



COMPARATIVO DO USO DE INTELIGÊNCIA ARTIFICIAL NA GESTÃO DE PROCESSOS INDUSTRIAIS

A COMPARATIVE STUDY OF THE USE OF ARTIFICIAL INTELLIGENCE IN INDUSTRIAL PROCESS MANAGEMENT

ESTUDIO COMPARATIVO DEL USO DE LA INTELIGENCIA ARTIFICIAL EN LA GESTIÓN DE PROCESOS INDUSTRIALES

BARBARA LUIZA MENDES DOS SANTOS | barbara_mendes02@hotmail.com | FATEC São José dos Campos
JACQUELINE MAIARA RIBEIRO DE ALMEIDA | jacqueline.mribeiro@hotmail.com | FATEC São José dos Campos
ROQUE ANTÔNIO MOURA | roque.amoura@unitau.br | Universidade de Taubaté /SP

RESUMO

A Indústria 4.0 representa uma transformação profunda nos processos produtivos, tendo a Inteligência Artificial (IA) como um de seus recursos fundamentais. No entanto, grande parte da literatura recente trata a IA como um conceito monolítico, ignorando as diferenças substanciais entre suas subtecnologias aprendizagem de máquina, aprendizagem profunda, processamento de linguagem natural, visão computacional e sistemas especialistas. O objetivo desta pesquisa foi realizar uma análise comparativa entre as tecnologias de IA, avaliando suas aplicações, limitações, custos e viabilidade no contexto da gestão de processos industriais. A metodologia baseou-se em uma revisão bibliográfica sistemática e estudo recentes complementados por uma análise de dados secundários sobre adoção tecnológica na gestão indústria. Os resultados indicaram que não existe uma solução universal de IA e que cada tecnologia apresenta vantagens específicas e barreiras igualmente específicas. Enquanto sistemas especialistas oferecem baixo custo e rápida implementação para processos bem definidos, o aprendizado de máquina requer volumes massivos de dados e infraestrutura computacional. Conclui-se que a adoção de IA na gestão de processos industriais depende de um planejamento estratégico realista, com atenção especial à capacitação profissional e ao custo-benefício de longo prazo.

Palavras-chave: Inteligência Artificial; Indústria 4.0; Aprendizagem de máquina; Gestão de processos industriais.

ABSTRACT

Industry 4.0 represents a profound transformation in production processes, with Artificial Intelligence (AI) as one of its fundamental resources. However, much of the recent literature treats AI as a monolithic concept, ignoring the substantial differences between its sub-technologies: machine learning, deep learning, natural language processing, computer vision, and expert systems. The objective of this research was to conduct a comparative analysis of AI technologies, evaluating their applications, limitations, costs, and feasibility in the context of industrial process management. The methodology was based on a systematic literature review and recent studies complemented by an analysis of secondary data on technological adoption in industrial management. The results indicated that there is no universal AI solution and that each technology presents specific advantages and equally specific barriers. While expert systems offer low cost and rapid implementation for well-defined processes, machine learning requires massive volumes of data and computational infrastructure. It is concluded that the adoption of AI in industrial process management depends on realistic strategic planning, with special attention to professional training and long-term cost-benefit.

Keywords: Artificial Intelligence; Industry 4.0; Machine Learning; Industrial Process Management.

RESUMEN

La Industria 4.0 representa una profunda transformación en los procesos de producción, con la Inteligencia Artificial (IA) como uno de sus recursos fundamentales. Sin embargo, gran parte de la literatura reciente trata la IA como un concepto monolítico, ignorando las diferencias sustanciales entre sus subtecnologías: aprendizaje automático, aprendizaje profundo, procesamiento del lenguaje natural, visión artificial y sistemas expertos. El objetivo de esta investigación fue realizar un análisis comparativo de las tecnologías de IA, evaluando sus aplicaciones, limitaciones, costes y viabilidad en el contexto de la gestión de procesos industriales. La metodología se basó en una revisión sistemática de la literatura y estudios recientes, complementada con un análisis de datos secundarios sobre la adopción tecnológica en la gestión industrial. Los resultados indicaron que no existe una solución universal de IA y que cada tecnología presenta ventajas y barreras específicas. Si bien los sistemas expertos ofrecen un bajo coste y una rápida implementación para procesos bien definidos, el aprendizaje automático requiere grandes volúmenes de datos e infraestructura computacional. Se concluye que la adopción de la IA en la gestión de procesos industriales depende de una planificación estratégica realista, con especial atención a la formación profesional y al análisis coste-beneficio a largo plazo.

Palabras clave: Inteligencia Artificial; Industria 4.0; Aprendizaje Automático; Gestión de procesos industriales.

1. INTRODUÇÃO

A manufatura global vive um momento de inflexão. Desde a primeira Revolução Industrial, a mecanização, a eletrificação e a automação sucessivamente redefiniram o chão de fábrica (Acemoglu; Restrepo, 2019). A digitalização promete conectar máquinas, sistemas e pessoas em redes inteligentes capazes de tomar decisões em tempo real. Esse movimento, batizado de Indústria 4.0, tem na Inteligência Artificial um de seus motores centrais (Oliveira *et al.*, 2025; Nunes; Santos, 2022).

Cada aplicação utiliza uma tecnologia fundamentalmente diferente, com requisitos, custos e resultados distintos. No entanto, a literatura acadêmica e técnica tende a agrupar todas sob o mesmo rótulo, criando expectativas irreais e decisões de investimento mal informadas.

Entender o papel da inteligência artificial (IA) na Indústria 4.0 requer primeiro entender as diferenças entre suas subtecnologias como por exemplo, que Machine learning (ML) não é Deep learning (DL), Visão computacional (VC) não é Processamento de linguagem natural (PLN) e Sistemas Especialistas (SE) muitas vezes esquecidos continuam sendo a opção mais viável para inúmeros problemas industriais (Benevides *et al.*, 2026).

Ignorar as distinções leva a uma escolha equivocada, especialmente onde recursos são limitados e o retorno sobre investimento precisa ser calculado com precisão.

Aplicações práticas em manutenção preditiva, controle de qualidade, logística e planejamento produtivo com ênfase nos desafios reais de implementação.

Ao se analisar o custo-benefício comparativo, o impacto humano, empregos eliminados e criados e a viabilidade no contexto social, especialmente para pequenas e médias empresas mostram-se um balanço crítico e desorientado na prática.

Ao final, espera-se oferecer uma visão realista para gestores industriais sem apologias tecnológicas, mas uma análise que ajude a separar promessas de possibilidades concretas.

2. REVISÃO DA LITERATURA

2.1 INDÚSTRIA 4.0

O termo Indústria 4.0 foi criado em 2011, durante a Feira de Hannover, na Alemanha, como parte de uma estratégia governamental para manter a competitividade industrial alemã frente à crescente digitalização global. Desde então, o conceito evoluiu para abranger um conjunto de tecnologias que integram o mundo físico e o digital (Kagermann, 2013).

Schwab (2016) descreve a quarta Revolução Industrial como uma mudança de paradigma na qual sistemas ciberfísicos, máquinas equipadas com sensores e conectadas em rede, são capazes de monitorar, analisar e controlar processos físicos de forma autônoma. Uma linha de produção pode, por exemplo, identificar um desvio de qualidade, ajustar parâmetros em tempo real e solicitar manutenção sem intervenção humana direta (Nunes; Santos, 2022).


Slack *et al.* (2014) alertam que a implementação de tecnologias avançadas requer investimento financeiro e mudanças culturais e organizacionais profundas. Ignorar esses fatores transforma a Indústria 4.0 em um rótulo vazio e sem finalidade.

Outro aspecto importante é reconhecer os limites humanos e um ambiente compartilhado entre humanos e máquinas com o ritmo produtivo geralmente é ditado pelas máquinas (De Moura *et al.*, 2025; Moura *et al.*, 2024).

No ecossistema fabril, a inteligência artificial ocupa um papel central, principalmente ao transformar os dados brutos gerados por sensores e sistemas em decisões inteligentes e assertivas.

Sem inteligência artificial (IA), a Indústria 4.0 seria apenas uma coleção de dispositivos conectados, incapazes de extrair valor real da informação disponível (Taurion, 2019) e por isso entender suas variações é essencial para sucesso de sua funcionalidade conforme ilustra a Figura 1.

Figura 1 | Gestão digital com otimização e monitoramento por Inteligência Artificial



2.2 INTELIGÊNCIA ARTIFICIAL: DEFINIÇÃO E EVOLUÇÃO

A inteligência artificial, como campo de estudo, nasceu oficialmente em 1956, durante a Conferência de Dartmouth, quando um grupo de pesquisadores propôs que cada aspecto do aprendizado ou qualquer outra característica da inteligência pode, em princípio, ser descrito com tal precisão que uma máquina pode ser construída para simulá-lo (Russell; Norvig, 2020).


Desde então duas categorias tem sido frequentemente estudadas:

- IA simbólica ou baseada em regras utiliza representações explícitas de conhecimento, como em sistemas especialistas;
- IA sub-simbólica ou baseada em dados aprende padrões a partir de exemplos, como no Machine Learning. Essa distinção não é meramente teórica: ela define quais problemas cada abordagem pode resolver e com que custo.

Para a gestão industrial a escolha correta tem consequências práticas positivas, pois, um sistema especialista para diagnóstico de falhas pode ser desenvolvido rapidamente com o conhecimento de engenheiros experientes, mas será frágil diante de situações não previstas (Taurion, 2019; Benevides *et al.*, 2025).

A Inteligência Artificial pode ser classificada em categorias relacionada a sua funcionalidade e tipos que demonstra por qual forma e método ocorre o aprendizado conforme ilustra Figura 2.

Figura 2 | Inteligência Artificial: categorias e tipos



Fonte: Elaborado pelos Autores (2026).

Neste contexto, o uso do Deep learning (DL) pode gerenciar melhor, mas requer milhares de exemplos de falhas algo que muitas empresas não possuem. Por sua vez, os sistemas especialistas são programas que simulam o raciocínio de um especialista humano em um domínio restrito e operam com base em uma base de conhecimento, um conjunto de regras do tipo "se-então" e um motor de inferência que aplica essas regras a fatos fornecidos pelo usuário (Taurion, 2019).

2.2.1 MACHINE LEARNING (APRENDIZADO DE MÁQUINA)

Machine Learning (ML) refere-se a algoritmos que aprendem padrões a partir de dados, sem serem explicitamente programados para cada tarefa. As abordagens mais comuns incluem regressão linear e logística, árvores de decisão, máquinas de vetores de suporte e florestas aleatórias (Russell; Norvig, 2020).

ML lida com problemas que sistemas especialistas não conseguem resolver porque as regras são complexas demais para serem descritas manualmente. ML oferece boa capacidade de generalização para problemas estruturados com dados moderadamente volumosos e requerem dados históricos de qualidade.

Modelos como redes neurais rasas podem ser treinados em *hardware* comum, mas a engenharia das variáveis relevantes, ainda requer conhecimento humano além da interpretabilidade por ser limitada em modelos mais complexos, o que dificulta a aceitação em setores regulados.

2.2.2 DEEP LEARNING (APRENDIZADO PROFUNDO)

Deep Learning (DL) é um subcampo do ML que utiliza redes neurais artificiais com múltiplas camadas (profundo). Essas redes são capazes de aprender representações hierárquicas dos dados, eliminando em grande parte a necessidade de engenharia manual de características (Goodfellow; Bengio; Courville, 2016).

O DL tem desempenho superior em tarefas complexas como reconhecimento de imagens, processamento de áudio e séries temporais de alta dimensionalidade. Consegue extrair padrões que seriam invisíveis para um ser humano.

A DL requer volumes massivos de dados rotulados que exemplificam tarefas como visão computacional. O treinamento demanda *hardware* especializado (GPUs, TPUs) e consome energia significativa. Os modelos são caixas-pretas mesmo para engenheiros experientes que muitas vezes não conseguem explicar por que uma decisão foi tomada.

O custo de implementação e manutenção de um sistema DL é elevado principalmente para aplicações típicas como inspeção visual automatizada de produtos, monitoramento de vibrações em máquinas rotativas, previsão de falhas com base em dados de sensores de alta frequência.

2.2.3 VISÃO COMPUTACIONAL

A Visão computacional (VC) capacita máquinas para interpretar e entenderem o mundo visual, processando imagens e vídeos. Embora frequentemente associada ao DL, a visão computacional também utiliza técnicas tradicionais de processamento de imagem (Szeliski, 2022).

A VC possibilita automação de inspeção visual com alta velocidade e consistência. Técnicas tradicionais são rápidas e baratas para problemas bem definidos. Em ambientes industriais reais, iluminação variável, sujeira, vibração e variações de posição degradam o seu desempenho. O custo de câmeras, ópticas e iluminação especializada pode ser proibitivo para a adoção de sistema VC que é geralmente aplicado no controle de qualidade dimensional, leitura de códigos e caracteres, detecção de presença ou ausência de componentes e robótica guiada por visão.

2.2.4 PROCESSAMENTO DE LINGUAGEM NATURAL (PLN)

O Processamento de linguagem natural (PLN) possibilita que máquinas compreendam, interpretem e gerem linguagem humana. Na indústria, suas aplicações incluem análise de relatórios de manutenção, atendimento aos operadores via *chatbots*, extração de informações de documentos técnicos e geração automática de instruções de trabalho (Keselj; Vlado, 2009).

O PLN processa grandes volumes de texto não estruturado, o que é algo extremamente comum em indústrias como geração de relatórios e ordens de serviço, manuais em tarefas de compreensão e geração de texto.

Modelos PLN requerem poder computacional para treinamento e inferência. Aplicações em português brasileiro enfrentam menos recursos disponíveis comparado ao inglês. Além disso, o PLN tende a alucinar gerando informações falsas quando aplicado aos domínios técnicos muito específicos sem ajuste finos e adequados.

O Quadro 1 mostra as principais diferenças entre as tecnologias discutidas, considerando fatores críticos para a tomada de decisão em um contexto industrial.

Quadro 1 | Exoesqueleto: Simulação de usuário do gênero feminino para membros inferiores

Tecnologias	Dados necessários	Custos iniciais	Interpretabilidade	Manutenção	Melhor para
Sistemas Especialistas	Nenhum (só conhecimento)	Baixo	Alta	Manual (regras)	Problemas bem definidos
Machine Learning	Centenas a milhares	Médio	Média	Periódica (retreinamento)	Problemas com históricos
Deep Learning	Milhões	Muito alto	Baixa	Contínua requer GPU/cloud)	Problemas complexos
Visão Computacional	Variável	Médio a alto	Variável	Depende da técnica	Inspeção visual e robótica
PLN	Milhões de textos	Alto	Baixa a média	Contínua	Processamento de documento

Fonte: Elaborado pelos Autores (2026).

Nota-se que essas tecnologias não são mutuamente excludentes. Uma aplicação industrial típica pode combinar visão computacional para inspeção com machine learning para classificação dos defeitos detectados, e ainda utilizar um sistema especialista para recomendar ações corretivas. A questão é qual combinação oferece o melhor custo-benefício para cada contexto. A escolha da tecnologia de IA certa não é uma questão de modismo, mas de adequação ao problema, aos dados disponíveis e ao orçamento (Divino, 2021).

Segundo a Pesquisa de Inovação (PINTEC) do IBGE, 23% das empresas industriais brasileiras com mais de 100 funcionários possuem sistemas integrados de gestão (ERP) capazes de fornecer dados estruturados para treinamento de modelos de IA. Para as empresas de menor porte, esse número cai para 8% (IBGE, 2024).

3. MATERIAIS E MÉTODOS

A metodologia adotada é qualitativa, baseada em revisão bibliográfica sistemática e análise de múltiplos casos hipotéticos, construídos a partir de dados reais de adoção tecnológica na indústria brasileira e internacional.

Foram consultados artigos acadêmicos, relatórios setoriais e publicações técnicas dos últimos cinco anos, com ênfase em fontes brasileiras e latino-americanas, buscando refletir as particularidades regionais.

A análise dos dados buscou correlacionar as limitações dos projetos industriais clássicos com as soluções oferecidas pela robótica vestível, estabelecendo um paralelo com a necessidade de

inclusão da força de trabalho feminina (Yin, 2018).

Os descritores utilizados foram: “*artificial intelligence in manufacturing*”; “*digital management*”; “*artificial intelligence and human-machine interaction*”. Os dados coletados foram categorizados para estabelecer as conexões entre a biomecânica da assistência física e a infraestrutura de dados industriais.

Uma cooperativa agrícola que processa grãos em três unidades no interior do Paraná, precisando otimizar o sequenciamento de produção em suas linhas de beneficiamento optou por desenvolver um sistema especialista com base no conhecimento de seus dois engenheiros mais experientes.

4. RESULTADOS E DISCUSSÕES

4.1 CUSTO-BENEFÍCIO COMPARATIVO DAS TECNOLOGIAS

A análise dos casos possibilita construir uma matriz de custo-benefício que auxilia gestores na tomada de decisão, sendo importante notar que os valores apresentados são aproximações baseadas em referências de mercado cada caso concreto pode variar significativamente.

O Quadro 2 mostra que quanto mais sofisticada a tecnologia, maior o custo, o risco e o prazo de retorno.

Quadro 2 | Exoesqueleto: Simulação de usuário do gênero feminino para membros inferiores

Tecnologias	Custo típico (R\$)	Tempo implantar	ROI típico	Risco de fracasso	Adequação na Empresa
Sistemas Especialistas	40k – 120k	2–4 meses	6–10 meses	Baixo	Alta
Machine Learning (clássico)	100k – 300k	4–8 meses	9–15 meses	Médio	Média-alta
Deep Learning (DL)	300k – 1,5M	8–18 meses	12–24 meses	Alto	Baixa
Visão Computador (tradicional)	80k – 250k	3–6 meses	8–14 meses	Médio	Média
Visão Computador (DL)	250k – 600k	6–12 meses	12–18 meses	Alto	Baixa
PLN (ajuste fino)	200k – 500k	4–10 meses	12–20 meses	Médio	Baixa

Fonte: Elaborado pelos Autores (2026).

Para a maioria das empresas, especialmente as de médio porte, as soluções mais simples são os sistemas especialistas e *Machine learning* (ML) clássico por oferecer uma melhor relação custo-benefício.

Deep learning (DL) e grandes modelos de linguagem são mais viáveis para grandes empresas com equipes de dados dedicadas e orçamentos maiores e robustos.

A complexidade justifica o investimento como inspeção de defeitos microscópicos em lentes oftálmicas ou previsão de demanda para cadeias logísticas complexas. O DL pode gerar retornos substanciais desde que a escolha seja guiada pelo problema e não pela tecnologia.

4.2 DISCUSSÃO ÉTICA E REGULATÓRIA

A implementação de IA na indústria levanta questões que vão além da eficiência, pois quando um sistema de IA comete um erro quanto ao rito de trabalho como assegurar que algoritmos de otimização não penalizam sistematicamente trabalhadores menos treinados ou inexperientes.

O Marco Legal da Inteligência Artificial, em tramitação no Congresso Nacional (PL 2338/2023), propõe princípios de transparência, não discriminação e responsabilização, mas sua aplicação prática na indústria é ainda incipiente pela falta de diretrizes claras para certificação de sistemas de IA em processos críticos de produção como por exemplo setores da indústria alimentícia, farmacêutica e automotiva (Brasil, 2023).

5. CONSIDERAÇÕES FINAIS

A presente pesquisa demonstrou que a Inteligência Artificial não deve ser encarada como um conceito monolítico, mas como um ecossistema diversificado de subtecnologias com características, custos e aplicabilidades distintos. Evidenciou-se que a busca por uma solução universal de IA é um equívoco estratégico que pode levar ao desperdício de recursos, especialmente em um cenário econômico como o brasileiro, onde o acesso a capital e a infraestrutura computacional de ponta é limitado para grande parte das empresas.

Os resultados reforçam que o sucesso da implementação de IA na gestão de processos industriais não reside apenas na sofisticação tecnológica, mas na correta adequação da ferramenta ao problema proposto.

Enquanto sistemas especialistas continuam sendo opções robustas, de baixo custo e implementação rápida para processos industriais bem definidos, tecnologias como *Deep Learning* e Processamento de Linguagem Natural exigem volumes massivos de dados, *hardware* especializado e equipes altamente capacitadas, apresentando um retorno sobre o investimento a longo prazo e riscos de fracasso mais elevados.

Conclui-se que o planejamento estratégico deve priorizar a viabilidade técnica e financeira, sem negligenciar o fator humano e a capacitação profissional. A transição para a Indústria 4.0 requer que gestores desenvolvam um olhar crítico para separar promessas de mercado de possibilidades concretas de ganho de eficiência, assegurando que a tecnologia sirva como um motor de suporte à decisão e otimização produtiva e não como um fim em si mesma.

6. TRABALHO FUTURO

Sugere-se com trabalho futuro a proposta de desenvolver estudos de caso focados especificamente na viabilidade econômica de sistemas especialistas e ML básico para empresas e médio porte explorando modelos de negócios baseados em *SaaS (Software as a Service)* ou soluções *open-source*.

REFERÊNCIAS

- ACEMOGLU, D.; RESTREPO, P. (2019). **Automation and new tasks: how technology displaces and reinstates labor**. Journal of Economic Perspectives, v. 33, n. 2, p. 3–30, 2019.
- BENEVIDES, K. D. G.; RUFINO, L. J. G. C.; DOS SANTOS, D. F. A.; BENEVIDES, M. P.; PIMENTA, C. D.; DE OLIVEIRA, M. R.; DE MOURA, R. A. (2025). **Inteligência Artificial na educação de indivíduos adultos com 50 anos de idade ou mais: abordagem assistiva**. ARACÊ, [S. l.], v7, n8, p. e7160. DOI: [10.56238/arev7n8-085](https://doi.org/10.56238/arev7n8-085). <https://periodicos.newsciencepubl.com/arace/article/view/7160>.
- BENEVIDES, M. P.; OLIVEIRA, M. R.; MOURA, R. A. (2026). **Uso da inteligência artificial neurosimbólica no planejamento assistivo de centros urbanos inteligentes**. Veredas do Direito, [S. l.], v. 23, n. 7, p. e236205, 2026. DOI: 10.18623/rvd.v23.6205. Disponível em: <https://revista.domhelder.edu.br/index.php/veredas/article/view/6205>. Acesso: 7may2026.
- BRASIL. (2023). Senado Federal aprova marco regulatório da inteligência artificial. **Projeto de Lei 2.338/2023**. Disponível em: <https://www.gov.br/cultura/pt-br/assuntos/noticias/senado-federal-aprova-marco-regulatorio-da-inteligencia-artificial>
- DE MOURA, R. A.; BENEVIDES, M. P.; et al.; (2025). **Neuroergonomia no controle ... e artificial feel e melhor feedback háptico**. ARACÊ, [S. l.], v7, n9, pe8071. DOI: [10.56238/arev7n9-139](https://doi.org/10.56238/arev7n9-139). Disponível em: <https://periodicos.newsciencepubl.com/arace/article/view/8071>. Acesso 13set2025.
- DIVINO, S. (2021). **Reflexões sobre a inteligência artificial na agenda 2030** para o desenvolvimento sustentável. Revista Eletrônica Direito e Política. 16. 30-64. 10.14210/rdp.v16n1.p30-64.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.
- IBGE – Instituto Brasileiro de Geografia e Estatística. **Pesquisa de Inovação (PINTEC)**. Rio de Janeiro: IBGE, 2024.
- KAGERMANN, H. et al. **Recommendations for implementing the strategic initiative Industrie 4.0**. Frankfurt: Acatech, 2013.
- KESELI, VLADO. (2009). **Speech and Language Processing (second edition)** Daniel Jurafsky and James H. Martin. Stanford University and University of Colorado at Boulder. Pearson Prentice Hall, 2009, 988 pp; hardbound, ISBN 978-0-13-187321-6. Computational Linguistics. 35. 463-466. 10.1162/coli.B09-001.
- MOURA, R. A.; VILLARTA, C. J. B.; BENEVIDES, M. P.; RICETTO, M. R.; ROSA JUNIOR, O.; SANTOS, D. F. A. (2024). **Anthropometry, neuroergonomics and immersive technologies for the workplace's future: safer, self-sustainable and digital**. RGSA, 18(12), e09859. <https://doi.org/10.24857/rgsa.v18n12-032>
- NUNES, P. R.; SANTOS, L. M. A transição para a Indústria 5.0: **O fator humano nos sistemas ciberfísicos**. Journal of Industrial Engineering and Innovation, Rio de Janeiro, v. 8, n. 1, p. 112-128, 2022.
- OLIVEIRA, M. R.; BENEVIDES, K. G.; RUFINO, L. G. C.; SANTOS, D. A.; BENEVIDES, M. P.; MOURA, R. A. (2025). **Direito Digital e sua limitação no uso da inteligência artificial hodierna: um ponto para reflexão e ações requeridas**. CLCS, [S. l.], v. 18, n. 7, p. e19679. DOI: 10.55905/revconv.18n.7-341. <https://ojs.revistacontribuciones.com/ojs/index.php/clcs/article/view/19679>
- RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 4. ed. Hoboken: Pearson, 2020.
- SCHWAB, K. A **Quarta Revolução Industrial**. São Paulo: Edipro, 2016.
- SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Administração da Produção**. 4. ed. São Paulo: Atlas, 2014.
- SZELISKI, R. **Computer Vision: Algorithms and Applications**. 2. ed. London: Springer, 2022.
- TAURION, C. **Inteligência Artificial: um guia prático para gestores**. Rio de Janeiro: Brasport, 2019.
- YIN, R. K. **Estudo de caso: planejamento e métodos**. 5. ed. Porto Alegre: Bookman, 2018.

