

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL

SARAH LOPES DE ALBUQUERQUE

Análise do uso da inteligência artificial na área de Engenharia da Qualidade

Três Lagoas – MS

2023

RESUMO

A Inteligência Artificial (IA) possui aplicação em diversas áreas da indústria e serviços, inclusive na melhoria da qualidade de processos produtivos. Diante disso, essa pesquisa tem como objetivo analisar o uso de técnicas de IA aplicadas na área da Engenharia da Qualidade. Para isso, como métodos de pesquisa foram utilizados a Revisão Bibliográfica Sistemática (RBS) e, como complemento, a análise textual dos resumos pelo *software* Iramuteq. As bases de dados utilizadas na pesquisa foram a *Engineering Village*, SCOPUS e *Web of Science* por sua relevância na área de estudo. Com a análise de 44 artigos, os resultados mostraram que o número de publicações sobre o tema tem aumentado nos últimos anos, cerca de 38% em relação aos últimos dois anos completos. Além disso, ao considerar os principais resultados foi observado que 77% das pesquisas são aplicadas na indústria e que a subárea com maior aplicação foi a de planejamento e controle da qualidade, presente em cerca de 66% dos artigos analisados. No que se refere aos procedimentos técnicos utilizados na aplicação da IA, tem-se que os dados utilizados para treinar os algoritmos, predominantemente, referem-se aos de produtos e equipamentos, já quanto a técnica mais utilizada tem-se as redes neurais artificiais, representando, aproximadamente, 50% dos artigos analisados. Constatou-se, também, que a aplicação da IA traz como principal vantagem a melhoria da qualidade do produto ou serviço, porém com o desafio de coletar e processar uma grande quantidade de dados. Ademais, de forma a complementar os resultados, as análises conduzidas por meio do *software* Iramuteq destacam a relevância no uso da IA na melhoria da qualidade na manufatura e nos processos industriais, confirmam as duas principais subáreas de aplicação constatadas na RBS e evidenciam que os tópicos de pesquisa analisados estão sujeitos a variações ao longo dos anos. Assim, esta pesquisa contribui para a identificação de quais áreas são promissoras para receber essa tecnologia, direcionar de maneira mais eficiente os investimentos em relação aos tipos de dados e equipamentos necessários, preenchendo assim uma lacuna na literatura sobre o uso da IA nas subáreas da Engenharia da Qualidade.

Palavras-chave: engenharia da qualidade; inteligência artificial; engenharia de produção.

ABSTRACT

Artificial Intelligence (AI) finds applications in various industrial and service sectors, including the enhancement of production process quality. In light of this, this research aims to analyze the use of AI techniques applied in the field of Quality Engineering. To achieve this, the research employed the Systematic Literature Review (SLR) as its primary research method and supplemented it with textual analysis of abstracts using the Iramuteq software. The research utilized Engineering Village, SCOPUS, and Web of Science databases due to their relevance in the study area. By analyzing 44 articles, the results demonstrated an increasing number of publications on the topic in recent years, with a 38% increase compared to the previous two full years. Furthermore, the key findings revealed that 77% of the research is applied in the industry, with the subarea of quality planning and control being the most prevalent, featured in approximately 66% of the analyzed articles. Regarding the technical procedures used in AI applications, the data predominantly consisted of product and equipment data, with artificial neural networks being the most frequently used technique, representing approximately 50% of the analyzed articles. It was also noted that the primary advantage of AI application is the improvement of product or service quality, albeit with the challenge of collecting and processing a large volume of data. Additionally, to complement the results, the analyses

conducted through the Iramuteq software underscore the significance of AI in enhancing quality in manufacturing and industrial processes, confirming the two main subareas identified in the SLR and highlighting that the research topics analyzed are subject to variations over the years. Thus, this research contributes to identifying promising areas for the adoption of this technology, directing investments more efficiently towards the required data types and equipment, thereby addressing a gap in the literature concerning the use of AI in Quality Engineering subareas.

Keywords: quality engineering; artificial intelligence; production engineering.

1 INTRODUÇÃO

A Inteligência Artificial (IA), um dos pilares da Indústria 4.0, está cada vez mais presente nos processos produtivos. Empresas estão utilizando IA aplicada na previsão da demanda, cadeia de suprimentos, logística, contratação de funcionários e para melhor atendimento dos seus clientes. Dentro desse cenário, a área de Engenharia da Qualidade também se beneficia desses avanços, centrando-se na qualidade do trabalho usando a análise de dados para digitalizar as operações e maximizar as possibilidades oferecidas pela Inteligência Artificial para produzir operações altamente autônomas e dinâmicas (Asif, 2020).

A Engenharia da Qualidade é uma das dez áreas de atuação dentro do amplo campo da Engenharia de Produção (Associação Brasileira de Engenharia De Produção, 2023). Conforme destacado por Homma Junior *et al.* (2021), quando analisadas as áreas específicas desse curso, observamos que a maioria das aplicações de IA se concentra na área de gestão da qualidade. Nesse contexto, há uma ênfase na utilização da técnica de redes neurais artificiais. Da mesma forma, Marques *et al.* (2021), identificam a Engenharia da Qualidade como um dos campos de destaque na utilização de IA por meio da aprendizagem de máquina. Quanto as técnicas mais utilizadas os resultados apontam para as redes neurais, árvores de decisão, *random forest* e *support vector machine* como as que aparecem com maior frequência na literatura.

Segundo Paladini (2019), a afinidade entre inteligência artificial e gestão da qualidade gera muitas áreas de aplicação, como por exemplo: processos de análise de eficiência dos sistemas de produção; suporte às decisões gerenciais; ações básicas de planejamento da qualidade; qualidade de projeto e conformação do produto e análise de dados e informações do controle de processo.

Diante do exposto, nota-se que a IA tem potencial para contribuir nessa área, porém há uma lacuna de estudos bibliométricos que analisem a aplicação dessa ferramenta dentro das subáreas da Engenharia da Qualidade, importante área do conhecimento relacionada à Engenharia de Produção. Portanto, a presente pesquisa tem como objetivo geral analisar o uso da IA nos processos de Engenharia da Qualidade. Como objetivos específicos, temos: apresentar a evolução do estudo do tema ao longo dos anos; identificar em quais subáreas da Engenharia da Qualidade a IA tem sido utilizada; quais tipos de dados utilizados no treinamento da IA e qual algoritmo é o mais utilizado; além de identificar as vantagens e desvantagens; e, por fim, realizar uma análise de texto dos artigos com o *software* Iramuteq.

Apesar dos benefícios evidentes em lidar com problemas complexos, a aplicação da IA requer esforço. Cada empresa deve identificar áreas de aplicações promissoras, tarefas que possam ser automatizadas e conjuntos de dados apropriados (Kraub *et al.*, 2019). Em vista disso, estudos como esse podem facilitar a implementação dessa ferramenta e prover, posteriormente, processos produtivos com alta eficiência, qualidade de produtos e competitividade de mercado.

Espera-se ainda corroborar com aspectos teóricos para a literatura e agregar mais detalhes às pesquisas que já apontam a área da qualidade como destaque na aplicação da IA, conforme Homma Junior *et al.* (2021) e Marques *et al.* (2021) já citados anteriormente. Além disso, o conhecimento dos métodos e técnicas que serão identificados pode auxiliar empresas na aplicação da IA no contexto da Engenharia da Qualidade, e conseqüentemente, otimizar a resolução de problemas e a tomada de decisão no processo de melhoria contínua de seus processos produtivos, bem como, identificar os requisitos necessários e áreas promissoras de implementação.

Este artigo está organizado da seguinte forma: os conceitos e definições de Engenharia da Qualidade e Inteligência Artificial são apresentados na seção 2, seguida da descrição do procedimento metodológico na seção 3, análise dos resultados na seção 4 e, por fim, a conclusão e sugestão de futuras pesquisas na seção 5.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 ENGENHARIA DA QUALIDADE

De acordo com a Associação Brasileira de Engenharia de Produção (ABEPRO), a Engenharia da Qualidade tem como objetivo o planejamento, projeto e controle de sistemas de gestão da qualidade que considerem o gerenciamento por processos, a abordagem factual para a tomada de decisão e a utilização de ferramentas da qualidade.

O *Institute of Industrial and Systems Engineers (IISE)* completa que a Engenharia da Qualidade abrange as ferramentas e técnicas usadas nas indústrias de manufatura e serviços. Na fabricação de produtos, essas técnicas ajudam a evitar erros ou defeitos nos produtos. Nos processos de prestação de serviços, essas ferramentas são usadas para evitar problemas ao fornecer soluções ou serviços aos clientes.

Dentro da Engenharia da Qualidade há ainda cinco subáreas de atuação, que conforme Batalha (2008), podem ser descritas da seguinte forma:

- a) gestão de sistemas da qualidade: traduzem os conceitos da qualidade em ações estratégicas. São exemplos: *Total Quality Management (TQM)*, Seis Sigma, ISO 9000;
- b) planejamento e controle da qualidade: o planejamento se divide em seis fases: definição da política da qualidade, diagnóstico, organização e administração, estruturação do plano de ação, implantação e avaliação. Já a função do controle da qualidade é analisar, pesquisar e prevenir a ocorrência de defeitos;
- c) normalização, auditoria e certificação para a qualidade: conjunto de padrões internacionais e certificações para garantia da qualidade;
- d) organização metrológica da qualidade: garante que dispositivos de medição sejam calibrados e aferidos periodicamente, com base em padrões adequados, além da análise do sistema de medição como repetibilidade, reprodutividade;
- e) confiabilidade de processos e produtos: garantir que um item (produto, serviço, equipamento) desempenhe sua função requerida, por um intervalo de tempo estabelecido, sob condições definidas de uso.

Parte da análise qualitativa dessa pesquisa será realizada com base nessa descrição apresentada para a classificação dos artigos dentro das subáreas da Engenharia da Qualidade, sendo possível assim, identificar em que subáreas as técnicas de IA são mais utilizadas.

2.2 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) pode ser definida como a ciência e engenharia capaz de extrair a capacidade das máquinas em simular o pensamento dos seres humanos, obtendo a capacidade de aprender, raciocinar, perceber, deliberar e decidir de forma racional e inteligente a respeito de um determinado problema (McCarthy, 1958). De certa forma, “a probabilidade e estatística apoia os sistemas de IA em seu raciocínio, fornecendo suporte à tomada de decisão e fazendo as melhores e mais racionais escolhas, apesar das incertezas” (Massaron; Mueller, 2018, p.141).

A análise de dados, proveniente da IA, possibilita identificar padrões de comportamento, auxiliar na resolução de problemas, redução de desperdícios e aumento da produtividade. Sendo assim, essa tecnologia se torna uma excelente forma de acompanhar os sistemas produtivos, podendo aumentar a eficiência dos negócios, desenvolver a melhoria contínua dos processos e gerar valor para as empresas (Lima *et al.*, 2021). Por isso, segundo Asif (2020), a adoção da IA é considerada como uma estratégia para aumentar a qualidade do produto, a produtividade e tornar os processos mais fluidos e eficientes.

Ademais, do ponto de vista da objetividade ou da segurança das informações obtidas, percebe-se que a utilização da Inteligência Artificial pode ser extremamente útil na obtenção de uma informação mais confiável no que diz respeito à avaliação de produtos e processos, além de poder ser obtida de forma mais rápida. Numa análise ampla, esses benefícios podem compensar os custos que a implementação do sistema traz (Paladini, 2019).

Dentro de uma indústria de manufatura ou serviços, uma ampla variedade de dados é gerada constantemente, os quais podem ser utilizados para treinar os algoritmos de IA. Nesse contexto, Cadavid (2019) sugere classificações para os tipos de dados comumente utilizados na manufatura, são eles:

- a) dados de gestão: registros históricos armazenados em sistemas de informação de manufatura, relacionados ao planejamento de produção, manutenção, despacho de pedidos, vendas, entre outros;
- b) dados de equipamentos: originados de tecnologias implementadas no chão de fábrica em máquinas, estações de trabalho, trabalhadores, entre outros;
- c) dados de usuários: obtidos a partir de informações dos consumidores coletadas em fontes da internet, como plataformas de comércio eletrônico ou redes sociais;

- d) dados de produtos: provenientes de produtos ou serviços. Eles são obtidos durante o processo de fabricação ou do consumidor final. Podem estar relacionados ao desempenho do produto, contexto de uso, dados ambientais, entre outros;
- e) dados públicos: provenientes de bancos de dados abertos, como repositórios universitários, dados governamentais ou de outros pesquisadores;
- f) dados artificiais: informações geradas por computador (por exemplo, simulações) para avaliar aplicações de aprendizado de máquina no planejamento, programação e controle da produção.

Dessa forma, para a análise qualitativa dessa pesquisa serão utilizadas tais classificações para definir os tipos de dados usados para treinar os algoritmos de IA nos artigos dentro das subáreas da Engenharia da Qualidade.

3 PROCEDIMENTO METODOLÓGICO

3.1 CARACTERIZAÇÃO DA PESQUISA

Uma pesquisa pode ser classificada de quatro formas: quanto ao seu propósito, natureza, abordagem e procedimento técnico adotado. Dentro do campo da Engenharia de Produção é comum encontrar propósitos do tipo exploratório, descritiva, preditiva, explicativa ou de avaliação. Em relação a natureza da pesquisa, ela pode ser classificada como pura ou aplicada. Assim como em relação a sua abordagem, podendo ser qualitativa ou quantitativa. Já os métodos comuns nessa área são: desenvolvimento teórico-conceitual, pesquisa bibliográfica sistemática, estudo de caso, pesquisa-ação, modelagem e simulação e *survey* (Martins, 2012).

Com base nisso, a presente pesquisa se classifica da seguinte forma: possui propósito exploratório, uma vez que busca proporcionar maior compreensão do tema proposto (Gil, 2002); caracteriza-se pela sua natureza como pura, pois se concentra na ampliação de conhecimentos teóricos (Marconi; Lakatos, 2021); quanto à abordagem, a pesquisa tem característica qualitativa, pois preocupa-se em obter informações sobre a perspectiva dos indivíduos, bem como interpretar o ambiente em que o problema acontece (Martins, 2012). Por fim, como método de pesquisa, propõe-se uma revisão bibliográfica sistemática, pois tem objetivo de coletar e avaliar as evidências disponíveis na literatura referentes ao tema de pesquisa (Biolchini *et al.* 2005).

3.2 PROCEDIMENTO METODOLÓGICO

A condução da revisão bibliográfica sistemática foi realizada em quatro etapas: definição das bases de dados; definição das palavras-chaves; escolha dos critérios de seleção dos artigos, ilustrados por meio de um fluxograma que segue as etapas de identificação, triagem e inclusão dos artigos, e por fim, escolha dos critérios de classificação e análises baseadas nas perguntas de pesquisa já apresentadas.

As bases de dados de literaturas técnicas e científicas (BDLTCs), a citar: *Engineering Village*, SCOPUS e *Web of Science*. Essas bases de dados são referências em diversas áreas de atuação, incluindo a engenharia, e oferecem um grande acervo de artigos científicos de alta qualidade.

As palavras-chave empregadas estão diretamente ligadas ao tópico de estudo, já as *strings* de busca (conjunto de palavras-chave) utilizadas no campo de busca da base de dados estão no Quadro 1 a seguir. Além disso, foram aplicados alguns filtros nas bases de dados, restringindo a pesquisa em artigos de revista em inglês e área de pesquisa de engenharia.

Quadro 1 – *Strings* utilizadas nas bases de dados.

Base de Dados	<i>Strings</i> de busca
Engineering Village	(((((artificial intelligence) WN KY) AND (((quality AND ("quality engineering" OR "quality systems management" OR "QMS" OR "quality planning" OR "quality control" OR "auditing" OR "certification" OR "normalization" OR "internacional standards" OR "measurement system" OR "calibration" OR "quality metrology" OR "process reliability" OR "product reliability" OR "failure analysis" OR "predictive maintenance" OR "process capability")))) WN KY)) AND (((manufactur* OR service)) WN KY))) AND (({ja} WN DT) AND ({english} WN LA) AND ({all} WN ACT)))
Scopus	(TITLE-ABS-KEY ("artificial intelligence") AND TITLE-ABS-KEY ("quality" AND ("quality engineering" OR "quality systems management" OR "QMS" OR "quality planning" OR "quality control" OR "auditing" OR "certification" OR "normalization" OR "internacional standards" OR "measurement system" OR "calibration" OR "quality metrology" OR "process reliability" OR "product reliability" OR "failure analysis" OR "predictive maintenance" OR "process capability")) AND TITLE-ABS-KEY (manufactur* OR service)) AND (LIMIT-TO (OA,"all")) AND (LIMIT-TO (DOCTYPE,"ar")) AND (LIMIT-TO (LANGUAGE,"English")) AND (LIMIT-TO (SUBJAREA,"ENGI"))
Web of Science	((TS=("artificial intelligence")) AND TS=(quality AND ("quality engineering" OR "quality systems management" OR "QMS" OR "quality planning" OR "quality control"

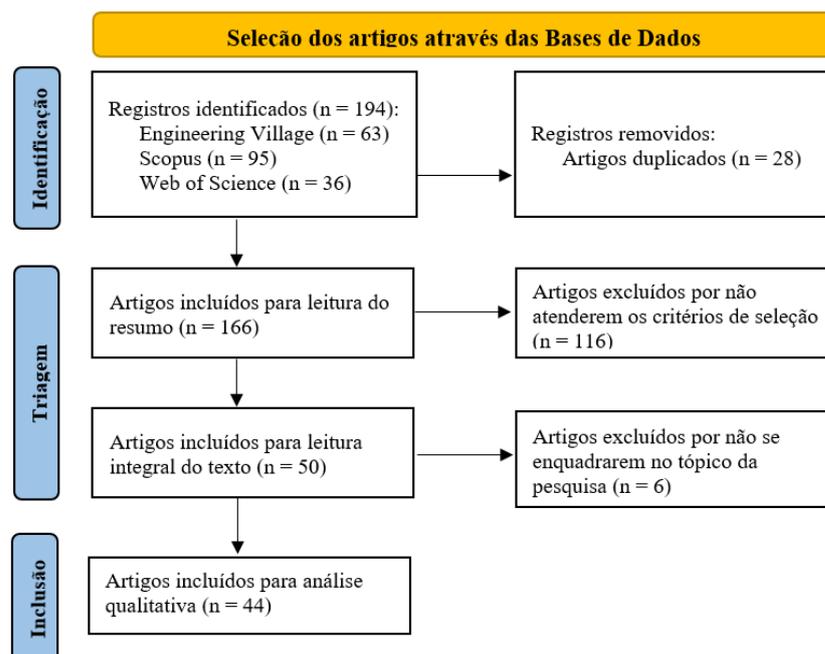
	OR "auditing" OR "certification" OR "normalization" OR "internacional standards" OR "measurement system" OR "calibration" OR "quality metrology" OR "process reliability" OR "product reliability" OR "failure analysis" OR "predictive maintenance" OR "process capability")) AND TS=(manufactur* OR service)
--	--

Fonte: Autoria própria (2023).

Com as *strings* de busca acima, 194 registros foram encontrados no total. Para garantir a relevância e qualidade dos artigos selecionados, foram adotados dois critérios de seleção: os artigos selecionados contêm em seu resumo as palavras-chave relacionadas ao tema proposto e empregam métodos de pesquisa-ação ou estudo de caso sobre a aplicação da inteligência artificial em alguma subárea de Engenharia da Qualidade. Uma vez que esses critérios são cumpridos, foi realizada a leitura integral dos textos, no qual outros artigos também foram excluídos por desvio do tema de pesquisa e objetivo proposto.

A Figura 1 mostra o fluxograma com as etapas para inclusão de artigos com base nos critérios de seleção. Esse fluxograma foi adaptado do método denominado PRISMA que busca estabelecer um padrão de protocolos a serem seguidos em uma revisão bibliográfica sistemática, ajudando autores a aprimorar suas pesquisas e análises (Page *et al*, 2021). As etapas passam pela identificação da quantidade de artigos de cada base e exclusão de registros duplicados; triagem com base nos dois critérios de seleção e, por fim, definição da quantidade de artigos incluídos para a análise qualitativa.

Figura 1 – Fluxograma: seleção dos artigos



Fonte: Adaptado de Page *et al* (2021).

Assim, 44 artigos foram incluídos para as análises qualitativas e quantitativas dos artigos. Primeiramente, os artigos selecionados foram classificados quanto ao seu extrato conforme a plataforma Qualis Periódicos, mantida pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), referência nacional na avaliação dos periódicos científicos brasileiros. Como resultado dessa classificação, dos 44 artigos, 36 estão dentro da classificação A, 4 na classificação B, 2 na classificação C e 2 não contêm classificação, mostrando a qualidade das pesquisas encontradas.

Além disso, foram elaborados fichamentos e montado um quadro para sintetizar os dados, que será apresentado nos resultados dessa pesquisa, utilizando-se técnicas de estatística descritiva. Nesse sentido, serão consideradas as questões de pesquisa apresentadas anteriormente: ano de publicação para traçar a evolução da pesquisa ao longo dos anos; subáreas da Engenharia da Qualidade; tipo de dados utilizados; técnicas de IA utilizadas e vantagens e desvantagens do seu uso. Observa-se que para as análises dos 44 artigos, os mesmos foram codificados por números entre colchetes em ordem crescente, a considerar a referência bibliográfica apresentada ao final desse relatório.

Por fim, para complementar as análises feitas a partir da leitura dos artigos, será utilizado o software Iramuteq para a análise de texto dos resumos de cada artigo. O Iramuteq é uma ferramenta de apoio à investigação científica qualitativa que possibilita a organização de grande volume de dados textuais, a identificação do contexto em que as palavras ocorrem, o gerenciamento e tratamento estatístico de textos, otimizando o tempo de análise textual (Silva; Ribeiro, 2021). Com ajuda do software, foi gerado uma árvore de similitude dos textos, no qual é possível observar a relação entre os principais termos; clusters dos principais assuntos tratados e associação de classes, que demonstram como esses temas evoluíram ao longo dos anos de publicação.

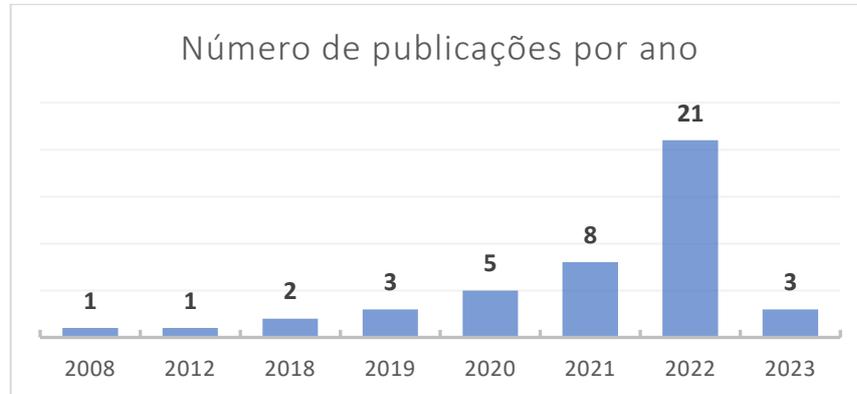
4 RESULTADOS

4.1 EVOLUÇÃO DO TEMA AO LONGO DOS ANOS

Primeiramente, quanto a evolução do tema ao longo dos anos de publicação, entre os 44 artigos selecionados para análise, observa-se que as publicações abrangem o período de 2008 a 2023. Os anos em que se concentram o maior número de publicações em ordem crescente são 2022, 2021, 2020, 2023 e 2019, conforme ilustrado na Figura 2. Assim, constata-se a importância e atualidade do tema, visto um aumento de 38% em relação aos anos completos

de 2021 e 2022, no qual se justifica pelo avanço tecnológico e popularização de ferramentas que utilizam Inteligência Artificial.

Figura 2 – Número de publicações por ano sobre o tema



Fonte: Autoria própria (2023).

4.2 ÁREA DE APLICAÇÃO

A segunda análise realizada foi em relação a área de aplicação das pesquisas. Tendo em vista a natureza das atividades produtivas, seja na indústria voltada para a produção de bens ou serviços, com a análise dos artigos, constata-se que cerca de 77% deles representam pesquisas com aplicação da IA em indústrias dos mais diversos ramos, como farmacêutica, automotiva, aeronáutica, têxtil, petróleo, metalúrgica, siderúrgica, entre outros. Os outros 9% dos artigos têm aplicação na área de serviços, na qual se destacam os serviços de internet, geolocalização e redes. Já os restantes 14% não tiveram área de aplicação especificada ou podem ser aplicados em ambas as áreas. A classificação dos artigos pode ser acompanhada no Quadro 2 abaixo.

Quadro 2 – Área de aplicação da IA

Área de Aplicação	Artigos
Indústria	[1]; [5]; [7]; [8]; [10]; [15]; [14]; [16]; [17]; [18]; [20]; [23]; [26]; [28]; [29]; [37]; [38]; [41]; [44]; [45]; [46]; [9]; [47]; [48]; [49]; [50]; [51]; [54]; [55]; [56]; [57]; [58]; [60]; [62]
Serviços	[31]; [39]; [59]; [61]
Não especificado	[4]; [13]; [22]; [25]; [40]; [52]

Fonte: Autoria própria (2023).

Esse resultado se deve principalmente à geração de dados e informações que podem ser obtidos do processo produtivo industrial. Com o avanço da tecnologia, a quantidade de

equipamentos, sensores e outros dispositivos facilita a coleta de dados e contribui para o desenvolvimento de modelos de IA.

4.3 SUBÁREAS DA ENGENHARIA DA QUALIDADE

Já em relação a quais subáreas da Engenharia da Qualidade esses artigos se enquadram, observa-se duas áreas de grande destaque: planejamento e controle da qualidade e confiabilidade de processos e produtos, conforme mostra o Quadro 3.

Quadro 3 – Subáreas da Engenharia da Qualidade de aplicação da IA

Subárea da Engenharia da Qualidade	Artigos
Gestão de Sistemas da Qualidade	[28];
Planejamento e Controle da Qualidade	[4]; [10]; [13]; [15]; [14]; [16]; [18]; [22]; [23]; [25]; [26]; [29]; [37]; [39]; [41]; [44]; [45]; [46]; [9]; [47]; [48]; [49]; [50]; [56]; [57]; [59]; [60]; [61]; [62]
Normalização, Auditoria e Certificação para a Qualidade	[40]; [52]
Organização Metrológica da Qualidade	
Confiabilidade de Processos e Produtos	[1]; [5]; [7]; [8]; [17]; [20]; [31]; [38]; [51]; [54]; [55]; [58];

Fonte: Autoria própria (2023).

Das pesquisas analisadas, cerca de 66% se aplicam a subárea de planejamento e controle da qualidade. São estudos que têm como objetivo a predição da qualidade antes da finalização da produção ou o controle da qualidade para itens já prontos, atuando na identificação de defeitos.

Já na subárea de confiabilidade de processos e produtos, se enquadram 27% dos artigos analisados, nos quais buscam, em sua maioria, atuar na otimização da manutenção preditiva dos equipamentos do processo produtivo, como por exemplo a análise e prevenção de falhas.

Os demais 7% se enquadram nas áreas de gestão de sistemas da qualidade e normalização, auditoria e certificação para a qualidade. Nota-se, ainda que a subárea de organização metrológica da qualidade não houve nenhum artigo que se aplicasse.

4.4 TIPO DE DADOS E ALGORITMOS DE IA UTILIZADOS

Outra análise realizada foi quanto aos tipos de dados e algoritmos de IA utilizadas nos artigos. Sobre os tipos de dados utilizados para treinar os algoritmos, destacam-se: dados de produtos, cerca de 48% dos artigos e dados de equipamentos, cerca de 39% dos artigos. Os demais tipos de dados juntos somam aproximadamente 18% dos artigos. É importante mencionar que algumas pesquisas utilizam mais de um tipo de dados, conforme mostra o Quadro 4.

Quadro 4 – Tipos de dados mais utilizados para treinamento dos algoritmos de IA

Tipo de Dados	Artigos
Dados de gestão	[17]; [40]
Dados de equipamentos	[5]; [7]; [10]; [13]; [20]; [22]; [25]; [28]; [29]; [37]; [38]; [47]; [49]; [51]; [55]; [57]; [60]
Dados de usuários	[23]; [31]; [59]
Dados de produtos	[1]; [4]; [9]; [15]; [14]; [16]; [18]; [23]; [26]; [39]; [41]; [44]; [45]; [46]; [48]; [50]; [54]; [56]; [58]; [61]; [62]
Dados públicos	[13]
Dados artificiais	[8]
Não especificado	[52]

Fonte: Autoria própria (2023).

As pesquisas que fizeram uso de dados de produtos são principalmente aquelas que buscam automatizar e otimizar a identificação de defeitos. Para isso, precisam realizar a avaliação da qualidade do produto e utilizar dados das características físicas como peso, altura, quantidade de inconformidades e até mesmo imagens do produto.

Já a maioria dos estudos que utilizam dados de equipamentos implantados no chão de fábrica, possuem como característica o objetivo de fazer previsões da qualidade de seus produtos. Para isso, considera as condições de produção como temperatura, velocidade, pressão, torque, entre outros.

Ademais, esses dados são utilizados para treinar os algoritmos de inteligência artificial. Como principal técnica, as redes neurais artificiais são aplicadas em 50% das pesquisas analisadas. Essa se destaca pela complexidade de análises que podem ser feitas. Outros algoritmos que podem ser citados são: *lógica fuzzy*, *random forest*, *decision trees*, *support vector machine* e *clustering k-means*.

4.5 VANTAGENS E DESAFIOS DA APLICAÇÃO DA IA NA ENGENHARIA DA QUALIDADE

Por fim, com a leitura integral dos artigos também foram identificados as principais vantagens e desafios da aplicação da IA na área de Engenharia da Qualidade. O Quadro 5, a seguir, apresenta as principais vantagens que as empresas podem obter com o uso da IA nessa área.

Quadro 5 – Vantagens da Aplicação da IA

Vantagens	Artigos
Otimização da produção	[1]; [7]; [10]; [25]; [28]; [44]; [46]; [49]; [50]; [57]; [60]; [62]
Melhoria da qualidade do produto ou serviço	[1]; [8]; [25]; [26]; [31]; [37]; [38]; [39]; [50]; [55]; [57]; [58]; [59]; [61]; [62]
Facilitar a identificação precoce de defeitos ou falhas	[4]; [7]; [8]; [13]; [17]; [22]; [28]; [29]; [38]; [51]; [54]; [55]; [56]; [62]
Redução da intervenção do operador e dependência humana	[4]; [14];
Aumento na eficiência e precisão da inspeção da qualidade	[4]; [15]; [14]; [18]; [22]; [40]; [45]; [56];
Redução de custos de produção	[4]; [5]; [7]; [8]; [18]; [20]; [23]; [44]; [45]; [46]; [49]; [56];
Aumento na produtividade	[4];
Melhora na tomada de decisão	[5]; [48]; [57];
Automatização de tarefas	[10]; [23]; [46]; [9]; [47]; [48];
Capacidade de lidar com dados complexos e identificar padrões e tendências entre variáveis	[16]; [17]; [20]; [23]; [29]; [31]; [39]; [40]; [41]; [47]; [52]; [59]; [60];

Fonte: Autoria própria (2023).

As vantagens identificadas estão bem distribuídas entre os artigos analisados, no entanto, a melhoria da qualidade do produto ou serviço é citada em um maior número de artigos (15 vezes, cerca de 34% do total de artigos). Outras também se destacam, como: otimização da produção, maior facilidade na identificação precoce de defeitos ou falhas, redução de custos da produção e capacidade de lidar com dados complexos e identificar padrões e tendências entre variáveis. Já os principais desafios no uso da IA na área de Engenharia da Qualidade são apresentadas no Quadro 6 abaixo.

Quadro 6 – Desafios da Aplicação da IA

Desafios	Artigos
Compreensão profunda do processo de produção	[1]; [8]; [10]; [20]; [54];
Coleta e análise de dados pode ser complexa e demorada	[1];
Necessidade de coletar e processar grande quantidade de dados	[4]; [5]; [7]; [8]; [10]; [15]; [14]; [16]; [18]; [22]; [25]; [37]; [39]; [41]; [44]; [47]; [48]; [50]; [55]; [56]; [57]; [60]; [61]; [62]
Ajuste constante do modelo de IA para lidar com variações dos parâmetros do processo	[4]; [13]; [15]; [18]; [20]; [28]; [37]; [62]

Necessidade de garantir a segurança e confiabilidade dos dados e do modelo de IA	[4]; [5]; [7]; [17]; [20]; [23]; [31]; [40]; [44]; [47]; [52]; [57]; [59];
Garantir que as informações geradas pela IA sejam compreensíveis e interpretáveis	[7]; [14]; [16]; [23]; [25]; [31]; [40]; [47]; [51];
Falta de dados ou necessidade de lidar com dados incompletos ou ruidosos	[17]; [20]; [23]; [25]; [28]; [38]; [40]; [45]; [46]; [52]; [59];
Necessidade de selecionar o algoritmo de IA mais adequado para cada tipo de problema específico	[22]; [61];
Necessidade conhecimento especializado para implantar sistemas de IA	[18]; [26]; [38]; [52]; [54]; [55]; [58]; [62]
Necessidade de recursos computacionais significativos	[37]; [39]; [41]; [49]; [56];
Não especificado	[29]; [9];

Fonte: Autoria própria (2023).

O desafio de implantar IA na área da Engenharia da Qualidade que mais vezes foi mencionado nas pesquisas foi a necessidade de coletar e processar grande quantidade de dados (55% dos artigos). Essa dificuldade se deve por duas razões: processos produtivos de pequeno porte que não possuem dados suficientes para serem coletados ou dados incompletos ou a falta de recursos para processar esses dados. É importante destacar que, para uma maior confiabilidade dos resultados gerados pelos modelos de IA, maior deve ser a quantidade de dados usados para treinar o algoritmo.

Outros desafios significativos são: necessidade de garantir a segurança e confiabilidade dos dados e do modelo de IA, falta de dados ou necessidade de lidar com dados incompletos ou ruidosos e garantir que as informações geradas pela IA sejam compreensíveis e interpretáveis.

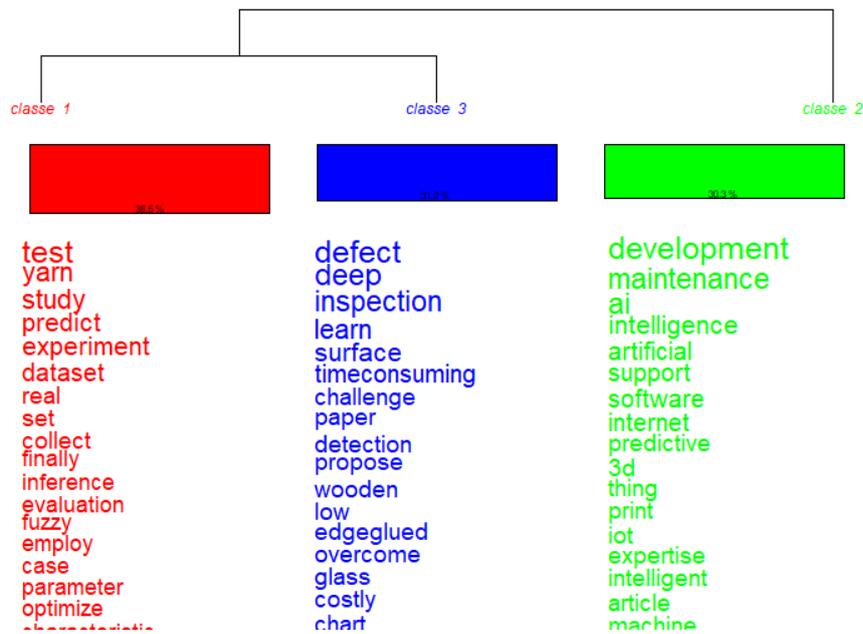
4.6 ANÁLISE DOS ARTIGOS COM O *SOFTWARE* IRAMUTEQ

De forma adicional, os resumos dos 44 artigos foram utilizados para gerar algumas análises de texto por intermédio do *software* Iramuteq. As ferramentas utilizadas nessa pesquisa foram o gráfico de similitude (Figura 3), classificação hierárquica descendente (Figura 4) e associação de classes (Figura 5).

No Iramuteq, a análise de similitude mostra um grafo que representa a ligação entre palavras do corpus textual. A partir desta análise é possível inferir a estrutura de construção do texto e os temas de relativa importância, a partir da coocorrência entre as palavras (SALVIATI, 2017). Assim, observa-se na Figura 3 que há ligações da palavra ‘*quality*’, principal termo da pesquisa, com ‘*manufacture*’, ‘*process*’ e ‘*datum*’.

processos, com foco em testes, predições e otimização. A classe 2 destaca o uso de sistemas de inteligência artificial (AI) e suas aplicações em suporte à manutenção preditiva com o suporte de softwares e equipamentos. Já a classe 3 concentra-se na detecção e superação de defeitos, com ênfase na inspeção profunda e desafios associados à detecção de defeitos em materiais diversos.

Figura 4 – Classes identificadas nos resumos

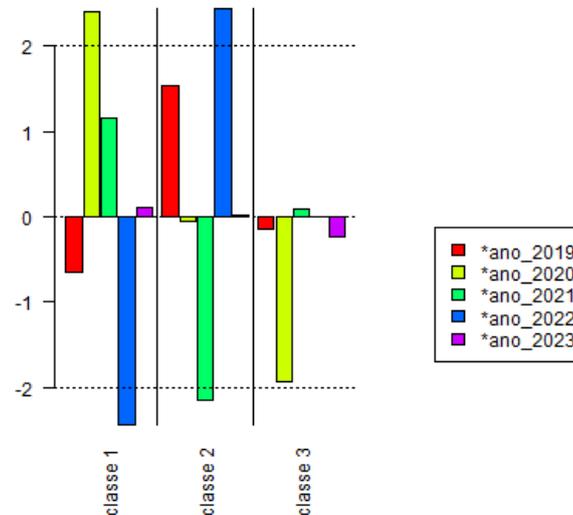


Fonte: Autoria própria (2023).

Além disso, pode-se constatar que há uma relação entre as classes 1 e 3, nas quais nesse artigo, por tratarem sobre predição da qualidade e detecção de defeitos respectivamente, foram enquadradas na subárea de planejamento e controle da qualidade. Já a classe 2 foi enquadrada na subárea confiabilidade de processos e produtos. Assim, os principais temas encontrados por meio do software Iramuteq confirmam as duas subáreas com maior número de aplicação apresentados na seção 4.3.

Com a CHD definida, o Iramuteq é capaz de associar as classes com as variáveis de ano de publicação determinadas, sendo possível identificar a evolução dos temas ao longo dos últimos cinco anos, que são aqueles com maior número de publicações. A Figura 5 apresenta o qui-quadrado de associação entre as classes de tema e a variável ano.

Figura 5 – Comportamento das classes por ano de publicação



Fonte: Autoria própria (2023).

Com o gráfico observa-se que, temas relacionados a predição da qualidade tiveram maior destaque no ano de 2020 e 2021, porém apareceu muito menos em 2022. Já temas relacionados a manutenção preditiva e confiabilidade de processos e produtos tiveram destaque em pesquisas dos anos de 2022 e 2019, no entanto teve queda no ano de 2021. Por fim, a classe 3 tem pequeno destaque no ano de 2021 e queda de pesquisas relacionadas a esse tema no ano de 2020. Então, podemos concluir que os tópicos de pesquisa analisados estão sujeitos a variações ao longo dos anos, com diferentes temas recebendo destaque em diferentes momentos. Isso pode refletir mudanças nas demandas da indústria ou serviços, avanços tecnológicos ou outros fatores que influenciam as prioridades de pesquisa.

5 CONCLUSÃO

Essa pesquisa teve como objetivo analisar o uso de técnicas de Inteligência Artificial na área da Engenharia da Qualidade, por meio de uma revisão bibliográfica e análise textual do *software* Iramuteq de 44 artigos. Foi possível entender a evolução acerca do assunto, identificar em quais subáreas da Engenharia da Qualidade a IA tem sido utilizada, quais tipos de dados utilizados no treinamento da IA e qual algoritmo é o mais utilizado, além de identificar as vantagens e desvantagens e, por fim, realizar uma análise de texto dos artigos com o *software* Iramuteq.

Os resultados mostram que o número de publicações acerca do tema vem crescendo ao longo dos anos e as principais aplicações são nas subáreas de planejamento e controle da

qualidade, com destaque para pesquisas sobre predição da qualidade e inspeção de defeitos, e confiabilidade de processos e produtos, com ênfase em pesquisas aplicadas na manutenção preditiva.

Ademais, os principais tipos de dados utilizados para treinar os modelos de Inteligência Artificial foram dados de produtos, tais como de características físicas e imagens do produto e dados de equipamentos que retornam as condições de produção como temperatura, velocidade, pressão, torque, entre outros. O principal modelo de algoritmo utilizados foram as redes neurais artificiais, que são capazes de lidar com problemas complexos e aprender a partir dos dados de treinamentos, retornando predições e classificações precisas.

Dentre as vantagens obtidas com o uso da IA, as mais relevantes foram a melhoria da qualidade do produto ou serviço, otimização da produção, maior facilidade na identificação precoce de defeitos ou falhas, redução de custos da produção e capacidade de lidar com dados complexos e identificar padrões e tendências entre variáveis. Já os desafios revelam que há dificuldade em coletar e processar grande quantidade de dados, garantir a segurança e confiabilidade dos dados e do modelo de IA, lidar com dados incompletos ou ruidosos e garantir que as informações geradas pela IA sejam compreensíveis e interpretáveis.

Como forma de complementar os resultados advindos da RBS, com o software Iramuteq foi possível identificar, por meio dos resumos de cada artigo, a importância da IA na melhoria da qualidade na manufatura e nos processos industriais, devido a relação dos principais termos na árvore de similitude, tais como: *'quality'*, *'manufacture'*, *'process'* e *'datum'*. Além de, por meio da Classificação Hierárquica Descendente (CHD), validar as duas principais subáreas de aplicação: planejamento e controle da qualidade e confiabilidade de processos e produtos. Por fim, foi observado conforme a associação de classes que os tópicos de pesquisa analisados estão sujeitos a variações ao longo dos anos, com diferentes temas recebendo destaque em diferentes momentos.

Esses resultados contribuem para o campo em rápida expansão do uso da IA aplicado à Engenharia da Qualidade. Com essa análise é possível identificar quais áreas são promissoras para receber essa tecnologia, direcionar melhor os investimentos em relação aos tipos de dados e equipamentos necessários e preencher uma lacuna na literatura sobre o uso da IA nas subáreas da Engenharia da Qualidade. Além disso, futuras pesquisas podem aprofundar o conhecimento de como a IA é utilizada nas demais áreas da Engenharia de Produção.

REFERÊNCIAS

- [1] AKSU, B. *et al.* A quality by design approach using artificial intelligence techniques to control the critical quality attributes of ramipril tablets manufactured by wet granulation. **Pharmaceutical Development and Technology**, v. 18, n.1, p.236-245, 2013.
- [2] ASIF, M. Are QM models aligned with Industry 4.0? A perspective on current practices. **Journal of Cleaner Production**, n. 120820, v. 258, 2020.
- [3] ASSOCIAÇÃO BRASILEIRA DE ENGENHARIA DE PRODUÇÃO (ABEPRO). A profissão da Engenharia de Produção. Disponível em <<https://portal.abepro.org.br/profissao/>>. Acesso em 05 de set. de 2023.
- [4] BAKAS, G. *et al.* Object Detection: Custom Trained Models for Quality Monitoring of Fused Filament Fabrication Process. **Processes**, v. 10, n. 10, p. 2147-2162, 2022.
- [5] BAMPOULA, X. *et al.* A Deep Learning Model for Predictive Maintenance in Cyber-Physical Production Systems Using LSTM Autoencoders. **Sensors**, v.21, n.3, p.972-986, 2021.
- [6] BATALHA, Mauro. **Introdução à engenharia de produção**. 7. ed. Rio de Janeiro: Elsevier, 2008. (Coleção Campus-ABEPRO. Engenharia de produção).
- [7] BEKAR, Ebru Turanoglu; NYQVIST, Per; SKOOGH, Anders. An intelligent approach for data pre-processing and analysis in predictive maintenance with an industrial case study. **Advances in Mechanical Engineering**, [S.L.], v. 12, n. 5, p. 1-14, 2020.
- [8] BELU, N; IONESCU, L M; RACHIERU, N. Risk-cost model for FMEA approach through Genetic algorithms – A case study in automotive industry. **Iop Conference Series: Materials Science and Engineering**, [S.L.], v. 564, n. 1, p. 12-21, 2019.
- [9] BERECIARTUA-PEREZ, Arantza *et al.* Deep Learning-Based Method for Accurate Real-Time Seed Detection in Glass Bottle Manufacturing. **Applied Sciences**, [S.L.], v. 12, n. 21, p. 11192, 2022.
- [10] BIOLCHINI, J.; MIAN, P. G.; NATALI, A. C. C.; TRAVASSOS, G. H. Systematic review in software engineering. Technical Report. **Systems Engineering and Computer Science Department**. COPPE/UFRJ, Rio de Janeiro, 2005.
- [11] BOCKLISCH, F. *et al.* Integrating human cognition in cyber-physical systems: a multidimensional fuzzy pattern model with application to thermal spraying. **Journal of Manufacturing Systems**, [S.L.], v. 63, p. 162-176, 2022.
- [12] CADAVID, Juan Pablo Usuga; LAMOURI, Samir; GRABOT, Bernard; FORTIN, Arnaud. Machine Learning in Production Planning and Control: a review of empirical literature. **Ifac-Papersonline**, [S.L.], v. 52, n. 13, p. 385-390, 2019.
- [13] CAMCI, F.; CHINNAM, R. B.; ELLIS, R. D. Robust kernel distance multivariate control chart using support vector principles. **International Journal of Production Research**, [S.L.], v. 46, n. 18, p. 5075-5095, 2008.
- [14] CHEN, Lun-Chi. *et al.* Edge-glued wooden panel defect detection using deep learning. **Wood Science and Technology**, [S.L.], v. 56, n. 2, p. 477-507, 2022.
- [15] CHEN, Yuh Wen; SHIU, Jing Mau. An implementation of YOLO-family algorithms in classifying the product quality for the acrylonitrile butadiene styrene metallization. **The**

International Journal of Advanced Manufacturing Technology, [S.L.], v. 119, n. 11-12, p. 8257-8269, 2022.

[16] COUVERTIER, V. Y. *et al.* Predicting T-cell quality during manufacturing through an artificial intelligence-based integrative multiomics analytical platform. **Bioengineering Translational Medicine**, [S.L.], v. 7, n. 2, p. 102-115, 2021.

[17] DANGUT, Maren David; SKAF, Zakwan; JENNIONS, Ian K. An integrated machine learning model for aircraft components rare failure prognostics with log-based dataset. **Isa Transactions**, [S.L.], v. 113, p. 127-139, 2021.

[18] EBADINEZHAD, Sahar. Design and performance evaluation of Improved DFACO protocol based on dynamic clustering in VANETs. **Sn Applied Sciences**, [S.L.], v. 3, n. 4, p. 486-501, 2021.

[19] GIL, A.C. Como Elaborar Projetos de Pesquisa. São Paulo. Atlas, 7 ed., 2002.

[20] HANZELIK, P. P.; KUMMER, A.; ABONYI, J. Edge-Computing and Machine-Learning-Based Framework for Software Sensor Development. **Sensors**, [S.L.], v. 22, n. 11, p. 4268, 2022.

[21] HOMMA, Junior *et al.* Aplicações de técnicas de machine learning nas áreas da Engenharia de Produção: uma revisão sistemática em eventos nacionais. In: Encontro Nacional de Engenharia de Produção, 41, 2021, Paraná. **Anais eletrônicos [...]**. Paraná: ABEPRO, 2021.

[22] HU, Jianming *et al.* Prediction of Resistance Spot Welding Quality Based on BPNN Optimized by Improved Sparrow Search Algorithm. **Materials**, [S.L.], v. 15, n. 20, p. 7323, 2022.

[23] HUANG, Jia. An Evaluation Model for Green Manufacturing Quality of Children's Furniture Based on Artificial Intelligence. **International Journal of Design & Nature and Ecodynamics**, [S.L.], v. 15, n. 6, p. 921-930, 2020.

[24] INSTITUTE OF INDUSTRIAL AND SYSTEMS ENGINEERS (IISE). **Body of knowledge: quality and reliability engineering**. Quality and Reliability Engineering. 2023. Disponível em: <https://www.iise.org/details.aspx?id=43631>. Acesso em: 01 set. 2023.

[25] JI, Shanling *et al.* Self-Attention-Augmented Generative Adversarial Networks for Data-Driven Modeling of Nanoscale Coating Manufacturing. **Micromachines**, [S.L.], v. 13, n. 6, p. 847, 2022.

[26] KALAYCI, Onur; PEHLIVAN, Ihsan; COSKUN, Selçuk. Improving the performance of industrial mixers that are used in agricultural technologies via chaotic systems and artificial intelligence techniques. **Turkish Journal of Electrical Engineering and Computer Sciences**, [S.L.], v. 30, n. 6, p. 2418-2432, 2022.

[27] KRAUB, J.; DORIBEN, J.; MENDE, H.; FRYE, M.; SCHMITT, R.H. Machine Learning and Artificial Intelligence in Production: Application Areas and Publicly Available Data Sets. In: Congress of the German Academic Association for Production Technology, 9, Berlin, 2019. **Anais eletrônicos [...]** Berlin: Springer Vieweg, 2019, p. 493-502.

[28] LEBERRUYER, Nicolas *et al.* Toward Zero Defect Manufacturing with the support of Artificial Intelligence: Insights from an industrial application. **Computers in Industry**, [S.L.], v. 147, p. 103877, 2023.

- [29] LEE, Junehyuck *et al.* Implementation of Cyber-Physical Production Systems for Quality Prediction and Operation Control in Metal Casting. **Sensors**, [S.L.], v. 18, n. 5, p. 1428, 2018.
- [30] LIMA, M. C.; ALMEIDA, R. M.; VALIM, S. R.; MIRANDA, W. M. A importância da análise de dados na Engenharia de Produção. In: Encontro Nacional de Engenharia de Produção, 41, 2021, Paraná. **Anais eletrônicos** [...]. Paraná: ABEPRO, 2021.
- [31] MAJI, Abhijnan. Service level modelling of motorized three-wheelers at un-signalized intersections under heterogeneous traffic conditions. **European Transport/Trasporti Europei**, [S.L.], n. 88, p. 1-15, 2022.
- [32] MARCONI, Marina de Andrade; LAKATOS, Eva Maria. Técnicas de pesquisa. 9. ed. São Paulo: Atlas, 2021.
- [33] MARQUES, M. A. M.; GENARO, T. M.; SILVA, W. A.; KLEINA, M. Aprendizagem de máquina aplicada a áreas da Engenharia de Produção: uma revisão sistemática de literatura. In: Encontro Nacional de Engenharia de Produção, 41, 2021, Paraná. **Anais eletrônicos** [...]. Paraná: ABEPRO, 2021.
- [34] MARTINS, R. A. Abordagens quantitativa e qualitativa. In: MIGUEL, P. A. C. (Coord.) **Metodologia de pesquisa em engenharia de produção e gestão de operações**. Rio de Janeiro: Campus Elsevier, 2010. cap. 3, p. 45-61.
- [35] MASSARON, L.; MUELLER, J. P. **Artificial Intelligence for Dummies**. New Jersey: John Wiley & Spons Inc, 2018.
- [36] MCCARTHY, John. Programs with common sense. In: SYMPOSIUM ON THE MECHANIZATION OF THOUGHT PROCESSES, 1., 1958, Teddington. **Programs with common sense**. Teddington: Proceedings of The Symposium, 1958. p. 1-10.
- [37] MOREIRA, L.C. *et al.* Supervision controller for real-time surface quality assurance in CNC machining using artificial intelligence. **Computers & Industrial Engineering**, [S.L.], v. 127, p. 158-168, 2019.
- [38] MURTHY, K. Vishnu; KUMAR, L. Ashok. Analysis of artificial intelligence in industrial drives and development of fault deterrent novel machine learning prediction algorithm. **Automatika**, [S.L.], v. 63, n. 2, p. 349-364, 2022.
- [39] NAZIB, Rezoan Ahmed; MOH, Sangman. Reinforcement Learning-Based Routing Protocols for Vehicular Ad Hoc Networks: a comparative survey. **Ieee Access**, [S.L.], v. 9, p. 27552-27587, 2021.
- [40] NIU, Wenjia *et al.* An Audit Risk Model Based on Improved BP Neural Network Data Mining Algorithm. **Advances in Multimedia**, [S.L.], v. 2022, p. 1-7, 27, 2022.
- [41] OBORSKI, Przemysław; WYSOCKI, Przemysław. Intelligent Visual Quality Control System Based on Convolutional Neural Networks for Holonic Shop Floor Control of Industry 4.0 Manufacturing Systems. **Advances in Science and Technology Research Journal**, [S.L.], v. 16, n. 2, p. 89-98, 2022.
- [42] PAGE, M. J. *et al.* The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **Bmj**, [S.L.], p. 71, 2021.
- [43] PALADINI, Edson Pacheco. **Gestão da qualidade: teoria e prática**. 4. ed. São Paulo: Atlas, 2019.

- [44] PEREIRA, Filipe *et al.* Intelligent Computer Vision System for Analysis and Characterization of Yarn Quality. **Electronics**, [S.L.], v. 12, n. 1, p. 236, 2023.
- [45] PERES, R. S. *et al.* Generative Adversarial Networks for Data Augmentation in Structural Adhesive Inspection. **Applied Sciences**, [S.L.], v. 11, n. 7, p. 3086, 2021.
- [46] PERES, R. S. *et al.* Simulation-Based Data Augmentation for the Quality Inspection of Structural Adhesive With Deep Learning. **Ieee Access**, [S.L.], v. 9, p. 76532-76541, 2021.
- [47] POLENTA, A. *et al.* A Comparison of Machine Learning Techniques for the Quality Classification of Molded Products. **Information**, [S.L.], v. 13, n. 6, p. 272, 2022.
- [48] RIEDEL, Henrik; *et al.* Automated quality control of vacuum insulated glazing by convolutional neural network image classification. **Automation in Construction**, [S.L.], v. 135, p. 104144, 2022.
- [49] ROJEK, I. *et al.* AI-Based Support System for Monitoring the Quality of a Product within Industry 4.0 Paradigm. **Sensors**, [S.L.], v. 22, n. 21, p. 8107, 2022.
- [50] SARABI, M. R. *et al.* Machine Learning-Enabled Prediction of 3D-Printed Microneedle Features. **Biosensors**, [S.L.], v. 12, n. 7, p. 491, 2022.
- [51] SELVARAJ, S. *et al.* A Multiclass Fault Diagnosis Framework Using Context-Based Multilayered Bayesian Method for Centrifugal Pumps. **Electronics**, [S.L.], v. 11, n. 23, p. 4014, 2022.
- [52] SEMENOVA, Galina N. *et al.* Audit of quality management at a smart company: independent expertise vs. artificial intelligence. **International Journal for Quality Research**, [S.L.], v. 17, n. 1, p. 1-12, 2023.
- [53] SILVA, S.; RIBEIRO, E. W. O software iramuteq como ferramenta metodológica para análise qualitativa nas pesquisas em educação profissional e tecnológica. **Brazilian Journal of Education**, Technology and Society (BRAJETS), v. 14, n. 2, p. 275-284, 2021.
- [54] STANOJEVIC, Darko; CIROVIC, Velimir. Contribution to development of risk analysis methods by application of artificial intelligence techniques. **Quality and Reliability Engineering International**, [S.L.], v. 36, n. 7, p. 2268-2284, 2020.
- [55] SUN, Han *et al.* Artificial Intelligence of Manufacturing Robotics Health Monitoring System by Semantic Modeling. **Micromachines**, [S.L.], v. 13, n. 2, p. 300, 2022.
- [56] SUNDARAM, Sarvesh; ZEID, Abe. Artificial Intelligence-Based Smart Quality Inspection for Manufacturing. **Micromachines**, [S.L.], v. 14, n. 3, p. 570, 2023.
- [57] TAKALO-MATTILA, Janne *et al.* Explainable Steel Quality Prediction System Based on Gradient Boosting Decision Trees. **IEEE Access**, [S.L.], v. 10, p. 68099-68110, 2022.
- [58] TAN, He *et al.* A design of fuzzy inference systems to predict tensile properties of as-cast alloy. **The International Journal of Advanced Manufacturing Technology**, [S.L.], v. 113, n. 3-4, p. 1111-1123, 2021.
- [59] WANG, Yu. Research on the Influence of Service Quality of Hotel Intelligent System on Customer Satisfaction Based on Artificial Intelligence Evaluation. **Mathematical Problems in Engineering**, [S.L.], v. 2022, p. 1-9, 2022.

- [60] WASMER, K. *et al.* In Situ Quality Monitoring in AM Using Acoustic Emission: a reinforcement learning approach. **Journal of Materials Engineering and Performance**, [S.L.], v. 28, n. 2, p. 666-672, 2018.
- [61] WU, Shuai *et al.* Intelligent Quality of Service Routing in Software-Defined Satellite Networking. **IEEE Access**, [S.L.], v. 7, p. 155281-155298, 2019.
- [62] ZHOU, Jian *et al.* Autonomous nondestructive evaluation of resistance spot welded joints. **Robotics and Computer-Integrated Manufacturing**, [S.L.], v. 72, p. 102183, 2021.