

# INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA APLICADOS À USINAGEM CNC: PERSPECTIVAS PARA A INDÚSTRIA 4.0

Marcos Roberto Maciel <sup>1</sup>  
Renato Marques de Barros <sup>2</sup>

## Resumo

A usinagem CNC (Comando Numérico Computadorizado) é fundamental para a manufatura moderna e seu desempenho tem sido ampliado pelo uso de Inteligência Artificial (IA) e Aprendizado de Máquina (Machine Learning – ML). A literatura mostra aplicações como otimização de trajetórias, manutenção preditiva e planejamento de processos, resultando em maior eficiência, melhor acabamento, redução de custos e menor tempo de fabricação. Apesar dos avanços, persistem desafios como alto custo, necessidade de dados confiáveis, complexidade dos modelos, falta de padronização e resistência organizacional. Ainda assim, a IA representa um caminho promissor, exigindo investimentos tecnológicos e capacitação profissional.

**Palavras-chave:** Aprendizado de Máquina. Indústria 4.0. Inteligência Artificial. Manufatura Inteligente. Usinagem CNC.

## **Abstract. Artificial Intelligence and Machine Learning Applied to CNC Machining: Perspectives for Industry 4.0.**

CNC (Computer Numerical Control) machining is a cornerstone of modern manufacturing, and its performance has been enhanced using Artificial Intelligence (AI) and Machine Learning (ML). The literature highlights applications such as toolpath optimization, predictive maintenance, and process planning, which improve efficiency, surface quality, cost reduction, and production time. Despite these advances, challenges remain, including high implementation costs, the need for reliable data, model complexity, lack of standardization, and organizational resistance. Even so, AI is a promising path for smart manufacturing, requiring continued technological investment and workforce training.

**Keywords:** Machine Learning. Industry 4.0. Artificial Intelligence. Intelligence Manufacturing. CNC Machining.

---

<sup>1</sup> Discente do Curso Superior de Tecnologia em Fabricação Mecânica da FATEC Mauá (E-mail marcos.maciell3@fatec.sp.gov.br).

<sup>2</sup> Professor de Ensino Superior da FATEC Mauá (E-mail renato.barros4@fatec.sp.gov.br).

## 1 Introdução

O uso da manufatura avançada tem transformado a produção industrial. A Indústria 4.0 destaca-se pela integração entre sistemas físicos e digitais capazes de usar sistemas inteligentes através da transferência de grandes volumes de dados. Nesse contexto, a usinagem CNC (Controle Numérico Computadorizado) tem papel importante na fabricação de peças de alta precisão, embora exija um nível considerável de conhecimento técnico para sua operação. Com os avanços da Inteligência Artificial (IA) e do Aprendizado de Máquina (Machine Learning – ML), tornou-se possível desenvolver sistemas inteligentes de manufatura capazes de se adaptar às mudanças nas condições de operação, reduzir perdas e otimizar o desempenho em tempo real.

Este artigo tem como objetivo analisar o panorama atual e as perspectivas futuras do uso de IA e ML na usinagem CNC, abordando os principais avanços tecnológicos, os desafios existentes e as oportunidades para novos estudos e inovações na área.

## 2 Referencial Teórico

O avanço das tecnologias relacionadas à IA e ML tem potencial de melhorar de forma significativa a usinagem CNC. Diversos estudos mostram como essas ferramentas podem ser integradas para aprimorar o desempenho e elevar a eficiência dos processos de manufatura. A seguir, são apresentadas algumas das principais aplicações de IA e ML na usinagem CNC, com destaque para as técnicas empregadas e os resultados obtidos.

O uso de redes neurais no monitoramento de processos de usinagem CNC tem se mostrado uma alternativa eficaz para aprimorar a qualidade do acabamento das peças, adaptando-se rapidamente às variações nos parâmetros do processo, como velocidade de corte, avanço e desgaste da ferramenta (OSAN & DRENTA, 2025). A capacidade dessas redes de aprender com dados em tempo real permite que o sistema realize rapidamente ajustes dinâmicos, resultando em maior precisão e melhor acabamento no produto final.

O aprendizado supervisionado aplicado à previsão do desgaste de ferramentas de corte representa uma das principais inovações da Indústria 4.0, com grande impacto na eficiência dos processos de usinagem CNC (WANG *et al.*, 2021). A partir da análise de dados históricos e sinais de desgaste como vibrações e aumento de temperatura ou redução do acabamento, algoritmos supervisionados conseguem prever o momento em que a aresta de corte necessitará substituição, permitindo uma operação mais eficiente (ALEXANDRE, 2005). Essa técnica reduz falhas inesperadas, evita paradas não programadas e garante a continuidade da produção. Além disso, a previsão precisa do desgaste permite a otimização do ciclo de vida das ferramentas e aumenta a eficiência operacional como um todo (COLANTONIO *et al.*, 2021).

Investiga-se, no estudo de Ganesan e Mohankumar (2013), a aplicação de algoritmos genéticos para otimizar os trajetos das ferramentas com o objetivo de reduzir o tempo de usinagem sem comprometer a qualidade do produto final. Devido à sua capacidade de adaptação, os algoritmos genéticos mostraram-se eficazes na resolução de problemas complexos de otimização que envolvem múltiplas variáveis e restrições, como os encontrados na usinagem CNC.

A segurança também tem se tornado uma preocupação crescente nesse contexto. Çekik e Turan (2025) propõem o uso de árvores de decisão para detectar colisões durante o processo de usinagem. Esse método analisa dados em tempo real e permite identificar riscos de impacto entre a ferramenta e a peça ou entre a ferramenta e a máquina. O objetivo é aumentar a segurança operacional, evitando danos aos equipamentos e às peças, além de garantir a continuidade da produção sem interrupções inesperadas.

Afif e Sarhan (2025) investigaram a automatização do planejamento de processos em ambientes de produção variáveis, utilizando redes neurais convolucionais. O estudo demonstrou como essas redes conseguem aprimorar a seleção de parâmetros de usinagem tais como velocidade de corte, avanço e geometria da ferramenta e definir estratégias de usinagem mais eficientes. A automação do processo com o uso desse tipo de rede permite ajustes rápidos às condições de produção.

## 2.1 Aplicações na usinagem CNC

É fato que a usinagem CNC moderna demanda processos cada vez mais autônomos, precisos e adaptáveis. A incorporação de técnicas de IA e ML tem impulsionado avanços significativos em diversas etapas da produção. A seguir, apresenta-se algumas das principais aplicações dessas tecnologias no contexto da usinagem CNC.

### *Otimização da trajetória da ferramenta*

Algoritmos de Aprendizado Profundo (Deep Learning - DL), como redes neurais e algoritmos genéticos, têm sido aplicados para otimizar as trajetórias das ferramentas de corte, particularmente durante as operações de fresamento. Essa otimização busca reduzir o tempo de usinagem ao mesmo tempo em que minimiza o desgaste da aresta de corte e diminui a rugosidade da superfície trabalhada. É possível, inclusive, realizar a otimização em tempo real através da medição de variáveis de processo como vibração e força de corte (PATIL *et al.*, 2021). Técnicas que envolvem temperatura ainda são pouco confiáveis devido às dificuldades de medição em tempo real.

Algoritmos que usam DL são capazes também de melhorar variáveis como velocidade de corte, avanço e número de passes, ajustando-as às condições da operação. A aprendizagem contínua desses sistemas também possibilita ajustes autônomos, resultando em maior precisão e menor necessidade de intervenção humana. Além disso, a implementação de técnicas de simulação por elementos finitos permite prever diferentes cenários de usinagem, contribuindo para a análise de desempenho das estratégias de corte (MUNARO, ATTANASIO & DEL PRETE, 2023).

O uso de IA para otimizar trajetórias de corte tem sido usado na redução da potência de corte e no aumento da vida útil da ferramenta (LEE *et al.*, 2017). O DL pode, por exemplo, analisar grandes volumes de dados históricos e informações de sensores em tempo real, ajustando as trajetórias com base nos padrões de desgaste das ferramentas e nas características do material sendo usinado (SERIN *et al.*, 2021). A Figura 1 demonstra um diagrama que evidencia como o DL faz parte da ML, que por sua vez faz parte da IA. Cada círculo representa o nível de abrangência de cada área.

Figura 1. Relação hierárquica entre IA, ML e Deep Learning.



Fonte: SILVA, MELLO & SALGADO (2019).

## 2.2 Planejamento de Processo Auxiliado por Computador (PPAC)

Aplicações da IA no PPAC permitem a seleção automática dos parâmetros de corte, considerando as limitações da ferramenta, a geometria da peça e as tolerâncias especificadas. Redes neurais convolucionais e sistemas especialistas auxiliam no reconhecimento de formas geométricas e na definição de trajetórias otimizadas de usinagem, reduzindo o tempo de preparação e aumentando a flexibilidade do processo (KOMURA *et al.*, 2023). Essas tecnologias não apenas elevam a eficiência operacional, mas também conferem maior agilidade à produção, possibilitando rápida adaptação a variações de demanda e condições de manufatura.

Já a Figura 2 mostra uma célula automatizada composta por um centro de usinagem CNC multitarefa e um robô industrial representando o ambiente de manufatura avançada em que a IA é aplicada para a seleção automática de parâmetros de corte e otimização de processos, reduzindo o tempo de preparação e aumentando a flexibilidade da produção. Esse conjunto da IA com a automação ilustra de forma prática sua aplicação no PPAC.

### *Otimização da trajetória da ferramenta*

Algoritmos de Aprendizado Profundo (DL), como redes neurais e algoritmos genéticos têm sido aplicados para otimizar as trajetórias das ferramentas de corte, particularmente durante as operações de fresamento. Essa otimização busca reduzir o tempo de usinagem ao mesmo tempo em que minimiza o desgaste da aresta de corte e diminui a rugosidade da superfície trabalhada. É possível, inclusive, realizar a otimização em tempo real através da medição de variáveis de processo como

vibração e força de corte (PATIL *et al.*, 2021). Técnicas que envolvem temperatura ainda são pouco confiáveis devido às dificuldades de medição em tempo real.

Figura 2. Célula de Usinagem Automatizada com Máquina CNC e Robô Industrial.



Fonte: AT-MACHINING, 2024.


As redes neurais, quando são treinadas com dados históricos de usinagem, aprendem a identificar padrões em diferentes formas e condições de corte. Isso permite que o sistema sugira automaticamente a sequência mais eficiente de operações e os parâmetros de usinagem ideais para cada operação, equilibrando as limitações técnicas com ganhos práticos, como reduzir o tempo de produção e economizar energia (ZHANG, JAISWAL & RAI, 2018). Além disso, sistemas produtivos com IA conseguem combinar as regras de produção com informações em tempo real sobre o funcionamento das máquinas. Isso permite sugerir ajustes quase imediatos nos parâmetros de usinagem, aumentando a precisão e a eficiência do processo, por exemplo, alterando o avanço e a geometria da ferramenta. Integrados a sensores IoT (Internet of Things ou Internet das Coisas em português) e *feedbacks* automáticos das máquinas, esses sistemas tornarão possível adaptar o planejamento em tempo real, com pouca ou nenhuma intervenção humana (YAO *et al.*, 2019).

### 2.3 Monitoramento das condições da ferramenta

Alguns sensores utilizados em máquinas CNC podem ser conectados a algoritmos de aprendizado, o que permite monitorar continuamente desgaste, quebras ou necessidade de troca. Esse tipo de conexão torna a troca de ferramenta mais eficiente e diminui paradas e falhas inesperadas durante a usinagem (SERIN *et al.*, 2020). Além de identificar defeitos, esses sistemas de monitoramento podem prever a vida útil restante das ferramentas, usando dados de vibração, força de corte, emissão acústica e calor. Sensores conectados via IoT captam esses sinais, que são processados em tempo quase real por redes neurais ou algoritmos de decisão, estimando a degradação

da ferramenta ao longo do tempo. A Figura 3 ilustra um sistema de monitoramento da condição da ferramenta em torno CNC, utilizando sensor de temperatura acoplado ao inserto de corte e câmera CCD para inspeção visual da aresta. Os dados adquiridos são transmitidos em tempo real para sistemas de análise baseados em aprendizado de máquina.

Figura 3. Monitoramento multissensorial em uma máquina CNC.



Fonte: MDPI, 2021.

## 2.4 Previsão de Manutenção

Técnicas de aprendizado preditivo usam dados históricos de operação e condições de uso para antecipar necessidades de manutenções corretiva e preventiva, aumentando a disponibilidade dos equipamentos e reduzindo custos. Esses métodos identificam padrões sutis antes que ocorram falhas e ajudam a planejar intervenções no momento certo e evitando paradas inesperadas (ZHENG, PAIVA & GURCIULLO, 2020) e, quando integrados a sensores IoT e monitoramento em tempo real, tornam a manutenção ainda mais precisa e baseada em dados.

A Figura 4 mostra um sensor de vibração utilizado comumente em máquinas-ferramenta e que podem ser integrados a sistemas de monitoramento em tempo real. Tais sensores estão sendo utilizados atualmente em técnicas de planejamento de manutenção que utilizam DL. Tal abordagem melhora o desempenho dos equipamentos industriais e também promove uma gestão mais inteligente dos recursos, alinhada aos princípios da Indústria 4.0 (SERRADILLA *et al.*, 2022).

Figura 4. Sensor IoT sem fio para monitoramento de vibração.



Fonte: NCD.IO, 2025.

### 3 Desafios e limitações da IA

Apesar dos benefícios proporcionados na usinagem CNC, ainda existem algumas barreiras para a ampla adoção dos modelos de IA. Essas barreiras envolvem aspectos técnicos, operacionais, econômicos e culturais que precisam ser superados (FRANK, DALENOGARE & AYALA, 2019).

Do ponto de vista técnico, a integração da IA com máquinas CNC ainda é um desafio. Algumas máquinas, particularmente aquelas construídas antes de 2010, não foram projetadas para lidar com a complexidade desses algoritmos nem são capazes de armazenar e transmitir dados com a velocidade necessária, exigindo substituição nos equipamentos e sistemas de controle mais avançados. Além disso, o uso de grandes volumes de dados de alta qualidade para treinar os modelos pode ser um obstáculo, especialmente em ambientes produtivos onde os dados podem ser corrompidos (LECUN, BENGIO & HINTON, 2015).

Em particular, a técnica de redes neurais convolucionais utilizam modelos de grade baseados em imagens que precisam ser transmitidas e analisadas em tempo real. Isso envolve a transmissão de vários gigabytes de dados para uma unidade de processamento que calcula e prevê vários parâmetros da operação de usinagem.

No ambiente operacional usar IA e ML exige alto nível de conhecimento técnico. Além disso, a adoção dessas tecnologias muda métodos de trabalho já consolidados, o que pode requerer requalificações da equipe. Tais problemas podem gerar resistência nas equipes e dificultar a adaptação (Id., 2019). A dependência em sistemas automatizados traz, em si mesma, alguns riscos de falhas inesperadas que necessitam de intervenção humana e podem abalar a confiança da equipe nessas tecnologias.

Do ponto de vista econômico, implantar sistemas produtivos baseados em IA e ML exige um investimento elevado, representando uma barreira importante, especialmente para micro, pequenas e médias empresas (MÜLLER *et al.*, 2017). A compra de novos equipamentos, a modernização da infraestrutura e os custos com capacitação demandam recursos significativos. Além disso, o retorno sobre o investimento pode demorar a se concretizar, gerando incertezas quanto à viabilidade a longo prazo. A Figura 5 resume os principais desafios da adoção da manufatura inteligente.

Figura 5. Principais desafios para adoção de IA e ML na usinagem CNC.



Fonte: os próprios autores (2025).

### 3.1 Coleta e qualificação de dados

A eficiência e precisão dos modelos de ML dependem da qualidade e da quantidade dos dados coletados. Em ambientes industriais muitas vezes esses dados são incompletos, ruidosos ou mal organizados. A integração de sensores apropriados à infraestrutura existente tende a ser custosa e tecnicamente complexa. A presença de dados ruidosos, incompletos ou inconsistentes, é um desafio significativo em aplicações de ML industrial, impactando diretamente a *performance* e a confiabilidade dos modelos preditivos (XU *et al.*, 2019), uma vez que ainda não existem parâmetros confiáveis para a filtragem desses dados.

De fato, a ausência de parâmetros adequados de dados pode comprometer tanto a confiabilidade quanto a segurança da informação, impactando negativamente a robustez dos modelos. Dessa forma, a coleta, transmissão e o armazenamento adequados dos dados são etapas fundamentais para garantir que as soluções baseadas em ML apresentem desempenho satisfatório e aplicabilidade prática no contexto industrial

### 3.2 Complexidade e interpretação

Modelos de Aprendizado Profundo (DL), como redes neurais, alcançam alta precisão mas são de interpretação difícil. Essa característica dificulta a validação dos resultados na indústria, visto que a rastreabilidade das decisões é importante para garantir segurança, confiabilidade e normalização dos procedimentos.

A natureza de *caixa-preta* dos modelos de IA decorre de sua complexidade e do grande número de parâmetros que se tornam difíceis para os humanos compreenderem como uma decisão ou previsão específica é alcançada. Em setores industriais, em que falhas podem ter graves consequências, a interpretação é uma barreira significativa para a adoção de soluções de ML. A capacidade de explicar o raciocínio por trás das previsões é importante para a sua validação, além de construir confiança entre os operadores e as partes interessadas (OLIVEIRA, 2020).

A interpretação dos modelos de IA é importante em aplicações como manutenção preditiva, controle de qualidade e otimização de processos, visando garantir a compreensão das causas de um problema ou a justificativa para uma ação recomendada leva a intervenções mais seguras. Sem essa transparência, a detecção de desvios nos dados de treinamento torna-se extremamente desafiadora, podendo levar a decisões errôneas ou não otimizadas.

A falta de transparência nos modelos complexos pode limitar sua adoção em setores nos quais decisões automáticas precisam ser justificadas perante normas regulatórias ou auditorias técnicas. Para abordar essa questão, o campo da Inteligência Artificial Explicável (Explainable Artificial Intelligence - XAI) tem ganhado destaque, buscando desenvolver métodos e técnicas que tornem os modelos de ML mais transparentes e compreensíveis. A aplicação de XAI em ambientes industriais visa aumentar a confiança e a aceitação dos modelos e facilitar a identificação de falhas, a otimização de processos e a conformidade com normas e regulamentos. (NIKIFORIDIS *et al.*, 2025).

Nesse contexto vale ressaltar a iniciativa da Associação Brasileira de Normas Técnicas (ABNT) na criação da norma ISO (International Organization for Standardization)/IEC (International Electrotechnical Commission) - TR (Technical Report) 24027:2024, que aborda especificamente o viés em sistemas de IA e a tomada de decisão assistida. Outra iniciativa governamental é o projeto de Lei 2338/2023 votado no Senado Federal brasileiro e que atualmente encontra-se em análise na Câmara dos Deputados (LAPIN, 2025).

Dessa forma, equilibrar precisão e interpretação constitui atualmente um dos principais desafios no uso de ML e IA em ambientes produtivos. A utilização de técnicas híbridas, que permitam modelos de alta *performance* com mecanismos de explicação é, atualmente, um caminho promissor para tornar as aplicações mais seguras e confiáveis na indústria.

### 3.3 Custo de implementação

A introdução de sistemas inteligentes requer investimentos significativos em *hardware*, *software*, treinamento de pessoal e reestruturação de processos. Pequenas e médias empresas (PME), que compõem grande parte do setor metalmeccânico, frequentemente não dispõem de recursos suficientes para essa transição - essa é a realidade de muitas ferramentarias e empresas de usinagem no Brasil.

Além dos custos diretos, a implementação de procedimentos baseadas em ML e automação envolve despesas recorrentes com manutenção de equipamentos, atualização de *softwares* e garantia de conectividade segura entre sensores e sistemas de análise de dados. Essa combinação de custos de capital e operacionais representa uma barreira à adoção em empresas de menor porte, limitando o potencial de modernização e competitividade (HUI, GROBMAN & MACHADO, 2024).

Para diminuir esses desafios, algumas organizações têm adotado estratégias como a implementação gradual de soluções pilotos, parcerias com fornecedores de tecnologia e utilização de serviços baseados em nuvem (*cloud computing*) que reduzem o investimento em infraestrutura própria (PAZ & LOOS, 2020). Outras empresas têm procurado agências governamentais como o Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (SEBRAE), a Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) e o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ). Essas abordagens permitem avaliar o retorno sobre o investimento de forma mais controlada e oferecem maior flexibilidade para expansão futura, sem comprometer a continuidade operacional.

### 3.4 Resistência organizacional

A mudança de paradigmas na produção pode gerar resistência por parte da equipe, especialmente quando há receio de substituição de mão de obra humana por sistemas automatizados. A capacitação contínua dos profissionais e a promoção de uma cultura de inovação são fundamentais para superar essa barreira.

A introdução de tecnologias da Indústria 4.0, como a automação e a IA, encontra resistência em diversos níveis organizacionais. Essa resistência é atribuída ao medo da perda de empregos, à falta de entendimento sobre os benefícios das novas tecnologias, à inércia cultural e à relutância em abandonar métodos de trabalho estabelecidos (LAZZARECHI, GRAGLIA & HUELSEN, 2021). Em muitos casos, a percepção de que as máquinas substituirão os trabalhadores gera insegurança e desmotivação, dificultando a transição para um ambiente de produção mais digitalizado e inteligente.

Para diminuir essa resistência é importante investir na capacitação contínua para transformar os profissionais de meros operadores em colaboradores capazes de interagir e gerenciar sistemas inteligentes. Requalificação e aperfeiçoamento profissional devem focar no desenvolvimento de novas habilidades, como análise de dados, programação básica, manutenção de sistemas automatizados e pensamento crítico, preparando a força de trabalho para os desafios e oportunidades da Indústria 4.0 (BUDIN & LOPES, 2019).

Além da capacitação, é importante a promoção de uma cultura de inovação para a aceitação e o engajamento com as novas tecnologias. Isso envolve a criação de um ambiente em que a experimentação é encorajada, o erro é visto como parte do aprendizado e a colaboração entre diferentes áreas é valorizada. A liderança desempenha um papel fundamental nesse processo, comunicando de forma clara os benefícios da transformação digital, envolvendo os colaboradores nas decisões e demonstrando o compromisso da organização com o desenvolvimento de seus talentos. Ao invés de focar na substituição, deve-se focar na interação entre humanos e máquinas, onde a tecnologia é uma ferramenta para aumentar a produção, a segurança e a qualidade, liberando os trabalhadores para tarefas de maior valor.

### 3.5 Normalização e integração

A padronização na indústria é crucial para otimizar a eficiência, a qualidade e a competitividade. No entanto, diferenças nos *softwares* e equipamentos de CNC representam barreiras à integração de sistemas inteligentes na indústria. Soluções de ML desenvolvidas para um tipo particular de máquina ou controlador não são diretamente aplicáveis em outros ambientes, resultando em customizações complexas e caras. Essa característica dificulta a disseminação de tecnologias avançadas, limitando o potencial de transformação digital das empresas.

Para superar esses desafios é fundamental investir em padronização e em soluções integradas que melhorem a comunicação no ambiente industrial. O uso de padrões abertos, como a norma ISO/IEC-TR 24027:2024 ajuda a garantir a compatibilidade e a reduzir custos com adaptações personalizadas. (LAPIN, 2025). Além disso, a cooperação entre fabricantes, desenvolvedores de *software* e usuários finais é decisiva para criar soluções melhores em que as inovações em ML são aplicadas e reproduzidas.

## 5 Considerações finais

A aplicação da IA e ML na usinagem CNC representa um grande avanço na direção de uma manufatura mais inteligente, autônoma e alinhada aos princípios da Indústria 4.0. Essas tecnologias oferecem suporte à tomada de decisão em tempo real, otimização de processos e melhoria contínua baseada em dados, contribuindo para o aumento da produtividade, da qualidade e da sustentabilidade nas operações industriais.

Este artigo buscou demonstrar, por meio de uma análise técnica e crítica da literatura recente, como diferentes técnicas de IA e ML, tais como redes neurais, algoritmos genéticos e aprendizado por reforço têm sido empregadas para resolver desafios relacionados à usinagem CNC, como o planejamento de trajetórias, o monitoramento de desgaste de ferramentas, a detecção de colisões e a automação do planejamento de processos. Tais aplicações aumentam a eficiência e promovem a flexibilidade e a adaptabilidade dos sistemas de produção.

No entanto, apesar dos avanços alcançados, ainda existem desafios técnicos, organizacionais e econômicos que limitam a adoção em grande escala dessas soluções. A necessidade de infraestrutura adequada para coleta e tratamento de dados, a complexidade de integração, os custos de implementação e a resistência à mudança por parte dos operadores são barreiras reais que precisam ser enfrentadas. Além disso, questões relacionadas à segurança cibernética e padronização dos modelos de IA ainda demandam atenção por parte da comunidade técnica e científica.

Dessa forma, espera-se que, com o avanço contínuo das pesquisas as soluções baseadas em IA e ML se tornem cada vez mais acessíveis, seguras e eficazes. A usinagem CNC, integrada a essas tecnologias, está posicionada para ser um dos pilares dessa nova era da manufatura digital.

## Referências

- AFIF, M. F., SARHAN, A. A. D. Computer-aided process planning, digital twin and smart manufacturing: interconnections and integration in CNC machining processes. **International Journal of Production Research**, p. 1-40, 2025.
- ALEXANDRE, R. P. **Redes neurais – aplicação no monitoramento**. 2005. Dissertação (Mestrado) – Universidade Estadual Paulista Júlio de Mesquita Filho, 2005.
- AT-MACHINING. Célula de Usinagem Automatizada com Máquina CNC e Robô Industrial. In: **AT-MACHINING. Inteligência Artificial na Usinagem CNC: O Futuro da Fabricação**. [S. l.], 2024. Disponível em: <https://at-machining.com/pt/artificial-intelligence-in-cnc-machining/>. Acesso em: 15 nov. 2025.
- BUDIN, D. D., LOPES, A. M. Z. A indústria 4.0 e os desafios para a capacitação profissional. **Revista Tecnológica da FATEC de Americana**, v. 7, n. 2, p. 88-97, 2019.
- ÇEKIK, R., TURAN, A. Deep learning for anomaly detection in CNC machine vibration data: A roughLSTM-Based Approach. **Applied Sciences**, v. 15, n. 6, p. 3179, 2025.
- COLANTONIO, L. *et al.* A systematic literature review of cutting tool wear monitoring in turning by using artificial intelligence techniques. **Machines**, v. 9, n. 12, p. 351, 2021.
- FRANK, A. G., DALENOGARE, L. S., AYALA, N. F. Tecnologias da Indústria 4.0: padrões de implementação em empresas de manufatura. **Revista Internacional de Economia da Produção**, v. 210, p. 15-26, 2019.
- GANESAN, H., MOHANKUMAR, G. Optimization of machining techniques in CNC turning centre using genetic algorithm. **Arabian Journal for Science and Engineering**, v. 38, n. 6, p. 1529-1538, 2013.
- HUI, T. H., GROBMAN, F., MACHADO, M. C. Indústria 4.0 no contexto das pequenas e médias empresas. **International Journal of Scientific Management and Tourism**, v. 10, n. 2, 2024.
- KOMURA, N. *et al.* Computer aided process planning for rough machining based on machine learning with certainty evaluation of inferred results. **International Journal of Automation Technology**, v. 17, n. 2, p. 120-127, 2023.
- LAPIN (LABORATÓRIO DE POLÍTICAS PÚBLICAS E INTERNET). **Regulação da Inteligência Artificial: subsídios para a autoridade competente no Brasil**. Disponível em: <<https://lapin.org.br/uploads/2024/12/final.pdf>>. Acesso em: 15 nov. 2025.
- LAZZARESCHI, N., GRAGLIA, M. A. V., HUELSEN, P. G. V. As formas de resistência dos trabalhadores no contexto da Indústria 4.0 e da Inteligência Artificial. **Argumentum**, v. 13, n. 2, p. 193-207, 2021.
- LECUN, Y., BENGIO, Y., HINTON, G. Deep learning. **Nature**, v. 521, p. 436-444, 2015.

MDPI (MULTIDISCIPLINARY DIGITAL PUBLISHING INSTITUTE). **Machine-Learning and Internet of Things Driven Techniques for Monitoring Tool Wear in Machining Process: A Comprehensive Review**. 2021. Disponível em: <<https://www.mdpi.com/2224-2708/13/5/53>>. Acesso em: 16 nov. 2025.

MÜLLER, J. *et al.* Cooperation strategies among SMEs for implementing industry 4.0. In: DIGITALIZATION IN SUPPLY CHAIN MANAGEMENT AND LOGISTICS: Smart and Digital Solutions for an Industry 4.0 Environment. **Proceedings of the Hamburg International Conference of Logistics (HICL)**, v. 23. Berlin: Epubli GmbH, 2017. p.301-318.

MUNARO, R., ATTANASIO, A., DEL PRETE, A. 2023. Tool Wear Monitoring with Artificial Intelligence Methods: A Review. **Journal of Manufacturing and Materials Processing**. Disponível em: <[https://www.mdpi.com/2504-4494/7/4/129?utm\\_source=researchgate.net&utm\\_medium=article](https://www.mdpi.com/2504-4494/7/4/129?utm_source=researchgate.net&utm_medium=article)>. Acesso em: 15 nov. 2025.

NCD.IO. **Industrial IoT Wireless Predictive Maintenance Sensor V3**. [S.d.]. Disponível em: <<https://store.ncd.io/product/iot-wireless-predictive-maintenance-sensor/>>. Acesso em: 15 nov. 2025.

NIKIFORIDIS, K. *et al.* Enhancing transparency and trust in AI-powered manufacturing: A survey of explainable AI (XAI) applications in smart manufacturing in the era of Industry 4.0/5.0. **ICT Express**, v. 11, n. 1, p. 135-148, 2025.

OLIVEIRA, D. F. N. **Interpretabilidade de modelos de aprendizado profundo aplicados ao diagnóstico e prognóstico não supervisionado de falhas**. Tese (Doutorado) – Universidade de São Paulo, 2020. Disponível em: <<https://www.teses.usp.br/teses/disponiveis/3/3141/tde-08032021-102116/en.php>>. Acesso em: 20 jun. 2025.

OSAN, A. R., DRENÇA, R. F. Application of artificial neural networks in predicting surface quality and machining time. **Machines**, v. 13, n. 7, p. 561, 2025.

PATIL, S. S. *et al.* Deep learning algorithms for tool condition monitoring in milling: A review. In: **JOURNAL OF PHYSICS: Conference Series**. IOP Publishing, 2021, p. 012039.

PAZ, A. C. M., LOOS, M. J. A importância da computação em nuvem para a indústria 4.0. **Revista Gestão Industrial**, v. 16, n. 2, 2020.

SERIN, G. *et al.* Review of tool condition monitoring in machining and opportunities for deep learning. **The International Journal of Advanced Manufacturing Technology**, v. 109, n. 3, p. 953-974, 2021.

SERRADILLA, O. *et al.* Deep learning models for predictive maintenance: a survey, comparison, challenges and prospects. **Applied Intelligence**, v. 52, n. 10, p. 10934-10964, 2022.

SILVA, C. R., MELLO, J. C., SALGADO, R. J. Relação Hierárquica entre Inteligência Artificial, Machine Learning e Deep Learning. In: **NÚCLEO DO CONHECIMENTO. Deep Learning: A Revolução da Inteligência Artificial** [S.l.], 2019. Disponível em: <<https://www.nucleodoconhecimento.com.br/administracao/deep-learning>>. Acesso em: 15 nov. 2025.

WANG, Q. *et al.* Overview of tool wear monitoring methods based on convolutional neural network. **Applied Sciences**, v. 11, n. 24, p. 12041, 2021.

WANG, Q. *et al.* Overview of Tool Wear Monitoring Methods Based on Convolutional Neural Network. **Applied Sciences**, v. 11, n. 24, p. 12041, 2021. Disponível em: <<https://www.mdpi.com/2076-3417/11/24/12041>>. Acesso em: 15 nov. 2025.

XU, G. *et al.* Data-driven fault diagnostics and prognostics for predictive maintenance: A brief overview. In: **IEEE INTERNATIONAL CONFERENCE ON AUTOMATION SCIENCE AND ENGINEERING (CASE)**, 15., 2019. p. 103-108.

YAO, X. *et al.* Smart manufacturing based on cyber-physical systems and beyond. **Journal of Intelligent Manufacturing**, v. 30, n. 8, p. 2805-2817, 2019.

ZHANG, Z., JAISWAL, P., RAI, R. Feature Net: Machining feature recognition based on 3D convolution neural network. **Computer-Aided Design**, v. 101, p. 12-22, 2018.

ZHENG, H., PAIVA, A. R., GURCIULLO, C. S. **Advancing from predictive maintenance to intelligent maintenance with AI and IoT**. 2020. Disponível em: <<https://arxiv.org/abs/2009.00351>>. Acesso em 15 nov. 2025.