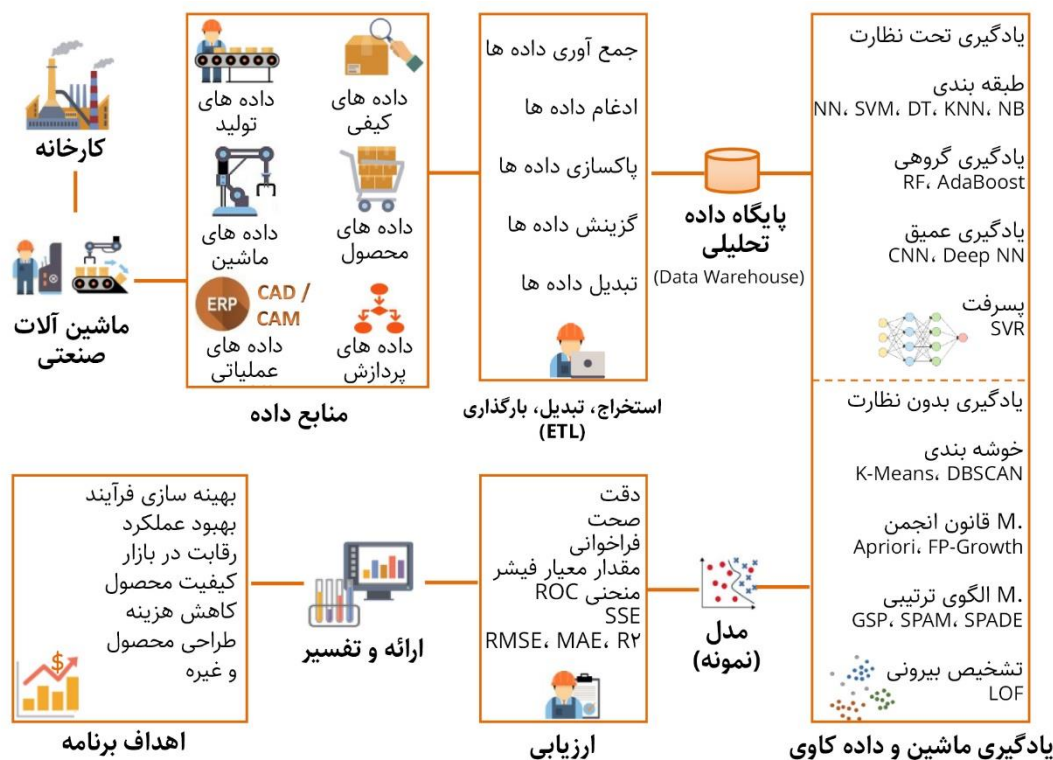
دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

صفحات فولادی^۱؛ در مطالعات مختلف (تیان، فو و وو،^۲ ۲۰۱۵) برای آموزش الگوریتم‌های یادگیری ماشین در تشخیص خودکار الگو استفاده شده است. این مجموعه شامل اطلاعاتی در مورد محصول ورق فولادی است و بنابراین شامل متغیرهای مربوط به محصول است. یک مجموعه داده تولیدی معیار بسیار قابل توجه به نام "عملکرد خط تولید بوش"^۳ نیز در چندین پژوهش (پاولیشنکو، ۲۰۱۶؛ ندلکوسکی و استوجانوفسکی، ۲۰۱۷؛ منگال و کومار، ۲۰۱۶) برای آزمایش عملکرد طبقه‌بندی الگوریتم‌های پیشنهادی استفاده شده و متغیرهای خط تولید، ویژگی اساسی این مجموعه داده است.

۳. فرآیند کشف دانش در تولید

فرآیند کشف دانش از پایگاه داده‌گزین صنعت تولید به کار می‌رود. این فرآیند اغلب شامل پنج مرحله اصلی است: درک حوزه تولید، آماده‌سازی داده، یادگیری ماشین/داده‌کاوی، ارزیابی و ارائه.



شکل ۲: فرآیند کشف دانش در پایگاه داده

مرحله اول را می‌توان "بخش طراحی" نامید. در این مرحله، هدف برنامه، منابع موجود، محدودیت‌های فرآیند استخراج، معیارهای رفع مشکل، هزینه‌ها و مزایای برنامه مشخص می‌شود. مرحله دوم، با عنوان آماده‌سازی داده‌ها، شامل جمع‌آوری، یکپارچه‌سازی، پاکسازی، گزینش و تبدیل داده‌ها است. مرحله جمع‌آوری داده‌ها، شامل جمع‌آوری بسیاری از متغیرهای تولید مانند مواد اولیه، محصولات نهایی یا تنظیمات ماشین (دما، فشار، تنظیمات تولید، مقیاس‌های زمانی و غیره) با کمک حسگرها

1	Steel Plates Faults	0
1	Tian, Fu, & Wu	0
1	Bosch Production Line Performance	0
1	Knowledge Discovery in Databases (KDD)	0

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

یا ضبط‌کننده‌های خودکار خارجی است. ادغام داده‌ها، تلاشی را برای ترکیب چندین منبع داده انجام می‌دهد. پاکسازی داده‌ها، با تکمیل مقادیر از دست رفته، مدیریت داده‌های آشفته، رفع مغایرت داده‌ها، در نظر گرفتن داده‌های ناهماهنگ (پروین، مینایی بیدگلی، علینژاد رکنی و پانچ، ۲۰۱۳)، شناسایی و حذف داده‌ها خارج از محدوده، به بهبود کیفیت آنها کمک می‌کند. گزینش داده‌ها، برای به دست آوردن مجموعه داده هدف از داده‌های اصلی، بدون از دست دادن قابل توجه اطلاعات، مانند انتخاب ویژگی انجام می‌شود (مینایی بیدگلی، اسدی و پروین، ۲۰۱۱). تبدیل داده‌ها، داده‌ها را به شکل‌های مناسب جهت استخراج در مواقع ضروری، مانند استانداردسازی و تفکیک، تبدیل می‌کند. پس از مرحله آماده‌سازی داده‌ها، مجموعه داده‌ها در یک انبار داده ذخیره می‌شوند. مرحله سوم، شامل استفاده از الگوریتم‌های یادگیری ماشین مناسب، بر روی داده‌های موجود در انبار، برای استخراج الگوها، قوانین یا توسعه یک مدل است. در حالی که الگوریتم‌های یادگیری نظارت‌شده را می‌توان برای مسائل طبقه‌بندی و رگرسیون استفاده نمود، الگوریتم‌های یادگیری بدون نظارت را می‌توان برای خوشه‌بندی، یادگیری قانون و وابستگی، الگوبرداری متوالی و تشخیص مشکلات بیرونی استفاده نمود. در مرحله چهارم، مدل ساخته شده، با استفاده از شاخص عملکرد مناسب ارزیابی می‌شود. به عنوان مثال، محبوب‌ترین معیارهای عملکرد مورد استفاده برای مسائل رگرسیون، عبارتند از ریشه میانگین مربعات خطا^۸؛ میانگین خطای مطلق^۸ و ضریب تعیین^۹. مرحله آخر، شامل تفسیر و تجسم الگوها است. به عنوان مثال، الگوها ممکن است به عنوان یک شاخص عملکرد کلیدی، روی پیشخوان نمایش داده شوند یا در صورت تشخیص ناهنجاری یا پیش‌بینی به‌دست‌آمده از یک مدل رگرسیون، به صورت هشدار نمایش داده شود. معمولاً برخی از مراحل فرآیند کشف دانش در پایگاه داده، باید چندین بار تکرار شوند تا نتیجه رضایت‌بخشی به دست آید. همچنین هنگامی که داده‌های جدید در دسترس قرار گیرد، مدل ایجاد شده باید اصلاح شود. به عنوان مثال، به دلیل ماهیت پویای سیستم‌های تولیدی، مدل رگرسیون باید به طور دوره‌ای به روز شود تا توانایی تعمیم آن حفظ شود. دانش کشف‌شده در نتیجه فرآیند کشف دانش در پایگاه داده، ممکن است کاربران و یا مدیران را در تصمیم‌گیری یاری کرده و یا برای بهبود مستقیم سیستم تولید به‌طور خودکار استفاده شود.

۴. کاربردهای یادگیری ماشینی در صنعت تولید

۴.۱. یادگیری تحت نظارت در صنعت تولید

هدف یادگیری تحت نظارت، یادگیری نگاشت بین ورودی و خروجی نمونه است. به بیان ساده، یک الگوریتم یادگیری نظارت شده ممکن است دارای متغیرهای ورودی و یک متغیر خروجی واحد باشد. به طور منطقی، تعداد نمونه‌های موجود برای یادگیری به طور متناسب بر قابلیت پیش‌بینی یک یادگیرنده تحت نظارت، تأثیر می‌گذارد. یادگیری تحت نظارت، معمولاً برای دو وظیفه جداگانه انجام می‌شود: طبقه‌بندی و رگرسیون. تفاوت عمده این است که طبقه‌بندی، فرآیند پیش‌بینی مقادیر گسسته یا مقوله‌ای مانند کم، متوسط و زیاد است، در حالی که از رگرسیون برای پیش‌بینی مقادیر پیوسته (کمیت عددی) یا مرتب‌شده مانند قیمت یک خودرو استفاده می‌شود. طیف گسترده‌ای از الگوریتم‌های یادگیری ماشینی برای خدمت به این

¹ Root mean square error (RMSE)
¹ Mean absolute error (MAE)
¹ Coefficient of determination (R²)

اهداف در دسترس هستند، که هر کدام مزایا و معایب خود را دارند، مانند درخت تصمیم؛ شبکه عصبی؛ ماشین‌های بردار پشتیبان؛^۱ الگوریتم‌های نزدیک‌ترین همسایگی^۲ و لایز ساده^۳ و^۴ از آنجایی که داده‌های صنعت تولید، دارای خصوصیات چندوجهی (یعنی ماشین، محصول، کاربر)، ناهمگنی و اختلال هستند (لو، کیم، ژنگ و جین، ۲۰۱۸)، برخی از مراحل پیش‌پردازش داده‌ها در بسیاری از پژوهش‌ها مانند استانداردسازی^۵ (چنگ و همکاران، ۲۰۱۸)، ساخت ویژگی‌ها^۶ (برگمن، فلدکمپ و استراسبورگر، ۲۰۱۷)، انتخاب امکانات^۷ (فوررو رامیرز، رسترپو ژیرون و نوپ رودریگز، ۲۰۱۹)^۸ و ترمیم مقادیر از دست رفته (محمدی و وانگ، ۲۰۱۶) توصیه شده‌اند. کیفیت نتایج داده-کاوی، به کیفیت داده‌ها بستگی دارد (آلفارو کورتز، آلفارو ناوارو، گیمز و گارسیا، ۲۰۲۱)^۹. انتظار می‌رود تمام عملیات پیش-پردازش، با انواع مشکلات مربوط به متغیرهای ساخت، مانند متغیرهای محصول، فرآیند و ماشین مقابله کنند. در حال حاضر، مشکل عدم تعادل طبقه‌بندی^{۱۰} در صنایع تولید، بسیار مورد توجه قرار گرفته است (اونگ، چو و مودا، ۲۰۱۵)^{۱۱} زیرا داده‌های تولید، اغلب شامل عدم تعادل در توزیع هستند. از آنجایی که این عدم تعادل ممکن است باعث کاهش عملکرد الگوریتم‌های یادگیری ماشین شود، شیوه نمونه‌برداری بیش از حد اقلیت مصنوعی^{۱۲} در چندین پژوهش (کیم، اوه، یونگ و کیم، ۲۰۱۸؛ کیم، هان و لی، ۲۰۱۷) برای غلبه بر این مشکل استفاده شده است. بسیاری از شرکت‌های تولیدی، داده‌های پردازشی را در سری‌های زمانی ذخیره می‌کنند و قصد دارند با ساختن مدل‌های پیش‌بینی در مقیاس بزرگی از داده‌های زمانی، کنترل کیفیت را بهبود بخشند (چو، جون، چانگ و چوی، ۲۰۲۳).

11

روش‌های یادگیری ماشین نظارت شده، به طور گسترده برای پیش‌بینی و حذف عیوب و شکست‌ها در صنعت فولاد در مراحل اولیه تولید مورد استفاده قرار گرفته‌اند (ژانگ، کانو، تانی، موری، ایسه و هارادا، ۲۰۲۴)^{۱۳}. این روش‌ها، همچنین برای ایجاد مدل‌های مؤثر در چاپ سه بعدی استفاده شده‌اند. در این زمینه‌ها، شبکه‌های عصبی به ساخت مدل‌های با دقت پیش‌بینی بالا کمک می‌کنند (فریرا، صباغی و هوانگ، ۲۰۲۵)^{۱۴}. رویه‌های کنترل، در تولید با شیوه‌های یادگیری تحت نظارت، مانند روش جنگل تصادفی بهبود یافته‌اند (آلفارو کورتز، آلفارو ناوارو، گیمز و گارسیا، ۲۰۲۰). از آنجایی که تولید هوشمند، امکان تولید کالاهای با کیفیت بالا را فراهم می‌سازد، پژوهش‌های فراوانی برای ایجاد مدل‌های پیش‌بینی کیفیت با استفاده از روش‌های یادگیری ماشین انجام شده است (چو، جون، چانگ و چوی، ۲۰۲۰). برخی از مواد خام تولیدی یا تجهیزات فرآیندی، در طول زمان در خطر خراب شدن قرار دارند. آنها فرآیندهای تولید را پرخطرتر و خطرناک‌تر می‌سازند. از این رو، از روش‌های نظارت شده برای تشخیص اینگونه خرابی‌های استفاده شده است (فوررو رامیرز، رسترپو ژیرون و نوپ رودریگز، ۲۰۱۹).

1	Decision trees (DT)	1
1	Neural network (NN)	1
1	Support vector machines (SVM)	1
1	K-nearest neighborhood (KNN)	1
1	Naive Bayes (NB)	1
1	Normalization	1
1	Attribute construction	1
1	Feature selection	1
1	Forero-Ramirez, Restrepo-Giron, & Nope-Rodriguez	1
1	Alfaro-Cortes, Alfaro-Navarro, Gamez, & Garcia	1
1	Class Imbalance Problem	2
1	Ong, Choo, & Muda	2
1	Synthetic minority oversampling technique (SMOTE)	2
1	Cho, Jun, Chang, & Choi	2
1	Zhang, Kano, Tani, Mori, Ise, & Harada	2
1	Ferreira, Sabbaghi, & Huang	2

۴.۲. یادگیری بدون نظارت در تولید

یادگیری بدون نظارت، یکی از الگوهای یادگیری ماشین است که برای شناسایی قاعده‌مندی‌ها و وابستگی‌ها در داده‌های بدون برچسب استفاده می‌شود. خوشه‌بندی، یادگیری قانون وابستگی، تشخیص ناهنجاری، برآورد چگالی^{۱۲} یادگیری بازنمایی^{۱۳} را می‌توان به عنوان محبوب‌ترین شیوه‌های یادگیری بدون نظارت نام برد. هدف اصلی در همه این شیوه‌ها، القای ساختار داخلی داده‌ها بدون برچسب‌گذاری مستقیم است، به گونه‌ای که یک نمایش مفید از آنها ایجاد شود. حجم پژوهش‌های یادگیری بدون نظارت، نسبتاً کمتر از پژوهش‌های تحت نظارت است زیرا امکان مواجهه با داده‌های برچسب‌گذاری شده در تولید بسیار زیاد است.

۴.۲.۱. خوشه‌بندی و تشخیص ناهنجاری در تولید

خوشه‌بندی، نمونه‌ها را با توجه به شباهت‌ها به گروه‌های مختلف تقسیم می‌کند. روش‌های اصلی خوشه‌بندی را می‌توان در پنج دسته سازماندهی کرد. روش پارتیشن‌بندی^{۱۴} سعی می‌کند داده‌ها را به خوشه‌هایی تجزیه کنند که اعضای هر خوشه، ارتباط نزدیکی با یکدیگر داشته باشند. روش خوشه‌بندی سلسله مراتبی^{۱۵} درختی از خوشه‌ها را با ادغام مکرر خوشه‌های کوچکتر به خوشه‌های بزرگتر (انباشتگی)، یا با تقسیم خوشه‌های بزرگتر به خوشه‌های کوچکتر (تقسیم‌کننده) ایجاد می‌کند. روش خوشه‌بندی مبتنی بر چگالی^{۱۶} سعی می‌کند خوشه‌های پراکنده با چگالی بالا را بیابد که از نظر اندازه و شکل متفاوت هستند. علاوه بر این، روش‌های دیگری نیز وجود دارد که به عنوان روش‌های مبتنی بر شبکه^{۱۷} و مبتنی بر مدل طبقه بندی می‌شوند.

در صنعت تولید، تجزیه و تحلیل خوشه‌ای برای تشخیص الگوها (لیوکونن و هیلتونن، ۲۰۱۸)، بهبود عملکرد (ناکاتا، اوربهارا، میزوکا، و تاکاگی، ۲۰۱۷)، ارزیابی کمی (اونل و همکاران، ۲۰۱۹^{۱۸}) و تشخیص وضعیت تجهیزات (رستمی، بلو و یوگما^{۱۹}، ۲۰۱۶) استفاده شده است. همچنین خوشه‌بندی برای تشخیص خطاهای محصول (زیدک، ماکسیم، پیتل و هوسوفسکی، ۲۰۱۶)، کمک به فرآیند تصمیم‌گیری (کوجاوینسکا، روگالوویچ، موچوفسکی و استانکوفسکا، ۲۰۱۸) و مشکلات برنامه‌ریزی چیدمان^{۲۰} استفاده شده است (کلار، گلات و اوریش، ۲۰۲۱). علاوه بر این، تعامل انسان و روبات، نقش مهمی در صنعت تولید دارد. عملیات لازم در این زمینه، توسط مدل‌های یادگیری بدون نظارت و واکنش‌های رویداد محور روبات‌ها توسعه تعیین شده است (وانگ، جیائو، وای یو، جانسون و ژانگ، ۲۰۱۹^{۲۱}).

همانگونه که توسط برخی از پژوهشگران مطرح شده است (سیافرویدین، آلفیان، فیتریانی و ری، ۲۰۱۸؛ سند، کونز، هابرت و فرانکه، ۲۰۱۶؛ ووست، ایرجنس و توبن، ۲۰۱۴^{۲۲}؛ لیبر، استولپ، کنراد، دیوز و موریک، ۲۰۱۳^{۲۳})، خوشه‌بندی می‌تواند به

1	Density estimation	2
1	Representation learning	2
1	Partitioning clustering	2
1	Hierarchical clustering	2
1	Density-based clustering	3
1	Grid-based	3
1	Model-based	3
1	Onel et al.	3
1	Rostami, Blue, & Yugma	3
1	Planning problems	3
1	Wang, Jiao, Yu, Johnson, & Zhang	3
1	Wuest, Irgens, & Thoben	3
1	Lieber, Stolpe, Konrad, Deuse, & Morik	3

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

عنوان یک مرحله پیش‌پردازش، قبل از اعمال الگوریتم، طبقه‌بندی داده‌ها را تسهیل کند. قبل از انجام یادگیری نظارت شده، نقاط خارج از محدوده با روشی بدون نظارت شناسایی می‌شوند زیرا حذف موارد خارج از محدوده می‌تواند قابلیت‌های پیش-بینی مدل‌های نظارت شده را به طور قابل توجهی افزایش دهد. تشخیص نقص در داده‌های تولید نیز از طریق خوشه‌بندی محقق می‌شود (جین، نا، پیاو، پوک . ریو،^{۳۹}۲۰۱۹). همچنین ارزیابی میزان تشابه در داده‌های تولید، با استفاده از ابزارهای خوشه‌بندی انجام شده و به فرآیندهای تصمیم‌گیری کمک کرده است (اونل و همکاران، ۲۰۱۹).

نتایج خوشه‌بندی به‌دست‌آمده از داده‌های تولید، با استفاده از معیارهای عملکرد مختلف برای اطمینان از کیفیت خوشه‌ها ارزیابی می‌شود. ارزیابی عملکرد الگوریتم‌های خوشه‌بندی، توسط با بررسی معیارهای داخلی و خارجی صورت می‌گیرد. معیار داخلی را می‌توان با شاخص دیویس-بولدین،^{۴۰} شاخص سیلوئت،^{۴۱} شاخص دان،^{۴۲} شاخص کالینسکی-هاراباسز^{۴۳} و غیره به دست آورد، در حالی که معیارهای خارجی شامل خلوص، آنتروپی، اطلاعات استاندارد شده، شاخص رند،^{۴۴} میزان دقت فراخوانی^{۴۵} و غیره است.

تشخیص ناهنجاری، شناسایی مواردی است که ممکن است به آسانی و مکرر مورد توجه قرار نگیرند. این مشاهدات یا رویدادهای پنهان، دارای ارزش‌ها یا رفتارهای متفاوتی نسبت به گرایش کلی مجموعه داده‌ای هستند که به آن تعلق دارند. روش‌های تشخیص ناهنجاری مرتبط با یادگیری ماشین، به سه گروه اصلی تقسیم می‌شوند: روش‌های مبتنی بر چگالی، مبتنی بر خوشه‌بندی و مبتنی بر ماشین‌های بردار پشتیبان. روش کی-نزدیک ترین همسایگی و ضریب خروج از محدوده،^{۴۶} انواع شناخته شده‌ای از روش‌های مبتنی بر چگالی هستند. به عنوان یک الگوریتم مبتنی بر خوشه‌بندی، روش مبتنی بر خطا^{۴۷} معمولاً برای تشخیص اختلال در داده‌ها استفاده می‌شود. داده‌کاوی، امکان نظارت و مشاهده بر اساس الگوهای تعریف شده در یک سیستم تولیدی را فراهم می‌کند که می‌تواند ناهنجاری‌هایی مانند خرابی ماشین‌ها (امریتنات و گوپتا،^{۴۸}۲۰۱۸)، مصرف انرژی غیرعادی ماشین‌ها (وانگ، لی و گان،^{۴۹}۲۰۱۸)، نتایج کیفی غیرمنتظره (کو، لی، چو، چو، لی، لی، ۲۰۱۷)، نقاط خارج از محدوده (سند، کونز، هابرت و فرانکه، ۲۰۱۶) و یا سایر اتفاقات را شناسایی کند. مشکلات یا شرایط شناسایی شده توسط الگوریتم‌ها، می‌توانند اعلان‌ها را فعال کنند. به عنوان مثال، یک کاربر یا یک سیستم می‌تواند از بروز مشکل یا شرایط خاص مطلع شود. نقاط خارج از محدوده را نیز می‌توان به عنوان یک شاخص کلیدی عملکرد، در پیشخوان نشان داد.

۴.۲.۲. یادگیری قانون وابستگی در تولید

یادگیری قانون وابستگی، یک شیوه رایج در داده‌کاوی است که روابط بین موارد موجود در یک مجموعه داده با اندازه بزرگ را کشف می‌کند. الگوهای مکرر در قالب قوانین $X \rightarrow Y$ با دو معیار جذابیت استخراج می‌شوند: پشتیبانی و اطمینان. پشتیبانی، نشان دهنده درصد روابطی است که شامل X و Y در بین تمام روابط مجموعه داده می‌شود. و اطمینان، بخشی از روابط حاوی X را بیان می‌کند که حاوی Y نیز هستند. در پژوهش‌های یادگیری قانون وابستگی، برخی مقادیر خاص برای حداقل

1	Jin, Na, Piao, Pok, & Ryu	3
1	Davies-Bouldin index	4
1	Silhouette index	4
1	Dunn index	4
1	Calinski-Harabasz	4
1	Rand index	4
1	F-measure	4
1	local outlier factor (LOF)	4
1	Density-based spatial clustering and application with noise (DBSCAN)	4
1	Amruthnath & Gupta	4
1	Wang, Li, & Gan	4

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

پشتیبانی^{۱۵۰} و حداقل اطمینان^{۱۵۱} باید از قبل تعیین شوند. برخی از الگوریتم‌های معروف یادگیری قانون وابستگی، عبارتند از اپریوری^{۱۵۲} (اوداباسی و ییلدیریم، ۲۰۲۰^{۱۵۳})، FP-Growth (موتلو و آلتونتاس، ۲۰۱۹^{۱۵۴}) و Eclat (کامسو فوگم، ریگال و ماژه، ۲۰۱۳).

الگوبرداری متوالی^{۱۵۵} علاقه‌مند به یافتن توالی‌های مکرر از مجموعه گزینه‌ها در یک مجموعه داده برای شناسایی الگوهای رویدادهای مرتب است. به طور کلی قصد دارد دنباله‌های معنی‌داری را از گروهی از دنباله‌ها کشف کند. برخی از پارامترهای مهم (مانند فراوانی وقوع، طول، سود) به عنوان معیار اندازه‌گیری برای تصمیم‌گیری در مورد جذابیت یک دنباله در نظر گرفته می‌شوند. محبوب‌ترین الگوریتم‌های الگوبرداری متوالی، عبارتند از PrefixSpan، SPADE (لیم، کیم و کیم، ۲۰۱۷)، SPAM^{۱۵۷} و GSP^{۱۵۸} جدای از این رویکردها، اخیراً روش‌هایی مانند CM-SPADE^{۱۵۹}، CM-SPAN^{۱۶۰}، FCloSM^{۱۶۱} و FGenSM^{۱۶۲} معرفی شده‌اند.

شیوه‌های یادگیری قانون وابستگی، به طور موثر برای بسیاری از عملیات‌های تولیدی مختلف استفاده شده‌اند. به عنوان مثال، سعی شده تا با استفاده از مدل‌های یادگیری قانون وابستگی، از حوادث شغلی در صنعت تولید جلوگیری شود، زیرا بسیاری از ویژگی‌های مرتبط، باعث ایجاد شرایط نامطلوب می‌شوند (موتلو و آلتونتاس، ۲۰۱۹). کاهش آلودگی، یکی از اهداف ضروری تولید برای کاهش پیامدهای زیانبار صنعتی شدن، برای محیط زیست است. برای این منظور، قوانین ارتباطی برای ارزیابی رابطه بین صنعتی شدن و کیفیت هوا در چین کشف شد (لی، لی، آن، هان، خو، لو و کریتندن، ۲۰۱۹^{۱۶۳}). پایداری برخی از مواد تولیدی مانند سلول‌های خورشیدی، با پژوهش‌های یادگیری قانون وابستگی بهبود یافت (اوداباسی و ییلدیریم، ۲۰۲۰). در نهایت، یادگیری قانون وابستگی برای کشف الگوهای رویداد انحرافی نیز مورد استفاده قرار گرفته است زیرا نقاط خارج از محدوده و انحراف، عوامل مهمی در نظارت بر سیستم برای فرآیندهای تولید هستند (پارک و جونگ، ۲۰۲۱^{۱۶۴}).

۴.۳. یادگیری گروهی و یادگیری عمیق در تولید

هنگامی که پژوهش‌های صنعت تولید مورد تجزیه و تحلیل قرار می‌گیرند، مشاهده می‌شود که یادگیری گروهی و یادگیری عمیق، بیشتر برای بهبود اثر مثبت وظایف یادگیری ماشین استفاده می‌شود. یادگیری گروهی، بخشی از روش‌های یادگیری ماشین هستند که به منظور انجام فرآیند طبقه‌بندی یا رگرسیون مورد استفاده قرار می‌گیرند. جدا از یادگیری گروهی، یادگیری عمیق، اخیراً به عنوان یک شیوه یادگیری ماشین ارائه شده است که داده‌ها را در بسیاری از لایه‌های متصل پردازش کرده و ساختاری غیر خطی و پیچیده دارد. یادگیری گروهی و یادگیری عمیق، پرکاربردترین الگوهای یادگیری ماشین هستند.

1	Minimum support (MinSup)	5
1	Minimum confidence (MinConf)	5
1	Apriori	5
1	Odabasi & Yildirim	5
1	Mutlu & Altuntas	5
1	Sequential pattern mining (SPM)	5
1	SPADE (spanning-tree progression analysis for density-normalized events)	5
1	SPAM (Sequential Pattern Mining)	5
1	GSP (Generalized Sequential Pattern)	5
1	CM-SPADE (Co-occurrence Map SPADE)	5
1	CM-SPAN (Co-occurrence Map SPAN)	6
1	FCloSM (frequent closed sequence mining)	6
1	FGenSM (frequent generator sequence mining)	6
1	Li, Li, An, Han, Xu, Lu, & Crittenden	6
1	Park & Jung	6

۴.۳.۱. یادگیری گروهی در تولید

یادگیری گروهی شیوه‌ای است برای استفاده از چندین یادگیرنده برای حل یک مشکل. یادگیری گروهی، به طور گسترده توسط پژوهشگران مورد بحث قرار گرفته است. به طور کلی توافق بر این است که در صنعت تولید، ترکیب چندین مدل معمولاً پیش‌بینی دقیق‌تری نسبت به مدل واحد ارائه می‌دهد (پریور، پونته، پونته و گومز، ۲۰۱۸؛ هوانگ، پان، لین و گوو، ۲۰۱۸). به عنوان مثال، در پژوهش (پریور، پونته، پونته و گومز، ۲۰۱۸)، در حالی که درخت تصمیم به ۸۱٫۸۲٪ دقت طبقه‌بندی رسید، درخت تصمیم گروهی به ۸۳٫۳۶٪ دقت دست یافت. به عنوان یک الگوریتم یادگیری گروهی، محققان استفاده از جنگل تصادفی را به جای یک درخت تصمیم واحد، آغاز کرده‌اند تا بتوانند به نتایج بهتری دست یابند (هوانگ، پان، لین و گوو، ۲۰۱۸).

در نتیجه پیشرفت‌های اخیر در فناوری اطلاعات، سیستم‌های جمع‌آوری داده، حجم عظیمی از داده‌های تولیدی را با انواع متمایزی از متغیرها مانند متغیرهای کاربر، خدمات و مواد خام جمع‌آوری می‌کنند (مانگل و کومار، ۲۰۱۶). از آنجایی که داده‌های کلان صنعت تولید، همیشه به زمان و قدرت پردازش زیادی نیاز دارند، برخی از پژوهش‌ها از چارچوب‌های محاسباتی Storm و Hadoop برای کاربردهای یادگیری ماشین استفاده کرده‌اند (ژانگ، رن، لیو و سی، ۲۰۱۷). سیستم پایگاه داده توزیع شده^{۶۶} سیستم فایل توزیع شده هادوپ^{۶۷} و سیستم مدیریت داده‌های غیر رابطه‌ای^{۶۸} برای ذخیره داده‌های تولید ناهمگن استفاده شده است (ناگورنی، لیما مونتیرو، باراتا و کلمبو، ۲۰۱۷).

15

ایجاد یک مدل پیش‌بینی واحد برای تشخیص شکست ممکن است برای برخی از وظایف تولیدی کافی نباشد. به همین دلیل دنگ و همکارانش^{۶۹} (۲۰۱۹) از یک روش یادگیری گروهی به نام D-CART برای دستیابی به تشخیص خطا، مکان‌یابی خطا و تعداد خطا به طور همزمان استفاده کردند. تولید قطعات با کارایی بالا، مستلزم حذف موفقیت‌آمیز مواد است. ثابت شده است که تقویت روش‌های یادگیری گروهی مانند k-fold XGBoost در محیط تولید امیدوارکننده است (گاؤو، چن، ژانگ، رن، چن و چن، ۲۰۱۹^{۷۰}). موفقیت نظارت بر شرایط، بستگی به اندازه‌گیری بلادرنگ مراحل تولید دارد. کواترینی و همکارانش^{۷۱} (۲۰۲۰) از یک روش مجموعه دو مرحله‌ای برای شناسایی بخش تولید و طبقه‌بندی داده‌های ورودی استفاده کردند.

۴.۳.۲. یادگیری عمیق در تولید

یادگیری عمیق^{۷۲} به عنوان مدل‌سازی شبکه‌های عصبی دارای بسیاری از لایه‌های پنهان تعریف می‌شود. برای یادگیری بهینه مدل‌های شبکه عصبی، گرادیان کاهشی متداول‌ترین روش مورد استفاده است (ژائو و همکاران، ۲۰۱۹). اگرچه شبکه‌های عصبی عمیق^{۷۳} دارای تعداد بالایی از پارامترهای حیاتی هستند که باید در طول طراحی مشخص شوند، آنها به عنوان امیدوارکننده‌ترین شیوه یادگیری ماشین در بسیاری از زمینه‌های تولید در نظر گرفته می‌شوند. به منظور به حداکثر رساندن دقت، می‌توان از الگوریتم ژنتیک^{۷۴} برای تعیین معماری شبکه عصبی مناسب مانند تعداد لایه‌های پنهان، تعداد نورون‌ها، دوره و نرخ یادگیری استفاده کرد. یادگیری عمیق، برای بهینه‌سازی پیش‌بینی شرایط، بسیار مؤثر است (وانگ، وانگ، وانگ، هوانگ

1	Bagged Decision Tree	6
1	Distributed database system (DDBS)	6
1	Hadoop distributed file system (HDFS)	6
1	Non-relational data management system (NoSQL)	6
1	Deng et al.	6
1	Gao, Chen, Zhang, Ren, Chen, & Chen	7
1	Quatrini et al.	7
1	Deep learning (DL)	7
1	Deep neural networks (DNN)	7
1	Genetic algorithm (GA)	7

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

و ژو، ۲۰۱۹)، مانند بهبود پیش‌بینی کیفیت (رن، سان، کوی و ژانگ، ۲۰۱۸؛ بای، لی، سان و چن، ۲۰۱۷^۵)، شناسایی علل شکست (لی، کیم و کیم، ۲۰۱۷؛ لی، چئون و کیم، ۲۰۱۷^۶؛ شائو، سان، یان، وانگ و گائو، ۲۰۱۷؛ کیم، هان و لی، ۲۰۱۷)، بهبود فرآیند بازرسی (یاسوتومی و انوکی، ۲۰۲۰^{۷۷})، تخمین موقعیت اشیاء متحرک در محیط‌های صنعتی (کانیزارو، زفیری، جاهیر پآلیاری، پاتی، ماسی، پونسینو و آکوایوا، ۲۰۲۰^{۷۸}) و پیش‌بینی تخریب (لو، یان، هو، ژو و پنگ، ۲۰۱۵^{۷۹}). رویکردهای ترکیبی (ترکیب منطق فازی با شبکه عصبی) نیز برای کاربردهای مختلف به دلیل عوامل مشخصه غیر قطعی در تولید، توسعه داده شده‌اند. به خصوص، ترکیب شبکه‌های عصبی با منطق فازی برای حل بهینه‌سازی زمان‌بندی و پیش‌بینی زمان تولید (لو، کیم، ژنگ و جین، ۲۰۱۸).

به عنوان یک شیوه یادگیری عمیق، استفاده از شبکه عصبی کانولوشنال^{۸۰} در تولید ترجیح داده شده است (ناکاتا، اورپهارا، میزوکا و تاکاگی، ۲۰۱۷؛ لی، کیم و کیم، ۲۰۱۷؛ ایموتو، ناکای، ایک، هاروکی و ساتو، ۲۰۱۹^{۸۱}). شبکه عصبی بازگشتی عمیق^{۸۲} همچنین در محیط‌های صنعتی برای اهداف مختلف مانند پیش‌بینی تکامل قطرات^{۸۳} و درک پویایی فرآیند، مورد استفاده قرار گرفته است (هوانگ، سگورا، وانگ، ژائو، سان و ژو، ۲۰۲۰^{۸۴}). ماشین بولتزمین عمیق^{۸۵} نیز به عنوان نوعی ساختار شبکه عصبی استفاده می‌شود که از واحدهای دودویی تصادفی جفت شده متقارن تشکیل شده است. همچنین یک ماشین بولتزمین محدود^{۸۶} وجود دارد که برخی از پارامترهای آن دارای مجموعه‌ای از مقادیر ثابت هستند. این راهبرد به طور موثر برای شناسایی مزیت‌های تولیدکنندگان استفاده می‌شود (وانگ، وانگ، وانگ، هوانگ و ژو، ۲۰۱۹؛ کیم، هان و لی، ۲۰۱۷؛ لو، یان، هو، ژو و پنگ، ۲۰۱۵).

شبکه باور عمیق^۷ به عنوان گروهی از شبکه‌های عصبی چندلایه از واحدهای پنهان تعریف می‌شود. شبکه باور و ماشین بولتزمین، دو عبارت مهم برای درک بهتر شبکه باور عمیق هستند. این روش می‌تواند روابط بین ویژگی‌ها را در سطوح مختلف تحلیل کند. برخی از پژوهش‌های تولیدی از آن برای نظارت بر سلامت ماشین (ژائو و همکاران، ۲۰۱۹)، پیش‌بینی کیفیت محصول (بای، لی، سان و چن، ۲۰۱۸) و تشخیص خرابی‌ها در موتورهای القایی (شائو، سان، یان، وانگ و گائو، ۲۰۱۷) استفاده می‌کنند.

یکی دیگر از شیوه‌های یادگیری عمیق قدرتمند، رمزنگار خودکار عمیق^{۸۸} نام دارد. این شیوه، ترکیبی از دو شبکه باور عمیق متقارن (نیم رمزنگاری و نیمه رمزگشایی) است که معمولاً چهار یا پنج لایه دارد. تجزیه و تحلیل سلامت بلبرینگ (رن، سان، چوی، و ژانگ، ۲۰۱۸)، تشخیص خطای مبتنی بر داده (ون، گائو و لی، ۲۰۱۹^{۸۹}؛ آرانو اسپیتیا، دلگادو پریتو، مارتینز ویول،

1 Bai, Li, Sun, & Chen	7
1 Lee, Cheon & Kim	7
1 Yasutomi & Enoki	7
1 Cannizzaro, Zafiri, Jahier Pagliari, Patti, Macii, Poncino, & Acquaviva	7
1 Luo, Yan, Hu, Zhou, & Pang	7
1 Convolutional neural network (CNN)	8
1 Imoto, Nakai, Ike, Haruki, & Sato	8
1 Deep recurrent neural network (DRNN)	8
1 Droplet evolution prediction	8
1 Huang, Segura, Wang, Zhao, Sun, & Zhou	8
1 Deep Boltzmann machine (DBM)	8
1 Restricted Boltzmann machine (RBM)	8
1 Deep belief network (DBN)	8
1 Deep autoencoder (DA)	8
1 Wen, Gao, & Li	8

ساوسدو دورانتس و اوسورنیو ریوس^۱ (۲۰۲۰) و تشخیص خطای ویفر (لی، کیم و کیم، ۲۰۱۷) برخی از وظایف در تولید هستند که در آنها اصل رمزنگار خودکار عمیق اجرا می‌شود.

پژوهش‌های یادگیری عمیق به اهداف صنعت تولید خدمت می‌کند. به عنوان مثال، هوانگ و همکارانش (۲۰۲۰) از شیوه‌های یادگیری عمیق برای تشخیص اطلاعات حرکت استفاده کردند که کیفیت نهایی را در فرآیند چاپ جوهر افشان افزایش می‌دهد. روش‌های یادگیری عمیق ممکن است مزیت‌هایی نسبت به مدل‌های سنتی داشته باشند، زیرا می‌توانند بدون فرضیات کلی کار کنند که آنها را سازگارتر می‌کند (ون، گائو و لی، ۲۰۱۹). آنها طبقه‌بندی خودکار نقص و هزینه‌های تولید را کاهش می‌دهند (ایموتو، ناکای، ایک، هاروکی و ساتو، ۲۰۱۹).

با استفاده از شبکه‌های عصبی عمیق، می‌توان از آسیب‌های مربوط به حمل و نقل اشیاء جلوگیری کرد (یاسوتومی و انوکی، ۲۰۲۰). منس و همکارانش^۱ (۲۰۱۹) از رویکرد شبکه عصبی کانولوشنال برای پیش‌بینی زمان برخورد سیگنال‌های رادیویی که فرآیندهای تولید را دیجیتالی می‌کنند، استفاده کرد. سیستم‌های الکترومکانیکی در تولید هوشمند، نیاز به راهبردهای نظارت کارآمد دارند و مدل‌های یادگیری عمیق مانند رمزنگارهای خودکار می‌توانند این الزامات را برآورده کنند (آرلانو اسپیتیا، دلگادو پریئو، مارتینز ویول، ساوسدو دورانتس و اوسورنیوریوس^۲، ۲۰۲۰).

۵. مزایای یادگیری ماشین و داده‌کاوی در تولید

۵.۱. فواید

داده‌کاوی به عنوان یک ابزار کشف دانش از پایگاه داده‌های صنعت تولید استفاده شده است. داده‌های لازم برای تجزیه و تحلیل را می‌توان در طول عملیات تولید جمع‌آوری کرد. در تولید، داده‌کاوی مزایای رقابتی زیادی مانند کیفیت بالاتر محصول، کاهش هزینه و بهبود فرآیند تولید را فراهم می‌کند. داده‌کاوی ممکن است به خودکارسازی فرآیند کشف دانش کمک کند و این ابزار برای توسعه سیستم‌های مبتنی بر دانش بسیار مهم است.

زمینه‌های تولید بسیاری وجود دارد که یادگیری ماشین ممکن است تاثیر مثبتی در آنها داشته باشد. اولاً، پیش‌بینی تقاضای کارآمد، به خوبی توسط یادگیری ماشین پشتیبانی می‌شود. با تجزیه و تحلیل رویدادهای گذشته، برآورد می‌شود که چه تعداد یا چه مقدار محصول باید تولید شود تا تقاضای آینده را تامین کند. ثانیاً، انتشار یک محصول جدید، فرآیندی است که یادگیری ماشین در آن نقش دارد. در حین معرفی یک محصول جدید، یادگیری ماشین به منظور پیگیری موفقیت انتشار، شامل اطلاعات فروش و مشتری، مورد استفاده قرار می‌گیرد. اثر دیگر آن، بهینه‌سازی قیمت است. شرکت‌های تولیدی می‌توانند موقعیت مکانی، فصلی، آب و هوا و تقاضا را در نظر بگیرند تا قیمت‌ها را تغییر داده و محصولاتی را با قیمت‌های بهینه ارائه کنند. مشاهده شده است که یادگیری ماشین، تولیدکنندگان را قادر می‌سازد تا زمان تأمین کالا را کاهش داده و استفاده از منابع را بهبود بخشند. علاوه بر این، یادگیری ماشین، رویکردهای قدرتمندی برای بهبود مستمر کیفیت در فرآیندهای پیچیده و بزرگ ارائه می‌کند (ووست، وایمر، ایرگنس و توبن^۳، ۲۰۱۶).

یادگیری ماشین، مبنایی را برای درک حوزه تولید فراهم می‌کند، زیرا اکثر مشکلات تولیدی از نظر داده‌ها غنی و از نظر دانش ضعیف هستند. شیوه‌های یادگیری بدون نظارت، ابزار بسیار قدرتمندی برای ایجاد مدل‌های توصیفی هستند، زیرا روابط بین

¹ Arellano-Espitia, Delgado-Prieto, Martinez-Viol, Saucedo-Dorantes, & Osornio-Rios

9

¹ Mennes et al.

9

¹ Arellano-Espitia, Delgado-Prieto, Martinez-Viol, Saucedo-Dorantes, & OsornioRios

9

¹ Wuest, Weimer, Irgens, & Thoben

9

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

متغیرها را آشکار کرده و درک بهتری از فرآیند تولید ارائه می‌دهند. آنها وضعیت فعلی را با وضوح بیشتری توصیف می‌کنند، مانند روابط بین رویدادها، عوامل تأثیرگذار و یا علل آنها. برای مثال، خوشه‌بندی اقلام در داده‌های تولیدی به کاربران یا مدیران اجازه می‌دهد تا فعالیت‌های گوناگونی را برای خوشه‌های مختلف برنامه‌ریزی کنند (ووست، ایرجنس و توبن، ۲۰۱۴؛ زیدک، ماکسیم، پیتل و هوسوفسکی، ۲۰۱۶). به طور مشابه، یادگیری قانون وابستگی، ظرفیت زیادی در تولید دارد، زیرا برای افزایش دانش در سیستم‌ها و فرآیندهای تولیدی تحلیل شده، مفید است (کامسو فوگم، ۲۰۱۳؛ کائو، هسیه، چن و لی، ۲۰۱۷؛ اونگ، چو و مودا، ۲۰۱۵؛ دجاتنا و آلیتو، ۲۰۱۵).

تقاضای بازار، روز به روز در حال افزایش است و نیازهای مشتری در جهت محصولات با کیفیت بالاتر و خدمات کارآمدتر تغییر می‌کند (ووست، ایرجنس و توبن، ۲۰۱۴؛ زیدک، ماکسیم، پیتل و هوسوفسکی، ۲۰۱۶). به همین سبب، شرکت‌های تولیدی شروع به جستجوی راه حل‌های نوآورانه برای تجزیه و تحلیل خواسته‌های بازار می‌کنند (دجاتنا و آلیتو، ۲۰۱۵). سازمان‌های تولیدی باید الگوهای فرایند را کشف کنند تا با پیچیدگی فزاینده انتظارات مشتریان از محصول نهایی کنار بیایند. امکان پیش‌بینی الگوهای فرایند، با پشتیبانی از رویکردهای تحلیلی پیشرفته وجود دارد.

۵.۲. مفاهیم مدیریتی

استفاده از روش‌های یادگیری ماشین در تولید، تأثیرات مثبتی در بعد مدیریتی نیز دارد. شرکت‌های تجاری از رویکردهای یادگیری ماشین برای مدیریت داده‌های چندگانه در محیط‌های پویا بسیار سود می‌برند. از آنجایی که یادگیری ماشین و داده-کاوی قادر به پردازش داده‌ها و پیش‌بینی‌های بلادرنگ هستند، مدیران بخش‌های مختلف را قادر می‌سازند تا تصمیم‌گیری مؤثرتری داشته باشند. آنها به تجزیه و تحلیل داده‌های بزرگ در فرآیندهای تولید و نگهداری بهینه‌تر محصولات پیچیده کمک می‌کنند. مفاهیم مدیریتی الگوریتم‌های یادگیری ماشین در تولید را می‌توان به چهار دسته اصلی گروه بندی کرد: بازاریابی، تحقیق و توسعه، تولید و خدمات (ژانگ، رن، لیو و سی، ۲۰۱۷).

از مزایای یادگیری ماشین در بازاریابی، می‌توان به شناسایی مشتریان متعهد، پیش‌بینی ریزش مشتریان، پیش‌بینی نیازهای ناگفته مشتریان با تجزیه و تحلیل داده‌های حاصل از ثبت جستجوی مشتریان و سابقه رفتارهای خرید آنها، برای هماهنگ-سازی محصولات گوناگون با مشتریان مختلف، برای انتخاب مناسب‌ترین مشتریان برای یک محصول جدید، امتیاز دادن به مشتریان و اینگونه موارد استفاده نمود (پاکیانثر، دیویس، هارادن، سومان و وایت، ۲۰۱۷).

از مزایای یادگیری ماشین در تحقیق و توسعه، می‌توان به اتخاذ تصمیمات صحیح در مرحله طراحی محصول، بهبود آزمایشات توسعه محصول و ارائه راهنمایی برای توسعه محصولات جدید با توجه به تجزیه و تحلیل بازخوردهای قبلی اشاره نمود (وانگ، تانگ و اینارد، ۲۰۰۷؛ توتونی و همکاران، ۲۰۱۷؛ وانگ، وانگ، هوانگ و ژو، ۲۰۱۸).

مزایای یادگیری ماشین در تولید، نظارت بر کیفیت محصول، مدیریت تجهیزات تولید (مانند تخمین سایش و پیش‌بینی خرابی تجهیزات)، کاهش مصرف انرژی ماشین، تجزیه و تحلیل داده‌های تولید پویا و بلادرنگ، بهینه سازی تولید، برنامه‌ریزی و حل مشکل تخصیص کارکنان هستند (اسماعیل، عثمان و ابوبکر، ۲۰۱۲؛ واشنگ و همکاران، ۲۰۱۸؛ کامسو فوگم، ۲۰۱۳؛ منگال و کومار، ۲۰۱۶).

همچنین از مزایای یادگیری ماشین در بخش خدمات، می‌توان به افزایش رضایت مشتریان از طریق تجزیه و تحلیل بازخوردهای مربوط به خدمات، نظارت بر خدمات در لحظه، پیش‌بینی خدمات با تجزیه و تحلیل سوابق تاریخی، انتخاب راهبرد خدمات مناسب، نظارت مداوم بر وضعیت محصول، ردیابی محصولات در طول چرخه عمر آنها و جلوگیری از شکست اشاره نمود (کو، لی، چو، لی و لی، ۲۰۱۷؛ بوداکولسومسیری و زاگریان، ۲۰۰۹؛ لو، یان، هو، ژو و پنگ، ۲۰۱۵).

دومین کنفرانس ملی مدیریت و صنعت گردشگری

۲۹ بهمن ۱۴۰۰ - تهران

۶. چالش‌های یادگیری ماشین در تولید

انجام مراحل فرآیند کشف دانش ممکن است به آسانی قابل انجام نباشد. چالش‌های کلیدی یادگیری ماشین در تولید، به اتفاق پژوهشگران (ووست، وایمر، ایرگنس و توبن، ۲۰۱۶) موارد زیر است. یادگیری از محیط‌های در حال تغییر و سازگاری خودکار با آنها، نقطه قوت اصلی یادگیری ماشین است. با توجه به محیط تولید پویا و در حال تغییر، سیستم یادگیری ماشین باید توانایی یادگیری و انطباق با تغییرات را داشته باشد و طراح سیستم، نیاز به ارائه راه حل برای تمام موقعیت‌های ممکن دارد. چالش اصلی دیگر، دستیابی به داده‌های تولیدی دقیق و مرتبط است، زیرا تأثیر زیادی بر عملکرد الگوریتم‌های یادگیری ماشین دارد. چالش بسیار رایج کاربرد یادگیری ماشین در تولید، پیش پردازش داده‌ها است زیرا تأثیر مهمی بر نتایج دارد. چالش کلیدی دیگر، انتخاب مناسب‌ترین روش و الگوریتم یادگیری ماشین است. همچنین تفسیر نتایج، از دیگر چالش‌های اساسی در یادگیری ماشین است (ووست، وایمر، ایرگنس و توبن، ۲۰۱۶).

۷. مسیره‌های آینده

برنامه‌های کاربردی یادگیری ماشین احتمالاً با سرعت بالاتری به ویژه در بخش تولید رشد خواهند کرد. زیرا قدرت محاسباتی روز به روز در حال افزایش است و اندازه داده‌های موجود بسیار بیشتر از سال‌های گذشته است. روش‌ها و فناوری‌های کلان‌داده می‌توانند داده‌های با ابعاد بالا را پردازش کنند. از این رو افزایش دسترسی به داده‌های تولید، به احتمال زیاد در آینده اهمیت بیشتری خواهند یافت.

یادگیری قانون وابستگی، بیشتر از الگوبرداری متوالی در صنعت تولید مورد استفاده قرار گرفته است. الگوبرداری متوالی می‌تواند تولیدکنندگان را قادر سازد تا در زمان مناسب، پاسخ سریع و شایسته را ارائه دهند. الگوهای متوالی، دانش بالقوه مهمی را برای پیش‌بینی فعالیت‌های آینده فراهم می‌کنند.

متن‌کاوی، در بسیاری از زمینه‌ها رواج یافته است. با این حال، در صنعت تولید به صورت محدود استفاده شده است. پژوهش‌های آینده را می‌توان بر متن‌کاوی مرتبط با تولید متمرکز نمود. زیرا حجم داده‌های متنی در صنعت تولید به طور مداوم در حال افزایش است و حجم زیادی از اطلاعات شرکت‌ها به صورت متنی ذخیره‌سازی می‌شود. انواع روش‌های متن‌کاوی مانند تولید قوانین، طبقه‌بندی و خوشه‌بندی را می‌توان به منظور پردازش این داده‌های بزرگ و استخراج دانش ارزشمند صنعت تولید، پیاده‌سازی کرد. اسناد صنعت تولید را می‌توان بر اساس انواع، محتویات و شباهت‌ها طبقه‌بندی یا خوشه بندی کرد. روش‌های متن‌کاوی ممکن است برای مدیریت منابع اسناد دیجیتال بسیار مفید باشند. راهکارهای متن‌کاوی مانند پاسخ به سؤال، یافتن متخصص، تشخیص احساسات، توصیه، برجسب‌گذاری گفتار و تجزیه داده‌ها، می‌توانند در راستای بهینه‌سازی تولید مورد استفاده قرار گیرند.

شرکت‌های تولیدی، اطلاعات مربوط به کسب‌وکار (یعنی طرح‌ها، فرآیندها، مواد و فناوری‌ها) را در بستر اینترنت به اشتراک می‌گذارند که می‌تواند به سایر تولیدکنندگان در تصمیم‌گیری مبتنی بر این اطلاعات کمک کند. وب‌کاوی^{۱۵}، شیوه‌ای خودکار برای جمع‌آوری داده‌های مربوط به تولید و استخراج اطلاعات تجاری ارزشمند و قابل فهم از داده‌های کسب و کار موجود در بستر وب است که می‌تواند برای سیاست‌گذاری و تصمیم‌سازی مورد استفاده قرار گیرند. با این حال، تفاوت اصطلاحات مورد استفاده توسط شرکت‌های تولیدی گوناگون، باعث سردرگمی در یک فرآیند عملی و پویا می‌شود. بنابراین، انتظار می‌رود که در آینده نیز مشارکت‌های بیشتری در موضوع وب‌کاوی در تولید انجام شود.

دو رویکرد رایج در پردازش داده‌ها وجود دارد: پردازش دسته‌ای^۶ و پردازش جریانی^۷ (پردازش داده‌ها در زمان واقعی). پردازش دسته‌ای داده به صورت ایستا انجام می‌شود که در آن، گروهی از تراکنش‌ها در یک دوره زمانی جمع‌آوری شده و برای ساخت یک مدل پردازش می‌شوند. همچنین مدل ساخته شده به صورت پویا بر اساس داده‌های ورودی جدید، به روز می‌شود. پردازش داده‌های جریانی (زمان واقعی) داده‌ها را به محض ورود پردازش می‌کند. بیشتر مطالعات داده‌کاوی در حوزه تولید، بر روی پردازش دسته‌ای انجام شده است. با این حال، پیشرفت‌های روزافزون فناوری، پردازش جریانی داده‌ها را برای به دست آوردن مزیت تصمیم‌گیری بلادرنگ می‌طلبد.

۸. نتیجه‌گیری

پژوهش حاضر، مروری بر ادبیات مربوط به فرآیندهای کاربردی یادگیری ماشین و داده‌کاوی در صنعت تولید ارائه می‌دهد. کاربردهای فعلی همراه با شیوه‌های مناسب انجام فعالیت‌ها شناسایی شد. انواع گوناگون یادگیری ماشین، مانند نظارت شده (طبقه‌بندی و رگرسیون)، بدون نظارت (خوشه بندی، یادگیری قانون وابستگی، الگوبرداری متوالی، تشخیص ناهنجاری)، یادگیری گروهی و یادگیری عمیق، به طور خلاصه بیان شده و کاربردهای آنها معرفی شد. همچنین مزایای پژوهش‌های مبتنی بر یادگیری ماشین در حوزه صنعت تولید ارائه شد. پژوهش حاضر، ایده روشنی در مورد مشکلات پیش روی متخصصان یادگیری ماشین، هنگام اجرای فرآیندها و به کارگیری تجهیزات صنعت تولید، ارائه می‌دهد.

۱- فهرست منابع

- Ahmad, A., & Dey, L. (2007). A k-mean clustering algorithm for mixed numeric and categorical data. *Data & Knowledge Engineering*, 63, 503–527. doi:https://doi.org/10.1016/j.datak.2007.03.016
- Ahmadinia, M., Alinejad-Rokny, H., & Ahangarikiasari, H. (2014). Data aggregation in wireless sensor networks based on environmental similarity: A learning automata approach. *Journal of Networks*, 9, 2567. doi:https://doi.org/10.4304/jnw.9.10.2567-2573
- Ahmadinia, M., Meybodi, M. R., Esnaashari, M., & Alinejad-Rokny, H. (2013). Energy-efficient and multi-stage clustering algorithm in wireless sensor networks using cellular learning automata. *IETE Journal of Research*, 59, 774–782. Retrieved from https://www.tandfonline.com/doi/abs/10.4103/0377-2063.126958
- Alabi, M. O., Nixon, K., & Botef, I. (2018). A survey on recent applications of machine learning with big data in additive manufacturing industry. *Am J Eng Appl Sci*, 11, 1114–1124. doi:https://doi.org/10.3844/ajeassp.2018.1114.1124
- Alfaro-Cortés, E., Alfaro-Navarro, J.-L., Gámez, M., & García, N. (2020). Using random forest to interpret out-of-control signals. *Acta Polytech. Hung.*, 17, 115–130. doi:http://acta.uni-obuda.hu/Alfaro-Cortes_Alfaro-Navarro_Gamez_Garcia_103.pdf
- Amruthnath, N., & Gupta, T. (2018). A research study on unsupervised machine learning algorithms for early fault detection in predictive maintenance. *2018 5th International Conference on Industrial Engineering and Applications (ICIEA)*, (pp. 355–361). doi:https://doi.org/10.1109/IEA.2018.8387124
- Arellano-Espitia, F., Delgado-Prieto, M., Martinez-Viol, V., Saucedo-Dorantes, J. J., & Osornio-Rios, R. A. (2020). Deep-learning-based methodology for fault diagnosis in electromechanical systems. *Sensors*, 20, 3949. doi:https://doi.org/10.3390/s20143949
- Arif, F., Suryana, N., & Hussin, B. (2013). A data mining approach for developing quality prediction model in multi-stage manufacturing. *International Journal of Computer Applications*, 69. Retrieved from https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.403.4882&rep=rep1&type=pdf

¹ Batch processing

9

¹ Flow processing

9



- Bai, Y., Li, C., Sun, Z., & Chen, H. (2017). Deep neural network for manufacturing quality prediction. *2017 Prognostics and System Health Management Conference (PHM-Harbin)*, (pp. 1–5). doi:<https://doi.org/10.1109/PHM.2017.8079165>
- Bergmann, S., Feldkamp, N., & Strassburger, S. (2017). Emulation of control strategies through machine learning in manufacturing simulations. *Journal of Simulation*, *11*, 38–50. doi:<https://doi.org/10.1057/s41273-016-0006-0>
- Buddhakulsomsiri, J., & Zakarian, A. (2009). Sequential pattern mining algorithm for automotive warranty data. *Computers & Industrial Engineering*, *57*, 137–147. doi:<https://doi.org/10.1016/j.cie.2008.11.006>
- Bustillo, A., Urbikain, G., Perez, J. M., Pereira, O. M., & de Lacalle, L. N. (2018). Smart optimization of a friction-drilling process based on boosting ensembles. *Journal of manufacturing systems*, *48*, 108–121. doi:<https://doi.org/10.1016/j.jmsy.2018.06.004>
- Cannizzaro, D., Zafiri, M., Jahier Pagliari, D., Patti, E., Macii, E., Poncino, M., & Acquaviva, A. (2020). A comparison analysis of BLE-based algorithms for localization in industrial environments. *Electronics*, *9*, 44. doi:<https://doi.org/10.3390/electronics9010044>
- Cheng, Y.-J., Chen, M.-H., Cheng, F.-C., Cheng, Y.-C., Lin, Y.-S., & Yang, C.-J. (2018). Developing a decision support system (DSS) for a dental manufacturing production line based on data mining. *Applied System Innovation*, *1*, 17. doi:<https://doi.org/10.3390/asi1020017>
- Choudhary, A. K., Harding, J. A., & Tiwari, M. K. (2009). Data mining in manufacturing: a review based on the kind of knowledge. *Journal of Intelligent Manufacturing*, *20*, 501–521. doi:<https://doi.org/10.1007/s10845-008-0145-x>
- Cupek, R., Ziebinski, A., Zonenberg, D., & Drewniak, M. (2018). Determination of the machine energy consumption profiles in the mass-customised manufacturing. *International Journal of Computer Integrated Manufacturing*, *31*, 537–561. doi:<https://doi.org/10.1080/0951192X.2017.1339914>
- Das, B., Pal, S., & Bag, S. (2017). Torque based defect detection and weld quality modelling in friction stir welding process. *Journal of Manufacturing Processes*, *27*, 8–17. doi:<https://doi.org/10.1016/j.jmapro.2017.03.012>
- de Jong, A. W., Rubrico, J. I., Adachi, M., Nakamura, T., & Ota, J. (2017). Big data in automation: Towards generalized makespan estimation in shop scheduling problems. *2017 13th IEEE Conference on Automation Science and Engineering (CASE)*, (pp. 1516–1521). doi:<https://doi.org/10.1109/COASE.2017.8256319>
- Deng, H., Diao, Y., Wu, W., Zhang, J., Ma, M., & Zhong, X. (2020). A high-speed D-CART online fault diagnosis algorithm for rotor systems. *Applied Intelligence*, *50*, 29–41. doi:<https://doi.org/10.1007/s10489-019-01516-2>
- Djatna, T., & Alitu, I. M. (2015). An application of association rule mining in total productive maintenance strategy: an analysis and modelling in wooden door manufacturing industry. *Procedia Manufacturing*, *4*, 336–343. doi:<https://doi.org/10.1016/j.promfg.2015.11.049>
- Djelloul, I., Sari, Z., & others. (2018). Fault diagnosis of manufacturing systems using data mining techniques. *2018 5th International Conference on Control, Decision and Information Technologies (CoDIT)*, (pp. 198–203). doi:<https://doi.org/10.1109/CoDIT.2018.8394807>
- Dogan, A., & Birant, D. (2021). Machine learning and data mining in manufacturing. *Expert Systems with Applications*, *166*, 114060. doi:<https://doi.org/10.1016/j.eswa.2020.114060>
- Dolgui, A., Bakhtadze, N., Pyatetsky, V., Sabitov, R., Smirnova, G., Elpashev, D., & Zakharov, E. (2018). Data mining-based prediction of manufacturing situations. *IFAC-PapersOnLine*, *51*, 316–321. doi:<https://doi.org/10.1016/j.ifacol.2018.08.302>
- Elmi, A., & Topaloglu, S. (2017). Multi-degree cyclic flow shop robotic cell scheduling problem with multiple robots. *International Journal of Computer Integrated Manufacturing*, *30*, 805–821. doi:<https://doi.org/10.1080/0951192X.2016.1210231>
- EUNNURI, C. H., JI-HYE, J. U., CHANG, T. A.-W., & YERIM, C. H. (2020). Quality prediction modeling of plastic extrusion process. *ICIC express letters. Part B, Applications: an international journal of*



research and surveys, 11, 447–452. Retrieved from <http://www.icicelb.org/ellb/contents/2020/5/elb-11-05-04.pdf>

- Ferreira, R. d., Sabbaghi, A., & Huang, Q. (2019). Automated geometric shape deviation modeling for additive manufacturing systems via Bayesian neural networks. *IEEE Transactions on Automation Science and Engineering*, 17, 584–598. doi:<https://doi.org/10.1109/TASE.2019.2936821>
- Forero-Ramírez, J.-C., Restrepo-Girón, A.-D., & Nope-Rodríguez, S.-E. (2019). Detection of internal defects in carbon fiber reinforced plastic slabs using background thermal compensation by filtering and support vector machines. *Journal of Nondestructive Evaluation*, 38, 1–11. doi:<https://doi.org/10.1007/s10921-019-0569-6>
- Gandhi, K., Schmidt, B., & Ng, A. H. (2018). Towards data mining based decision support in manufacturing maintenance. *Procedia Cirp*, 72, 261–265. doi:<https://doi.org/10.1016/j.procir.2018.03.076>
- Gao, K., Chen, H., Zhang, X., Ren, X., Chen, J., & Chen, X. (2019). A novel material removal prediction method based on acoustic sensing and ensemble XGBoost learning algorithm for robotic belt grinding of Inconel 718. *The International Journal of Advanced Manufacturing Technology*, 105, 217–232. doi:<https://doi.org/10.1007/s00170-019-04170-7>
- Ge, Z., Song, Z., Ding, S. X., & Huang, B. (2017). Data mining and analytics in the process industry: The role of machine learning. *Ieee Access*, 5, 20590–20616. doi:<https://doi.org/10.1109/ACCESS.2017.2756872>
- Harding, J. A., Shahbaz, M., & Kusiak, A. (2006). Data mining in manufacturing: a review. doi:<https://doi.org/10.1115/1.2194554>
- Hu, L., Zhou, M., Xiang, F., & Feng, Q. (2018). Modeling and recognition of steel-plate surface defects based on a new backward boosting algorithm. *The International Journal of Advanced Manufacturing Technology*, 94, 4317–4328. doi:<https://doi.org/10.1007/s00170-017-1113-4>
- Huang, J., Segura, L. J., Wang, T., Zhao, G., Sun, H., & Zhou, C. (2020). Unsupervised learning for the droplet evolution prediction and process dynamics understanding in inkjet printing. *Additive Manufacturing*, 35, 101197. doi:<https://doi.org/10.1016/j.addma.2020.101197>
- Huang, Y.-J., Pan, C.-L., Lin, S.-C., & Guo, M.-H. (2018). Machine-learning approach in detection and classification for defects in TSV-based 3-D IC. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 8, 699–706. doi:<https://doi.org/10.1109/TCPMT.2017.2788896>
- Imoto, K., Nakai, T., Ike, T., Haruki, K., & Sato, Y. (2018). A CNN-based transfer learning method for defect classification in semiconductor manufacturing. *2018 international symposium on semiconductor manufacturing (ISSM)*, (pp. 1–3). doi:<https://doi.org/10.1109/ISSM.2018.8651174>
- Ismail, R., Othman, Z., & Bakar, A. A. (2012). A production schedule generator framework for pattern sequential mining. *2012 7th International Conference on Computing and Convergence Technology (ICCT)*, (pp. 784–788). Retrieved from <https://ieeexplore.ieee.org/abstract/document/6530440>
- Jin, C. H., Na, H. J., Piao, M., Pok, G., & Ryu, K. H. (2019). A novel DBSCAN-based defect pattern detection and classification framework for wafer bin map. *IEEE Transactions on Semiconductor Manufacturing*, 32, 286–292. doi:<https://doi.org/10.1109/TSM.2019.2916835>
- Kamsu-Foguem, B., Rigal, F., & Mauget, F. (2013). Mining association rules for the quality improvement of the production process. *Expert systems with applications*, 40, 1034–1045. doi:<https://doi.org/10.1016/j.eswa.2012.08.039>
- Kao, H.-A., Hsieh, Y.-S., Chen, C.-H., & Lee, J. (2017). Quality prediction modeling for multistage manufacturing based on classification and association rule mining. *MATEC Web of Conferences*, 123, p. 00029. doi:<https://doi.org/10.1051/mateconf/201712300029>
- Kerdprasop, K., & Kerdprasop, N. (2011). A data mining approach to automate fault detection model development in the semiconductor manufacturing process. *Int. J. Mech*, 5, 336–344. Retrieved from <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.1085.2938&rep=rep1&type=pdf>
- Kim, A., Oh, K., Jung, J.-Y., & Kim, B. (2018). Imbalanced classification of manufacturing quality conditions using cost-sensitive decision tree ensembles. *International Journal of Computer Integrated Manufacturing*, 31, 701–717. doi:<https://doi.org/10.1080/0951192X.2017.1407447>



- Kim, J. K., Han, Y. S., & Lee, J. S. (2017). Particle swarm optimization–deep belief network–based rare class prediction model for highly class imbalance problem. *Concurrency and Computation: Practice and Experience*, 29, e4128. doi:<https://doi.org/10.1002/cpe.4128>
- Klar, M., Glatt, M., & Aurich, J. C. (2021). An implementation of a reinforcement learning based algorithm for factory layout planning. *Manufacturing Letters*, 30, 1–4. doi:<https://doi.org/10.1016/j.mfglet.2021.08.003>
- Ko, T., Lee, J. H., Cho, H., Cho, S., Lee, W., & Lee, M. (2017). Machine learning-based anomaly detection via integration of manufacturing, inspection and after-sales service data. *Industrial Management & Data Systems*. doi:<https://doi.org/10.1108/IMDS-06-2016-0195>
- Köksal, G., Batmaz, I., & Testik, M. C. (2011). A review of data mining applications for quality improvement in manufacturing industry. *Expert systems with Applications*, 38, 13448–13467. doi:<https://doi.org/10.1016/j.eswa.2011.04.063>
- Kujawińska, A., Rogalewicz, M., Muchowski, M., & Stańkowska, M. (2018). Application of cluster analysis in making decision about purchase of additional materials for welding process. In *Smart Technology* (pp. 10–20). Springer. doi:https://doi.org/10.1007/978-3-319-73323-4_2
- Lee, C. K., Choy, K. L., Ho, G. T., Chin, K.-S., Law, K. M., & Tse, Y. K. (2013). A hybrid OLAP-association rule mining based quality management system for extracting defect patterns in the garment industry. *Expert Systems with Applications*, 40, 2435–2446.
- Lee, H., Kim, Y., & Kim, C. O. (2016). A deep learning model for robust wafer fault monitoring with sensor measurement noise. *IEEE Transactions on Semiconductor Manufacturing*, 30, 23–31. doi:<https://doi.org/10.1109/TSM.2016.2628865>
- Lee, J., Noh, S. D., Kim, H.-J., & Kang, Y.-S. (2018). Implementation of cyber-physical production systems for quality prediction and operation control in metal casting. *Sensors*, 18, 1428. doi:<https://doi.org/10.3390/s18051428>
- Lee, K. B., Cheon, S., & Kim, C. O. (2017). A convolutional neural network for fault classification and diagnosis in semiconductor manufacturing processes. *IEEE Transactions on Semiconductor Manufacturing*, 30, 135–142. doi:<https://doi.org/10.1109/TSM.2017.2676245>
- Lei, Q., Bo, L., & Kun, C. (2017, 6). Online Monitoring of Manufacturing Process Based on autoCEP. *International Journal of Online Engineering (iJOE)*, 13, 22. doi:<http://dx.doi.org/10.3991/ijoe.v13i06.6812>
- Li, T., Li, Y., An, D., Han, Y., Xu, S., Lu, Z., & Crittenden, J. (2019). Mining of the association rules between industrialization level and air quality to inform high-quality development in China. *Journal of environmental management*, 246, 564–574. doi:<https://doi.org/10.1016/j.jenvman.2019.06.022>
- Lieber, D., Stolpe, M., Konrad, B., Deuse, J., & Morik, K. (2013). Quality prediction in interlinked manufacturing processes based on supervised & unsupervised machine learning. *Procedia Cirp*, 7, 193–198. doi:<https://doi.org/10.1016/j.procir.2013.05.033>
- Lim, H. K., Kim, Y., & Kim, M.-K. (2017). Failure prediction using sequential pattern mining in the wire bonding process. *IEEE Transactions on Semiconductor Manufacturing*, 30, 285–292. doi:<https://doi.org/10.1109/TSM.2017.2721820>
- Lingitz, L., Gallina, V., Ansari, F., Gyulai, D., Pfeiffer, A., Sihm, W., & Monostori, L. (2018). Lead time prediction using machine learning algorithms: A case study by a semiconductor manufacturer. *Procedia Cirp*, 72, 1051–1056. doi:<https://doi.org/10.1016/j.procir.2018.03.148>
- Liukkonen, M., & Hiltunen, Y. (2018). Recognition of systematic spatial patterns in silicon wafers based on SOM and K-means. *IFAC-PapersOnLine*, 51, 439–444. doi:<https://doi.org/10.1016/j.ifacol.2018.03.075>
- Luo, M., Yan, H.-C., Hu, B., Zhou, J.-H., & Pang, C. K. (2015). A data-driven two-stage maintenance framework for degradation prediction in semiconductor manufacturing industries. *Computers & Industrial Engineering*, 85, 414–422. doi:<https://doi.org/10.1016/j.cie.2015.04.008>
- Lv, S., Kim, H., Zheng, B., & Jin, H. (2018). A review of data mining with big data towards its applications in the electronics industry. *Applied Sciences*, 8, 582. doi:<https://doi.org/10.3390/app8040582>



- Mangal, A., & Kumar, N. (2016). Using big data to enhance the bosch production line performance: A kaggle challenge. *2016 IEEE international conference on big data (big data)*, (pp. 2029–2035). doi:<https://doi.org/10.1109/BigData.2016.7840826>
- Meidan, Y., Lerner, B., Rabinowitz, G., & Hassoun, M. (2011). Cycle-time key factor identification and prediction in semiconductor manufacturing using machine learning and data mining. *IEEE transactions on semiconductor manufacturing*, *24*, 237–248. doi:<https://doi.org/10.1109/TSM.2011.2118775>
- Mennes, R., Claeys, M., De Figueiredo, F. A., Jabandžić, I., Moerman, I., & Latre, S. (2019). Deep learning-based spectrum prediction collision avoidance for hybrid wireless environments. *IEEE Access*, *7*, 45818–45830. doi:<https://doi.org/10.1109/ACCESS.2019.2909398>
- Minaei, B., Asadi, M., & Parvin, H. (2011). An Ensemble Based Approach for Feature Selection. Retrieved from <https://www.researchgate.net/publication/220827715>
- Minaei-Bidgoli, B., Parvin, H., Alinejad-Rokny, H., Alizadeh, H., & Punch, W. F. (2014). Effects of resampling method and adaptation on clustering ensemble efficacy. *Artificial Intelligence Review*, *41*, 27–48. doi:<https://doi.org/10.1007/s10462-011-9295-x>
- Mohammadi, P., & Wang, Z. J. (2016). Machine learning for quality prediction in abrasion-resistant material manufacturing process. *2016 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)*, (pp. 1–4). doi:<https://doi.org/10.1109/CCECE.2016.7726783>
- Moldovan, D., Cioara, T., Anghel, I., & Salomie, I. (2017). Machine learning for sensor-based manufacturing processes. *2017 13th IEEE international conference on intelligent computer communication and processing (ICCP)*, (pp. 147–154). doi:<https://doi.org/10.1109/ICCP.2017.8116997>
- Munirathinam, S., & Ramadoss, B. (2016). Predictive models for equipment fault detection in the semiconductor manufacturing process. *IACSIT International Journal of Engineering and Technology*, *8*, 273–285. Retrieved from <http://www.ijetch.org/vol8/898-T10023.pdf>
- Mutlu, N. G., & Altuntas, S. (2019). Assessment of occupational risks In Turkish manufacturing systems with data-driven models. *Journal of Manufacturing Systems*, *53*, 169–182. doi:<https://doi.org/10.1016/j.jmsy.2019.09.008>
- Nagorny, K., Lima-Monteiro, P., Barata, J., & Colombo, A. W. (2017). Big data analysis in smart manufacturing: A review. *International Journal of Communications, Network and System Sciences*, *10*, 31–58. doi:<https://doi.org/10.4236/ijcns.2017.103003>
- Nakata, K., Orihara, R., Mizuoka, Y., & Takagi, K. (2017). A comprehensive big-data-based monitoring system for yield enhancement in semiconductor manufacturing. *IEEE Transactions on Semiconductor Manufacturing*, *30*, 339–344. doi:<https://doi.org/10.1109/TSM.2017.2753251>
- Nedelkoski, S., & Stojanovski, G. (2017). Machine learning for large scale manufacturing data with limited information. *2017 13th IEEE International Conference on Control & Automation (ICCA)*, (pp. 70–75). doi:<https://doi.org/10.1109/ICCA.2017.8003037>
- Odabaşı, Ç., & Yıldırım, R. (2020). Machine learning analysis on stability of perovskite solar cells. *Solar Energy Materials and Solar Cells*, *205*, 110284. doi:<https://doi.org/10.1016/j.solmat.2019.110284>
- Onel, M., Kieslich, C. A., & Pistikopoulos, E. N. (2019). A nonlinear support vector machine-based feature selection approach for fault detection and diagnosis: Application to the Tennessee Eastman process. *AICHE Journal*, *65*, 992–1005. doi:<https://doi.org/10.1002/aic.16497>
- Ong, P.-L., Choo, Y.-H., & Muda, A. K. (2015). A manufacturing failure root cause analysis in imbalance data set using pca weighted association rule mining. *Jurnal Teknologi*, *77*. doi:<https://doi.org/10.11113/jt.v77.6496>
- Packianather, M. S., Davies, A., Harraden, S., Soman, S., & White, J. (2017). Data mining techniques applied to a manufacturing SME. *Procedia CIRP*, *62*, 123–128. doi:<https://doi.org/10.1016/j.procir.2016.06.120>
- Park, H., & Jung, J.-Y. (2020). SAX-ARM: Deviant event pattern discovery from multivariate time series using symbolic aggregate approximation and association rule mining. *Expert Systems with Applications*, *141*, 112950. doi:<https://doi.org/10.1016/j.eswa.2019.112950>



- Parvin, H., Alinejad-Rokny, H., & Parvin, S. (2013). A classifier ensemble of binary classifier ensembles. *International Journal of Learning Management Systems*, 1, 37–47. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.403.11&rep=rep1&type=pdf>
- Parvin, H., Alinejad-Rokny, H., Minaei-Bidgoli, B., & Parvin, S. (2013). A new classifier ensemble methodology based on subspace learning. *Journal of Experimental & Theoretical Artificial Intelligence*, 25, 227–250. doi:<https://doi.org/10.1080/0952813X.2012.715683>
- Parvin, H., Helmi, H., Minaei, B., Rokny, H. A., & Shirgahi, H. (2011). Linkage learning based on differences in local optimums of building blocks with one optima. *International Journal of Physical Sciences*, 6, 3419–3425. doi:<https://doi.org/10.5897/IJPS11.798>
- Parvin, H., Minaei-Bidgoli, B., Alinejad-Rokny, H., & Punch, W. F. (2013). Data weighing mechanisms for clustering ensembles. *Computers & Electrical Engineering*, 39, 1433–1450. doi:<https://doi.org/10.1016/j.compeleceng.2013.02.004>
- Parvin, H., MirnabiBaboli, M., & Alinejad-Rokny, H. (2015). Proposing a classifier ensemble framework based on classifier selection and decision tree. *Engineering Applications of Artificial Intelligence*, 37, 34–42. doi:<https://doi.org/10.1016/j.engappai.2014.08.005>
- Pavlyshenko, B. (2016). Machine learning, linear and bayesian models for logistic regression in failure detection problems. *2016 IEEE International Conference on Big Data (Big Data)*, (pp. 2046–2050). doi:<https://doi.org/10.1109/BigData.2016.7840828>
- Pham, D. T., & Afify, A. A. (2005). Machine-learning techniques and their applications in manufacturing. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 219, 395–412. doi:<https://doi.org/10.1243%2F095440505X32274>
- Pospíšil, M., Bartík, V., & Hruška, T. (2016). Analyzing Machine Performance Using Data Mining. *2016 IEEE Symposium Series on Computational Intelligence (SSCI)*, (pp. 1–7). doi:<https://doi.org/10.1109/SSCI.2016.7849923>
- Priore, P., Ponte, B., Puente, J., & Gómez, A. (2018). Learning-based scheduling of flexible manufacturing systems using ensemble methods. *Computers & Industrial Engineering*, 126, 282–291. doi:<https://doi.org/10.1016/j.cie.2018.09.034>
- Przewozniczek, M. W., & Komarnicki, M. M. (2020). Empirical linkage learning. *IEEE Transactions on Evolutionary Computation*, 24, 1097–1111. doi:<https://doi.org/10.1109/TEVC.2020.2985497>
- Quatrini, E., Costantino, F., Di Gravio, G., & Patriarca, R. (2020). Machine learning for anomaly detection and process phase classification to improve safety and maintenance activities. *Journal of Manufacturing Systems*, 56, 117–132. doi:<https://doi.org/10.1016/j.jmsy.2020.05.013>
- Ren, L., Sun, Y., Cui, J., & Zhang, L. (2018). Bearing remaining useful life prediction based on deep autoencoder and deep neural networks. *Journal of Manufacturing Systems*, 48, 71–77. doi:<https://doi.org/10.1016/j.jmsy.2018.04.008>
- Rivetti, N., Busnel, Y., & Gal, A. (2017). Flinkman: Anomaly detection in manufacturing equipment with apache flink: Grand challenge. *Proceedings of the 11th ACM International Conference on Distributed and Event-based Systems*, (pp. 274–279). doi:<https://doi.org/10.1145/3093742.3095099>
- Rostami, H., Blue, J., & Yugma, C. (2016). Equipment condition diagnosis and fault fingerprint extraction in semiconductor manufacturing. *2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA)*, (pp. 534–539). doi:<https://doi.org/10.1109/ICMLA.2016.0094>
- Rostami, H., Dantan, J.-Y., & Homri, L. (2015). Review of data mining applications for quality assessment in manufacturing industry: support vector machines. *International Journal of Metrology and Quality Engineering*, 6, 401. doi:<https://doi.org/10.1051/ijmqe/2015023>
- Ryu, J. W., Kantardzic, M., & Walgampaya, C. (2010). Ensemble classifier based on misclassified streaming data. *Proc. of the 10th IASTED Int. Conf. on Artificial Intelligence and Applications, Austria*, (pp. 347–354). doi:<http://dx.doi.org/10.2316/P.2010.674-048>
- Samie Tootooni, M., Dsouza, A., Donovan, R., Rao, P. K., Kong, Z. J., & Borgesen, P. (2017). Classifying the dimensional variation in additive manufactured parts from laser-scanned three-dimensional point cloud



data using machine learning approaches. *Journal of Manufacturing Science and Engineering*, 139. doi:<https://doi.org/10.1115/1.4036641>

- Sand, C., Kunz, S., Hubbert, H., & Franke, J. (2016). Towards an inline quick reaction system for actuator manufacturing using data mining. *2016 6th International Electric Drives Production Conference (EDPC)*, (pp. 74–79). doi:<https://doi.org/10.1109/EDPC.2016.7851317>
- Seyedaghaee, N., & Alinejad-Rokny, H. (2013). An optimized model for the university strategic planning. *International Journal of Basic Sciences & Applied Research*, 2, 500–505. Retrieved from https://www.researchgate.net/publication/262380211_An_Optimized_Model_for_the_University_Strategic_Planning
- Shao, S.-Y., Sun, W.-J., Yan, R.-Q., Wang, P., & Gao, R. X. (2017). A deep learning approach for fault diagnosis of induction motors in manufacturing. *Chinese Journal of Mechanical Engineering*, 30, 1347–1356. doi:<https://doi.org/10.1007/s10033-017-0189-y>
- Stanisavljevic, D., & Spitzer, M. (2016). A Review of Related Work on Machine Learning in Semiconductor Manufacturing and Assembly Lines. *SAMI@ iKNOW*. Retrieved from <http://ceur-ws.org/Vol-1793/paper1.pdf>
- Susto, G. A., Terzi, M., & Beghi, A. (2017). Anomaly detection approaches for semiconductor manufacturing. *Procedia Manufacturing*, 11, 2018–2024. doi:<https://doi.org/10.1016/j.promfg.2017.07.353>
- Syafurudin, M., Alfian, G., Fitriyani, N. L., & Rhee, J. (2018). Performance analysis of IoT-based sensor, big data processing, and machine learning model for real-time monitoring system in automotive manufacturing. *Sensors*, 18, 2946. doi:<https://doi.org/10.3390/s18092946>
- Tian, Y., Fu, M., & Wu, F. (2015). Steel plates fault diagnosis on the basis of support vector machines. *Neurocomputing*, 151, 296–303. doi:<https://doi.org/10.1016/j.neucom.2014.09.036>
- Wang, J., Wang, K., Wang, Y., Huang, Z., & Xue, R. (2019). Deep Boltzmann machine based condition prediction for smart manufacturing. *Journal of Ambient Intelligence and Humanized Computing*, 10, 851–861. doi:<https://doi.org/10.1007/s12652-018-0794-3>
- Wang, K. (2007). Applying data mining to manufacturing: the nature and implications. *Journal of Intelligent Manufacturing*, 18, 487–495. Retrieved from <https://link.springer.com/content/pdf/10.1007/s10845-007-0053-5.pdf>
- Wang, K., Tong, S., Eynard, B., Roucoules, L., & Matta, N. (2007). Review on application of data mining in product design and manufacturing. *Fourth International Conference on Fuzzy Systems and Knowledge Discovery (FSKD 2007)*, 4, pp. 613–618. doi:<https://doi.org/10.1109/FSKD.2007.482>
- Wang, K.-S. (2013). Towards zero-defect manufacturing (ZDM)—a data mining approach. *Advances in Manufacturing*, 1, 62–74. doi:<https://doi.org/10.1007/s40436-013-0010-9>
- Wang, Q., Jiao, W., Yu, R., Johnson, M. T., & Zhang, Y. (2019). Modeling of Human Welders' Operations in Virtual Reality Human–Robot Interaction. *IEEE Robotics and Automation Letters*, 4, 2958–2964. doi:<https://doi.org/10.1109/LRA.2019.2921928>
- Wang, Y., Li, K., & Gan, S. (2018). A kernel connectivity-based outlier factor algorithm for rare data detection in a baking process. *IFAC-PapersOnLine*, 51, 297–302. doi:<https://doi.org/10.1016/j.ifacol.2018.09.316>
- Waschneck, B., Reichstaller, A., Belzner, L., Altenmüller, T., Bauernhansl, T., Knapp, A., & Kyek, A. (2018). Deep reinforcement learning for semiconductor production scheduling. *2018 29th annual SEMI advanced semiconductor manufacturing conference (ASMC)*, (pp. 301–306). doi:<https://doi.org/10.1109/ASMC.2018.8373191>
- Wen, L., Gao, L., & Li, X. (2017). A new deep transfer learning based on sparse auto-encoder for fault diagnosis. *IEEE Transactions on systems, man, and cybernetics: systems*, 49, 136–144. doi:<https://doi.org/10.1109/TSMC.2017.2754287>
- Wuest, T., Irgens, C., & Thoben, K.-D. (2014). An approach to monitoring quality in manufacturing using supervised machine learning on product state data. *Journal of Intelligent Manufacturing*, 25, 1167–1180. Retrieved from <https://link.springer.com/content/pdf/10.1007/s10845-013-0761-y.pdf>

- Wuest, T., Weimer, D., Irgens, C., & Thoben, K.-D. (2016). Machine learning in manufacturing: advantages, challenges, and applications. *Production & Manufacturing Research*, 4, 23–45.
doi:<https://doi.org/10.1080/21693277.2016.1192517>
- Yasutomi, A. Y., & Enoki, H. (2020). Localization of Inspection Device Along Belt Conveyors With Multiple Branches Using Deep Neural Networks. *IEEE Robotics and Automation Letters*, 5, 2921–2928.
doi:<https://doi.org/10.1109/LRA.2020.2974709>
- Zhang, X., Kano, M., Tani, M., Mori, J., Ise, J., & Harada, K. (2020). Prediction and causal analysis of defects in steel products: Handling nonnegative and highly overdispersed count data. *Control Engineering Practice*, 95, 104258. doi:<https://doi.org/10.1016/j.conengprac.2019.104258>
- Zhang, Y. F., & Ren, S. (2015). Big data based analysis architecture of complex product manufacturing and maintenance process for sustainable production. *J. Clean. Prod*, 142, 626–641.
doi:http://dx.doi.org/10.1007/978-3-319-22759-7_50
- Zhang, Y., Ren, S., Liu, Y., & Si, S. (2017). A big data analytics architecture for cleaner manufacturing and maintenance processes of complex products. *Journal of cleaner production*, 142, 626–641.
doi:<https://doi.org/10.1016/j.jclepro.2016.07.123>
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., & Gao, R. X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213–237.
doi:<https://doi.org/10.1016/j.ymssp.2018.05.050>
- Zhou, J.-T., Li, X.-Q., Wang, M.-W., Niu, R., & Xu, Q. (2017). Thinking process rules extraction for manufacturing process design. *Advances in Manufacturing*, 5, 321–334.
doi:<https://doi.org/10.1007/s40436-017-0205-6>
- حمزه شیخ شعاعی. (۱۴۰۰ ج). ملاحظات اخلاقی در سیاستگذاری هوش مصنوعی پزشکی. دهمین کنفرانس بین المللی نوآوری و تحقیق در علوم مهندسی، (صفحه ۲۳). تم الاسترداد من <https://civilica.com/doc/1318155>
- شیخ شعاعی، ح. (۱۴۰۰ الف). هوش مصنوعی پزشکی و لزوم سیاستگذاری همه جانبه. اولین کنفرانس بین المللی مدیریت و صنعت، (ص. ۱۳). بازیابی از <https://civilica.com/doc/1277812>
- شیخ شعاعی، ح. (۱۴۰۰ ب). مروری بر سیاستگذاری بین المللی در زمینه هوش مصنوعی. اولین کنفرانس بین المللی مدیریت و صنعت، (ص. ۱۳). بازیابی از <https://civilica.com/doc/1277814>
- شیخ شعاعی، ح. (۱۴۰۰ د). چالش ها، نقش ها و سیاستگذاری پژوهش های هوش مصنوعی در آموزش و پرورش. بازیابی از <https://civilica.com/doc/1353371>
- شیخ شعاعی، ح. (۱۴۰۰ ه). دیپلماسی علم و فناوری مبتنی بر داده. اولین کنفرانس بین المللی مدیریت و صنعت، (ص. ۲۳). بازیابی از <https://civilica.com/doc/1277811>