

Aplicações de machine learning nas áreas da engenharia de produção

Este artigo teve como objetivo a realização de uma revisão sistemática, seguida de uma bibliometria, para analisar quantitativamente e qualitativamente as publicações sobre machine learning (ML) no período de 2015 a 2020, contidas nos principais eventos da Engenharia de Produção (EP) no Brasil. Foi desenvolvido um protocolo de pesquisa e critérios de elegibilidade para identificar pesquisas que continham aplicações das técnicas de ML, resultando em 71 artigos elegíveis para a etapa de bibliometria. Em seguida, analisou-se a quantidade de artigos por evento, publicações por instituição, autores mais frequentes, rede de cooperação, áreas da EP mais exploradas, principais tarefas e técnicas de ML. Os resultados mostraram que as áreas mais exploradas foram a Gestão da Qualidade e a Engenharia Econômica, enquanto que as tarefas voltadas à classificação e os algoritmos baseados em Redes Neurais e Árvores de Decisão, foram os mais frequentes nas pesquisas. Quanto às instituições de ensino, a Universidade Tecnológica Federal do Paraná (UTFPR) foi a que mais publicou neste período, e em conjunto com a Pontifícia Universidade Católica do Paraná (PUC-PR) e a Universidade Federal Fluminense, foram as instituições que mais participaram de artigos em parceria com outras universidades. A pesquisadora que mais publicou, participou de seis artigos e pertence ao programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS), da PUC-PR.

Palavras-chave: Machine learning; Mineração de dados; Engenharia de produção; Revisão sistemática; Bibliometria

Machine learning applications in the areas of production engineering

This paper carried out a systematic review and a bibliometric analysis to assess quantitatively and qualitatively the papers that applied machine learning (ML) techniques published between 2015 and 2020 on the main Brazilian scientific events related to Production Engineering (PE). A research protocol along with a set of eligibility criteria were devised to identify research that contained applications of ML techniques, resulting in 71 articles being selected for the bibliometric analysis. This study measured the number of papers per event, publications per institution, most frequent authors, cooperation networks, most explored PE areas, as well as the main ML tasks and techniques being used. The results show that Quality Management and Economic Engineering are the PE areas in which most ML applications take place, while ML tasks aimed at classification and algorithms based on Neural Networks and Decision Trees were the most frequent in the selected papers. As for the main research institutions involved with this research, the Federal University of Technology – Paraná (UTFPR) was the most active in the period analyzed, and along with the Pontifical Catholic University of Paraná (PUC-PR) and the Fluminense Federal University, these were the three top universities that most participated in research that involved partnership with other universities. The researcher who published the most participated in six papers and belongs to the Graduate Program in Production and Systems Engineering (PPGEPS) at PUC-PR.

Keywords: Machine learning; Data mining; Production engineering; Systematic review; Bibliometric Analysis

Topic: **Pesquisa Operacional**

Received: **30/01/2022**

Approved: **25/03/2022**

Reviewed anonymously in the process of blind peer.

Edmilson Homma Junior

Universidade Tecnológica Federal do Paraná, Brasil
<http://lattes.cnpq.br/0728610976197520>
edmilsonj@alunos.utfpr.edu.br

Marlon Alves Bonfim

Universidade Tecnológica Federal do Paraná, Brasil
<http://lattes.cnpq.br/9411627444934132>
marlonalves@alunos.utfpr.edu.br

Ricardo Franco de Almeida Filho

Universidade Tecnológica Federal do Paraná, Brasil
<http://lattes.cnpq.br/3319716839798723>
ricfil@alunos.utfpr.edu.br

Amauri Ornellas da Silva

Universidade Tecnológica Federal do Paraná, Brasil
<http://lattes.cnpq.br/8060571628251221>
amauris@alunos.utfpr.edu.br

Gustavo Cruz Rigonati

Universidade Tecnológica Federal do Paraná, Brasil
<http://lattes.cnpq.br/5229774122091335>
gustavorigonati@alunos.utfpr.edu.br

Daniele Gonçalves de Toledo Luchetta Raminelli

Universidade Tecnológica Federal do Paraná, Brasil
<http://lattes.cnpq.br/8975746288140656>
daraminelli@gmail.com

Bruno Samways dos Santos

Universidade Tecnológica Federal do Paraná, Brasil
<http://lattes.cnpq.br/5500192844287607>
brunosantos@utfpr.edu.br

Rafael Henrique Palma Lima 

Universidade Tecnológica Federal do Paraná, Brasil
<http://lattes.cnpq.br/3263781278157068>
<https://orcid.org/0000-0002-9098-3025>
rafaelhlma@utfpr.edu.br



DOI: 10.6008/CBPC2179-684X.2022.001.0026

Referencing this:

HOMMA, E. J.; BONFIM, M. A.; ALMEIDA, R. F. F.; SILVA, A. O.; RIGONATI, G. C.; RAMINELLI, D. G. T. L.; SANTOS, B. S.; LIMA, R. H. P.. Aplicações de machine learning nas áreas da engenharia de produção. *Revista Brasileira de Administração Científica*, v.13, n.1, p.368-384, 2022. DOI: <http://doi.org/10.6008/CBPC2179-684X.2022.001.0026>

INTRODUÇÃO

Nos últimos anos houve um aumento de interesse na área conhecida como ‘aprendizado de máquina’, também conhecida pelo termo em inglês *Machine Learning* (ML). De acordo com Goodfellow et al. (2016), as técnicas de ML conseguem encontrar padrões não triviais em bases de dados, contribuindo para melhores decisões a serem tomadas nas empresas. ML pode ser considerado uma ramificação da Inteligência artificial em que os algoritmos aprendem diretamente de um conjunto de dados de entrada, atendendo às várias necessidades baseadas na coleta de dados, uso e compartilhamento em várias organizações (BERTOLINI et al., 2021).

Os algoritmos de ML são amplamente relacionados com uma tarefa de mineração de dados (do inglês, *data mining*), a qual pertence a um processo bem definido e consolidado conhecido como Descoberta de Conhecimento em Bases de Dados (do inglês, *Knowledge Discovery in Databases* – KDD). Esse processo é amplamente utilizado na literatura e foi idealizado por Fayyad et al. (1996), mostrando as etapas necessárias para a descoberta de conhecimento em grandes bases de dados, associado geralmente a alguma metodologia de aplicação, como a Cross-Industry Standard Process for Data Mining (ou CRISP-DM, proposto por Chapman¹). Os dados brutos são manipulados e analisados para a construção de modelos que possam utilizar algum tipo de aprendizado de acordo com uma tarefa de mineração de dados, tipicamente divididas em classificação, regressão (ou estimação), agrupamento (ou clusterização), associação e detecção de anomalia (GUARASCIO et al., 2019).

Estas técnicas de ML têm sido aplicadas nas mais diversas áreas, como na saúde (GARG et al., 2021; FENERICH et al., 2020), educação (KAUR et al., 2015; ADEKITAN et al., 2019; FERNANDES et al., 2019), investimentos (SINGH et al., 2017; ORIMOLOYE et al., 2020), sustentabilidade (PUENTE et al., 2019) ou mesmo na agropecuária (GARCÍA et al., 2020). Devido à grande quantidade de dados gerados em indústrias, a aplicação de ML no setor industrial tem se tornado o foco de trabalhos publicados recentemente (BERTOLINI et al., 2021). Para as áreas específicas da Engenharia de Produção (EP), as aplicações das técnicas de ML podem ser vistas na gestão de cadeias de suprimentos, (WENZEL et al., 2013; WOSCHANK et al., 2020), gestão de resíduos (GARRE et al., 2020), desenvolvimento de novos produtos (BAUMUNG et al., 2020; (MISKELL et al., 2019), gestão de riscos em projetos (GOUTHAMAN et al., 2021), manufatura aditiva (NASIRI et al., 2021) entre outros.

No contexto da EP no Brasil, muitos pesquisadores têm concentrado a sua atenção para o uso de técnicas de ML e isso pode ser verificado em eventos científicos já consolidados no âmbito nacional. Por exemplo, o trabalho de Rocha et al. (2016), onde os autores aplicaram técnicas de ML na área da Engenharia Econômica, foi um dos primeiros a explorar estes tipos de técnicas no Encontro Nacional de Engenharia de Produção (ENEGEP). Em anos posteriores, mais publicações com técnicas de ML foram encontradas não só no ENEGEP, mas também no Simpósio de Engenharia de Produção (SIMPEP), Simpósio Brasileiro de Pesquisa Operacional (SBPO) e Congresso Brasileiro de Engenharia de Produção (ConBRepro). Neste sentido, destaca-

¹ <https://www.semanticscholar.org/paper/CRISP-DM-1.0%3A-Step-by-step-data-mining-guide-Chapman-Clinton/54bad20bbc7938991bf34f86dde0babfbd2d5a72>

se a necessidade de se mapear esses estudos a partir de uma revisão sistemática da literatura com o intuito de avaliar as contribuições mais recentes que utilizaram técnicas de ML em áreas relacionadas à EP, especificamente em eventos nacionais.

Para as áreas que competem à EP (também conhecida como “engenharia industrial” em alguns países) tem-se aplicado este tipo de revisão da literatura internacional, incluindo a busca por aplicações de inteligência artificial (IA) e ML. Pode ser citado aqui, por exemplo, a revisão sistemática de aplicações de ML na análise de sentimentos de consumidores com artigos da Google Scholar (base de artigos que compila artigos de várias bases terceiras) (JAIN et al., 2021). A revisão sistemática de Xu et al. (2021) teve como foco as publicações na área da engenharia de confiabilidade e segurança (sem citar as bases de artigos verificadas). Já Hegde et al. (2020) realizaram uma revisão na Scopus e Engineering Village para aplicações de ML na avaliação de risco na engenharia e Lei et al. (2020), por sua vez, analisaram as publicações sobre ML em diagnósticos de falhas de máquinas a partir dos trabalhos publicados na base da Web of Science.

Explorando também áreas específicas da indústria, tem-se a revisão de Dalzochio et al. (2020) sobre ML na manutenção preditiva da indústria 4.0 a partir dos artigos coletados das bases IEEE, Google Scholar, Springer, ACM Digital Library e ScienceDirect, enquanto que Nasiri et al. (2021) analisaram ML no comportamento mecânico de componentes na manufatura aditiva. Revisões sistemáticas de aplicações de ML na manufatura também podem ser encontrados nos trabalhos de Dogan et al. (2021) e Bertolini *et al.* (2021), com o primeiro utilizando as bases da Scopus e Web of Science, e o segundo também incluiu, além destas duas, o Google Scholar. Com foco no aspecto ambiental, as revisões sistemáticas de Narciso et al. (2020) e Guo et al. (2021) tiveram esta abrangência, sendo a primeira pesquisa relacionada à eficiência energética na indústria com técnicas de ML, baseados nos trabalhos das bases da Science Direct e Scopus, enquanto que o segundo direcionou a pesquisa em processos de reciclagem e tratamento de resíduos sólidos orgânicos em artigos da Web of Science e Science Direct.

Nota-se que, filtrando apenas por trabalhos de 2020 e 2021, há um interesse crescente em pesquisas que se utilizam da revisão sistemática da literatura para analisar e/ou quantificar as aplicações de ML em algumas áreas da EP, principalmente em periódicos internacionais de grande impacto. Limitando esta busca para o Brasil, uma revisão sistemática sobre as técnicas de ML aplicadas em áreas da EP pode ser feita usando-se as bases dos principais eventos da EP. Tal estudo ainda não foi realizado no contexto brasileiro e sua realização poderia revelar o estado da arte das pesquisas envolvendo aplicações de ML em áreas da EP por pesquisadores nacionais.

Este artigo busca preencher essa lacuna de pesquisa por meio de uma revisão sistemática e análise bibliométrica em eventos de grande relevância no cenário nacional (ENEGEP, SIMPEP, ConBRepro e SBPO) quantificando e analisando trabalhos que fizeram o uso de técnicas de ML nas áreas da EP, especificamente nos últimos 5 anos. Para tal, um protocolo de pesquisa foi elaborado para identificar trabalhos que se enquadram no objetivo desta pesquisa.

O restante deste artigo está organizado da seguinte maneira. A Seção 2 introduz o conceito de revisão sistemática da literatura e a Seção 3 apresenta brevemente o panorama sobre a mineração de dados. A Seção

4 descreve o protocolo de pesquisa. As seções 5 e 6 apresentam e discutem os resultados da revisão sistemática. Finalmente, a Seção 7 lista as principais considerações finais e fornece direções para pesquisa futuras.

REVISÃO TEÓRICA

A Revisão Sistemática da Literatura (RSL) é um processo de identificação e avaliação sobre o conhecimento existente em uma área de interesse, baseando-se em uma forma metódica e rigorosa de revisão (SILVESTRI et al., 2020). Neste tipo de revisão, pode-se incluir análises quantitativas e qualitativas, ampliando debates da literatura fundamentado em questões de pesquisa bem definidos (TRANFIELD et al., 2003). São criados sistemas de revisão chamados de “protocolos” de pesquisa que possam ser reproduzidos por outros pesquisadores (AHMED et al., 2018), superando assim estudos mais antigos com a adição de amostras de diferentes bases de dados, resultando em resultados atualizados e significativos (PETTICREW et al., 2006). As revisões sistemáticas geram resultados para mostrar novos caminhos, com um crescente interesse por parte dos pesquisadores para capturar os acontecimentos do passado e indicar o futuro da área de pesquisa (VEIGA et al., 2020).

Quanto às metodologias para a condução de uma RSL, existem três bastante conhecidas na literatura: (i) a análise de conteúdo, (ii) a análise semântica, (iii) e a bibliometria. A escolha da metodologia varia com relação aos dados levantados, sua quantidade e o nível de maturidade que o campo de pesquisa possui.

A análise de conteúdo auxilia a exploração de um tema já consolidado (TSAI et al., 2005), formado por um conjunto de técnicas de análise das comunicações que utiliza procedimentos sistemáticos e objetivos de descrição e/ou predição do conteúdo das mensagens explícitas, e ocultas por meio de indicadores quantitativos e/ou qualitativos que buscam conhecer aquilo que está por trás do significado dos elementos analisados (BARDIN, 1977). Utiliza-se a análise semântica para sintetizar e categorizar termos e expressões para gerar uma interpretação coerente dos conceitos (CHEN et al., 2010). Já a bibliometria é utilizada quando um campo tem vasta quantidade de publicações para analisar as correlações entre citações, palavras-chave ou outras informações dos artigos por meio de métodos estatísticos e matemáticos, observando e construindo indicadores sobre a dinâmica e evolução da informação científica e tecnológica de determinadas disciplinas, áreas, organizações ou países (CHAI et al., 2012).

Um dos métodos de construção de protocolo para um portfólio de pesquisa foi idealizado por Tranfield et al. (2003), os quais sugerem três estágios: planejamento da revisão, constituído por três fases, identificando a necessidade, proposta e desenvolvimento do protocolo; condução da revisão, possui cinco fases que identificam os estudos, qualidade das pesquisas, extração e sintetização dos dados, e; relatório e disseminação, contém duas fases que incluem os resultados da revisão, gerando-se um relatório de evidências e recomendações sobre área explorada.

Exemplos de revisões sistemáticas da literatura baseadas na metodologia proposta de Tranfield et al. (2003) e nas suas complementações (TRANFIELD et al., 2004) podem ser vistas em Karl et al. (2020) e Carneiro et al. (2019).

Mineração de dados e aprendizado de máquina

A origem do termo Machine Learning (ML) habitualmente traduzido para o português como “aprendizado de máquina”, foi mencionado pela primeira vez por um pioneiro em jogos de computador e inteligência artificial, Arthur Lee Samuel, especificando como a ciência que utiliza computadores para a realização de trabalhos autônomos sem necessitar de uma programação explícita (SYAM et al., 2018). De maneira direta, o aprendizado de máquina é definido como um campo de estudo em que os programas de computador possuem a capacidade de aprender e aperfeiçoar a execução de tarefas específicas por meio do treinamento em dados históricos (JONSSON et al., 2016).

Roza (2016) afirma que o objetivo principal de ML é extrapolar os exemplos existentes no conjunto de treinamento, independentemente da quantidade de dados existentes. Sendo assim, é muito pouco provável que durante os testes, exatamente os mesmos exemplos sejam executados.

Bhavsar et al. (2017) explicam que os métodos de aprendizado de máquina são caracterizados, ou categorizados com base no tipo de aprendizado. Para tal, os métodos de aprendizado de ML são subdivididos em quatro grupos, sendo eles: supervisionado, não supervisionado, semi supervisionado e por reforço.

Shalev et al. (2014) descrevem que o método de aprendizado de máquina supervisionado pode ser descrito como o processo aquisição de conhecimento a partir do uso da experiência. A aprendizagem supervisionada executa um cenário em que a experiência contém informações consideráveis que faltam nos exemplos de teste e invisíveis à experiência aprendida que deve ser aplicada. A experiência adquirida neste cenário deverá prever as informações faltantes para os dados separados em uma base de teste.

Já no aprendizado não supervisionado, a estrutura de dados é utilizada sem algum rótulo específico. Neste caso, pode-se encontrar relações entre os valores existentes nas variáveis (ou atributos, geralmente em forma de regras, ou até agrupar objetos (ou instâncias) que possuam uma similaridade entre si (BRAMER, 2016).

O aprendizado semi supervisionado é usado para as mesmas aplicações que o aprendizado supervisionado, juntando com o modo não supervisionado, utilizando exemplos rotulados e exemplos não rotulados (RUSSEL et al., 2013).

No algoritmo de aprendizado por reforço, as classes de agentes aprendem a se adaptar a um determinado estado de acordo com a construção de um modelo que diz qual ação deve ser realizada a partir de um determinado estado (BAZZAN, 2021).

Os tipos de aprendizados mais comuns atualmente podem ser os supervisionados e os não supervisionados. Para cada um deles, existem objetivos distintos que dependem das características dos dados obtidos, bem como o que se propõe a descrever ou prever. Estes objetivos podem ser definidos no que é chamado de “tarefa” de mineração de dados.

Tarefas de Mineração de Dados

Os objetivos com as aplicações de algum algoritmo ou técnica de mineração de dados está vinculada

com as tarefas de mineração. Estas tarefas são comumente divididas em quatro principais (RASCHKA, 2015): classificação, regressão (ou estimação), agrupamento (ou clusterização), e associação.

Para se trabalhar com uma tarefa de classificação, o algoritmo deve ter como objetivo de aprendizado de máquina, categorizar ou classificar as entradas fornecidas com base no conjunto de dados de treinamento (BHAVSAR et al., 2017). Com relação à tarefa de regressão, deseja-se encontrar alguma correlação padrão entre as variáveis, como uma relação funcional entre os componentes X e Y dos dados (SHALEV et al., 2014). Para as tarefas de clusterização, os algoritmos não realizam uma etapa de treinamento com algum rótulo específico, mas sim buscam agrupar pontos de dados em *clusters* a partir de uma métrica baseada em similaridade (AHMAD et al., 2019). Por fim, a regra de associação é utilizada para descobrir relacionamentos entre variáveis e grupos de atributos para um determinado padrão de entrada (ALDOWAH et al., 2019).

Técnicas de Mineração de Dados

Como exemplo de técnicas mais utilizadas no aprendizado de máquina, serão descritas as máquinas de vetores de suporte (ou do inglês *Support Vector Machines*, SVM), as Árvores de Decisão e as Redes Neurais.

O SVM é baseado na teoria da aprendizagem estatística, projetando pontos em um conjunto de treinamento em um espaço e construindo uma superfície chamada de hiperplano (ADAMS et al., 2015). As instâncias mais próximas às margens deste hiperplano são identificadas como vetores de suporte, frequentemente tendo mais de um vetor de suporte para cada classe (quando aplicados a problema de classificação) (WITTEN et al., 2005).

As Árvores de Decisão possuem a vantagem de se conseguir uma análise visual de regras e de fácil interpretação (KASTHURIRATHNE et al., 2016). O modelo basicamente funciona como um fluxograma em uma árvore em que as folhas (nós finais) tem relação com a classe ou valor que está sendo avaliado, os nós internos e o nó raiz indicam um determinado teste sobre o atributo, e todas as conexões representam os valores possíveis (ou limiares) do atributo escolhido (TAN et al., 2019). O algoritmo é considerado bastante versátil, sendo capaz de lidar com problemas de classificação e regressão.

As Redes Neurais são assim chamadas devido à sua semelhança com o funcionamento do cérebro humano (LIOU et al., 2008). Os resultados não são de fácil interpretação, como ocorre nas Árvores de Decisão, porém a boa acurácia, tolerância aos ruídos e adaptação em ambientes dinâmicos favorecem o seu uso (SRIDAR et al., 2014). Alguns avanços com relação às Redes Neurais fizeram com que ela fosse uma das estudadas nos últimos tempos, com a elaboração de livros inteiramente dedicados à abordagem de aprendizagem profunda (do inglês, *deep learning*), como pode ser encontrado na referência de Aggarwal (2018).

As técnicas citadas anteriormente são apenas algumas utilizadas atualmente na área de aprendizagem de máquina e mineração de dados. Outras técnicas para as tarefas de classificação ou regressão, como *Naïve Bayes*, *k*-vizinhos mais próximos e Florestas Randômicas podem ser encontradas

frequentemente em artigos e livros. Para os algoritmos não supervisionados, podem ser citados aqui o *k-means*, agrupamento hierárquico, *Principal Component Analysis* (PCA) e Apriori, também com ampla literatura publicada sobre cada uma destas técnicas.

MATERIAIS E MÉTODOS

A revisão sistemática desta pesquisa busca avaliar os temas abordados por pesquisadores que associam o aprendizado de máquina à área de Engenharia de Produção, bem como identificar as principais subáreas estudadas e as técnicas utilizadas.

Estratégia de busca

A construção da base de dados dos artigos é constituída pelos congressos ENEGEP, SIMPEP, SBPO e ConBRepro, na qual foram examinados os anais do período de 2015 à 2019, contemplando o ciclo de cinco anos. Os termos de busca foram definidos de acordo com a Tabela 1.

Tabela 1: Lista de termos de buscas

Identificação	Palavras-chave
1	Mineração de dados OU Data mining
2	Aprendizado de máquina OU Aprendizagem de máquina OU Machine learning
3	Inteligência Artificial OU Artificial Intelligence
4	Ciência de dados OU Data Science
5	Classificação
6	Regressão
7	Estimação
8	Clusterização
9	Agrupamento
10	Previsão

Definidas os termos de busca, o foco da pesquisa foi nas seguintes sub-áreas da EP: Cadeias de Suprimentos; Projeto de Produto; Planejamento da Produção; Gestão da Qualidade; Gestão de Pessoas; Engenharia Econômica; Engenharia do Trabalho; Sustentabilidade.

Destaca-se que a área de “Pesquisa Operacional” não foi incluída, pois as técnicas de ML constituem um “meio” para as aplicações das áreas acima e, como definido pela ABEPRO, a subárea da “Inteligência Computacional” se encontra na grande área de Pesquisa Operacional (ABEPRO, 2021).

Vale destacar que as páginas de busca dos anais dos eventos não permitem a realização de consultas usando combinações de strings usando palavras como “AND” e “OR”, o que é comum em bases de periódicos científicos. Por essa razão, a busca pelos termos indicados na Tabela 1 teve que ser feita manualmente, um termo de cada vez.

Critérios de Elegibilidade

Os artigos elegíveis deveriam apresentar os seguintes aspectos: (i) ser artigo original; (ii) ter desenvolvimento na área de EP e; (iii) ser publicado em português. A forma de utilização dos critérios de elegibilidade permitiu inserir artigos que utilizam a composição de dados de estudos próprios ou obtidos por terceiros, e estudos práticos e conceituais.

Seleção dos Estudos

A partir das definições das informações e de quais dados estão sendo focados para extração nos congressos e simpósios, foi necessário realizar a seleção dos artigos. A atividade foi executada pelos pesquisadores, incluindo cinco alunos de graduação e dois docentes. Os dados foram registrados em uma planilha eletrônica compartilhada em nuvem. A divisão da seleção dos estudos foi feita em três fases.

Primeira fase, caracterizada pelo levantamento dos motivos da pesquisa, estruturação dos termos, locais de busca dos artigos e divisão das funções. Com os procedimentos anteriores já descritos, os avaliadores acessaram os portais, e a extração dos artigos deu-se apenas pelo conjunto de termos, cujas palavras estivessem no nome, no resumo ou nas palavras-chaves. Todos os resultados obtidos foram armazenados e separados por congresso e ano de publicação.

Segunda fase, em que os artigos selecionados da primeira fase foram submetidos a uma nova avaliação, mas desta vez realizando a leitura de seu abstract, para que fosse possível a identificação e validação caso o artigo realmente envolvesse uma aplicação prática com ML. Artigos que atendem aos critérios estabelecidos para a revisão sistemática foram registrados na planilha registrando informações como a aplicação específica que foi feita no artigo, a técnica de mineração de dados, o método e a(s) ferramenta(s) usadas, a origem do banco de dados adotado e se foi uma aplicação prática ou levantamento bibliográfico. Assim, realizou-se o enquadramento do artigo em uma das dez áreas da EP ou em outra área (“Outros”) não pertencente a ela.

A segunda fase também seguiu a mesma estrutura da primeira, sendo separada por congresso e por ano, realizando-se a tabulação das informações adicionais fornecidas pelo artigo, entre elas: os autores; se o artigo realmente correspondia ao conceito de ML; tarefa(s) realizada(s); técnicas de mineração, e; as palavras-chave.

Terceira fase, em que os artigos selecionados anteriormente foram submetidos à última avaliação, realizando-se a leitura completa do artigo, verificando se as decisões definidas na fase anterior estão corretas e se o artigo realmente correspondia às necessidades estabelecidas para a primeira fase. Esta fase também possui a mesma estrutura de dados das primeira e segunda fases, ou seja, estratificação por congresso e ano, tabulação e análise das características finais da fase 2.

Quarta Fase, que consistiu em consolidar a base de dados extraída e validá-las, elaborando-se gráficos e análises na sequência para discussão. Assim, foi feito todo o tratamento e limpeza dos dados para poder manipulá-los posteriormente. Um fluxograma com todas as etapas citadas anteriormente está ilustrado na Figura 1.

RESULTADOS

Buscando organizar a apresentação dos resultados das pesquisas foram criados gráficos demonstrativos. Para cada figura, serão apresentados os principais resultados dos artigos de forma articulada. A Figura 2 mostra a quantidade de artigos obtida para cada evento nos últimos cinco anos.

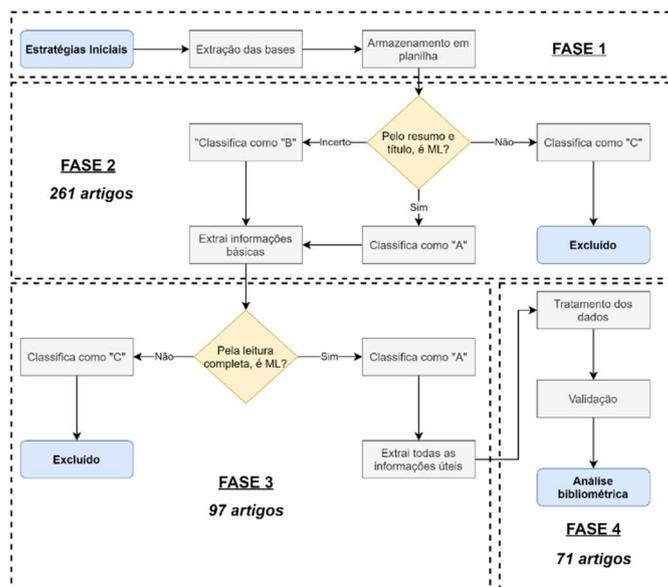


Figura 1: Fluxograma da aplicação do protocolo

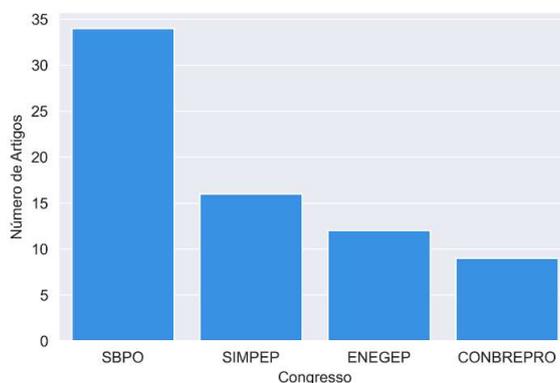


Figura 2: Frequência de publicações para cada evento

A Figura 2 mostra a representatividade em artigos, que corresponderam aos critérios pré-definidos, de cada um. Com 48%, o SBPO contém a maior popularidade em termos de publicações sobre o tema, seguido pelo SIMPEP (22%), ENEGEP (17%) e ConBRepro (13%). Para a análise da evolução das publicações ao longo dos cinco anos avaliados, foi criada a Figura 3, mostrando um crescimento considerável a partir de 2017 (18 artigos) mas se estabilizando nos anos seguintes.

A Figura 4 mostra o número de artigos publicados em cada um dos eventos, porém estratificado por universidades que contribuíram nestes últimos cinco anos. Observa-se na Figura 4 que, no período analisado, 46 instituições trataram sobre o tema. Vale ressaltar que nos casos de artigos com vários autores de uma mesma instituição, ela foi contabilizada apenas uma vez por artigo, e não pela quantidade de autores. Destacou-se a Universidade Tecnológica Federal do Paraná (UTFPR) com 13 artigos publicados, única instituição com média acima de dois artigos por ano. Observou-se também 27 instituições com apenas uma publicação, o que pode indicar o começo do estudo da área por elas, possibilitando no futuro o aumento de publicações e consequentemente, representatividade delas.

A estratificação representada na Figura 4 também indica a relação entre a Universidade Federal do Espírito Santo (UFES) e o SBPO, único evento em que a instituição publicou sobre o tema (sete artigos), a UTFPR, que manteve uma média de quatro artigos em três eventos, não tendo publicações no SIMPEP, e a

Universidade Cândido Mendes (UCAM) com cinco dos seus seis artigos sendo publicados no SIMPEP.

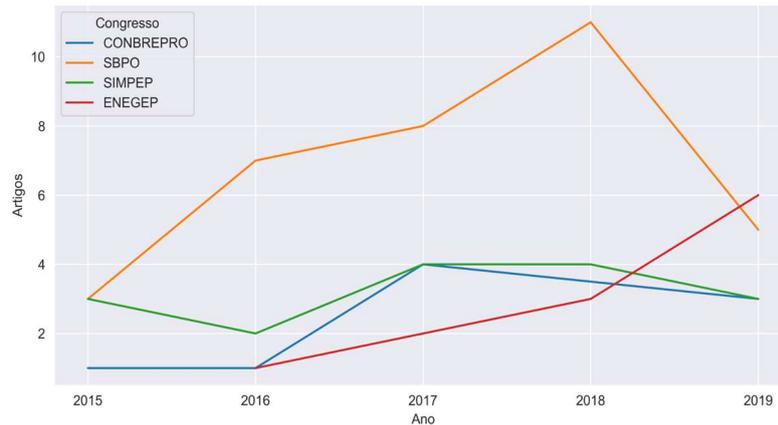


Figura 3: Evolução das publicações por evento/ano

	Anhangüera-Niterói	Cesupa	FURB	Faculdade Multivix	Fatec	IBGE	IFF	IFNMG	IGTI	PF-RS	PUC-GO	PUC-PR	PUC-Rio	SENAI	UCAM	UCG	UFABC	UFCA	UFCSPA	UFES	UFF	UFG	UFMG	UFFPA	UFPE	UFPR	UFRA	UFRGS	UFSJ	UNIFEI	UNIP	UNIRIO	UPE	USP	UTFPR	Unicamp	Unimontes	Universidade Positivo	University of Bath	Univesp	
SIMPEP	0	0	0	2	1	0	3	0	0	0	1	0	0	0	5	1	2	1	0	0	4	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	1
SBPO	1	1	1	0	0	2	0	1	0	1	0	4	4	1	0	0	0	0	2	7	3	0	3	1	1	2	1	3	1	1	0	2	1	0	4	1	1	1	1	0	
ENEGEP	0	0	0	0	0	0	0	0	0	0	2	1	0	0	0	0	0	0	0	1	3	0	0	1	0	0	0	0	0	0	0	0	0	0	1	4	0	0	0	0	
CONBREPRO	0	0	0	1	0	0	0	0	1	0	0	1	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	1	0	0	
TOTAL	1	1	1	3	1	2	3	1	1	1	3	6	4	1	6	1	2	1	2	7	9	3	3	2	2	2	1	3	1	1	1	2	1	1	13	2	1	2	1	1	

Figura 4: Número de publicações por instituição no período analisado

A Tabela 2 mostra o número de publicações por autor, sendo que a frequência analisada considerou tanto autoria como coautoria. Observa-se que a autora que mais publicou nestes eventos avaliados foi a pesquisadora Dra. Maria Teresinha Arns Steiner, docente vinculada ao Programa de Pós-Graduação em Engenharia de Produção e Sistemas da Pontifícia Universidade Católica do Paraná (PUC-PR), com um total de seis publicações.

Tabela 2: Frequência de publicações por autor(a) ou coautor(a).

Posição	Autor(a)	Frequência	Posição	Autor(a)	Frequência
1º	STEINER, M. T. A.	6	10º	TSUTSUMI, D. P.	2
2º	GOMES, G. R. R.	5	11º	BRITO, J. A. M.	2
3º	VIEIRA, S. L.	3	12º	ANZANELLO, M.	2
4º	FENERICH, A. T.	3	13º	ACOSTA, S. M.	2
5º	LUCENA, S. C.	2	14º	FONTANA, V. S.	2
6º	ANDRADE, A. A.	2	15º	PACHECO, A. G. C.	2
7º	OLIVEIRA, F. L. C.	2	16º	SEMAAN, G. S.	2
8º	FACÓ, J. F. B.	2	17º	KROHLING, R. A.	2
9º	LIMA, R. H. P.	2	18º	ALCALÁ, S. G. S.	2

A Figura 5 ilustra a rede de cooperação entre as instituições de acordo com os artigos publicados. Buscou-se na Figura 5 a montagem visual das relações entre as instituições, de forma a estabelecer aquelas que possuem publicações em conjunto. As instituições UTFPR, PUC-PR e a Universidade Federal Fluminense (UFF) foram as que mais participaram entre artigos com outras instituições, cada uma delas colaborou com quatro outras. A Figura 6 representa a frequência de artigos distribuídos nas diferentes áreas da EP.

saída de referência para a etapa de treinamento do algoritmo, sendo esta saída do tipo “nominal”. Enquanto isso, a menor participação foi da “Associação”, com apenas cinco artigos, que é uma tarefa trabalhada com algoritmos não supervisionados, buscando encontrar relações entre as diferentes variáveis do conjunto de dados. Diversas técnicas de ML foram utilizadas, sendo estas ranqueadas na Figura 8, totalizando 36 técnicas.

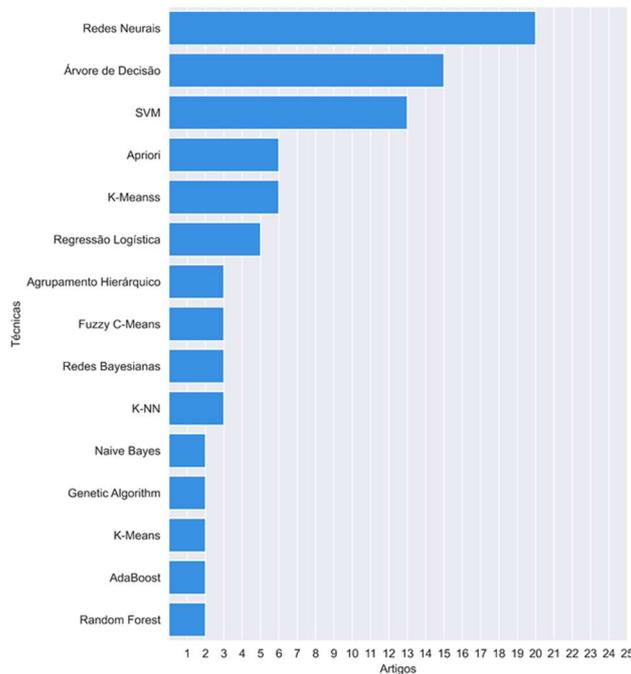


Figura 8: Técnicas de machine learning utilizadas nos artigos

Dentre as técnicas mais utilizadas, a Figura 8 fez a representação daquelas que foram aplicadas ao menos em dois trabalhos distintos. As principais técnicas utilizadas foram Redes Neurais, presente em 20 artigos, Árvores de Decisão, presente em 15 artigos e Máquinas de Vetores de Suporte (Support vector Machines - SVM), presente em 13 artigos. A Figura 9 mostra a frequência de tarefas por áreas da EP através de um mapa de calor, podendo observar que a área “Outros” tem predominância tanto na classificação como na clusterização.



Figura 9: Número de Tarefas por área da EP

Vale observar que a tarefa de clusterização não possui uma área específica da EP, dentro das abordadas pelo artigo, com destaque além de “Outros”. Já a figura 10 mostra a frequência de tarefas

utilizadas por ano. E nela destaca-se o ano 2018 com 14 publicações que abordavam a tarefa de classificação, sendo que a quantidade das outras três tarefas diminuíram no mesmo período.

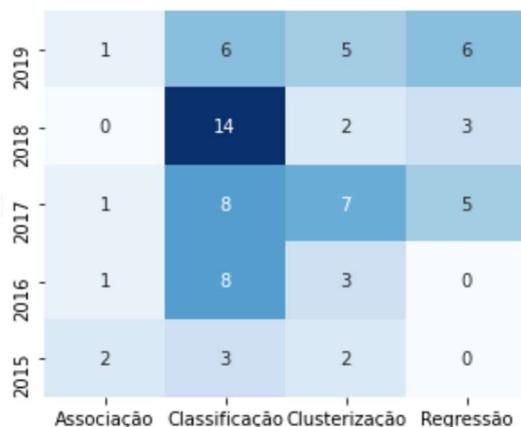


Figura 10: Número de tarefas por ano

A Figura 11 mostra uma nuvem de palavras com as palavras-chave dos artigos. Nota-se pela Figura 11 que as palavras de maior ocorrência são “Mineração”; “Dados”; “Máquina”; “Aprendizado”; “Inteligência” e “Artificial”. Logo as expressões “Mineração de Dados”, “Aprendizado de máquina” e “Inteligência Artificial” podem ser consideradas como as principais palavras-chave envolvidas em artigos do tema. Então, observa-se que os trabalhos utilizam a grande área da mineração de dados para melhor caracterizar o seu trabalho. Já a inteligência artificial é um tema mais amplo, porém não se utiliza tanto como a citada anteriormente.



Figura 11: Nuvem de Palavras

DISCUSSÃO

Como mostrado pela análise do número de publicações por evento ao longo dos anos, percebe-se uma tendência de crescimento nas publicações do ENEGEP e SBPO, apesar de em 2019 ter ocorrido uma queda significativa no número de artigos selecionados. De 2018 para 2019, no SBPO, foram selecionados para a primeira etapa, 43 e 69 artigos, respectivamente, porém apenas 11 e cinco artigos chegaram até a última etapa, ou seja, apesar do aumento no número de artigos coletados, a quantidade de artigos que realmente atendiam aos requisitos foi menor.

As palavras-chave usadas durante as buscas de artigos podem ter inflado a quantidade de resultados na primeira etapa, o que explica a grande quantidade de artigos excluídos. Por exemplo, o termo “classificação” é bastante comum em problemas multicritérios, e o SBPO possui uma área dedicada apenas para este tipo de problema. Contudo, esse tema não se enquadra nos artigos que este trabalho buscou identificar. Vale destacar que, no SBPO, foram descartados muitos artigos por serem apenas estudos de técnicas que, apesar de envolver assuntos correlatos, não se enquadraram como aplicações práticas de ML.

Já para o ENEGEP, a tendência é crescente a cada ano que passa, mostrando que cada vez mais artigos estão sendo selecionados e incluídos na base desta revisão sistemática, e isso mostra o crescente interesse pela mineração de dados e no ambiente de EP. Por fim, para o ConBRepro e o SIMPEP, o comportamento foi mais estável, tendo um leve aumento até 2017 e depois se manteve. Talvez, tenha aumentado o interesse em outras áreas fora da mineração de dados nestes eventos, porém, esta análise foge do escopo deste trabalho.

Analisando-se as áreas em que foram publicados artigos relacionados à mineração de dados, é notório que uma parte significativa não é enquadrada nas áreas da EP definidas pela ABEPRO, somando um total de 25 artigos, sendo 20 classificados em “Outros” e cinco em “Saúde”. Já olhando para as áreas da EP, foi evidenciado que as mais presentes foram a Gestão da Qualidade, Engenharia Econômica e Planejamento da Produção. Isso se mostra coerente pois são áreas abundantes em dados, portanto são mais propensas a terem oportunidades de se desenvolver estudos e aplicações práticas nesse tema. Por outro lado, as áreas menos presentes foram o Projeto de Produto, Engenharia Organizacional e Gestão de Pessoas. Por mais que estas áreas possam gerar dados para exploração, as técnicas de ML ainda não são aplicadas para os conjuntos de dados elaborados para estas áreas.

Outro ponto importante a ressaltar é que no SBPO a maior participação dentre as áreas da EP foi o “Outros”, com 16 publicações, justamente por estar incluso a Pesquisa Operacional nesta classificação, seguido por cinco publicações da área de Planejamento da Produção. Já para o ENEGEP foi a área da Gestão de Qualidade, com quatro publicações, e para o SIMPEP a área de Educação, também com quatro artigos. O ConBRepro se mostrou equilibrado, com o máximo de duas publicações por área.

Quanto às tarefas de mineração de dados, a classificação foi a mais explorada e, possivelmente, em conjunto com a técnica de Redes Neurais para este fim. Extrapolando o escopo deste trabalho, as Redes Neurais vêm ganhando destaque internacionalmente devido ao campo da aprendizagem profunda (deep learning), no qual vários pesquisadores a utilizam frequentemente para a classificação de imagens e mineração de texto. Inclusive, este tipo de aprendizagem pode ter uma maior utilização nos eventos aqui analisados devido à sua popularização em bibliotecas de programação e softwares especializados.

CONSIDERAÇÕES FINAIS

Este trabalho realizou uma revisão sistemática dos artigos que estudam aplicações de mineração de dados em sub-áreas da Engenharia de Produção publicados nos eventos científicos ENEGEP, SBPO, SIMPEP e ConBRePro. Dentre os principais resultados, destacam-se o crescente interesse pelo tema, com um

crescimento significativo na quantidade de publicações sobre o tema nos últimos 5 anos.

Entre as áreas mais estudadas da EP destaca-se a Engenharia da Qualidade, Engenharia Econômica, Planejamento da Produção e Logística, as quais concentram a maior parte das aplicações de ML dentre os trabalhos identificados. Além disso, foi possível constatar que os eventos têm publicados diversos trabalhos sobre ML que não se enquadram em sub-áreas da EP, havendo grande foco na área de saúde.

Outra constatação relevante da revisão sistemática foi a frequente aplicação da tarefa de classificação, porém com recente avanço das tarefas de clusterização e regressão, o que tem ampliado o debate e a riqueza de resultados.

Este trabalho também ajudou a identificar as principais instituições que vêm estudando aplicações de ML na Engenharia de Produção, com destaque para a UTFPR, UFF e UFES. Vale ressaltar que artigos publicados em eventos científicos geralmente são realizados por alunos de graduação e pós-graduação e, assim, podem servir como indício sobre futuros grupos de pesquisa na área.

É importante destacar que a realização deste trabalho foi dificultada pela inexistência de uma base integrada para busca de artigos, nos moldes encontrados em periódicos científicos. Cada evento possui seu próprio sistema e o mecanismo de busca não permite a realização de consultas usando palavras-chave combinadas, o que pode ter prejudicado a busca por artigos.

Para trabalhos futuros, recomenda-se a atualização desta revisão sistemática em eventos científicos para que seja possível ter um panorama geral da área de ML na Engenharia de Produção sob a ótica de pesquisadores nacionais. Também se recomenda a aplicação de metodologia semelhante para investigar as publicações sobre o tema em periódicos nacionais e em português, como forma de complementar os resultados deste artigo.

REFERÊNCIAS

ADAMS, L. J.; BELLO, G.; DUMANCAS, G. G.. Development and application of a genetic algorithm for variable optimization and predictive modeling of five-year mortality using questionnaire data. **Bioinformatics and Biology Insights**, v.9, p.31-41, 2015.

ADEKITAN, A. I.; SALAU, O.. The impact of engineering students' performance in the first three years on their graduation result using educational data mining. **Heliyon**, v.5, n.2, p. e01250, 2019.

AGGARWAL, C. C.. **Neural Networks and Deep Learning**. Cham: Springer International Publishing, 2018. DOI 10.1007/978-3-319-94463-0. Available at: <http://link.springer.com/10.1007/978-3-319-94463-0>. AHMAD, A.; KHAN, S. S. Survey of State-of-the-Art Mixed Data Clustering Algorithms. **IEEE Access**, v.7, p.31883-31902, 2019.

AHMED, Y. A.; AHMAD, M. N.; AHMAD, N.; ZAKARIA, N. H.. Social media for knowledge-sharing: A systematic literature review. **Telematics and Informatics**, v.37, p.72-112, 2018.

ALDOWAH, H.; SAMARRAIE, H.; FAUZY, W. M.. Educational data mining and learning analytics for 21st century higher

education: A review and synthesis. **Telematics and Informatics**, v.37, p.13-49, 2019.

BARDIN, L.. **Análise de Conteúdo**. Lisboa: Edições, 1977.

BAUMUNG, W.; BAUMUNG, V.. Application of Machine Learning and Vision for real-time condition monitoring and acceleration of product development cycles. **Procedia Manufacturing**, v.52, p.61-66, 2020.

BAZZAN, A. L. C.. Contribuições de aprendizado por reforço em escolha de rota e controle semafórico. **Estudos Avançados**, v.35, n.101, p.95-110, 2021.

BERTOLINI, M.; MEZZOGORI, D.; NERONI, M.; ZAMMORI, F.. Machine Learning for industrial applications: A comprehensive literature review. **Expert Systems with Applications**, v.175, 2021.

BHAVSAR, P.; SAFRO, I.; BOUAYNAYA, N.; POLIKAR, R.; DERA, D.. Machine Learning in Transportation Data Analytics. *Data Analytics for Intelligent Transportation Systems*. Elsevier, p.283-307, 2017.

BRAMER, M.. **Principles of Data Mining**. 3 ed. Londres:

Springer London, 2016.

CARNEIRO, M. B.; COSTA, F. H. de O.; GILBERTO, T. M. J.; TOMAS, R. N.. Gerenciamento de riscos para a cadeia de suprimentos: Uma revisão sistemática da literatura. **Revista Produção Online**, v.19, n.3, p.1048-1068, 2019.

CHAI, K. H.; XIAO, X.. Understanding design research: A bibliometric analysis of Design Studies (1996–2010). **Design Studies**, v.33, n.1, p.24-43, 2012.

CHEN, C.; IBEKWE-SANJUAN, F.; HOU, J.. The structure and dynamics of cocitation clusters: A multiple-perspective cocitation analysis. **Journal of the American Society for Information Science and Technology**, p.1386-1409, 2010.

DALZUCHIO, J.; KUNST, R.; PIGNATON, E.; BINOTTO, A.; SANYAL, S.; FAVILLA, J.; BARBOSA, J.. Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges. **Computers in Industry**, v.123, p.103298, 2020.

DOGAN, A.; BIRANT, D.. Machine learning and data mining in manufacturing. **Expert Systems with Applications**, v.166, p.114060, 2021.

FAYYAD, U.; PIATETSKY, G. S.; SMYTH, P.. From Data Mining to Knowledge Discovery in Databases. **AI Magazine**, v.17, n.3, p.37-53, 1996.

FENERICH, A. T.; STEINER, M. T. A.; NIEVOLA, J. C.; MENDES, K. B.; TSUTSUMI, D. P.; SANTOS, B. S.. Diagnosis of Headaches Types Using Artificial Neural Networks and Bayesian Networks. **IEEE Latin America Transactions**, vol. 18, n.1, p.59-66, 2020.

FERNANDES, E.; HOLANDA, M.; VICTORINO, M.; BORGES, V.; CARVALHO, R.; ERVEN, G. V.. Educational data mining : Predictive analysis of academic performance of public school students in the capital of Brazil. **Journal of Business Research**, v.94, p.335-343, 2019.

GARCÍA, R.; AGUILAR, J.; TORO, M.; PINTO, A.; RODRÍGUEZ, P.. A systematic literature review on the use of machine learning in precision livestock farming. **Computers and Electronics in Agriculture**, v.179, p.105826, 2020.

GARG, A.; MAGO, V.. Role of machine learning in medical research: A survey. **Computer Science Review**, v.40, p.100370, 2021.

GARRE, A.; RUIZ, M. C.; HONTORIA, E.. Application of Machine Learning to support production planning of a food industry in the context of waste generation under uncertainty. **Operations Research Perspectives**, v.7, 2019.

GOUTHAMAN, P.; SANKARANARAYANAN, S.. Prediction of Risk Percentage in Software Projects by Training Machine Learning Classifiers. **Computers & Electrical Engineering**, v.94, p.107362, 2021.

GUARASCIO, M.; MANCO, G.; RITACCO, E. **Knowledge Discovery in Databases**. Oxford: Academic Press, 2019.

GUO, H.; WU, S.; TIAN, Y.; ZHANG, J.; LIU, H.. Application of machine learning methods for the prediction of organic solid waste treatment and recycling processes: A review.

Bioresource Technology, v.319, p.124114, 2021.

HEGDE, J.; ROKSETH, B.. Applications of machine learning methods for engineering risk assessment – A review. **Safety Science**, v.122, p.104492, 2020.

JAIN, P. K.; PAMULA, R.; SRIVASTAVA, G.. A systematic literature review on machine learning applications for consumer sentiment analysis using online reviews. **Computer Science Review**, v.41, 2021.

JONSSON, L.; BORG, M.; BROMAN, D.; SANDAHL, K.; ELDH, S.; RUNESON, P.. Automated bug assignment: Ensemble-based machine learning in large scale industrial contexts. **Empirical Software Engineering**, v.1, n.4, p.1533-1578, 2016.

KARL, A. A.; PEREIRA, C. R.; CAMPOS, L. M. S.. Indicadores de desempenho na logística humanitária: Um estudo teórico sob a ótica green. **Revista Produção Online**, v.20, n.3, p.1038-1055, 2020.

KASTHURIRATHNE, S. N.; DIXON, B. E.; GICHOYA, J.; XU, H.; XIA, Y.; MAMLIN, B.; GRANNIS, S. J.. Toward better public health reporting using existing off the shelf approaches: A comparison of alternative cancer detection approaches using plaintext medical data and non-dictionary based feature selection. **Journal of Biomedical Informatics**, v.60, p.145-152, Apr. 2016.

KAUR, P.; SINGH, M.; JOSAN, G. S.. Classification and Prediction Based Data Mining Algorithms to Predict Slow Learners in Education Sector. **Procedia Computer Science**, v.57, p.500-508, 2015.

LEI, Y.; YANG, B.; JIANG, X.; JIA, F.; LI, N.; NANDI, A. K.. Applications of machine learning to machine fault diagnosis: A review and roadmap. **Mechanical Systems and Signal Processing**, v.138, p.106587, 2020.

LIOU, F. M.; TANG, Y. C.; CHEN, J. Y.. Detecting hospital fraud and claim abuse through diabetic outpatient services. **Health Care Management Science**, Graduate Institute of Business Management, Yuanpei University Hsinchu, 306, Yuanpei St., Hsin Chu 300, Taiwan, v.11, n.4, p.353-358, 2008.

MISKELL, G.; PATTINSON, W.; WEISSERT, L.; WILLIAMS, D.. Forecasting short-term peak concentrations from a network of air quality instruments measuring PM 2.5 using boosted gradient machine models. **Journal of Environmental Management**, v.242, p.56-64, 2019.

NARCISO, D. A. C.; MARTINS, F. G.. Application of machine learning tools for energy efficiency in industry: A review. **Energy Reports**, v.6, p.1181-1199, 2020.

NASIRI, S.; KHOSRAVANI, M. R.. Machine learning in predicting mechanical behavior of additively manufactured parts. **Journal of Materials Research and Technology**, v.14, p.1137-1153, 2021.

ORIMOLOYE, L. O.; SUNG, M.-C.; MA, T.; JOHNSON, J. E. V.. Comparing the effectiveness of deep feedforward neural networks and shallow architectures for predicting stock price indices. **Expert Systems with Applications**, v.139, p.112828, 2020.

PETTICREW, M.; ROBERTS, H.. Systematic Reviews in the

Social Sciences: A Practical Guide. **Counselling and Psychotherapy Research**, v.6, n.4, p.304-305, 2006.

PUENTE, Á. G.; GONZÁLEZ, A. M.; BORGE, D. D.; MARTÍNEZ, M. Á. C.; DE SIMÓN, M. M.. True power consumption labeling and mapping of the health system of the Castilla y León region in Spain by clustering techniques. **Energy Procedia**, v.157, p.1164-1181, 2019.

RASCHKA, S. **Python Machine Learning**. Birmingham: Packt Publishing, 2015.

ROCHA, S.; VIEIRA, S.. Mineração de dados aplicada à classificação de contribuintes de ICMS. 2016. ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 36. **Anais**. João Pessoa; 2016.

RUSSEL, S. J.; NORVIG, P.. **Artificial Intelligence: A Modern Approach**. 3 ed. São Paulo: GEN LTC, 2013.

SHALEV, S. S.; BEN, S. D.. **Understanding Machine Learning: From Theory to Algorithms**. New York: Cambridge University Press, 2014.

SILVESTRI, L.; FORCINA, A.; INTRONA, V.; SANTOLAMAZZA, A.; CESAROTTI, V.. Maintenance transformation through Industry 4.0 technologies: A systematic literature review. **Computers in Industry**, v.123, p.103335, 2020.

SINGH, R.; SRIVASTAVA, S.. Stock prediction using deep learning. **Multimedia Tools and Applications**, v.76, n.18, p.18569-18584, 2017.

SRIDAR, K.; SHANTHI, D.. Medical diagnosis system for the diabetes mellitus by using back propagation-apriori algorithms. **Journal of Theoretical and Applied Information Technology**, v.68, n.1, p.36-43, 2014.

SYAM, N.; SHARMA, A.. Waiting for a sales renaissance in the fourth industrial revolution: Machine learning and artificial intelligence in sales research and practice. **Industrial Marketing Management**, v.69, p.135-146, 2018.

TAN, P. N.; STEINBACH, M.; KARPATNE, A.; KUMAR, V.. **Introduction to Data Mining**. New York: Pearson Prentice Hall, 2019.

TRANFIELD, D.; DENYER, D.; MARCOS, J.; BURR, M.. Co-producing management knowledge. **Management Decision**, v.42, n.3/4, p.375-386, 1 Jan. 2004.

TRANFIELD, D.; DENYER, D.; SMART, P. Towards a Methodology for Developing Evidence-Informed Management Knowledge by Means of Systematic Review. **British of Journal Management**, v.14, p.207-222, 2003.

TSAI, C.; LYDIA WEN, M.. Research and trends in science education from 1998 to 2002: a content analysis of publication in selected journals. **International Journal of Science Education**, v.27, n.1, p.3-14, 2005.

VEIGA, E. S. D.; DA SILVA, E. M.. A systematic review of management in projects. **Revista Produção Online**, v.3, n.1, p.837-857, 2020.

WENZEL, H.; SMIT, D.; SARDESAI, S.. A literature review on machine learning in supply chain management. 2013. HAMBURG INTERNATIONAL CONFERENCE OF LOGISTICS. **Proceedings**. Hamburg, 2013.

WITTEN, I. H.; FRANK, E.. **Data Mining: Practical Machine Learning Tools and Techniques**. 2 ed. San Francisco: Elsevier Ltd, 2005.

WOSCHANK, M.; RAUCH, E.; ZSIFKOVITS, H. A. Review of Further Directions for Artificial Intelligence, Machine Learning, and Deep Learning in Smart Logistics. **Sustainability**, v.12, n.9, 2020.

XU, Z.; SALEH, J. H.. Machine learning for reliability engineering and safety applications: Review of current status and future opportunities. **Reliability Engineering and System Safety**, v.211, 2021.

Os autores detêm os direitos autorais de sua obra publicada. A CBPC – Companhia Brasileira de Produção Científica (CNPJ: 11.221.422/0001-03) detêm os direitos materiais dos trabalhos publicados (obras, artigos etc.). Os direitos referem-se à publicação do trabalho em qualquer parte do mundo, incluindo os direitos às renovações, expansões e disseminações da contribuição, bem como outros direitos subsidiários. Todos os trabalhos publicados eletronicamente poderão posteriormente ser publicados em coletâneas impressas ou digitais sob coordenação da Companhia Brasileira de Produção Científica e seus parceiros autorizados. Os (as) autores (as) preservam os direitos autorais, mas não têm permissão para a publicação da contribuição em outro meio, impresso ou digital, em português ou em tradução.

Todas as obras (artigos) publicadas serão tokenizadas, ou seja, terão um NFT equivalente armazenado e comercializado livremente na rede OpenSea (https://opensea.io/HUB_CBPC), onde a CBPC irá operacionalizar a transferência dos direitos materiais das publicações para os próprios autores ou quaisquer interessados em adquiri-los e fazer o uso que lhe for de interesse.



Os direitos comerciais deste artigo podem ser adquiridos pelos autores ou quaisquer interessados através da aquisição, para posterior comercialização ou guarda, do NFT (Non-Fungible Token) equivalente através do seguinte link na OpenSea (Ethereum).

The commercial rights of this article can be acquired by the authors or any interested parties through the acquisition, for later commercialization or storage, of the equivalent NFT (Non-Fungible Token) through the following link on OpenSea (Ethereum).



<https://opensea.io/assets/ethereum/0x495f947276749ce646f68ac8c248420045cb7b5e/44951876800440915849902480545070078646674086961356520679561157599894150578177/>