

INTELIGÊNCIA ARTIFICIAL E SIMULAÇÃO NAS APLICAÇÕES EM SISTEMAS DE PRODUÇÃO: UMA REVISÃO DE LITERATURA

ARTIFICIAL INTELLIGENCE AND SIMULATION IN PRODUCTION SYSTEM APPLICATIONS: A LITERATURE REVIEW

José Rafael Pilan¹

Gustavo Bonin Gava²

RESUMO

Este trabalho apresenta uma revisão de literatura sobre a integração entre Inteligência Artificial (IA) e Simulação em sistemas de produção no contexto da Indústria 4.0. A IA utiliza técnicas como Sistemas Especialistas, Lógica Fuzzy, Raciocínio Baseado em Casos e *Machine Learning* para reproduzir processos de raciocínio e tomada de decisão humanos. A Simulação permite modelar e analisar processos produtivos complexos e, quando integrada à IA, origina a Simulação Baseada em Conhecimento, tornando-se uma ferramenta avançada de apoio à decisão. A literatura apresenta aplicações industriais relevantes dessa integração, como no controle do processo de clinkerização na indústria cimenteira, na otimização do sequenciamento de ordens em fundições e na manutenção preditiva de equipamentos por meio de algoritmos de *Machine Learning*. Esses estudos demonstram ganhos em eficiência, precisão e confiabilidade, evidenciando o potencial da integração entre IA e Simulação para aprimorar a gestão e a otimização de sistemas produtivos complexos.

Palavras-chave: Indústria 4.0. Manutenção preditiva. Otimização de processos produtivos. Simulação baseada em conhecimento. Tomada de decisão inteligente.

ABSTRACT

This work presents a literature review on the integration of Artificial Intelligence (AI) and Simulation in production systems within the context of Industry 4.0. AI encompasses approaches such as Expert Systems, Fuzzy Logic, Case-Based Reasoning, and Machine Learning, which can be used to emulate aspects of human reasoning and support decision-making processes. Simulation enables the modeling and analysis of complex production processes, and its integration with AI, can support Knowledge-Based Simulation as an advanced decision-support approach. The literature reports several industrial applications of this integration, including clinkerization process control in the cement industry, order sequencing optimization in foundries, and predictive maintenance of equipment using Machine Learning algorithms. These studies report improvements in efficiency, accuracy, and reliability, highlighting the potential of integrating AI and Simulation to support the management and optimization of complex production systems.

Key words: Industry 4.0. Predictive maintenance. Production process optimization. Knowledge-based simulation. Intelligent decision-making.

¹ Docente na Faculdade de Tecnologia de Botucatu, Av. José Ítalo Bacchi, s/nº; e-mail jose.pilan@fatec.sp.gov.br

² Docente da Faculdade de Tecnologia de Rio Claro

1 INTRODUÇÃO

A Inteligência Artificial (IA) é um campo de estudo multidisciplinar que teve seu marco inicial formalizado na Conferência de Dartmouth em 1956 (Sichman, 2021). A IA é definida como a ciência e tecnologia de construção de máquinas inteligentes, em particular programas de computador, e está relacionada ao uso de computadores para o entendimento e exploração da inteligência humana. De uma perspectiva mais prática, a IA é o estudo de como fazer computadores realizarem tarefas que, até o momento, o ser humano realiza de modo superior. Este campo de conhecimento procura imitar mecanismos da natureza através de mecanismos tecnológicos, com o objetivo principal de construir sistemas que exibam comportamento inteligente e desempenhem tarefas com um grau de competência equivalente ou superior ao de um especialista humano (Sellitto, 2002). A IA, portanto, busca modelar os processos humanos de aprendizagem, permitindo a emulação desses processos em uma máquina computacional.

No cenário competitivo atual, a capacidade de construir e gerenciar conhecimento de apoio a especialistas no controle de processos industriais é altamente útil para organizações de fabricação, principalmente naquelas em que os processos operam sob incertezas e com dados incompletos (Sellitto, 2002). A IA é apontada como um campo de conhecimento que oferece modelos de apoio à decisão e ao controle com base em fatos e conhecimentos empíricos, sendo frequentemente mais simples e mais precisos do que outros métodos, como a modelagem matemática tradicional ou a gestão por indicadores (Sellitto, 2002).

O domínio da IA abrange uma vasta coleção de modelos, técnicas e tecnologias, incluindo raciocínio, representação de conhecimento, mecanismos de decisão, planejamento e Aprendizado de Máquina (*Machine Learning* – ML). Dentre as diversas abordagens da IA com aplicações em sistemas de produção, destacam-se os Sistemas Especialistas (SE), que resolvem problemas de forma similar a um especialista humano em campos restritos de conhecimento (Nikolopoulos, 1997), e o Raciocínio Baseado em Casos (CBR), que resolve novos problemas adaptando soluções conhecidas de experiências passadas (Aamodt; Plaza, 1994). A Lógica Fuzzy também se apresenta como uma técnica importante, que utiliza a teoria de conjuntos difusos para representar e manipular o conhecimento de especialistas, sendo particularmente indicada para o controle de processos industriais complexos que não possuem um modelo exato, mas são bem controlados por especialistas humanos (Kacprzyk, 1997). Mais recentemente, o Aprendizado de Máquina (ML) surge como uma metodologia da IA focada no aprimoramento de algoritmos que simulam a inteligência humana através da análise estatística de grandes volumes de dados (El Naqa; Murphy, 2015).

Em paralelo, a Simulação, que compartilha similaridades metodológicas com a IA ao modelar a realidade, representando objetos e suas relações, tem tido sua capacidade potencializada. A integração da simulação com conceitos de IA, conhecida como Simulação Baseada em Conhecimento (SBC) ou Nova Simulação (Costa, 1991) cria uma ferramenta poderosa de suporte à decisão.

As aplicações dessas abordagens conjuntas e individuais na Engenharia de Produção são vastas. Sistemas inteligentes combinando simulação discreta e técnicas de IA têm sido desenvolvidos para a verificação de alternativas de projeto em Sistemas Avançados de Manufatura (SAM) (Borenstein, 1998). Na Programação da Produção, abordagens heurísticas que utilizam a lógica Fuzzy são aplicadas para sistematizar o conhecimento prático de especialistas, como na determinação de um sequenciamento de ordens em indústrias de fundição que equilibre a demanda e a oferta de metal (Landmann; Erdmann, 2011). Além disso, em processos contínuos, o CBR e a lógica Fuzzy têm sido empregados em sistemas de controle multivariável, como o processo de clinquerização na indústria cimenteira (Sellitto, 2002). Um campo de grande relevância na Indústria 4.0 é a Manutenção Preditiva Industrial (PdM), onde a integração de metodologias de IA, como o *Machine Learning*, possibilita uma maior capacidade de análise de grandes volumes de dados, viabilizando a detecção precoce e eficiente de falhas em equipamentos (Panagou *et al.*, 2022).

Dada a crescente e inegável importância da Inteligência Artificial e da Simulação como ferramentas complementares para otimização, controle e suporte à decisão em sistemas de produção complexos, e considerando a rápida evolução das técnicas e a diversificação dos domínios de aplicação, o presente trabalho tem como objetivo realizar uma revisão de literatura para analisar as principais abordagens, técnicas e domínios de aplicação da Inteligência Artificial e da Simulação em Sistemas de Produção, fornecendo um panorama atualizado e consolidado das tendências e contribuições científicas na área.

2 DESENVOLVIMENTO DO ASSUNTO

A análise dos artigos selecionados permitiu traçar um panorama detalhado da aplicação da Inteligência Artificial (IA) e da Simulação em Sistemas de Produção, revelando a consolidação de modelos híbridos e a emergência de tendências metodológicas, especialmente no contexto da Indústria 4.0.

2.1 A Simulação Baseada em Conhecimento (SBC) e a Otimização de Sistemas de Manufatura

A literatura (Costa, 1991) demonstra que a integração entre Simulação e IA, denominada Simulação Baseada em Conhecimento (SBC) ou Nova Simulação, é uma abordagem poderosa de suporte ao projeto. Essa combinação transforma a simulação de uma ferramenta descritiva em uma ferramenta prescritiva. Essa evolução é crucial, pois supera uma limitação fundamental da simulação tradicional, que é sua inabilidade em modelar comportamentos inteligentes. A SBC utiliza a capacidade da simulação para prever valores de conjuntos complexos de variáveis, combinando-a com a habilidade de raciocínio de Sistemas Especialistas (SE).

Ainda segundo Costa (1991), os Sistemas Especialistas (SE), que pertencem ao campo da IA, são utilizados na SBC para automatizar as atividades consideradas "inteligentes" no processo de simulação, incluindo a organização e a conservação do conhecimento. Além disso, o uso de raciocínio qualitativo, inerente aos sistemas baseados em conhecimento, auxilia na redução das altas complexidades matemáticas. As atividades que caracterizam a SBC incluem receber a descrição de um problema, sintetizar um modelo de simulação consultando uma base de conhecimento, gerar o espaço de pesquisa de cenários e recomendar aquele que satisfaça a meta estabelecida, com a capacidade de aprender com a experiência.

Em termos de aplicação, a combinação de simulação discreta e técnicas de IA tem sido utilizada com sucesso para a verificação de alternativas de projeto em Sistemas Avançados de Manufatura (SAM). O sistema inteligente *ExpertFlex*, por exemplo, realiza um ciclo de análise-diagnóstico-recomendação baseado na experiência e conhecimento de especialistas. O sistema verifica se um projeto de SAM respeita objetivos pré-fixados de produtividade, investimento inicial e utilização de equipamentos. As recomendações oferecidas são específicas, podendo incluir a alteração do número de máquinas em uma célula, a modificação do *layout* ou a inclusão de *buffers*. Em um caso ilustrativo, o *ExpertFlex* demonstrou eficácia ao guiar o processo de projeto de forma evolutiva, priorizando a intervenção em máquinas sobrecarregadas, culminando na seleção da melhor alternativa (Borenstein, 1998).

2.2 Aplicações em Controle de Processos Contínuos e Programação da Produção

A Inteligência Artificial é particularmente útil no controle de processos industriais que operam sob incertezas e com dados incompletos, oferecendo modelos de apoio mais simples e mais precisos do que a modelagem matemática tradicional.

Na indústria cimenteira, as técnicas de Lógica Fuzzy e Raciocínio Baseado em Casos (CBR) foram aplicadas em um sistema de controle multivariável para o processo de clínquerização. A Lógica Fuzzy é apropriada para modelar sistemas complexos que são bem controlados por especialistas, mas que carecem de um modelo exato. O bloco de regras de inferência e *defuzzificação* foi obtido por meio de CBR, resgatando e adaptando bases de regras de plantas similares. Os especialistas ajustam as ações de controle (como *fuel*, *feed* e *fan*) nos 27 casos possíveis de cada estratégia. Após a revisão, o bloco de regras gerado é adicionado à base de casos, completando o ciclo do CBR (Sellitto, 2002).

No domínio da Programação da Produção em fundições, a questão central é o sequenciamento de ordens para equilibrar a demanda de metal líquido na moldagem com a oferta do forno de fusão. Foi utilizada uma abordagem heurística com Lógica Fuzzy para sistematizar os procedimentos empíricos dos especialistas. O modelo utiliza regras linguísticas para sequenciar combinações de peças leves, médias e pesadas. Os resultados de simulação demonstraram que o modelo heurístico obteve um desempenho mais eficiente em comparação com os profissionais da fundição: em um dia de simulação, a melhor alternativa do modelo heurístico apresentou uma perda de capacidade de 8% contra 10% do programa gerado pelo especialista, representando um ganho de 11.040 Kg de metal por dia (Landmann; Erdmann, 2011)

No contexto da roteirização veicular urbana, a combinação da Lógica Fuzzy com Redes Neurais Artificiais (RNAs), resultando na Rede Neuro *Fuzzy Multilayer Perceptron* (RNF MLP), foi utilizada para prever o percentual de lentidão do tráfego. O RNF MLP demonstrou boa capacidade de treinamento, identificando padrões de comportamento do tráfego, o que pode auxiliar a tomada de decisão que antecede a roteirização. A escolha dessa rede se justifica pela união das capacidades de aprendizado das RNAs e do raciocínio e representação da Lógica Fuzzy.(Ricardo; Ferreira, 2011).

2.3 Sistemas de Planejamento de Ações e Raciocínio Baseado em Casos

O Raciocínio Baseado em Casos (CBR) é uma metodologia de aprendizado incremental que resolve novos problemas adaptando soluções conhecidas de experiências passadas. O ciclo CBR consiste em: recuperar casos similares, reutilizar a solução, revisar a proposta e registrar a nova solução na base de casos (Aamodt; Plaza, 1994).

No campo do planejamento de ações para automação inteligente, o sistema *FAR-OFF* (*Fast and Accurate Retrieval on Fast Forward*) é um sistema de Planejamento Baseado em Casos (PBC) que emprega novos e precisos métodos de resgate. O *FAR-OFF* usa a regra de similaridade ADG (*Adaptation-Guided Similarity Metric*) e demonstrou ser um sistema mais estável e com menor probabilidade de falhar em encontrar uma solução em tempo aceitável, em comparação com sistemas generativos baseados em busca heurística, como o FF (Tonidandel; Rillo, 2002). Os resultados indicam o potencial do *FAR-OFF* para o controle inteligente de processos e da produção.

2.4 Machine Learning (ML) e Manutenção Preditiva Industrial (PdM)

A aplicação de abordagens de IA, em particular o *Machine Learning* (ML), na Manutenção Preditiva Industrial (PdM) visa identificar falhas nos equipamentos de forma precisa e eficiente.

2.4.1 Machine Learning (ML) e Manutenção Preditiva Industrial (PdM): Equipamentos, Datasets e Pré-processamento

As máquinas e motores rotativos foram os equipamentos mais estudados na revisão de literatura, com destaque para rolamentos e bombas. Os *datasets* utilizados tipicamente contêm o histórico de funcionamento operacional dos equipamentos. O tipo de dado mais frequente é a vibração seguido por temperatura, pressão e corrente elétrica. Contudo, há uma tendência em explorar novos atributos, como imagens térmicas, sinais acústicos e dados elétricos brutos (Bampoula *et al.*, 2021).

Quanto ao pré-processamento, a matriz de correlação linear e a Análise de Componentes Principais (PCA) foram as técnicas mais exploradas para a seleção e transformação de *features*. O pré-processamento resulta em *datasets* mais compactos, com uma média de aproximadamente 12 *features*, facilitando a interpretação dos resultados.

2.4.2 Machine Learning (ML) e Manutenção Preditiva Industrial (PdM): Algoritmos e Tendências Metodológicas

Segundo Bromberger (2024), os algoritmos de IA mais adotados na PdM são o *Random Forest* (RF) e o *Support Vector Machine* (SVM), o que podemos observar no Quadro 1, presentes em mais de 50% dos artigos avaliados em seu trabalho, o que se deve à sua flexibilidade na detecção de padrões de falha complexos e não lineares.

Quadro 1: Algoritmos de IA Mais Adotados na PdM (Mais de 50% dos 33 Artigos)

Algoritmo	Artigos/Estudos que Adotaram a Abordagem	Quantidade de Artigos
Random Forest (RF)	Herrero Zorrilla (2022); Jiang <i>et al.</i> (2022); Nikfar; Bitencourt; Mykoniatis (2022); Coelho <i>et al.</i> (2022); Chen <i>et al.</i> (2021); Alladio <i>et al.</i> (2021); Kim; Park; Jung (2021); Züfle <i>et al.</i> (2021); Bodo; Bertocco; Bianchi (2021); Ayvaz; Alpay (2021); Ahmad <i>et al.</i> (2021); Huang; Chung (2021).	12
Support Vector Machine (SVM)	Zermane; Drardja (2022); Christou <i>et al.</i> (2022); Herrero; Zorrilla (2022); Jiang <i>et al.</i> (2022); Nikfar; Bitencourt; Mykoniatis (2022); Coelho <i>et al.</i> (2022); Pan; Jiang (2021); Alladio <i>et al.</i> (2021); Kim, Park, and Jung (2021); Ahmad <i>et al.</i> (2021); Aqueveque <i>et al.</i> (2021).	11

Fonte: Adaptado de Bromberger, 2024.

A pesquisa também identificou uma tendência crescente para o uso de redes neurais convolucionais (CNN) e recorrentes (RNN), frequentemente combinadas com LSTM, para extrair informações relevantes de dados temporais e espaciais. Novas abordagens foram propostas, como a *cumulative uncertainty reduction network* (CURNet) para reduzir incertezas de previsão (RUAN *et al.*, 2022) e o Electrical-STGCN (JIANG *et al.*, 2022) para analisar interações de atributo e dependência temporal em registros elétricos. Outras combinações incluem a ResNet com ELM (RNELM), que mostrou ter os melhores resultados de *accuracy*, *precision*, *recall* e *F1-Score* em três experimentos com máquinas rotativas (Wei *et al.*, 2021).

2.4.3 Machine Learning (ML) e Manutenção Preditiva Industrial (PdM): Desempenho, Validação e Ajuste de Hiperparâmetros

A avaliação do desempenho dos modelos utiliza métricas como acurácia (ACC), F-score (FSC) e precisão (PRE). Para julgar os resultados de *datasets* desbalanceados, métricas como *precision*, *recall* e *F1-Score* são considerados mais adequadas do que métricas globais como *accuracy* (BAGUI; LI, 2021). Em termos de validação, segundo Bromberger (2024), o método de *cross-validation* (validação cruzada) foi o mais utilizado, sendo encontrado em 55% dos artigos em seu trabalho, pois ajuda a avaliar a capacidade de generalização do modelo e a diminuir o *overfitting*.

Também, segundo Bromberger (2024), o ajuste de hiperparâmetros foi empregado em aproximadamente 67% dos artigos, sendo o *grid search* e o *Adam optimizer* os algoritmos de busca mais comuns. A otimização desses fatores é crucial para melhorar o processo de aprendizagem dos modelos.

O Quadro 2 inclui apenas as métricas de desempenho mais utilizadas identificadas em nossa revisão de literatura: Acurácia (ACC), Precision (PRE), Recall (REC) e F-score (FSC).

Quadro 2: Levantamento das métricas predominantemente adotadas nos estudos contemplados por esta revisão de literatura, visando identificar tendências e padrões metodológicos

Estudo/Artigo (Original)	Identificação do artigo	ACC (Acurácia)	PRE (Precisão)	REC (Recall)	FSC (F-score)
Random Forest c/ Cluster Centroids (RF_CC) (Bromberger, 2024)	(Bromberger; Maria, 2024)	X	X	X	X
A INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA DE AUXÍLIO DIAGNÓSTICO E ANÁLISE DE MATERIAIS EM BIOSSENSORES (Grafite) (Simão, 2023)	(Simão, 2023)	X		X	
A INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA DE AUXÍLIO DIAGNÓSTICO E ANÁLISE DE MATERIAIS EM BIOSSENSORES (Grafeno) (Simão, 2023)	(Simão, 2023)	X			
Supervised Learning Applied to Graduation	(Canto; De Oliveira; De	X	X	X	X

Forecast of Industrial Engineering Students (Canto <i>et al.</i> , 2021)	Mattos Veroneze, 2022)				
Development of an efficient cement production monitoring system based on the improved random forest algorithm (Zermane; Drardja, 2022)	(Bromberger; Maria, 2024)		X	X	X
A multi-modal unsupervised fault detection system based on power signals and thermal imaging via deep AutoEncoder (Cordoni <i>et al.</i> , 2022)	(Bromberger; Maria, 2024)	X			X
An I4.0 data intensive platform suitable for the deployment of machine learning models: a predictive maintenance service case study (Herrero; Zorrilla, 2022)	(Bromberger; Maria, 2024)	X			
Improved Ensemble-Learning Algorithm for Predictive Maintenance... (Hung, 2021)	(Bromberger; Maria, 2024)	X		X	
Deep Learning-Based Fault Prediction in Wireless Sensor Network... (Ruan <i>et al.</i> , 2022)	(Bromberger; Maria, 2024)		X		
Electrical-STGCN: An Electrical Spatio-Temporal Graph Convolutional Network... (Jiang <i>et al.</i> , 2022)	(Bromberger; Maria, 2024)	X	X	X	X
A Two-Phase Machine Learning Approach for Predictive Maintenance... (Nikfar <i>et al.</i> , 2022)	(Bromberger; Maria, 2024)	X			
Predictive maintenance on sensorized stamping presses... (Coelho <i>et al.</i> , 2022)	(Bromberger; Maria, 2024)	X			X
Anomaly Detection Using Autoencoder Reconstruction upon	(Bromberger; Maria, 2024)		X		

Industrial Motors. (Givnan <i>et al.</i> , 2022)					
Explainable AI for Industry 4.0: semantic representation... (Terziyan; Vitko, 2022)	(Bromberger; Maria, 2024)	X			
SME 4.0: Machine learning framework for real-time machine health monitoring system. (Velmurugan <i>et al.</i> , 2021)	(Bromberger; Maria, 2024)	X			
Computer Prediction Model for Equipment Maintenance Using Cloud Computing... (Pan; Jiang, 2021)	(Bromberger; Maria, 2024)	X			
Extreme learning Machine-based classifier for fault diagnosis... (Wei <i>et al.</i> , 2021)	(Bromberger; Maria, 2024)	X	X	X	X
The "DOLPHINS" Project: A low-Cost Real-time Multivariate Process Control... (Alladio <i>et al.</i> , 2021)	(Bromberger; Maria, 2024)				
Adding interpretability to predictive maintenance by machine learning... (Steurtewagen; Poel, 2021)	(Bromberger; Maria, 2024)	X	X		
Evaluation of One-Class Classifiers for Fault Detection... (Kim; Park; Jung, 2021)	(Bromberger; Maria, 2024)	X	X	X	X
A Deep Learning Approach for Short Term Prediction of Industrial Plant Working Status. (Bellini <i>et al.</i> , 2021)	(Bromberger; Maria, 2024)	X			X
A Predictive Maintenance Methodology: Predicting the Time-to-Failure... (Züfle <i>et al.</i> , 2021)	(Bromberger; Maria, 2024)	X			X
Cost-Sensitive Fault Identification in Predictive Maintenance Applications... (Bodo; Bertocco; Bianchi, 2021)	(Bromberger; Maria, 2024)	X	X	X	
Auto-NAHL: A Neural Network Approach for Condition-Based	(Bromberger; Maria, 2024)	X			

Maintenance... (Berghout <i>et al.</i> , 2021)					
DeepHealth: A Self-Attention Based Method for Instant Intelligent Predictive Maintenance... (Zhang <i>et al.</i> , 2021)	(Bromberger; Maria, 2024)	X			
Intelligent Predictive Maintenance Model for Rolling Components... (Ahmad <i>et al.</i> , 2021)	(Bromberger; Maria, 2024)	X	X	X	X
Smart Anomaly Detection and Prediction for Assembly Process Maintenance... (Tanuska <i>et al.</i> , 2021)	(Bromberger; Maria, 2024)	X	X	X	X
A Deep Learning Model for Predictive Maintenance in Cyber-Physical Production Systems... (Bampoula <i>et al.</i> , 2021)	(Bromberger; Maria, 2024)	X			
Development of a Cyber-Physical System to Monitor Early Failures Detection... (Aqueveque <i>et al.</i> , 2021)	(Bromberger; Maria, 2024)	X			

Fonte: Autor, 2025.

2.4.4 Machine Learning (ML) e Manutenção Preditiva Industrial (PdM): Desafios Metodológicos e a Interpretabilidade (XAI)

Apesar dos avanços, a pesquisa destaca que a implementação da IA em PdM é desafiadora devido à ausência de dados históricos confiáveis, o desbalanceamento de classe dos *datasets* (poucas falhas) e a falta de interpretabilidade das decisões dos modelos.

O desbalanceamento de classe é frequentemente tratado com técnicas de *datasampling*, como o SMOTE (*Synthetic Minority Over-sampling Technique*) e o Cluster Centroids. (Bromberger; Maria, 2024).

A falta de interpretabilidade, ou a natureza de "caixa-preta" dos modelos, é uma lacuna de pesquisa significativa, sendo a interpretabilidade (XAI) essencial para aumentar a confiança nas previsões. A literatura explora metodologias para tornar as decisões de modelos de aprendizado profundo explicáveis através de regras semânticas (Terziyan; Vitko, 2022). Além disso, o uso de ferramentas como os SHAP *values* permite quantificar a contribuição de cada *feature* para as previsões do modelo, revelando relações complexas entre variáveis e resultados.

Outra área de análise de fatores mostrou que a manipulação de diferentes fatores (algoritmos de IA, hiperparâmetros, tempo de resposta do modelo e tamanho do *dataset*) é comumente realizada para aprimorar a performance dos modelos. No entanto, a manipulação de mais de um fator pode aumentar a complexidade das análises (Leukel; Gonzáles; Riekert, 2021). A ausência de uma descrição clara sobre a manipulação de fatores foi identificada em alguns artigos.

3 CONSIDERAÇÕES FINAIS

A presente revisão de literatura cumpriu seu objetivo ao analisar as principais abordagens, técnicas e aplicações da Inteligência Artificial (IA) e da Simulação em sistemas de produção, demonstrando que a integração entre essas áreas constitui uma estratégia promissora para o avanço da Indústria 4.0. A convergência entre IA e Simulação, materializada na Simulação Baseada em Conhecimento (SBC), transforma a simulação de uma ferramenta descritiva em uma abordagem prescritiva e inteligente, capaz de apoiar a tomada de decisão, o controle e a otimização de processos complexos.

Constatou-se que técnicas como Sistemas Especialistas, Lógica Fuzzy e Raciocínio Baseado em Casos (CBR) têm se mostrado eficazes em contextos industriais que operam sob incertezas e com dados incompletos, como nos sistemas de controle de clinquerização e na

programação da produção em fundições. Além disso, a combinação entre Lógica Fuzzy e Redes Neurais Artificiais revelou-se eficiente na modelagem de fenômenos dinâmicos, como o tráfego urbano, ampliando o escopo de aplicação da IA em processos decisórios complexos.

Na Manutenção Preditiva Industrial (PdM), as abordagens baseadas em *Machine Learning* (ML), especialmente *Random Forest* (RF) e *Support Vector Machine* (SVM), destacaram-se pela capacidade de prever falhas em equipamentos com alta acurácia. Entretanto, desafios persistem, como o desbalanceamento de classes, a falta de interpretabilidade dos modelos (XAI) e a influência de hiperparâmetros no desempenho das previsões.

Em síntese, a IA e a Simulação configuram-se como ferramentas estratégicas para aumentar a confiabilidade, eficiência e sustentabilidade dos sistemas produtivos. Recomenda-se que futuras pesquisas aprofundem o estudo da interpretabilidade dos modelos, da automação na construção de bases de conhecimento e da validação em diferentes contextos industriais, de modo a consolidar o uso integrado dessas tecnologias como pilares da manufatura inteligente.

REFERÊNCIAS

- AAMODT, Agnar; PLAZA, Enric. Case-Based Reasoning: Foundational Issues, Methodological Variations, and System Approaches. **AI Communications**, v. 7, n. 1, p. 39–59, 1994.
- BAGUI, S.; LI, K. Resampling imbalanced data for network intrusion detection datasets. **Journal of Big Data**, [s. l.], v. 8, n. 1, p. 1–41, 2021
- BAMPOULA, Xanthi *et al.* A Deep Learning Model for Predictive Maintenance in Cyber-Physical Production Systems Using LSTM Autoencoders. **Sensors**, v. 21, n. 3, p. 972, 1 fev. 2021.
- BORENSTEIN, Denis. Combinando simulação e sistemas baseados em conhecimento para o projeto de sistemas avançados de manufatura. **Gestão & Produção**, v. 5, n. 2, p. 89–103, ago. 1998.
- BOTELHO, Roedel; CUNHA, Almeida; MACEDO, Marcelo. **O método da revisão integrativa nos estudos organizacionais**. 2011.
- BROMBERGER, Dani Antonini; MARIA, Santa. **Abordagens de machine learning aplicadas à manutenção preditiva industrial para a detecção de falhas**. 2024.
- CANTO, Natalia Gil; DE OLIVEIRA, Marcelo Albuquerque; DE MATTOS VERONEZE, Gabriela. Supervised Learning Applied to Graduation Forecast of Industrial Engineering Students. **European Journal of Educational Research**, v. 11, n. 1, p. 325–337, 1 jan. 2022.
- COSTA, Miguel Antonio Bueno Da. **Uma abordagem sobre inteligência artificial e simulação, com uma aplicação na pecuária de corte nacional**. 1991.

ISSN 2176 – 4808

EL NAQA, Issam; MURPHY, Martin J. **What is machine learning?**. Machine Learning in Radiation Oncology, Springer, p. 3-11, Cham, 2015.

GIL, Antonio Carlos. **Métodos e Técnicas de Pesquisa Social**. 7. ed. São Paulo: Atlas, 2019.
KACPRZYK, J. **Multistage fuzzy control**. Chichester, UK: John Wiley Sons, 1997.

LANDMANN, Raul; ERDMANN, Rolf Hermann. **Uma abordagem heurística para a programação da produção na indústria de fundição com utilização da lógica Fuzzy**. Gest. Prod. 2011.

LEUKEL, J.; GONZÁLEZ, J.; RIEKERT, M. Adoption of machine learning technology for failure prediction in industrial maintenance: A systematic review. **Journal of Manufacturing Systems** 61, pp. 87-96, <https://doi.org/10.1016/j.jmsy.2021.08.012>, 2021

NIKOLOPOULOS. Expert Systems. CRC Press, 1997.

PANAGOU, Sotirios *et al.* Feature investigation with Digital Twin for predictive maintenance following a machine learning approach. **IFAC-PapersOnLine**, v. 55, n. 2, p. 132–137, 2022.

RUAN, H.; DORNEANU, B.; ARELLANO-GRACIA, H.; XIAO, P.; ZHANG, L. Deep Learning-Based Fault Prediction in Wireless Sensor Network Embedded Cyber-Physical Systems for Industrial Processes. In **IEEE Access**, vol. 10, pp. 10867-10879, 2022

SELLITTO, Miguel Afonso. **Inteligência Artificial: uma aplicação em uma indústria de processo contínuo**. 2002.

SICHMAN, Jaime Simão. Inteligência Artificial e sociedade: avanços e riscos. **Estudos Avancados**, v. 35, n. 101, p. 37–49, 1 jan. 2021.

SIMÃO, Guilherme Felipe. **A Inteligência Artificial como ferramenta de auxílio diagnóstico e análise de materiais em biossensores eletroquímicos**. 2023.

TERZIYAN, V.; VITKO, O. Explainable AI for Industry 4.0: semantic representation of deep learning models. **Procedia Computer Science**, 200, 216-226, 2022

TONIDANDEL, Flavio; RILLO, Márcio. Planejamento de ações para automação inteligente da manufatura. **Gestão & Produção**, v. 9, n. 3, p. 345–361, dez. 2002.

WEI, H.; ZHANG, Q.; M., SHANG; GU, Y. **Extreme learning Machine-based classifier for fault diagnosis of rotating Machinery using a residual network and continuous wavelet transform**. Measurement, 2021. Disponível em <https://doi.org/10.1016/j.measurement.2021.109864>