

UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
FACULDADE DE ENGENHARIA MECÂNICA

João Victor Assunção Pereira

**Aprimorando Processos de Usinagem com Inteligência Artificial:  
Uma Revisão Abrangente**

Uberlândia - MG

2025

João Victor Assunção Pereira

**Aprimorando Processos de Usinagem com Inteligência Artificial:  
Uma Revisão Abrangente**

Trabalho de Conclusão de Curso apresentado à  
Faculdade de Engenharia Mecânica da  
Universidade Federal de Uberlândia como  
requisito parcial para obtenção do título de  
bacharel em Engenharia Mecatrônica.

Orientador: Profº Doutor Leonardo Rosa  
Ribeiro da Silva

Uberlândia - MG

2025

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU  
com dados informados pelo(a) próprio(a) autor(a).

P436 Pereira, João Victor Assunção, 2000-  
2025 Aprimorando Processos de Usinagem com Inteligência Artificial  
[recurso eletrônico] : Uma Revisão Abrangente / João Victor  
Assunção Pereira. - 2025.

Orientador: Leonardo Rosa Ribeiro da Silva.  
Trabalho de Conclusão de Curso (graduação) - Universidade  
Federal de Uberlândia, Graduação em Engenharia Mecatrônica.  
Modo de acesso: Internet.  
Inclui bibliografia.

1. Mecatrônica. I. Silva, Leonardo Rosa Ribeiro da,1991-,  
(Orient.). II. Universidade Federal de Uberlândia. Graduação em  
Engenharia Mecatrônica. III. Título.

CDU: 621.03

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091

Nelson Marcos Ferreira - CRB6/3074



## UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Curso de Graduação em Engenharia Mecatrônica  
Rodovia BR 050, KM 78, Bloco 1D, 2º andar - Bairro Glória, Uberlândia-MG, CEP 38400-902  
Telefone: (34) 2512-6771 - www.mecanica.ufu.br - mecatronica@mecanica.ufu.br



### ATA DE DEFESA - GRADUAÇÃO

Curso de Graduação em:	Engenharia Mecatrônica				
Defesa de:	FEMEC42100 - Projeto de Fim de Curso II				
Data:	16/09/2025	Hora de início:	13:30	Hora de encerramento:	15:00
Matrícula do Discente:	11921EMT008				
Nome do Discente:	João Victor Assunção Pereira				
Título do Trabalho:	Aprimorando Processos de Usinagem com Inteligência Artificial: Uma Revisão Abrangente				
A carga horária curricular foi cumprida integralmente?	<input checked="" type="checkbox"/> Sim <input type="checkbox"/> Não				

Reuniu-se de forma remota, através da Plataforma Digital Microsoft Teams (<https://teams.microsoft.com/l/team/19%3AZ3GvgRd857A95VIPVYQtG24KIhDW-wEDnJ9lbOIerU1%40thread.tacv2/conversations?groupId=09a0d580-807a-4999-90ce-e1094bda9779&tenantId=cd5e6d23-cb99-4189-88ab-1a9021a0c451>), a Banca Examinadora, designada pelo docente orientador, assim composta: Prof. Dr. Luiz Eduardo dos Santos Paes - FEMEC/UFU; Eng. M.Sc. Felipe Chagas Rodrigues de Souza - Doutorando/FEMEC/UFU; e Prof. Dr. Leonardo Rosa Ribeiro da Silva - FEMEC/UFU, orientador do candidato.

Iniciando os trabalhos, o presidente da mesa, Prof. Dr. Leonardo Rosa Ribeiro da Silva, apresentou a Comissão Examinadora e o candidato, e concedeu ao estudante a palavra, para a exposição do seu trabalho. A duração da apresentação do estudante e o tempo de arguição e resposta foram conforme as normas do curso.

A seguir o(a) senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(as) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado sem nota.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Leonardo Rosa Ribeiro da Silva, Professor(a) do Magistério Superior**, em 16/09/2025, às 14:32, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Luiz Eduardo dos Santos Paes**, **Professor(a) do Magistério Superior**, em 16/09/2025, às 14:57, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Felipe Chagas Rodrigues de Souza**, **Usuário Externo**, em 16/09/2025, às 21:43, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site  
[https://www.sei.ufu.br/sei/controlador\\_externo.php?  
acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **6684415** e o código CRC **E9444F82**.

**Referência:** Processo nº 23117.064588/2025-84

SEI nº 6684415

João Victor Assunção Pereira

**Aprimorando Processos de Usinagem com Inteligência Artificial:  
Uma Revisão Abrangente**

Trabalho de Conclusão de Curso apresentado à  
Faculdade de Engenharia Mecânica da  
Universidade Federal de Uberlândia como  
requisito parcial para obtenção do título de  
bacharel em Engenharia Mecatrônica.

Uberlândia, 2025

Banca Examinadora:

---

Prof. Dr. Leonardo Rosa Ribeiro da Silva - Orientador (UFU)

---

Mestre Felipe Chagas Rodrigues de Souza (UFU)

---

Prof. Dr. Luiz Eduardo dos Santos Paes (UFU)

Dedico este trabalho aos meus pais e minha  
avó, por todo o apoio e compreensão para eu  
estar aqui.

## **AGRADECIMENTOS**

Agradeço ao professor e Doutor Leonardo Rosa Ribeiro da Silva e também ao Mestre Felipe Chagas Rodrigues de Souza pelo incentivo, motivação e orientação nesta caminhada acadêmica.

Aos meus grandes colegas da turma 32 de engenharia mecatrônica, por passar todos esses anos de graduação juntos, além das experiências que irei levar para o resto da minha vida.

Agradeço a minha noiva, Emily Taziri, por estar presente do início ao fim da minha graduação, por todo o apoio, amor e compreensão.

Agradeço à minha amada mãe, pelo apoio incondicional em todos os momentos, sem ela eu jamais conseguiria chegar onde estou.

Agradeço também aos diversos professores que possibilitaram essa jornada, vocês foram a base para diversas inspirações que adquiri ao longo dessa formação.

“A Inteligência Artificial é a nova eletricidade. Ela irá transformar todos os setores da sociedade e impulsionar o progresso humano de uma forma sem precedentes.”

(NG, Andrew, *AI is the New Electricity*, 2017)

## RESUMO

O presente trabalho consiste em uma revisão bibliométrica e abrangente sobre a aplicação de técnicas de inteligência artificial nos processos de usinagem. O objetivo central do estudo foi mapear o cenário de pesquisa científica no período de 2021 a 2025, com o intuito de identificar as principais tendências e lacunas de estudo, quantificando o impacto de diversas técnicas de inteligência artificial em processos como fresamento, torneamento, furação e retificação. Para possibilitar esta pesquisa, 85 artigos foram analisados estatisticamente para gerar dados sobre o tema. Como resultado, fresamento e torneamento foram os processos mais investigados, enquanto machine learning e redes neurais artificiais são as técnicas mais dominantes. Foi revelado que o foco principal das pesquisas reside na otimização da rugosidade superficial e do desgaste da ferramenta, embora se observe um crescimento notável na avaliação de impactos ambientais e econômicos. Também foi possível identificar os desafios persistentes, como a gestão do big data e a dificuldade da generalização dos modelos de inteligência artificial para diferentes cenários industriais. Concluiu-se que o campo de pesquisa é maduro em otimização de qualidade e desgaste, mas aponta para novas direções promissoras, como o uso de abordagens híbridas e gêmeos digitais para superar as limitações existentes. Sugere-se para trabalhos futuros o foco em soluções mais acessíveis e padronizadas que permitam a transição para a manufatura inteligente, garantindo a máxima eficiência, qualidade e sustentabilidade.

**Palavras-chave:** inteligência artificial; usinagem; revisão bibliométrica; manufatura inteligente; otimização de parâmetros, sustentabilidade, desgaste de ferramenta, análise de dados.

## ABSTRACT

This work consists of a comprehensive bibliometric review on the application of artificial intelligence techniques in machining processes. The central objective of the study was to map the scientific research scenario from 2021 to 2025, aiming to identify the main trends and research gaps, quantifying the impact of various artificial intelligence techniques on processes such as milling, turning, drilling, and grinding. To enable this research, 85 articles were statistically analyzed to generate data on the topic. As a result, milling and turning were the most investigated processes, while machine learning and artificial neural networks are the most dominant techniques. It was revealed that the main focus of the research lies in optimizing surface roughness and tool wear, although a notable growth in the evaluation of environmental and economic impacts is observed. It was also possible to identify persistent challenges, such as big data management and the difficulty of generalizing artificial intelligence models for different industrial scenarios. It was concluded that the research field is mature in quality and wear optimization but points to new promising directions, such as the use of hybrid approaches and digital twins to overcome existing limitations. It is suggested for future work to focus on more accessible and standardized solutions that allow the transition to intelligent manufacturing, ensuring maximum efficiency, quality, and sustainability.

**Keywords:** artificial intelligence; machining; bibliometric review; intelligent manufacturing; parameter optimization; sustainability; tool wear; data analysis.

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>13</b>
<b>2 OBJETIVOS.....</b>	<b>14</b>
<b>3 REVISÃO BIBLIOGRÁFICA .....</b>	<b>15</b>
<b>3.1 Visão geral dos processos de usinagem.....</b>	<b>15</b>
<b>3.1.1 Torneamento .....</b>	<b>15</b>
<b>3.1.2 Fresamento .....</b>	<b>16</b>
<b>3.1.3 Furação .....</b>	<b>17</b>
<b>3.1.4 Retificação .....</b>	<b>19</b>
<b>3.2 Visão geral das técnicas de IA e Big Data.....</b>	<b>20</b>
<b>3.2.1 Machine Learning (ML).....</b>	<b>21</b>
<b>3.2.2 Redes Neurais (NN) .....</b>	<b>22</b>
<b>3.2.3 Algoritmos Genéticos (GA) .....</b>	<b>24</b>
<b>3.2.4 Lógica Fuzzy ou Lógica Difusa (FL) .....</b>	<b>26</b>
<b>3.2.5 Metodologia de Superfície de Resposta (RSM).....</b>	<b>28</b>
<b>3.2.6 Big Data .....</b>	<b>30</b>
<b>4 METODOLOGIA.....</b>	<b>31</b>
<b>5 RESULTADOS E DISCUSSÕES.....</b>	<b>35</b>
<b>5.1 Desafios do Big Data e Generalização dos Modelos .....</b>	<b>35</b>
<b>5.2 O Papel da IA na Manufatura Inteligente e no Controle de Qualidade.....</b>	<b>39</b>
<b>5.3 Pesquisas de Processos de Usinagem com o Uso de Inteligência Artificial .....</b>	<b>43</b>
<b>5.3.1 Pesquisas com o uso de Aprendizado de Máquina (ML) .....</b>	<b>45</b>
<b>5.3.2 Pesquisas com o uso de Redes Neurais Artificiais (ANN) .....</b>	<b>48</b>
<b>5.3.3 Pesquisas com o uso de Algoritmos Genéticos (GA).....</b>	<b>51</b>
<b>5.3.4 Pesquisas com o uso de Lógica Fuzzy (FL) .....</b>	<b>54</b>
<b>5.3.5 Pesquisas com o uso de Metodologia da Superfície de Resposta (RSM) .....</b>	<b>57</b>
<b>5.4 Características Gerais dos Temas de Pesquisa dos Artigos .....</b>	<b>60</b>
<b>6 CONCLUSÃO .....</b>	<b>65</b>
<b>REFERÊNCIAS.....</b>	<b>67</b>
<b>APÊNDICE A – TABELA DE DADOS DA REVISÃO.....</b>	<b>81</b>

## 1 INTRODUÇÃO

A usinagem é um dos pilares fundamentais da indústria de manufatura, sendo um processo de fabricação vital na criação de peças e componentes para praticamente todos os setores, que envolve a remoção controlada de material de uma peça para atingir a forma, as dimensões e o acabamento superficial desejados (EL-HOFY, 2018). Os processos são de importância global, estando interligados na produção em massa e também na fabricação de componentes de alta precisão para indústrias aeroespaciais e biomédicas. Porém, fica evidente a grande quantidade de desafios que a usinagem tradicional enfrenta, incluindo a necessidade de otimizar os parâmetros de corte, o monitoramento do desgaste das ferramentas e, além disso, a garantia de qualidade superficial das peças de forma eficiente, econômica e que esteja adequada aos padrões ambientais no cenário atual. Então, é nesse contexto que a busca pela maior produtividade, qualidade e sustentabilidade, impulsiona a indústria a buscar inovações tecnológicas para superar tais limitações.

Nesse cenário, a Inteligência Artificial (IA) está se consolidando cada vez mais como uma tecnologia transformadora, sendo capaz de aprimorar quase todos os aspectos da manufatura, desde o design de produtos até as operações da fábrica, permitindo a criação de sistemas inteligentes que, com base em dados, identificam padrões para descobrir novas correlações, fazer previsões nos processos de usinagem, otimizar o desempenho e minimizar o tempo de inatividade (FERNÁNDEZ MARTÍNEZ et al., 2024). Por meio de diversas técnicas da IA, como *Machine Learning* (ML), Redes Neurais Artificiais (ANN) e outras técnicas, é possível criar sistemas capazes de tomar decisões autônomas, oferecendo um controle mais preciso e adaptativo, tendo uma aplicação no monitoramento em tempo real do desgaste da ferramenta, detecção automática de defeitos e rachaduras por meio da visão computacional (GÖKTEPE; UZUN, 2025), e também a otimização complexa de diversos parâmetros de corte para melhorar a qualidade do acabamento superficial da peça.

Com toda essa complexidade nos processos de usinagem, devido às variáveis multifatoriais e relações não lineares, são gerados grande volumes de dados através de múltiplos experimentos, que variam não só no processo em si, mas também em toda a configuração de aquisição de dados, laboratórios, softwares e diversos outras variações possíveis, sendo englobados no que comumente é referido de *Big Data*. Essa riqueza de dados, no entanto, torna inviável a análise e a tomada de decisão em tempo real usando métodos estatísticos ou empíricos tradicionais (LAMPATHAKI et al., 2024). Assim, as técnicas de IA se destacam, devido a sua capacidade de processar e extrair padrões significativos desse volume

de dados, possibilitando a transformação de informações brutas em *insights* que otimizam a produção e eficiência.

Este trabalho apresenta uma revisão bibliométrica abrangente sobre a aplicação da tecnologia de IA nos processos tradicionais de usinagem, abordando a produção científica no período de 2021 a 2025, tendo como objetivo fazer o mapeamento desse cenário. O impacto de técnicas específicas como *Machine Learning*, Redes Neurais, Algoritmos Genéticos, Lógica Fuzzy e Metodologia da Superfície de Resposta, em processos de Fresamento, Torneamento, Furação e Retificação, é quantificado de forma que seja possível a discussão sobre as singularidades de cada achado. O estudo serve como bússola para revelar as principais tendências e as áreas de estudo mais robustas, de forma que seja possível identificar oportunidades para novas investigações no campo.

A estrutura deste trabalho está dividida, inicialmente, na revisão bibliométrica, que explicita os conceitos de usinagem e IA que serão discutidos, a metodologia da coleta e a análise de dados, que visa mostrar o passo a passo de como a revisão bibliométrica foi feita, a apresentação dos resultados estatísticos com base nos artigos analisados e a discussão sobre as características e dificuldades que foram observadas ao longo das diversas pesquisas abordadas. Com isso, a conclusão termina sintetizando os achados e dificuldades, de forma que as contribuições dessa pesquisa fiquem evidentes, além de também discutir sobre as limitações do estudo e sugestões para futuras melhorias no trabalho em si.

## 2 OBJETIVOS

O objetivo desse Trabalho de Conclusão de Curso é a confecção de uma Revisão Bibliométrica sobre o uso de técnicas de Inteligência Artificial para a otimização de processos de usinagem. Essa Revisão Bibliométrica tem o intuito de compreender como o campo de pesquisa nessa área está se moldando ao longo dos anos, visando servir como apoio para mostrar o impacto de cada técnica e seus devidos processos de usinagem. Com isso, é possível estabelecer uma conexão de resultados a partir do ano da publicação e do tema do artigo publicado, ajudando a identificar impactos e lacunas de pesquisa para áreas que ainda não foram suficientemente exploradas, possibilitando sugestões de futuras investigações.

### 3 REVISÃO BIBLIOGRÁFICA

#### 3.1 Visão geral dos processos de usinagem

Existem diversos processos diferentes de usinagem sendo utilizados para permitir a confecção e utilização de inúmeras peças em diversos setores no mundo. Nesta seção, serão apresentados os principais tipos de processos de usinagem que são relevantes em um contexto de aplicação de Inteligência Artificial, seguindo a lógica que será apresentada neste trabalho de revisão bibliométrica.

##### 3.1.1 Torneamento

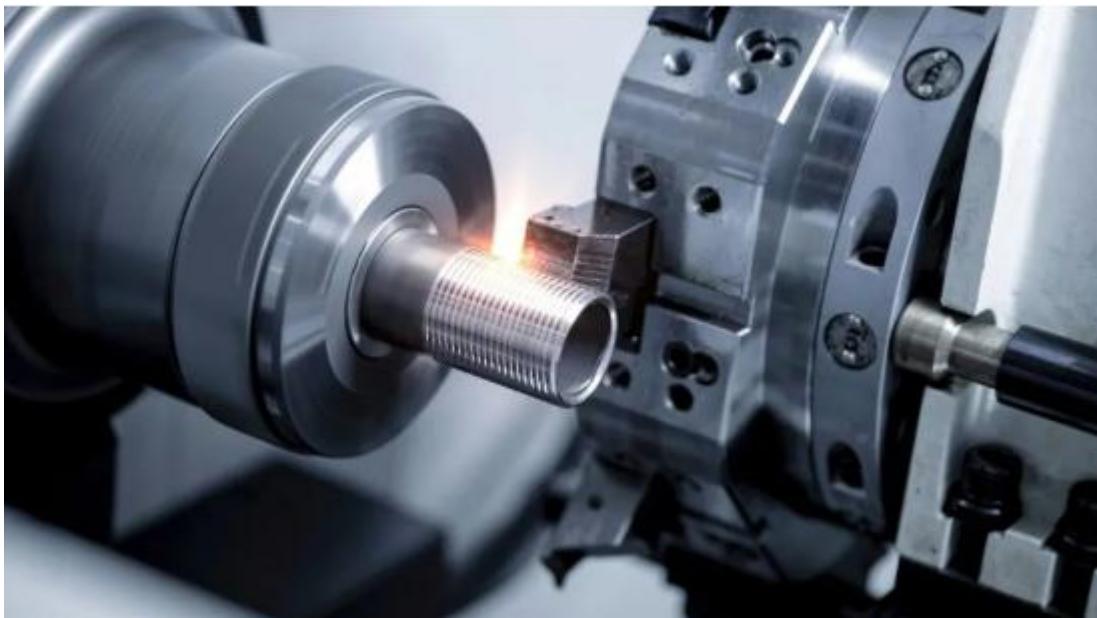
O torneamento é um antigo processo de usinagem da indústria manufatureira, sendo caracterizado pela remoção de material de uma peça que gira em torno do seu próprio eixo, e enquanto esse processo ocorre, uma ferramenta de corte se move de forma linear e cria superfícies cilíndricas, cônicas ou outras geometrias de revolução. Diversos são os fatores que influenciam na qualidade de uma peça usinada por torneamento, porém é necessário definir os parâmetros que estão na relação de entrada-saída do processo. A velocidade de corte ( $vc$ ) é a velocidade periférica da peça, a taxa de avanço é a velocidade do movimento da ferramenta ao longo do eixo da peça torneada para uma rotação, sendo definido como *feed rate* ( $f$ ). Esses parâmetros juntos com a profundidade do corte irão afetar de forma clara a qualidade do acabamento superficial, o comportamento do corte e o desgaste na ferramenta.

Existem diversos tipos possíveis de operações no torneamento, sendo que de acordo com Ye (2025):

- Faceamento: Usado para nivelar a superfície final de uma peça em rotação, aparecendo mais em etapas de preparação ou acabamento;
- Mandrilagem: Refina ou alarga um diâmetro interno ao longo do eixo da peça, melhorando concentricidade e tolerância;
- Rosqueamento: Usa insertos especializados e avanços que envolvem o corte de roscas internas ou externas;
- Acabamento de canais: Corta ranhuras estreitas ou rebaixos nas superfícies externas ou internas.
- Recartilhamento: Cria texturas padronizadas para aderência ou fim estético.

Na Figura 1 é possível observar o processo de torneamento na prática.

**Figura 1:** Processo de torneamento.



Fonte: Adaptado de 3ERP (2025, Torneamento vs Fresamento).

### 3.1.2 Fresamento

O fresamento utiliza também uma ferramenta de corte rotativa, porém essa possui múltiplas arestas para remover o material da peça de trabalho. Essa ferramenta, conhecida como fresa, gira em alta velocidade enquanto a peça de trabalho vai se movimentando contra ela, o que permite a criação de várias geometrias, sendo contornos, superfícies planas, ranhuras e formas complexas. Essa flexibilidade permite a fresagem ser um dos processos de usinagem mais versáteis atualmente. É válido mencionar algumas operações comuns nesse processo, novamente, segundo Ye (2025):

- Faceamento: Corta uma superfície plana na parte superior da peça, ideal para esquadrejar material e criar planos horizontais precisos;
- Fresamento de Ranhuras: Utilizado para cortar ranhuras, canais ou ombros nas laterais da peça, usando as arestas externas da ferramenta;
- Contorno e Fresamento Angular: Feito para componentes com superfícies angulares ou curvas, o que permite a criação de chanfros, inclinações e perfis complexos;
- Fresamento de Cavidades: Remove material do interior de uma peça, o que produz características rebaixadas como cavidades ou ranhuras;
- Fresamento Especializado (Helicoidal, de Roscas, de Engrenagens): São métodos avançados que dependem de controle preciso do caminho da fresa e da profundidade do corte para realizar geometrias complexas.

Na Figura 2 é possível observar o processo de Fresamento na prática.

**Figura 2:** Processo de Fresamento.



Fonte: Adaptado de Wolf Brasil (s.d, Fresamento: como funciona esse Processo de Usinagem e quais as Aplicações).

### 3.1.3 Furação

A furação é um processo em que furos cilíndricos são feitos em uma peça, utilizando uma ferramenta de corte rotativa, a broca. Essa ferramenta possui arestas de corte em sua extremidade, avança axialmente na peça, removendo o material e formando um furo. A eficiência de furação depende também de diversos fatores, como velocidade de rotação da broca, taxa de avanço, material da peça e da broca, geometria de ferramenta, adequada remoção de cavacos e também a aplicação do fluido de corte. Mesmo sendo uma operação simples, possui diversas aplicações nos processos de fabricação e industriais, sendo válido destacar algumas de suas operações, segundo Ye (2024):

- Furação de Centro: Funciona como guia na superfície da peça, garantindo o devido posicionamento das brocas e ajustando a precisão de furo;
- Alargamento: Serve como acabamento para melhorar a precisão e é essencial para adequar tolerâncias apertadas;
- Mandrilamento: Amplia furos existentes para um diâmetro específico com maior precisão;

- Escareamento Cilíndrico: Cria um furo escalonado para permitir que a cabeça de um parafuso ou pino fique nivelada ou abaixo da superfície da peça;
- Escareamento Cônico: Cria um furo cônico para que a cabeça de um parafuso fique nivelada com a superfície;
- Rosqueamento: Cria roscas internas em um furo pré-furado para permitir a inserção de parafusos;
- Microfuração: Furos extremamente pequenos, muitas vezes em micrômetros, sendo necessário máquinas CNC especializadas;
- Furação com picote: É uma técnica para furos profundos, os quais envolvem a retração periódica da broca, isso ajuda a quebrar e evacuar cavacos, reduzindo entupimentos e acúmulo de calor;
- Furação de Arma: Cria furos profundos e retos com alta precisão, utilizando uma longa e fina broca com canais de refrigeração internos;
- Furação Vibratória: Incorpora vibração ao processo, o que melhora condições de corte e vida útil da ferramenta, otimizando taxas de remoção de material e reduzindo falhas na broca.

Na Figura 3 é possível observar o processo de Furação na prática.

**Figura 3:** Processo de Furação.



Fonte: Adaptado de WCM COMPONENTES (s.d, Furação e Rosqueamento).

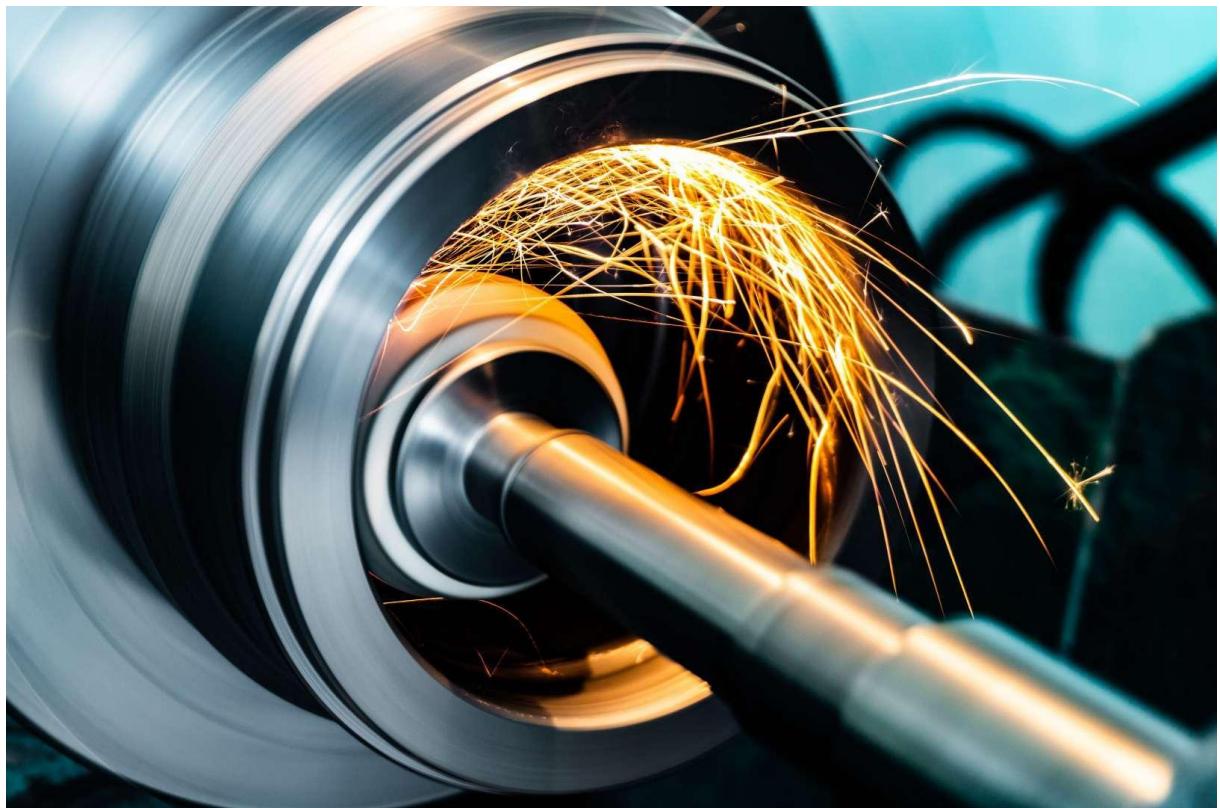
### 3.1.4 Retificação

O processo de retificação (*grinding*) envolve a remoção do material de uma peça de trabalho, utilizando uma ferramenta de corte rotativa, que é composta por grãos abrasivos que servem para remover o material da superfície de uma peça. É um processo essencial na produção de peças que precisam de superfícies de alta qualidade e com pouca tolerância, sendo muito utilizada no acabamento de diversos componentes de máquinas. Assim como os outros processos aqui destacados, segundo Ye (2024), diversos parâmetros podem modificar a qualidade final da peça, como a velocidade de corte da ferramenta, a velocidade relativa da peça, a taxa de avanço, aplicação de líquidos refrigerantes para o controle de temperatura, alinhamento e retificação dos rebolos, a pressão aplicada durante o processo de retificação na usinagem e a rigidez do equipamento alteram a precisão e acabamento. Segundo o que Ye (2024) diz, existem diversos tipos de operação de retificação:

- Retificação a Seco: Não utiliza fluido de corte ou lubrificante, sendo usado quando a geração de calor não é uma preocupação significativa;
- Retificação Úmida: Introduz o uso de fluido de corte ou lubrificante no processo, reduzindo o calor gerado e minimizando danos térmicos para alcançar acabamentos finos, especialmente em materiais sensíveis ao calor;
- Retificação Bruta: Foco na remoção rápida de grandes quantidades de material;
- Retificação de Alta Velocidade: Usa um rebolo que gira em velocidades muito mais altas que o normal, permitindo alta precisão e acabamentos finos em um ritmo mais rápido;
- Retificação Vibratória: A peça e ferramenta abrasiva são colocadas em um recipiente vibratório, sendo que a vibração faz a ferramenta esfregar contra a peça, servindo para rebarbar e polir superfícies;
- Retificação de Superfície Rotativa: Utiliza um fuso vertical e mesa magnética rotativa, para remoção rápida de material em peças grandes;
- Retificação de Ultraprecisão: Busca acabamentos extremamente finos e dimensões ultraprecisas, empregando o uso de máquinas com alta tolerância e controle de temperatura e vibração para máxima precisão;
- Retificação Eletroquímica (ECG): Combina a usinagem eletroquímica com a retificação usual, usando rebolo rotativo e fluido eletrolítico para remover material por dissolução anódica, sendo útil para materiais duros e com pouca geração de calor, sendo adequado para peças de parede fina.
- Retificação Peel: Usa um rebolo estreito que segue um caminho programável, sendo similar ao torneamento, o que permite uma retificação de alta precisão em perfis complexos;
- Retificação Criogênica: Resfria o material a baixas temperaturas, o que facilita a retificação de materiais tipicamente resistentes e sensíveis ao calor (plásticos, borracha e certos metais que se tornam quebradiços em baixas temperaturas).

Essas diferentes formas de utilizar a retificação mostram a alta versatilidade desse processo de usinagem e como diversos parâmetros são essenciais para realizar um trabalho de qualidade. Na Figura 4 é possível visualizar o processo de retificação na prática.

**Figura 4:** Processo de Retificação.



Fonte: Adaptado de Retificadora Canadense (s.d., Serviços de Retífica).

### 3.2 Visão geral das técnicas de IA e Big Data

Para dar continuidade no entendimento das técnicas de IA que foram analisadas durante a revisão bibliométrica, é necessário especificar de forma a conceituar os padrões de cada técnica. Nessa seção, as técnicas de Machine Learning (ML), Redes Neurais (NN), Algoritmos Genéticos (GA) e Lógica Fuzzy serão abordadas de forma objetiva. Além disso, também é vital explicitar um modelo de estatística que também foi usado em algumas análises de pesquisadores em conjunto com as técnicas de IA, a metodologia de superfície de resposta.

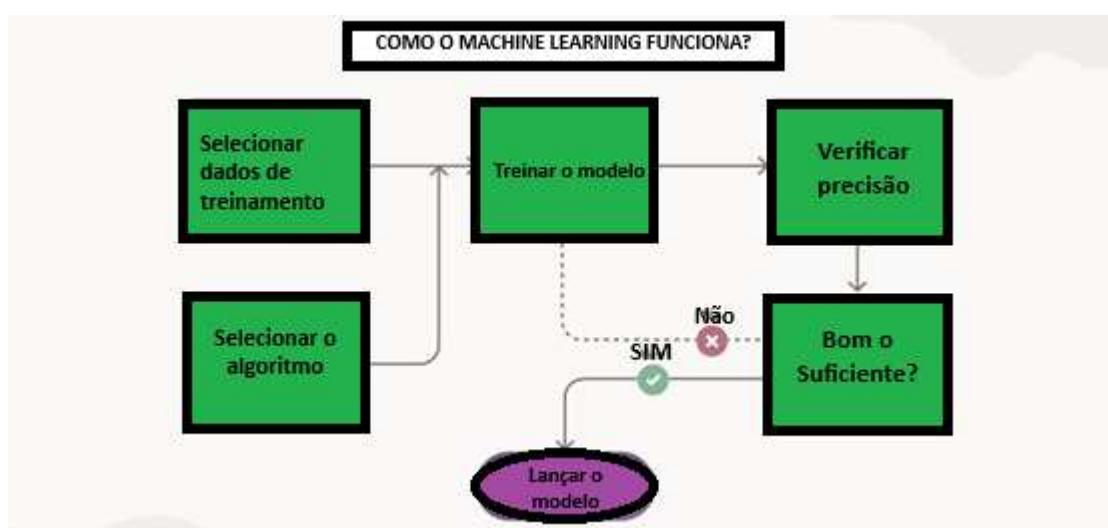
### 3.2.1 Machine Learning (ML)

Segundo Brown (2021), Machine Learning (Aprendizado de Máquina) é um subcampo da Inteligência Artificial (IA), que busca capacitar máquinas a imitar o comportamento inteligente do ser humano. A IA é um conceito amplo da criação de sistemas para resolver problemas como humanos, sendo o ML uma dessas formas de criação.

Uma das vantagens do ML, é que ao invés de se usar uma programação habitual (muitas instruções detalhadas), é possível ensinar os computadores a “se programar” com experiência, e existem diversas formas de se ensinar a máquina, facilitando trabalhos que demorariam muito tempo para ser feito de forma manual, colocando como exemplo o reconhecimento de imagens de objetos e pessoas.

O Aprendizado de Máquinas possui alguns padrões para funcionar, sendo necessário uma grande quantidade de dados para começar a trabalhar de forma eficiente, esses dados podem ser números, fotos, textos e outros, pois eles serão utilizados como dados de treinamento. Além disso, vários modelos de ML existem e tem suas vantagens dependendo do tipo de processo que o programador quer resolver, ajustando os parâmetros e dados de forma que os resultados previstos sejam mais precisos. Nesse caso, dados são separados em dados de treinamento e dados de teste para que seja possível analisar as estatísticas e avaliar a qualidade do modelo para as previsões com dados nunca antes vistos. Na Figura 5, é possível visualizar os passos discutidos de como o ML funciona.

**Figura 5:** Como o Machine Learning funciona.



Fonte: Adaptado de Oracle (2024, O que é Machine Learning?).

Existem algumas subcategorias principais em que o Aprendizado de Máquina está mais comumente ligado e que também aparecem nos artigos e pesquisas que foram realizadas ao longo dos anos relacionados com os processos de usinagem, sendo definidos por Brown (2021) como:

- Aprendizado Supervisionado: Os modelos são treinados com conjuntos de dados rotulados, sendo que esses rótulos ajudam o modelo a aprender. Por exemplo, um algoritmo de ML que é treinado com fotos de cães, sendo rotuladas como “cão”, possibilitando o aprendizado do modelo por conta própria. Esse tipo é o mais comum hoje.
- Aprendizado Não Supervisionado: Diferente do supervisionado, dessa vez o modelo tem que procurar padrões em dados que não são rotulados. Por exemplo, uma análise de dados de vendas online que identifica diversos tipos de clientes, porém esses não foram definidos previamente.
- Aprendizado por Reforço: Esse tipo treina as máquinas por tentativa e erro, utilizando um sistema de recompensas que incentiva os acertos e penaliza por erros. Por exemplo, o treino de modelos de veículos autônomos, o veículo será recompensado se tomar decisões corretas e seguir um percurso de forma a evitar colisões, sendo que com qualquer colisão ele é penalizado e deve começar o teste novamente.

Existem diversos subcampos do estudo de ML e diversas aplicações no contexto atual sendo comum ligações com o mercado financeiro, setor médico, mídia de streaming, varejo e muitos outros que trabalham com o uso de dados no cotidiano. Porém, sempre é necessário averiguar a qualidade dos dados, sendo importante o uso de técnicas de estatística e tratamento para que vieses sejam evitados, overfitting ou underfitting, que são os casos em que um modelo se acostuma muito somente com os dados de treinamento e não consegue prever de forma eficaz dados que ele nunca viu. Por isso, é de bom senso diversificar os dados e garantir uma boa otimização dos parâmetros nos modelos para que ele possa ser utilizado em cenários reais.

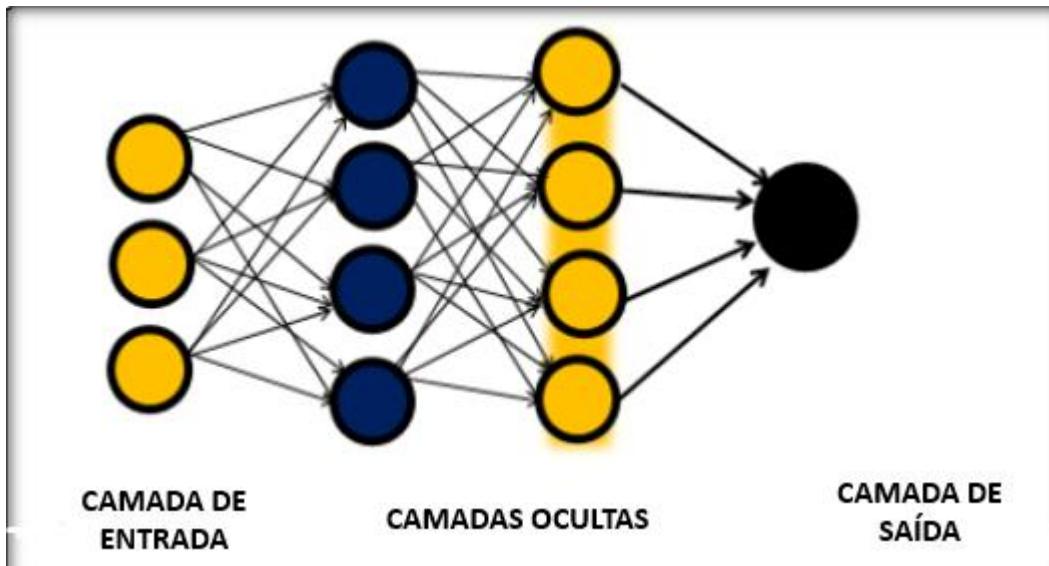
### **3.2.2 Redes Neurais (NN)**

As Redes Neurais (NN), que também são conhecidas como Redes Neurais Artificiais (ANN), são um subcampo do Aprendizado de Máquina. Elas são inspiradas no cérebro humano, replicando as formas que os neurônios se comunicam. Qamar e Zardari (2023) descreveram as ANNs como sistemas massivamente paralelos que são compostos por um grande número de processadores básicos interconectados.

Uma Rede Neural Artificial é composta por um sistema de modelagem de dados não linear, em que os modelos e padrões são estabelecidos de forma complexa entre entradas e

saídas. A capacidade de aprendizado delas, segundo Qamar e Zardari (2023), é superior e são comumente usadas em tarefas como reconhecimento de escrita e reconhecimento facial. As redes são compostas por três camadas diferentes, sendo uma de “entrada” que é conectada a uma ou mais camadas “ocultas”, que estão conectadas com uma camada de “saída”. Esses dados passam por essas camadas até atingir um resultado na camada de saída. A Figura 6, representa de forma visual as camadas de uma rede neural.

**Figura 6:** Exemplo das camadas de entrada, ocultas e saída em uma rede neural.



Fonte: Adaptado de QAMAR E ZARDARI (2023).

Os benefícios de se utilizar NNs, segundo Qamar e Zardari (2023) são:

- Aprendizado adaptativo: Sendo essa a capacidade de aprender tarefas com base em dados de treinamento ou experiência prévia.
- Auto-Organização: Conseguem organizar ou representar a informação que recebem durante o aprendizado.
- Operação em Tempo Real: Cálculos são realizados em paralelo, aproveitando do hardware atual para aproveitar os benefícios dessa característica.
- Tolerância a Falhas: Com codificação redundante de informações, uma falha parcial da rede resulta na redução de desempenho, mas algumas funções são mantidas mesmo se houver danos significativos.

É válido falar sobre alguns tipos de redes neurais existentes, com base no que Qamar e Zardari (2023) discutiram:

- Rede Neural *Feed-Forward*: ANN mais fundamental, pois é utilizada em problemas de classificação e recorrência, não há ciclos e os dados fluem em apenas uma direção em cada camada.

- Rede Neural Recorrente (RNN): Possui ligações de volta da saída para a entrada e uma camada oculta. Muito utilizada em processamento de imagens, de linguagem e na modelagem de programas.
- Rede Neural Rasa (*Shallow Neural Network*): Comumente utilizada com apenas uma camada oculta.
- Rede Neural Recursiva: Com uma estrutura hierárquica similar às ANNs, porém a entrada é limitada no tempo e usada para entradas que tem hierarquia no formato de árvore.
- Rede Neural em Cascata: É semelhante às redes *feed-forward*, porém possuem conexão da camada de entrada e de todas as camadas anteriores para os níveis seguintes.

A forma que as ANNs funcionam está ligado ao papel crucial de pesos, os quais determinam força e importância para realizar as conexões entre os neurônios e suas diversas camadas. Segundo Shweta (2023), as entradas de cada nó são multiplicadas por pesos específicos , sendo que essa soma ponderada é combinada com um viés (bias), e é processada por uma função de ativação. Se esse resultado exceder um limiar, o neurônio será ativado e envia os dados para a próxima camada, o que significa que pesos maiores irão conferir maior influência a certas entradas e saídas da rede. Todo o processo de ANN envolve esse ajuste interativo de pesos, comparando as saídas previstas com as reais, minimizando o erro e otimizando a capacidade da rede aprender padrões e fazer previsões precisas.

### 3.2.3 Algoritmos Genéticos (GA)

Soluções eficientes para problemas complexos impulsionaram o desenvolvimento de diversas técnicas computacionais avançadas, sendo uma delas o Algoritmo Genético. Esse algoritmo é inspirado em processos da natureza para a resolução e otimização de problemas computacionais.

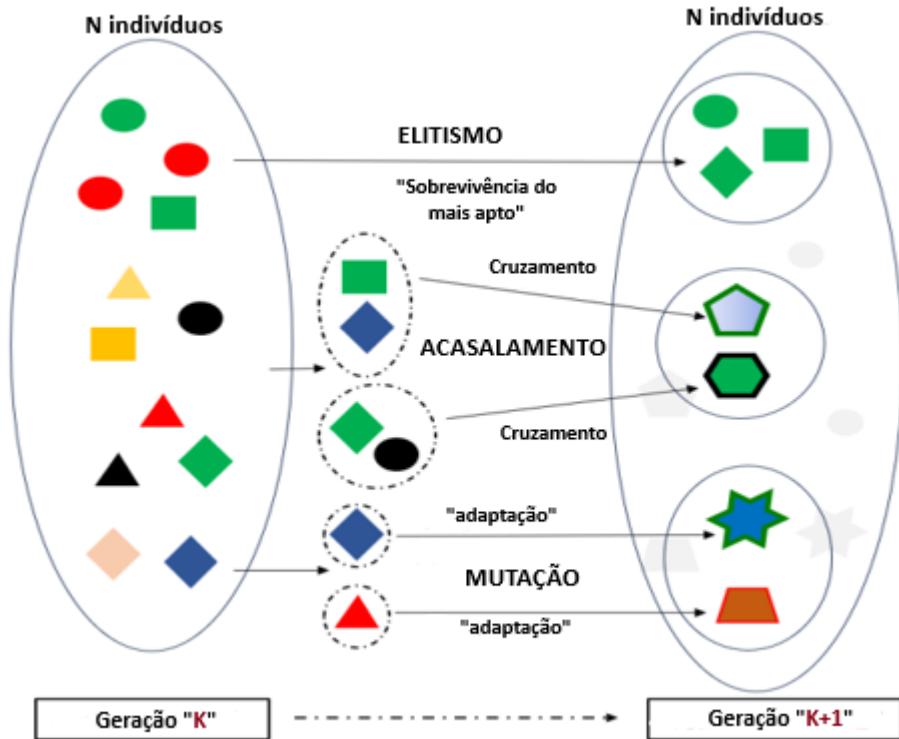
De acordo com o que Biscontini (2022) diz sobre Algoritmos Genéticos, um GA opera em um conjunto de possíveis soluções para um problema, denominado de “população”. Tais soluções são selecionadas a partir do seu “nível de aptidão” (*fitness*), indicando a sua eficiência em resolver o problema. Diversas soluções que são consideradas “aptas” possuem uma chance de “acasalar” e produzir “descendentes”, que são novas soluções que podem ser melhor que as originais.

Continuando na ideia de Biscontini (2022), a visão geral de funcionamento dos algoritmos genéticos está baseada no conceito de seleção natural. Seguindo essas seis etapas principais:

- Inicialização: Soluções iniciais são geradas de forma aleatória, formando a população, é comum a representação de cada solução como uma array de bits (sequência de zeros e uns).
- Avaliação: Cada membro da população será avaliado e recebe também um “nível de aptidão”, sendo que quanto maior esse nível, melhor será a solução.
- Seleção: As soluções com os piores níveis de aptidão são descartadas, sobrando apenas as melhores.
- Cruzamento: Se assemelha com a reprodução, dois “pais” que são soluções aptas unem-se para criar “descendentes”, com a intenção de que as melhores características de cada pai seja herdada, isso com o tempo vai criando soluções mais aptas.
- Mutação: No algoritmo também existe probabilidades de mutação, essa adição de aleatoriedade com pequenas mudanças garante uma diversidade genética para a população, eliminando diversos resultados que seriam idênticos.
- Repetição: A repetição é essencial para garantir uma boa diversidade de soluções, passando pelas mesmas etapas diversas vezes, sendo que a cada população é dado também o nome de “geração”.

O GA é encerrado quando uma solução que é considerada boa o suficiente é encontrada ou quando toda essa população atinge um nível de aptidão aceitável. Biscontini (2022) também discutiu sobre as desvantagens do GA, sendo que mesmo sejam muito mais rápidos que cálculos manuais para problemas complexos, eles ainda podem ser demorados e mesmo que gere soluções aceitáveis, não necessariamente será a melhor solução, exigindo então a intervenção humana. Na Figura 7 é possível ver um exemplo de como o GA funciona.

**Figura 7:** Diagrama de funcionamento de um Algoritmo Genético



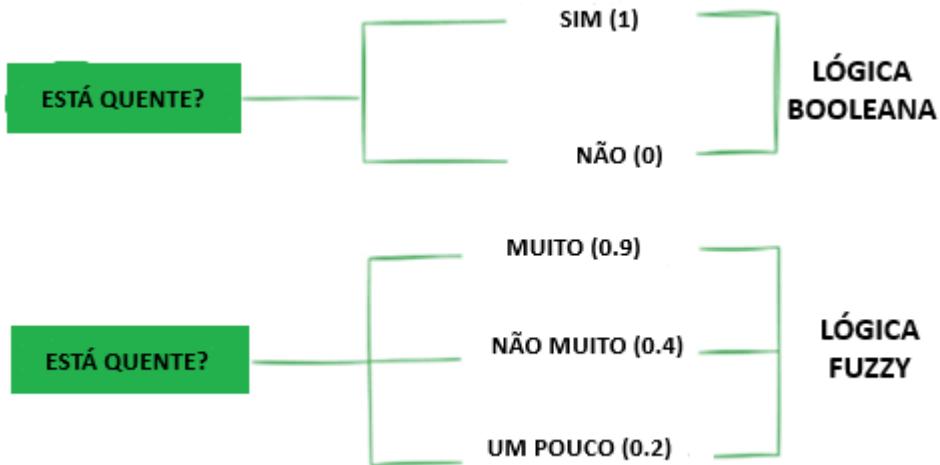
Fonte: Adaptado de Yves Matanga (MLInsightsCentral, Algoritmos Genéticos).

### 3.2.4 Lógica Fuzzy ou Lógica Difusa (FL)

A lógica Fuzzy no contexto de IA, sai do raciocínio de lógica booleana binária e permite que variáveis assumam graus de pertinência (*membership*) a diversos conjuntos fuzzy em um intervalo contínuo de 0 a 1. Conforme Ferrer (2025) explica, a abordagem criada por Lotfi Zadeh é crucial para lidar com sistemas de incerteza, ambiguidade e com imprecisão de dados.

As diferenças entre a lógica Fuzzy e a lógica binária estão em seus operadores, onde a lógica binária trabalha com entradas exatas e com saídas VERDADEIRO ou FALSO. A lógica Fuzzy, segundo Ferrer (2025), permite estados intermediários desse processo, como “muito” ou “muito pouco”, permitindo assim decisões mais realistas. Na Figura 8 é possível visualizar esse conceito.

**Figura 8:** Exemplo do conceito de incerteza da Lógica Fuzzy.



Fonte: Adaptado de Josep Ferrer(2025, Lógica Fuzzy na IA).

Continuando na ideia de Ferrer (2025), o Sistema de Inferência Fuzzy (FIS), ou Sistema Fuzzy, geralmente, envolve as seguintes etapas:

- **Fuzzificação (*Fuzzification*):** A conversão de entradas nítidas (*crisp inputs*) para conjuntos fuzzy (*fuzzy sets*) por meio das funções de pertinência (*membership functions*). Tomando como exemplo uma temperatura de 25°C pode ter um grau de pertinência de 0.8 para “quente” e 0.3 para “morno”, permitindo uma diversificação de detalhes maior em um sistema.
- **Base de Regras (*Rule Base*):** Possui um conjunto de regras “SE-ENTÃO” (IF-THEN), as quais são definidas por especialistas e representam o conhecimento sobre o sistema. Um exemplo seria, “SE a temperatura está QUENTE e com ALTA umidade ENTÃO a velocidade do ventilador será MUITO ALTA”.
- **Mecanismo de Inferência (*Inference Engine*):** A base de regras fuzzy é avaliada, aplicando os operadores lógicos fuzzy (como AND, OR) e métodos de inferência (como Mamdani ou Sugeno), que determinam o grau de ativação de cada regra e o conjunto fuzzy de saída.
- **Defuzzificação (*Defuzzification*):** O valor de saída do conjunto fuzzy será convertido novamente para um valor de saída nítido, podendo ser utilizado para o controle do sistema. Métodos comuns incluem o Centróide (*Center of Gravity*) ou a Média dos Máximos (*Mean of Maxima*).

Existem diversas aplicações para o uso da lógica Fuzzy, o que torna a capacidade de modelar informações imprecisas e decisões uma ferramenta de extrema utilidade no controle e otimização de sistemas complexos, ainda mais quando modelos matemáticos exatos são difíceis de obter ou manter. Então, tomando como base os exemplos de Ferrer (2025), alguns domínios onde a Lógica fuzzy é útil:

- Eletrônicos de Consumo: A FL, consegue otimizar o desempenho de eletrodomésticos, como o ciclo de máquinas de lavar e regulagem de temperatura e velocidade de um ventilador ou ar condicionado com base nas entradas difusas.
- Sistemas Automotivos: O aprimoramento de sistemas de veículos automáticos, que visa a mudança da marcha em tempo ideal e o *cruise control* adaptativo, ajustando a velocidade em tempo real com base nas condições de tráfego imprecisas.
- Saúde: O apoio do diagnóstico e monitoramento médico, com a análise de sintomas e resultados de testes, visando o rastreamento de sinais vitais e anomalias, para fornecer diagnósticos probabilísticos, mesmo com dados incertos.
- Automação industrial: O gerenciamento de processos industriais complexos, a regulação da temperatura e pressão em reatores químicos para garantir a consistência de qualidade, e processos de usinagem que dependem de diversos parâmetros para obter-se uma qualidade final melhor, casos em que as variáveis podem flutuar em faixas difusas.
- Robótica: Possibilita a navegação autônoma dos robôs em ambientes incertos, sendo utilizada como planejamento de caminho em tempo real e na prevenção dos obstáculos e percepções que podem ser consideradas ambíguas em um ambiente.

### 3.2.5 Metodologia de Superfície de Resposta (RSM)

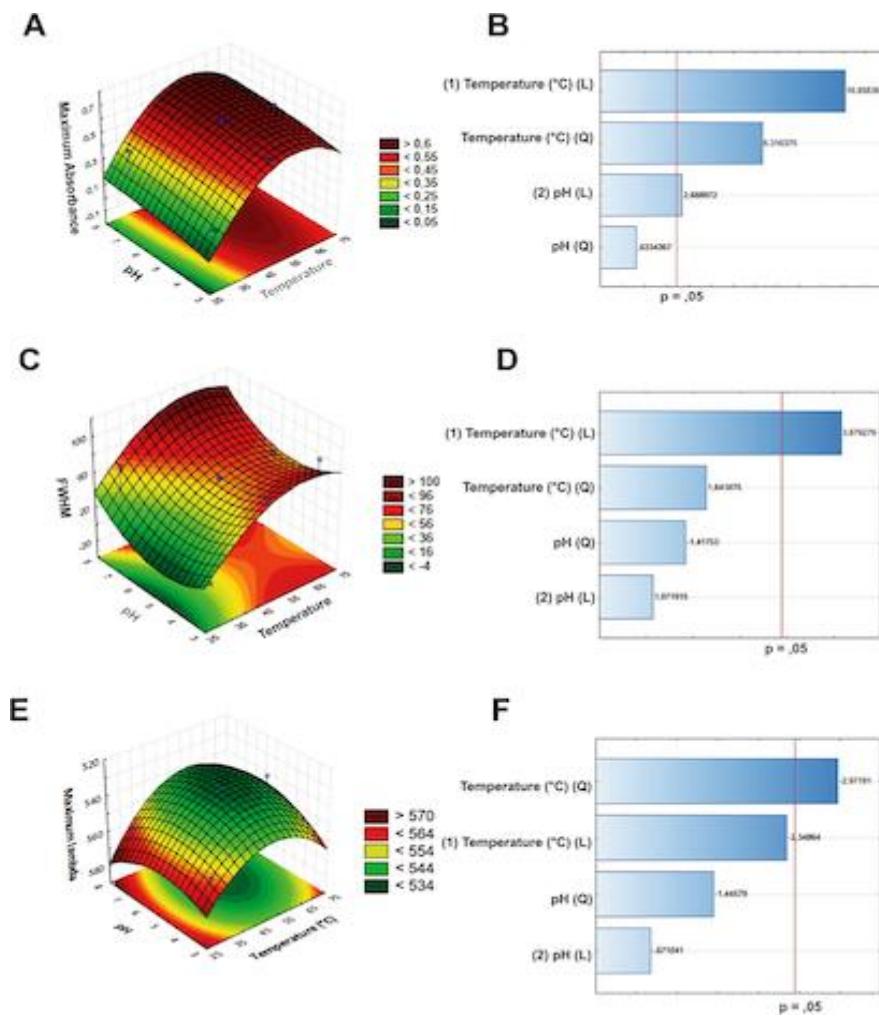
A metodologia de Superfície de Resposta (RSM), tem uma abordagem estatística junto com técnicas matemáticas que são empregadas para modelar e analisar relações entre diversas variáveis independentes e suas respectivas respostas em uma variável dependente (NEURAL CONCEPT, s.d.).

O design do experimento com RSM precisa de planejamento e etapas que precisam ser seguidas à risca para explorar os diversos fatos que afetam a resposta de saída. O artigo da Neural Concept (s.d), listou esse processo da seguinte forma:

- Identificação de Fatores: Definição das variáveis da entrada que influenciam a resposta ( por exemplo, parâmetros de processo e propriedades de materiais).
- Seleção dos Níveis de Fatores: Uma faixa de teste e nível para cada fator que vai ser testado. Isso vai garantir uma compreensão abrangente do espaço fatorial.
- Design Experimental: A escolha do design apropriado para a otimização de recursos e o fornecimento de informações profundas, sendo que os designs mais comuns incluem experimentos fatoriais, design composto central (CCD) e design box-behnken (BBD).

Na Figura 9, o exemplo dado pelo artigo da Neural Concept (s.d) fala sobre um experimento de um processo químico, que tem fatores como temperatura, pressão e concentração. O planejamento do experimento com o RSM vai envolver a especificação das faixas de temperatura, níveis de pressão e variação da concentração, sendo que nesse caso o design escolhido foi o factorial, o qual estuda o efeito dos múltiplos fatores, fazendo o maior número de combinações possível.

**Figura 9:** Exemplo de um experimento de RSM com o Design Fatorial.



Fonte: Adaptado de Neural Concept (s.d., Visão geral e aplicações da metodologia de superfície de resposta).

Após esse processo é necessário analisar os dados coletados no experimento, garantindo uma ampla extensão e qualidade dos mesmos, garantindo que o *dataset* represente de forma precisa as nuances das interações das variáveis independentes e da variável de resposta (NEURAL CONCEPT, s.d.). Com isso, é criado um modelo matemático que descreve como as variáveis interagem, e uma análise rigorosa de precisão preditiva e generalização do modelo é feita, com o uso de técnicas como validação cruzada e bondade de ajuste. Ainda seguindo o

artigo da Neural Concept (s.d), a interpretação dos coeficientes do modelo determinam o impacto quantitativo de cada variável na previsão de resposta, sendo que existem coeficientes lineares e coeficientes de interação para demonstrar esse conjunto de influências.

Finalmente, é possível concluir que esse modelo tem muita importância em diversos setores, a partir do fornecimento de *insights* que modificam tomadas de decisões, impulsionando resultados e otimização de operações.

### **3.2.6 Big Data**

O termo Big Data é utilizado para descrever conjuntos de dados que são tão grandes e complexos que não podem ser processados de maneira eficaz com ferramentas tradicionais, sendo amplamente utilizado em projetos de aprendizado de máquinas, modelos de previsão e outros métodos analíticos avançados (HASHEMI-POUR; BOTELHO; BIGELOW, 2024). O conceito em si geralmente é definido por três características principais, conhecidas como os “3 V's” (HASHEMI-POUR; BOTELHO; BIGELOW, 2024).

- Volume: É a quantidade massiva de dados que são gerados a cada segundo das mais diversas fontes, como redes sociais, dispositivos IoT e transações online.
- Velocidade: A rapidez na criação dos dados, coleta e processamento, geralmente em tempo real ou próximo dele.
- Variedade: Fala sobre à diversidade e complexidade dos dados, que chegam em diferentes formatos, sejam estruturados, semiestruturados e não estruturados.

Existem diversos benefícios na análise do Big Data para empresas e instituições (SALESFORCE, 2024):

- Tomadas de decisão: Uma tomada de decisão mais assertiva e menos dependente de intuição se torna possível, pois os insights são detalhados em tempo real.
- Eficiência Operacional: Com a ajuda da identificação de gargalos, a otimização na produção garante redução de custos e desperdícios.
- Prevenção de Falhas e Riscos: Com a análise de grandes volumes de dados, é possível a identificação de padrões que indicam falha em maquinários ou tentativas de fraude, aprimorando a gestão de riscos.
- Personalização e Desenvolvimento de produtos: Com a análise dos dados de comportamento e o consumo de clientes, empresas podem desenvolver produtos personalizados, segmentando o público alvo e prevendo tendências.

Ainda assim, existem diversos desafios no gerenciamento de um grande volume de dados como no Big Data, como o gerenciamento e coleta, que exigem cada vez mais técnicas e tecnologia avançadas para acontecer de forma eficiente (SALESFORCE, 2024). Além disso,

também existem problemas relacionados na qualidade dos dados, que podem ser “sujos” ou incompletos, e na integração que pode vir de diferentes fontes e formatos, possibilitando resultados não confiáveis (SALESFORCE, 2024). O problema da segurança e privacidade é evidente, pois é um desafio constante manter tantos dados que podem ser confidenciais mantidos na normas de conformidade e privacidade, e também o alto custo de implementação dessas tecnologias e resistência interna à adoção de uma cultura orientada a dados podem ser barreiras para as empresas (HASHEMI-POUR; BOTELHO; BIGELOW, 2024).

#### 4 METODOLOGIA

A pesquisa do trabalho consiste em uma revisão abrangente sobre a aplicação de técnicas de Inteligência Artificial (IA) em processos de usinagem. O objetivo da revisão bibliométrica é servir como método de pesquisa que utiliza técnicas estatísticas e matemáticas para analisar e descrever a produção científica de uma determinada área. Ela tem o intuito de mapear o desenvolvimento do campo de estudo, de forma que seja possível identificar como ele tem se moldado ao longo dos anos, e sua importância reside na capacidade de estabelecer conexão entre os resultados, os anos de publicação e os temas dos artigos, evidenciando o impacto de cada técnica e processo estudado. Com a coleta e análise dos dados das publicações, como artigos e teses, são geradas estatísticas que permitem avaliar o impacto de técnicas, identificação de tendências e mensuração do volume de estudos sobre tópicos particulares. A abordagem estatística serve como base e apoio para a comunidade acadêmica, evidenciando não somente áreas com estudo consolidado, mas também áreas que possuem “lacunas de pesquisa”, ou seja, temas que não foram suficientemente explorados e que, portanto, representam oportunidades para futuras investigações (PASSAS, 2024). Dessa forma, a revisão bibliométrica demonstra a solidez nas linhas de pesquisa e também orienta novos trabalhos, possibilitando sugestões de futuras investigações e estabelecendo a importância do contexto na sua contribuição (PASSAS, 2024).

Nesse caso, foi analisado a evolução e impacto de técnicas de IA, como *Machine Learning* (ML), Redes Neurais Artificiais (ANN), Algoritmos Genéticos (GA), Lógica Fuzzy (FL) e a Metodologia da Superfície de Resposta (RSM), nos processos de usinagem de fresamento, torneamento, furação e retificação.

Para a realização da coleta de dados, foi realizada uma busca sistemática em bases de dados acadêmicas, sendo que a pesquisa inicial sempre foi atrelada ao Google Acadêmico, com o intuito de achar artigos que não ultrapassem 5 anos e que foram filtrados como os mais

relevantes (mais citados), para ser possível ter uma visão mais atualizada do campo de pesquisas. Para realizar essas pesquisas, foi utilizado como base um esquema de artigo sobre o mesmo tema, feito pelo professor orientador, utilizando as palavras chaves de cada capítulo. Na Tabela 1 é possível visualizar as principais palavras chave que foram utilizadas na pesquisa do Google acadêmico.

**Tabela 1:** Capítulo do Esquema e palavras chave utilizadas na pesquisa.

CAPÍTULO	PALAVRAS CHAVE
<i>Overview Of Machining Processes</i>	<i>Types of Machining: Turning, Milling, Drilling, Grinding.</i> <i>Challenges: Tool Wear, surface finish, process optimization.</i> <i>Current Solutions: Conventional Methods and Limitations.</i>
<i>AI Techniques in Machining</i>	<i>Machine Learning (ML):Supervised, unsupervised, reinforcement learning.</i> <i>Neural Networks (NN):Deep learning applications in pattern recognition.</i> <i>Genetic Algorithms (GA):Optimization of machining parameters.</i> <i>Fuzzy Logic:Handling uncertainty in process variables.</i> <i>Comparison:Strengths and weaknesses of each technique.</i>
<i>Applications of AI in Machining</i>	<i>Predictive Maintenance:Monitoring tool wear and life expectancy.</i> <i>Process Optimization:Parameter tuning for enhanced performance.</i> <i>Quality Control:Real-time defect detection and correction.</i> <i>Adaptive Control Systems:Dynamic adjustments to machining conditions.</i>
<i>Case Studies and Recent Advances</i>	<i>Significant Case Studies: Examples from industry applications.</i> <i>Recent Advances:Innovations in AI-driven machining.</i> <i>Impact:Measurable improvements in efficiency and quality.</i>
<i>Benefits and Challenges</i>	<i>Advantages:Improved efficiency and reduced costs/Enhanced product quality and consistency.</i> <i>Challenges:Data requirements and integration issues/Resistance to change and skill gaps.</i>
<i>Future Trends and Research Directions</i>	<i>Emerging Trends:AI in sustainable manufacturing/Smart factories and Industry 4.0.</i> <i>Research Opportunities:Development of hybrid AI models/Exploration of AI in new machining domains.</i>

Fonte: O autor.

Os principais bancos de dados de artigos acadêmicos foram *Science Direct*, MDPI, *Springer Nature* e *Research Gate*. O período de análise abrange os anos de 2021 a 2025, sendo que 105 artigos foram originalmente selecionados, mas apenas 85 fizeram parte da análise, devido a divergências do tema especificado. Enquanto as pesquisas eram feitas, os artigos foram sendo armazenados em uma planilha de excel, onde foram separados por número do artigo, com o intuito de facilitar a identificação de cada pesquisa, o tópico correspondente, que visa identificar a discussão do artigo com base no esquema de artigo feito pelo professor orientador, o ano de publicação, o título do arquivo e seu link de acesso, o processo de usinagem, a técnica de IA utilizada e os *Key findings* da pesquisa. Essa planilha foi feita com a intenção da construção de uma base de dados sólida, onde foi possível quantificar e filtrar as diversas pesquisas para ser realizada a análise estatística da revisão bibliométrica, permitindo a geração de gráficos e tabelas dinâmicas que identificam a quantidade total de artigos por processo de usinagem, a análise da distribuição percentual de técnicas de IA aplicadas a cada processo de usinagem, além de permitir acompanhar a tendência de publicação de artigos e avaliar os principais focos de pesquisa no cenário atual.

Para facilitar ainda mais a análise, também foi feito no Word um arquivo que identifica todas as pesquisas com o número indicado na planilha de dados, onde foi colocado o título da pesquisa e um breve resumo sobre os principais achados de cada artigo, focando principalmente no tema da pesquisa, a metodologia e os resultados encontrados, cada resumo foi feito de forma que uma página fosse o suficiente para abranger um artigo, também foi colocado em algumas pesquisas um resumo rápido se seria possível utilizar o artigo em outro tópico de discussão que seja diferente do selecionado na planilha de dados.

Os dados da planilha que diferenciam as pesquisas foram, originalmente, feitos com os seguintes critérios observados na Tabela 2.

**Tabela 2:** Dados que serviram de base para preencher a planilha de dados.

<b>Processo de Usinagem</b>	<b>Técnica de IA</b>	<b>Principais Achados</b>
<i>Turning</i>	<i>Machine Learning</i>	<i>Enhanced Productivity and tool life with cryogenic machining</i>
<i>Milling</i>	<i>ANN</i>	<i>Improved tool vibration and surface roughness using nanofluid-MQL</i>
<i>Grinding</i>	<i>Response Surface Methodology</i>	<i>Superior wear resistance and surface finish in high-feed turning</i>
<i>Drilling</i>	<i>Coated Ceramic Tool</i>	<i>Optimization of surface roughness and tool wear</i>
<i>Hard Turning</i>	<i>Sustainability Assessment</i>	<i>Evaluation of environmental and economic impacts</i>
<i>Hybrid Machining</i>	<i>Genetic Algorithm</i>	-

Fonte: O autor.

É possível observar na Tabela 2 que existem diversos parâmetros para a pesquisa, sendo que dois não foram utilizados na planilha final, na coluna de *AI Technique* temos os parâmetros de *Coated Ceramic Tool* e *Sustainability Assessment*. Esses parâmetros não foram utilizados, pois o *Coated Ceramic Tool* é um componente físico do processo de usinagem e *Sustainability Assessment* representa mais um objetivo ou resultado da pesquisa, sendo considerado como o *Key Finding* de *Evaluation of environmental and economic impacts*. Para facilitar o entendimento no trabalho, foi feita também uma tradução dos dados da planilha original para melhorar a visualização dos gráficos demonstrados.

A partir dessa abordagem metodológica, foi possível iniciar uma visão abrangente e detalhada do cenário atual das pesquisas, fornecendo a base para os resultados, discussões e conclusão do trabalho.

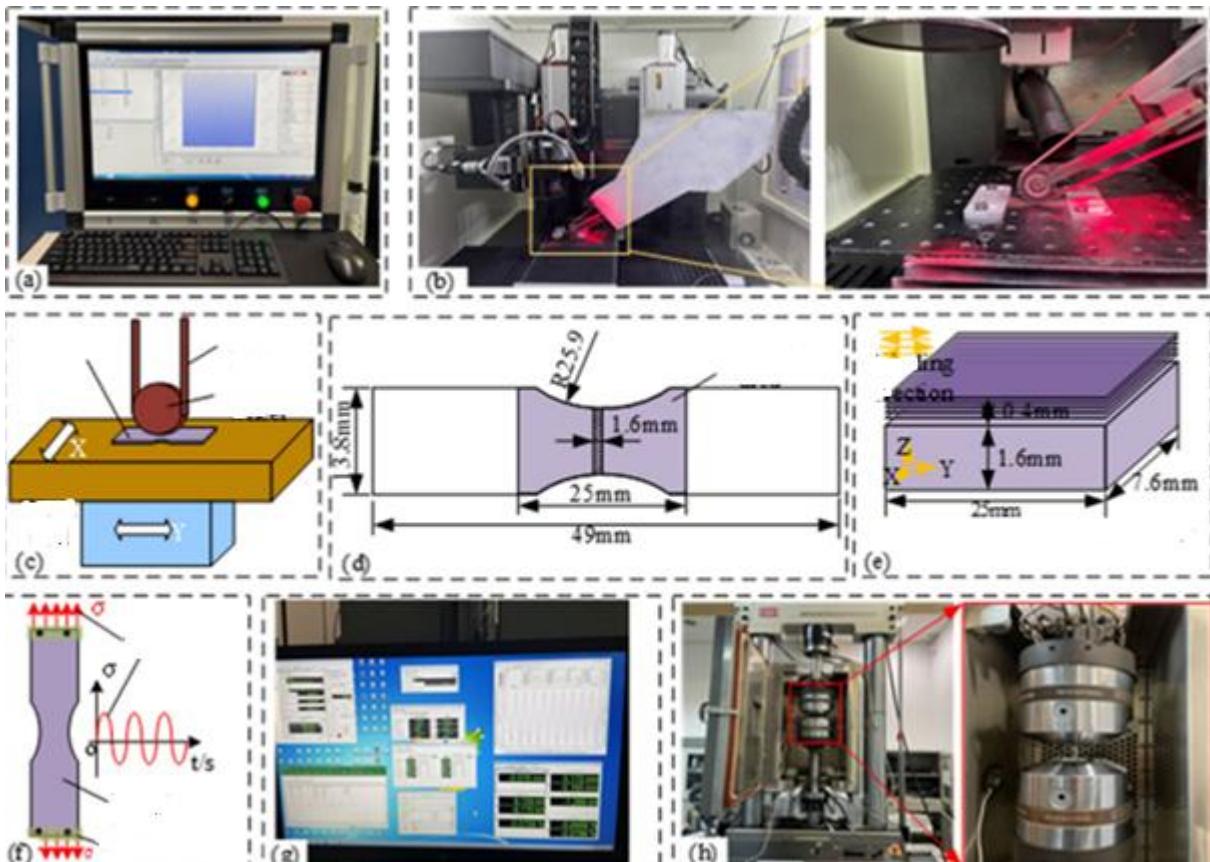
## 5 RESULTADOS E DISCUSSÕES

Nessa seção, os resultados adquiridos através do estudo dos temas relacionados aos processos de usinagem com o uso de inteligência artificial e suas diversas técnicas, serão interpretados e discutidos de forma que as estatísticas e nuances sejam explicitadas para demonstrar os caminhos que as pesquisas estão seguindo. Primeiramente, serão abordados desafios recorrentes e inovações que a IA possibilita no contexto de manufatura inteligente.

### 5.1 Desafios do Big Data e Generalização dos Modelos

Mesmo com o potencial da IA na otimização dos processos de usinagem, uma implementação em larga escala enfrenta diversos desafios, seja na gestão de *Big Data* e na generalização dos modelos. Como será mencionado nas discussões sobre as pesquisas, a complexidade e a variabilidade dos processos geram muitos tipos de dados, de forma que nem sempre são dados de qualidade e baratos de conseguir, o que pode comprometer a capacidade dos modelos de IA na adaptação de novos cenários. Essas dificuldades foram abordadas em vários estudos analisados, como no artigo (Número 72 na tabela de dados) “*Enhanced prediction accuracy in high-speed grinding of brittle materials using advanced machine learning techniques*” (LEE et al., 2024), que analisa a retificação de alta velocidade, e explicita que a coleta de dados é um grande obstáculo, mencionando a necessidade de diversos sensores (forças, temperaturas, vibrações, emissões acústicas, imagens) em alta frequência. Além disso, também é ressaltado as dificuldades impostas pela heterogeneidade, volume e velocidade dos dados para o processamento e armazenamento em tempo real (LEE et al., 2024). Outro artigo que reforça essa ideia é o (Número 83 na tabela de dados) “*A hybrid approach of process reasoning and artificial intelligence-based intelligent decision system framework for fatigue life of belt grinding*” (ZHANG et al., 2024), que foca na predição de vida útil à fadiga, apontando que a coleta de dados para essa métrica é “demorada e cara, o que limita o tamanho do conjunto de dados” (ZHANG et al., 2024). Na Figura 10 é possível visualizar a dificuldade de toda a configuração de experimento da pesquisa de Zhang et al. (2024).

**Figura 10:** Configuração de experimento complexa e cara do artigo 83.

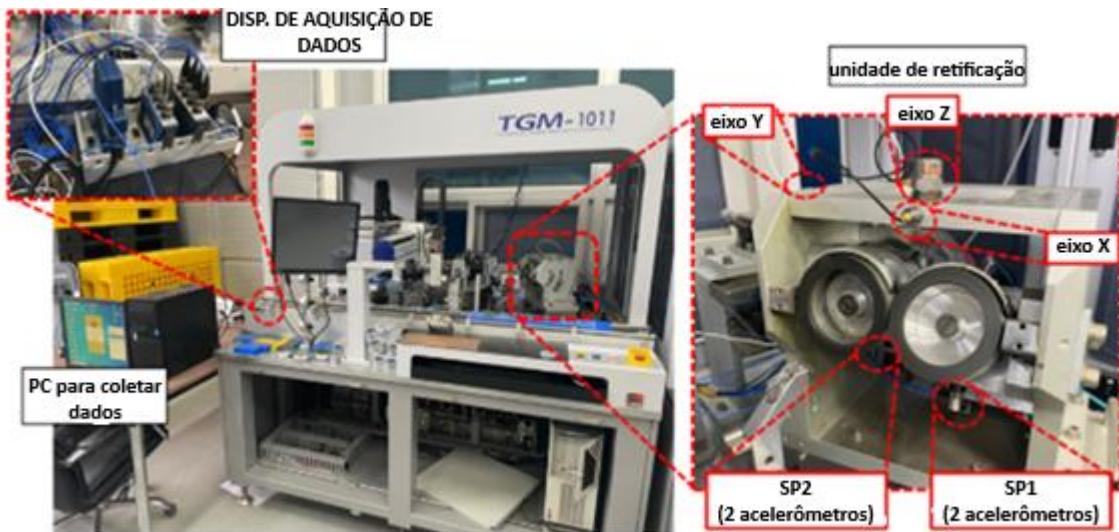


Fonte: Adaptado de Zhang et al. (2024, Uma abordagem híbrida de raciocínio de processo e estrutura de sistema de decisão inteligente baseada em inteligência artificial para vida de fadiga de retificação de correia, p.9).

Também existe o desafio da generalização, que é a capacidade de um modelo treinado com dados específicos manter a alta acurácia em outras máquinas, materiais e condições de usinagem. A pesquisa (Número 99 na tabela de dados) “*Exploring the Efficiencies of Spectral Isolation for Intelligent Wear Monitoring of Micro Drill Bit Automatic Regrinding In-Line Systems*” (AKPUDO; HUR, 2022), foca no monitoramento do desgaste de microbrocas, discutindo sobre o problema de generalizabilidade dos modelos para outras configurações de microfuração, afirmando que essa limitação é um obstáculo crítico para o cenário industrial, pois a criação de um modelo para cada cenário é economicamente inviável. Além disso, no artigo ainda é questionado se acelerômetros são os sensores mais apropriados para o processo, sugerindo que sensores de emissão acústica e câmeras “podem oferecer melhores soluções de monitoramento” (AKPUDO; HUR, 2022 , p.18), pois os acelerômetros foram escolhidos pelo custo benefício, mas os autores reconhecem que eles “apenas fornecem conhecimento inferido da unidade de retificação como respostas mecânicas ( que podem ser comprometidas por outras fontes irreconhecíveis)” (AKPUDO; HUR, 2022 , p.18). Os autores também discutiram sobre

a dificuldade do monitoramento direto, pois mesmo considerando câmeras como um método mais adequado para fornecer informações diretas sobre o nível de desgaste das rodas de retificação, a usabilidade em tempo real pode ser afetada, devido as rodas girarem em alta velocidade e resultar em imagens pouco claras, o que exige frequentemente a interrupção da máquina (AKPUDO; HUR, 2022 , p.18). Na Figura 11 é possível visualizar o sistema de monitoramento e localização dos sensores utilizados no experimento do artigo 99.

**Figura 11:** Configuração do experimento do artigo 99.

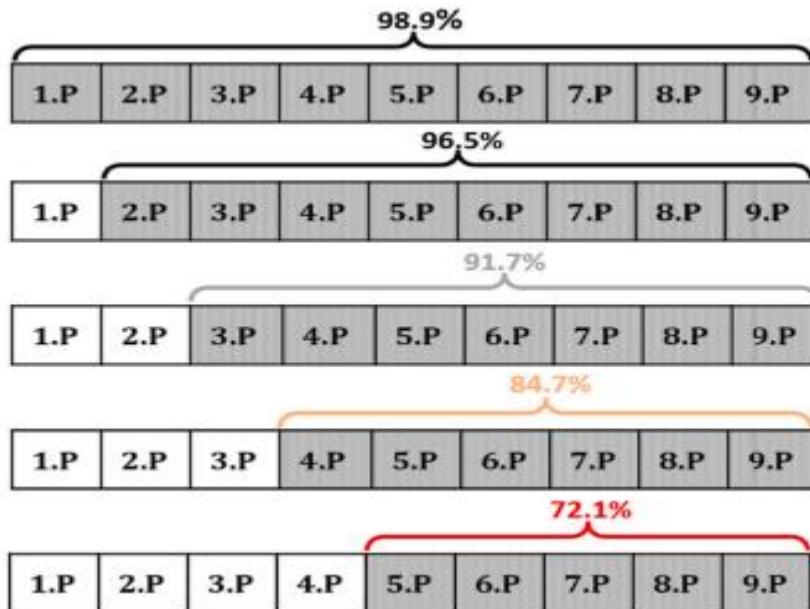


Fonte: Adaptado de Akpudo; Hur (2022, Explorando a eficiência do isolamento espectral para monitoramento inteligente do desgaste de sistemas de reafiação automática em linha de microbrocas, p.9).

Visando superar essas dificuldades de generalização e coleta de dados, abordagens híbridas de IA estão sendo utilizadas como forma de mitigação para a escassez, qualidade e padronização dos conjuntos de dados, permitindo uma maior transferibilidade de modelos nos processos de fabricação. O artigo (Número 78 na tabela de dados) “*Improving milling force predictions: A hybrid approach integrating physics-based simulation and machine learning for remarkable accuracy across diverse unseen materials and tool types*” (ARAGHIZAD et al., 2024), é um excelente exemplo de como a utilização de modelos híbridos ajuda na predição de forças de fresamento que integra a simulação baseada em física com o aprendizado de máquina (ML), pois foram utilizados 3 modelos diferentes de ML junto com modelos analíticos e dados limitados. Como resultado, conseguiram não apenas reduzir a necessidade de testes experimentais para treinamento, mas também foi provado a capacidade do modelo de generalizar materiais nunca vistos, como o Inconel 625, com alta precisão (95%) (ARAGHIZAD et al., 2024). Na Figura 12, é possível visualizar graficamente como a acurácia

da previsão do modelo se comporta quando os parâmetros de entrada estão fora da faixa de treinamento, sendo que cada “P” que está branco, indica um parâmetro que não está dentro da faixa de treinamento, ou seja, que não foi visto, por exemplo, a parte com o número pintado de vermelho indica uma precisão do modelo de 72,1% quando 4 parâmetros estão fora da faixa de treinamento, indicando a capacidade do modelo de generalizar.

**Figura 12:** Precisão da predição do modelo do artigo 78, para parâmetros fora da faixa de treinamento.



Fonte: Adaptado de ARAGHIZAD et al. (2024, Melhorando as previsões de força de fresamento: uma abordagem híbrida que integra simulação baseada em física e aprendizado de máquina para uma precisão notável em diversos materiais e tipos de ferramentas nunca antes vistos, p.14)

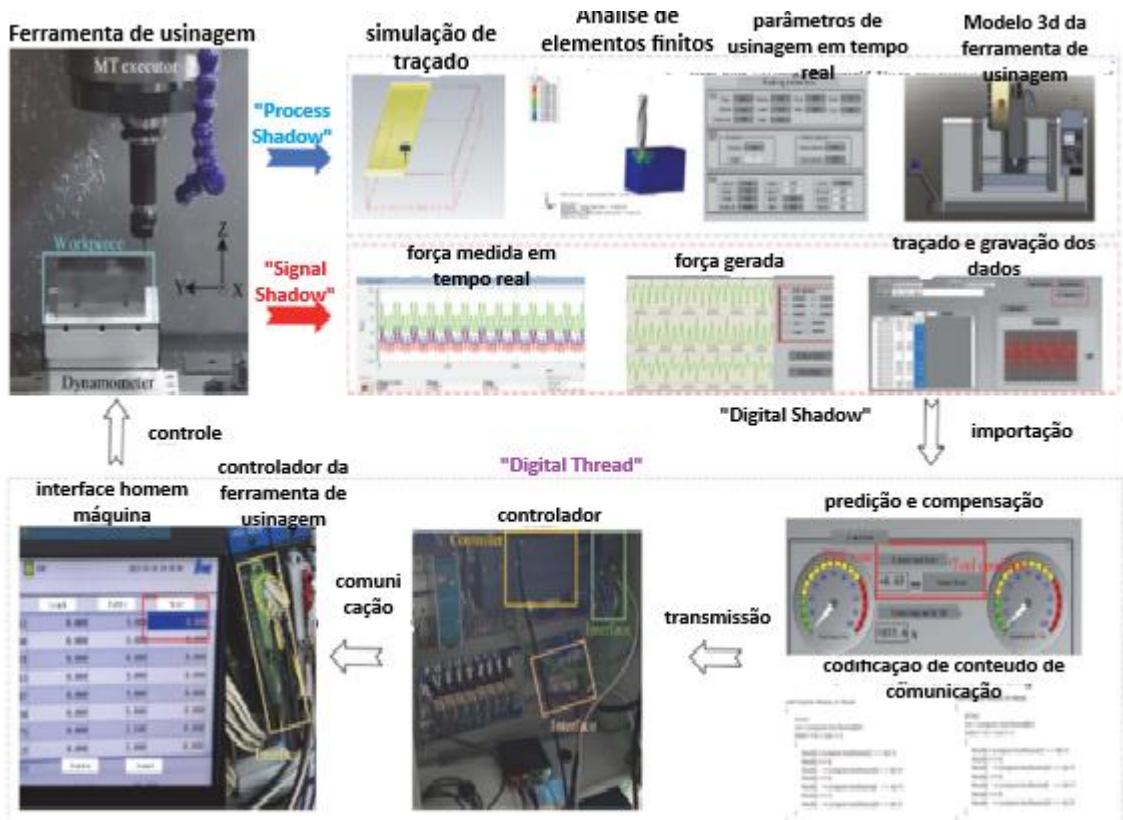
A análise dos artigos demonstrou que a complexidade de coleta de dados, heterogeneidade das informações e a falta de padronização impõe diversos obstáculos para a implementação completa da IA nos processos de usinagem. Porém, também foi revelado nas análises que existem formas de mitigação para essas dificuldades, como as abordagens de modelos híbridos, que estão em um período de ascensão nas pesquisas, como foi discutido anteriormente. Pode-se concluir que a habilidade de construir sistemas de Inteligência Artificial que sejam adaptáveis, práticos e resilientes aos mais variados ambientes é um desafio e objetivo das pesquisas desse campo na usinagem.

## 5.2 O Papel da IA na Manufatura Inteligente e no Controle de Qualidade

Além da otimização de parâmetros de usinagem, a transição para a manufatura inteligente tem impulsionado a aplicação da IA no desenvolvimento de soluções inovadoras que impactam diretamente a produtividade, qualidade e autonomia dos processos industriais. O cenário da manufatura tradicional ainda depende de muita inspeção reativa e manutenção corretiva, mas a IA está permitindo mudanças para sistemas proativos e autônomos, não limitando-se somente na previsão de uma única métrica, mas com a integração de dados complexos para formar sistemas de controle de malha fechada, que são capazes de tomar decisões em tempo real. Dessa forma, a capacidade de manutenção preditiva e garantia de qualidade in-situ (no local) em processos críticos é o que realmente está definindo o avanço da IA na indústria, reduzindo tempo de inatividade, minimizando sucata e garantindo uma maior confiabilidade do produto final.

No artigo (Número 101 na tabela de dados) "*Hybrid Knowledge-Based Digital Twin for Cutters of Machine Tools*" (YUAN et al., 2025), a ideia discutida é bem apresentada, pois esse tipo de pesquisa representa um avanço tecnológico fundamental no conceito de fábricas inteligentes. O estudo propôs uma arquitetura de Gêmeo Digital (*Digital Twin*) híbrido, para cortadores de máquinas-ferramenta, onde o sistema é composto por três subsistemas essenciais: o sistema físico (equipamentos de usinagem e sensores), o sistema cibernético (onde os modelos inteligentes de diagnóstico, previsão e compensação são armazenados) e o fio digital (*digital thread*), que é responsável por conectar na transferência de comandos de otimização em tempo real. Com isso, o chamado "*Digital Shadow*" espelha o mundo real através do "*Process Shadow*" (simulação da usinagem) e do "*Signal Shadow*" (sinais medidos e gerados por modelos físicos), o que permite o diagnóstico de condições e a previsão do desgaste da ferramenta. Com base nessas informações, algoritmos inteligentes calculam compensações que são transmitidas à máquina, ajustando os parâmetros de usinagem online e garantindo a qualidade da peça em tempo real, resultando em um processo de fabricação auto-otimizável e eficiente (YUAN et al., 2025). O fato de que o Gêmeo Digital conseguiu prever o desgaste da ferramenta com uma acurácia de 96,5% e de compensar esse desgaste em tempo real, reduziu o erro dimensional das peças usinadas em mais de 30%, otimizando não somente a vida útil da ferramenta e precisão da usinagem, mas também estabelece um precedente na integração completa e autônoma de sistemas de monitoramento na manufatura moderna (YUAN et al., 2025). Na Figura 13 é possível observar a forma que ocorreu o experimento do artigo 101.

**Figura 13:** Configuração de experimento do artigo 101.

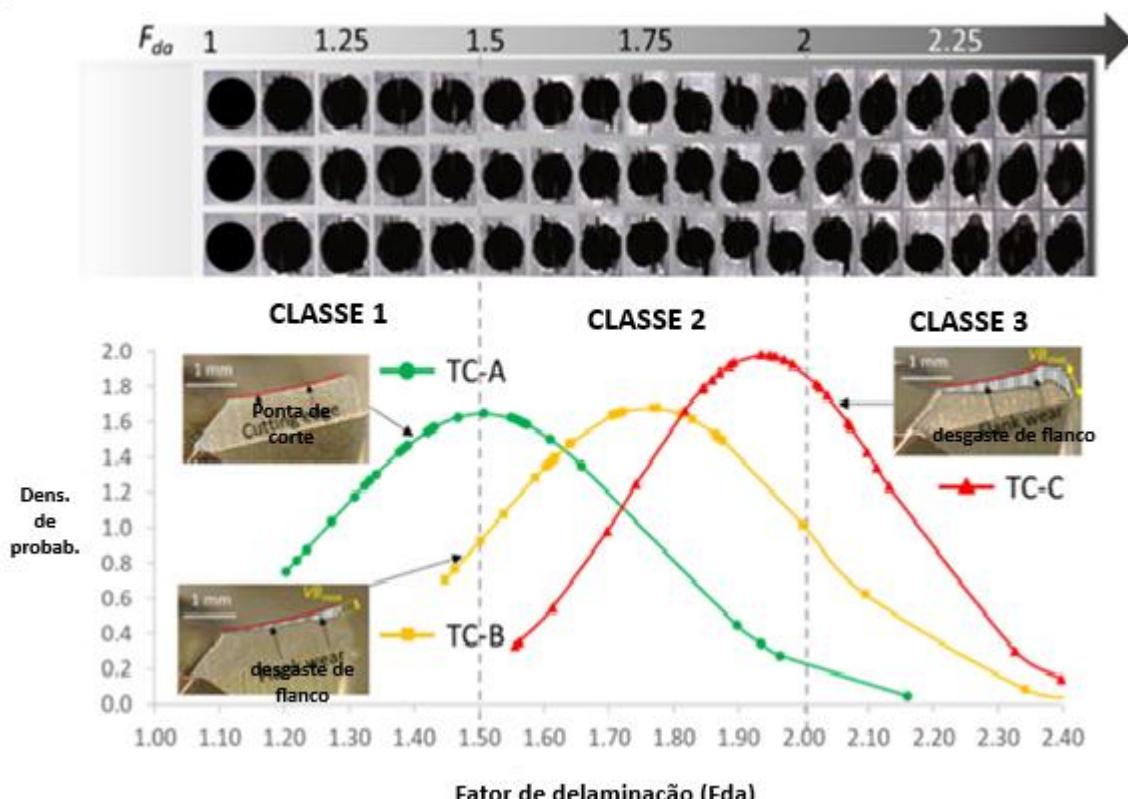


Fonte: Adaptado de YUAN et al. (2025, Gêmeo digital híbrido baseado em conhecimento para cortadores de máquinas-ferramentas, p.5).

Com o intuito de complementar essa visão de inovação, o artigo (Número 49 na tabela de dados) “*In-situ evaluation of hole quality and cutting tool condition in robotic drilling of composite materials using machine learning*” (LEE et al., 2025), em que o estudo apresenta uma abordagem inovadora para inspeção da qualidade de furos e monitoramento da condição da ferramenta em tempo real, utilizando dados de sensores integrados de um robô de perfuração industrial e um modelo de ML, tendo grande relevância no cenário da indústria aeroespacial, em que o compósito utilizado é o Hexcel IM7 fibra de carbono reforçada com epóxi HexPly 8552, sendo utilizado na construção de estruturas de aeronaves (LEE et al., 2025). A usinagem desses compósitos, devido à sua estrutura heterogênea e complexa, impõe desafios significativos que exigem inspeção rigorosa para garantir a segurança e integridade da peça. O modelo utiliza uma rede neural combinada com um algoritmo genético, para conectar os parâmetros do processo de furação com a qualidade do furo e condição da ferramenta, além de que, com a coleta de sinais do torque do servomotor (sem a necessidade de sensores externos adicionais), é possível processar esses sinais utilizando um filtro gaussiano e a análise de

variância (ANOVA) para determinar a contribuição de cada parâmetro no torque e na qualidade do furo (LEE et al., 2025). Dessa forma, a ANOVA confirmou que a condição de ferramenta é o maior influenciador do torque e da qualidade do furo, sendo que os resultados atingidos pelo modelo foram capazes de prever corretamente cinco de seis casos não vistos, sem classificar incorretamente furos com “defeito grave” como de menor gravidade, demonstrando robustez na classificação de furos, o que permite uma abordagem que reduz custos de inspeção, aumenta a eficiência e garante a alta qualidade do produto final, possibilitando a integridade de componentes que são cruciais em um setor onde a segurança e a precisão são primordiais (LEE et al., 2025). Na Figura 14, é possível visualizar a demonstração gráfica de como a qualidade dos furos (quantificada pelo fator de delaminação  $F_{da}$ ) se distribui para cada uma das três condições da ferramenta testada, sendo que TC-A representa uma ferramenta não danificada, que tende a produzir furos de Classe 1 e 2 (sem defeito ou com defeito menor/moderado). TC-B representa uma ferramenta moderadamente desgastada, que apresenta potencial para produzir furos das três classes, e o TC-C representa a ferramenta desgastada, tendendo a produzir furos de Classe 2 e Classe 3 (com defeito grave), não produzindo furos de Classe 1 (LEE et al., 2025).

**Figura 14:** Probabilidade de classificação de furos com base no desgaste da ferramenta.



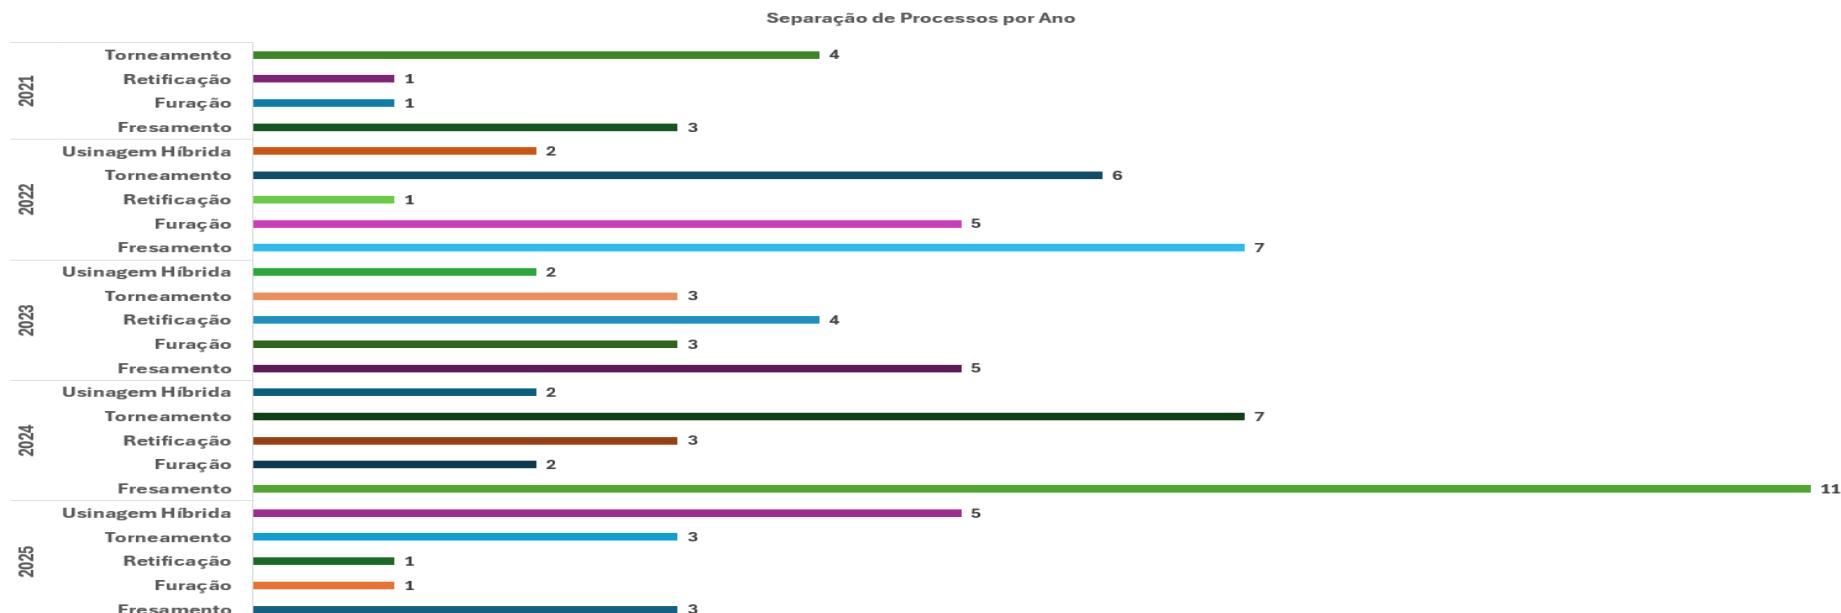
Fonte: Adaptado de LEE et al.(2025, Avaliação in situ da qualidade do furo e das condições da ferramenta de corte na perfuração robótica de materiais compósitos usando aprendizado de máquina, p.15)

Em suma, essas inovações nos artigos aqui discutidos serviram como um breve exemplo para demonstrar a mudança de paradigma do cenário atual, onde a IA não é uma ferramenta apenas para análises pontuais, mas sim um componente central de sistemas de usinagem inteligentes e autoadaptativos, impactando diretamente a indústria

### 5.3 Pesquisas de Processos de Usinagem com o Uso de Inteligência Artificial

Para complementar a visão e evolução do foco de pesquisa ao longo do tempo, a Figura 15 apresenta a contagem de artigos para cada processo de usinagem, segmentada por ano. Da mesma forma, na Figura 16 é possível visualizar a segmentação por ano da quantidade de artigos no quesito de técnicas de IA.

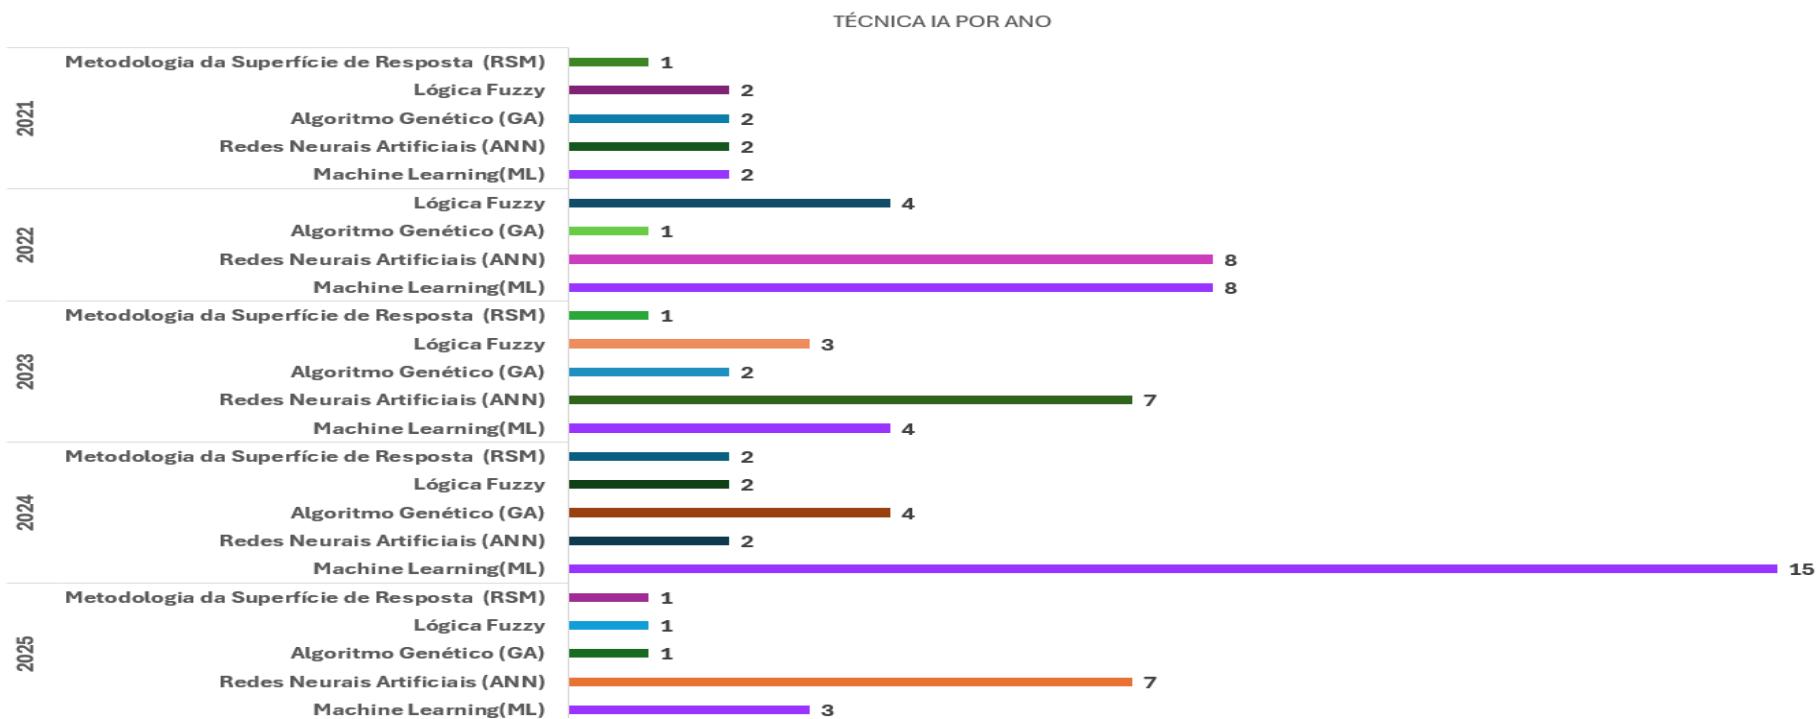
**Figura 15:** Gráfico de segmentação dos processos de usinagem por ano (2021 – 2025).



Fonte: O autor.

Essas ilustrações servem como forma de melhor complementar os gráficos de porcentagem que serão discutidos nos próximos tópicos, em que cada técnica é abordada com o intuito de discutir sobre algumas de suas características e resultados. É válido mencionar que o ano de 2025 foi ocultado em alguns gráficos de tendência de uso de técnica de IA ao longo dos anos, para não comprometer a linha de tendência, a não ser que 2025 tenha tido quantidades expressivas de pesquisas sobre o tema, já que na data de publicação deste trabalho, o ano de 2025 ainda não acabou e novas pesquisas devem ser publicadas.

**Figura 16:** Gráfico de segmentação das técnicas de IA por ano (2021 – 2025).

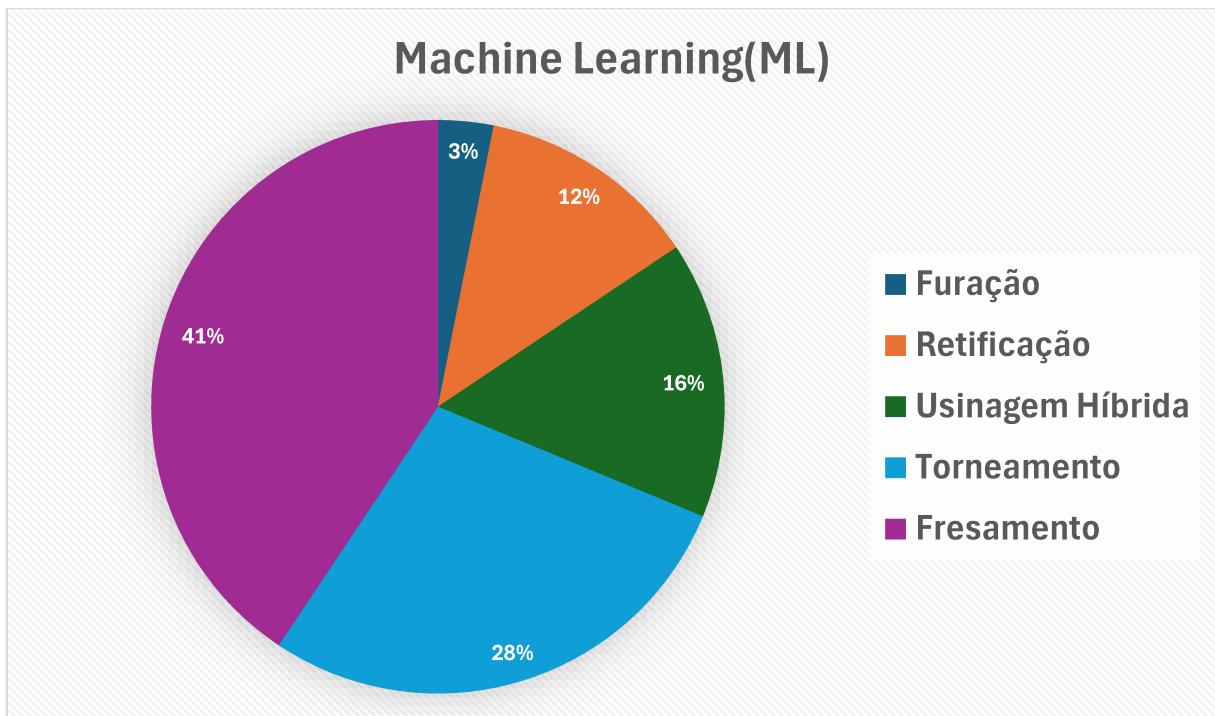


Fonte: O autor.

### 5.3.1 Pesquisas com o uso de Aprendizado de Máquina (ML)

A técnica de *Machine Learning* foi bastante utilizada ao longo das pesquisas, e na Figura 17 é possível visualizar a porcentagem de uso da técnica em cada processo de usinagem.

**Figura 17:** Gráfico da porcentagem de processos de usinagem no uso de ML.



Fonte: O autor.

É possível ver que o processo de usinagem mais utilizado foi o de fresamento (*Milling*) com 41% dos resultados no uso de ML para a otimização de parâmetros. Um dos possíveis motivos para isso é que o ML tem se mostrado altamente eficaz para prever e classificar o desgaste de ferramenta, que necessita de diversas comparações de parâmetros para a criação de um modelo, por isso, no artigo (Número 16 na tabela de dados) de Kaliayannan et al. (2024), que discute sobre como aplicações de técnicas de *Deep Learning* com o uso de aprendizado com reforço, mais especificamente o SARSA (*State-Action-Reward-State-Action*), aprimora significativamente o monitoramento da condição da ferramenta em fresamento, alcançando uma grande acurácia de classificação de 98,66%. Além disso, também foi concluído que o desgaste da ferramenta exerce uma grande influência nos sinais de vibração da usinagem, sendo que quanto mais eficiência é perdida na aresta de corte da ferramenta, a área de contato da ferramenta com a peça aumenta muito a amplitude da vibração (KALIYAYNNAN et al., 2024).

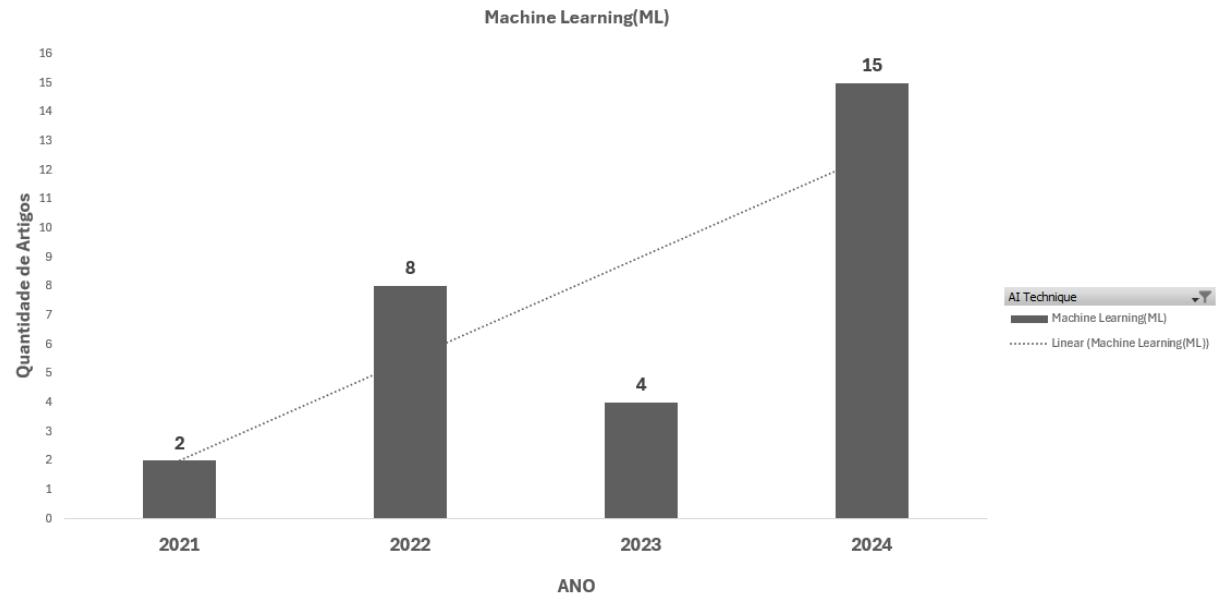
O segundo processo mais visto no uso de ML foi o de torneamento (*Turning*), com 25% dos resultados, que é um processo que sofre com grandes empecilhos relacionados a otimização de desempenho, eficiência energética e sustentabilidade. Um bom exemplo sobre a importância da integração do ML no torneamento é demonstrado no artigo (Número 15 na tabela de dados) "*Prediction of power consumption and its signals in sustainable turning of PH13-8Mo steel with different machine learning models*" (YURTKURAN et al., 2024), o qual exemplifica a importância dessa ligação ao investigar o consumo de energia no torneamento sustentável de aço PH13-8Mo. Nesse estudo, foi demonstrado como diferentes modelos de ML podem ser aplicados para prever o consumo de energia, alcançando um  $R^2$  de 0.996 na predição do consumo, permitindo que fabricantes ajustem parâmetros de usinagem com o intuito de operar de forma mais eficiente, sendo um pilar da manufatura sustentável.

Além desses processos, é válido também mencionar a Usinagem Híbrida, tendo um destaque no uso de ML, com 16% dos resultados, nas diversas operações de usinagem, a dificuldade da predição precisa da qualidade é um problema devido à natureza complexa e de alta dimensionalidade de dados gerados, frequentemente resultando em modelos tradicionais com baixa acurácia e pouca interpretabilidade. Com esse contexto, o artigo (Número 67 na tabela de dados) "*Research on Critical Quality Feature Recognition and Quality Prediction Method of Machining Based on Information Entropy and XGBoost Hyperparameter Optimization*" (QU et al., 2024), exemplifica o uso de ML com uma gestão na qualidade em processos diversos. Foi proposto um método para o reconhecimento de características e predição de qualidade em processos de usinagem, sendo que nesse caso utilizaram especificamente a usinagem de pistões de motor a diesel marítimo. A metodologia do artigo utiliza *Information Entropy* buscando selecionar características críticas de qualidades e optimiza os hiperparâmetros com XGBoost, utilizando o algoritmo de *Bayesian Optimization* (BO), essa combinação permitiu um caminho para lidar com a complexidade dos dados e superar limitações de métodos tradicionais (QU et al., 2024). Com altos resultados atingidos, o método melhorou a acurácia de predição em 12,6%, em comparação com outras abordagens, permitindo uma melhora na qualidade de usinagem e redução das taxas de trabalho e refugo.

Para finalizar a discussão sobre ML, a Figura 18 representa a quantidade de artigos por ano de publicação da técnica de ML, sendo possível notar um aumento constante ao longo dos anos, o que pode ser explicado por diversos motivos, seja o avanço constante no desenvolvimento de algoritmos, o aumento exponencial de poder computacional, que permite um treino de modelos de ML complexos com grande volumes de dados em tempo razoável, maior disponibilidade de ferramentas e frameworks (TensorFlow, PyTorch, Scikit-learn) e o

crescimento constante da digitalização da indústria. Todos esses motivos e também outros aqui não mencionados contribuem com a popularização do ML como uma das principais escolhas para aplicação nos processos de usinagem.

**Figura 18:** Gráfico da tendência do uso de ML ao longo dos anos.

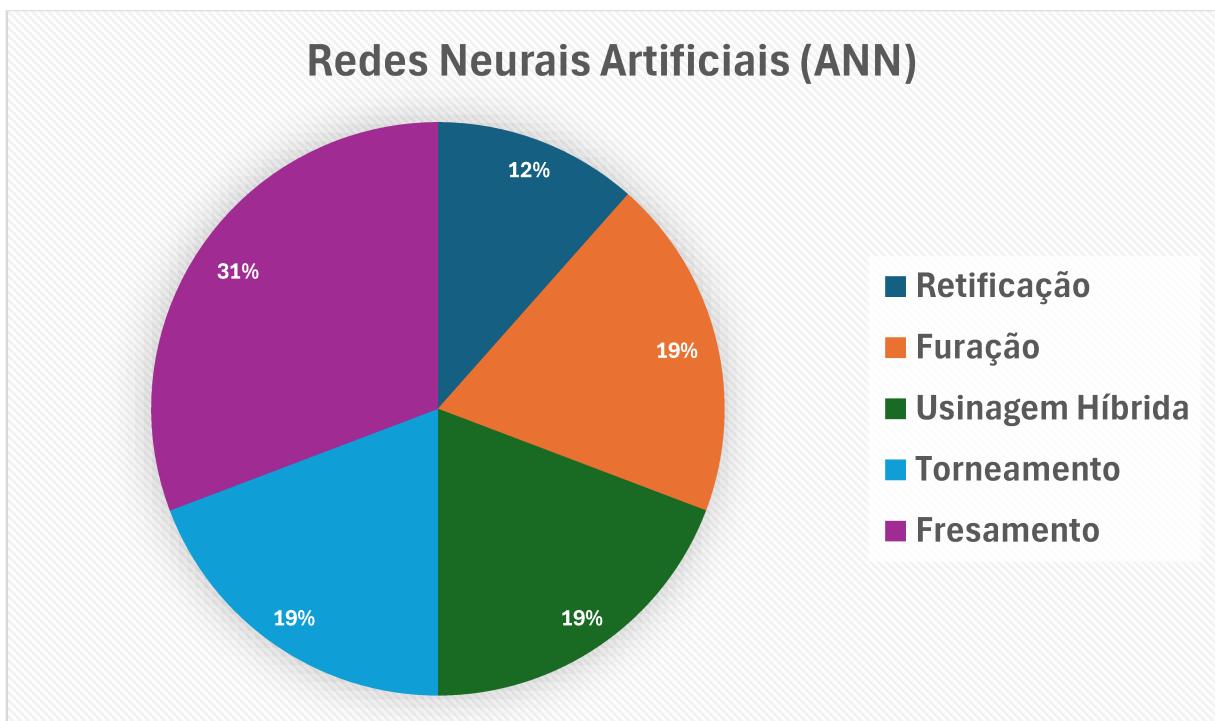


Fonte: O autor.

### 5.3.2 Pesquisas com o uso de Redes Neurais Artificiais (ANN)

O uso de Redes Neurais Artificiais seguiu um padrão um pouco diferente do uso de ML, sendo que o modelo foi bastante utilizado no processo de fresamento (*Milling*), porém teve a furação (*Drilling*) e a usinagem híbrida (*Hybrid Machining*), empatadas na porcentagem de pesquisas analisadas no período de 2021-2025, ambas com 19%, podendo ser ligado ao uso de ANN devido a natureza complexa e multifatorial de dados e objetivos de otimização e predição, pela possibilidade de modelar relações não lineares e integrar-se em sistemas maiores. Na Figura 19 é possível perceber esses detalhes.

**Figura 19:** Gráfico da porcentagem de processos de usinagem no uso de ANN.



Fonte: O autor.

Um dos prováveis fatores para que o fresamento também seja o processo mais pesquisado em conjunto com ANN, é uma abundância e qualidade de dados notável, pois máquinas de fresamentos modernas são equipadas com diversos sensores (acústica, corrente, força, vibração), os quais geram dados em tempo real e em alta frequência, sendo que ANNs, são modelos *data-hungry*, prosperando com a riqueza de informação, melhorando o treinamento e validação dos mesmos. O artigo (Número 19 na tabela de dados) "Tool Wear Classification in Chipboard Milling Processes Using 1-D CNN and LSTM Based on Sequential Features" (KUREK et al., 2024), é um reflexo dessa integração de dados, focando na

classificação do desgaste de ferramentas em processos de fresamento de aglomerado. A metodologia desse artigo envolveu a extração das características de diversos sinais de sensores (emissão acústica, força, vibração e parâmetros elétricos), os quais foram utilizados como dados para a classificação do desgaste da ferramenta (em níveis “Verde”, “Amarelo” e “Vermelho”), esses dados foram retirados de um centro de usinagem de CNC. Foram comparadas duas arquiteturas de NN, uma Rede Neural Convolucional 1-D (1D-CNN) e uma rede *Long Short-Term Memory* (LSTM), o modelo 1D-CNN apresentou desempenho superior, com uma acurácia geral de 97,33% na classificação do desgaste da ferramenta, comparado ao modelo LSTM, que ficou com apenas 69,33% (KUREK et al., 2024). Isso permite garantir uma continuidade na qualidade da produção, o que solidifica a posição do fresamento como o processo de usinagem mais investigado em conjuntos com ANNs.

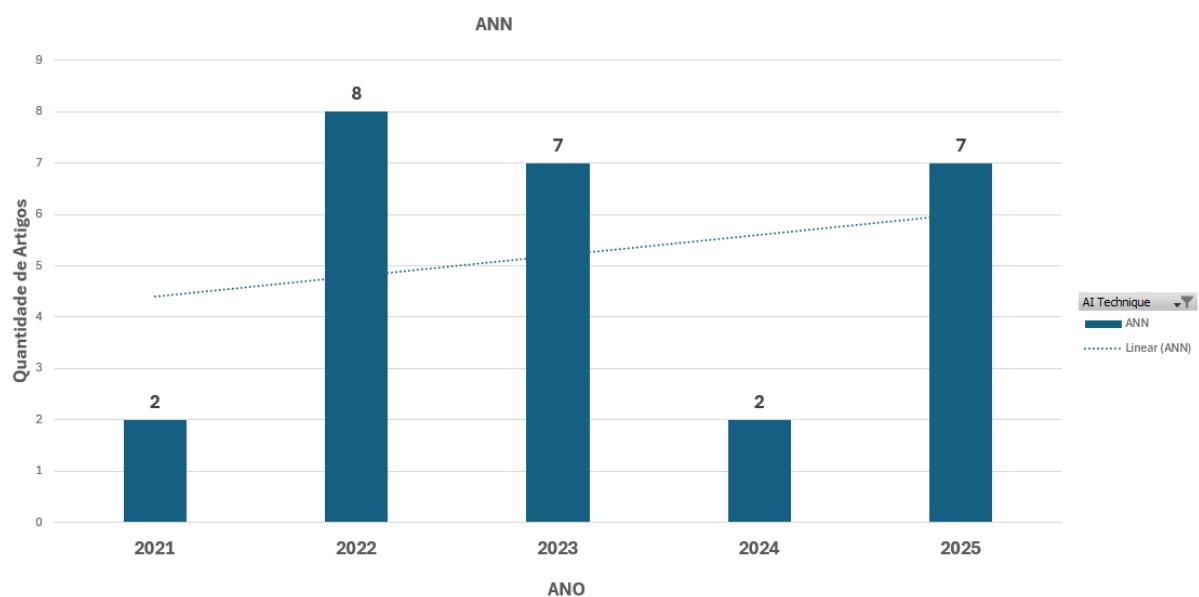
Na furação, fatores como desgaste de broca, formação de rebarbas, delaminação em compósitos e rugosidade superficial são problemas que dependem de interação multifatorial nos parâmetros de corte, sendo essencial o uso de ferramentas poderosas como as ANNs para modelar relações não lineares e complexas entre as variáveis de entrada e saída. O artigo (Número 35 na tabela de dados) "*Investigating the Accuracy of Artificial Neural Network Models in Predicting Surface Roughness in Drilling Processes*" (OKWU et al., 2024) é um bom exemplo para essa ligação, pois o estudo se dedica a investigar a acurácia de modelos ANN na predição da rugosidade superficial em processos de furação, sendo que a otimização buscada foi na furação de aço-ferramenta endurecido não retrátil (OHNS). Os parâmetros selecionados nas variáveis de entrada (velocidade de corte, avanço, tamanho da broca e profundidade de corte) foram mapeadas para a rugosidade superficial como saída, o modelo ANN desenvolvido demonstrou alta acurácia preditiva, com um  $R^2$  (Coeficiente de Determinação) de 0.997 e MSE (Erro Quadrático Médio) de 0.231893 para os dados de treinamento (OKWU et al., 2024). A alta taxa de predição da rugosidade superficial permite que fabricantes optimizem parâmetros de furação para obter qualidade desejada, mostrando que modelos ANN são úteis para deixar uma produção mais eficiente e precisa.

Na retificação, o processo possui uma natureza estocástica de altas temperaturas e forças, tornando uma predição precisa de rugosidade um desafio complexo para modelos tradicionais, por isso as ANNs, de forma mais específica, técnicas de *Deep Learning*, são fundamentais para superar essas limitações. O artigo (Número 7 da tabela de dados) "*Explainable AI (XAI)-driven vibration sensing scheme for surface quality monitoring in a smart surface grinding process*" (HANCHATE et al., 2023), investiga o uso de Inteligência Artificial Explicável (XAI), com foco em LIME (*Lime Interpretable Model-Agnostic*

*Explanations*), para monitorar a qualidade superficial em um processo de retificação inteligente, predizendo a rugosidade superficial ( $R_a$ ) a partir de dados de vibração. O experimento capturou sinais de vibração em uma retificadora de superfície de precisão CNC, transformando-os em espectrogramas que foram alimentados em uma Rede Neural Convolucional (CNN), alcançando um  $R^2$  de 0.95, o LIME interpreta as previsões da CNN, permitindo uma identificação da banda de frequência de 11.7 a 19.1 kHz como mais crítica para estimativa da rugosidade superficial, reduzindo taxas de amostragem em aproximadamente 70%, possibilitando a diminuição de custos para pequenas e médias empresas (HANCHATE et al., 2023).

Para completar a discussão sobre ANN, a Figura 20 representa a quantidade de artigos por ano de publicação da técnica de ANN. Diferente do ML, é possível notar que a ANN teve picos de publicação nos artigos analisados em 2022 e 2023, com queda em 2024 que retorna ao nível de 2021, tendo uma recuperação em 2025. Os motivos mais prováveis são combinações dinâmicas naturais de pesquisa, além do dataset da revisão ser limitado, podendo ocasionar nesses picos e vales, já que artigos mais recentes podem ainda não ter sido totalmente indexados nas bases de dados acadêmicas. Porém, isso não limita o uso da técnica, sendo que como acaba sendo usada como base em muitas técnicas de IA, refletindo a evolução e especialização no campo de Inteligência Artificial, o que mostra uma maturidade das ANNs em soluções mais complexas, podendo ser referenciada por termos mais específicos de arquiteturas avançadas.

**Figura 20:** Gráfico da tendência do uso de ANN ao longo dos anos.

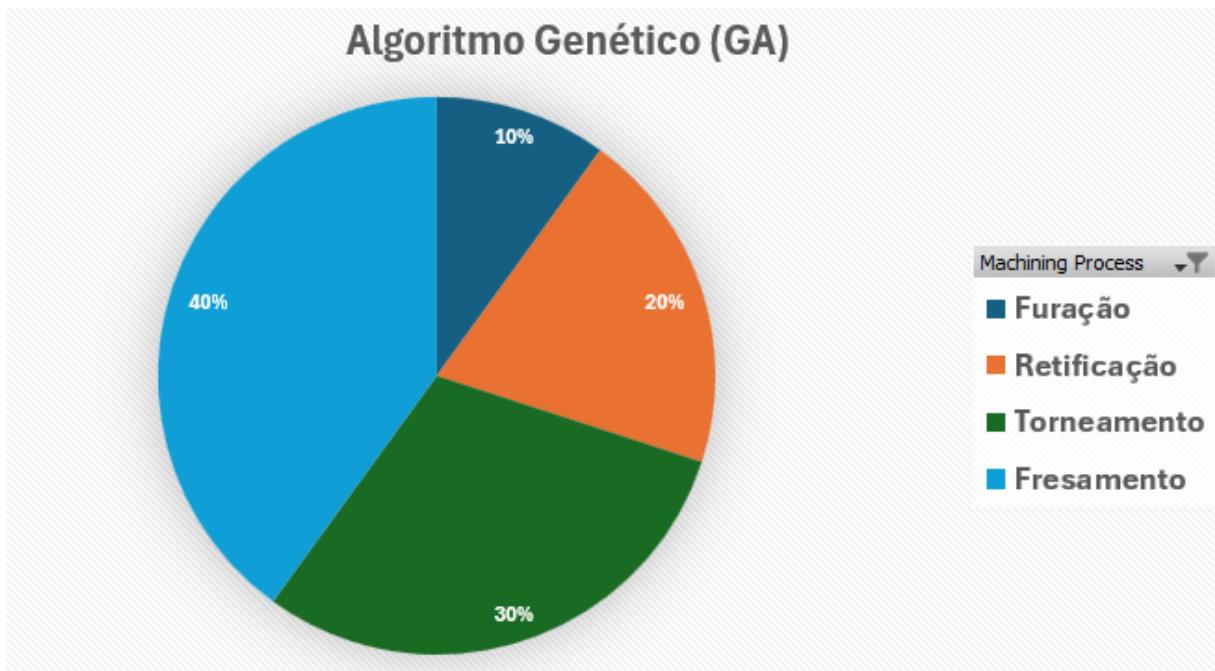


Fonte: O autor.

### 5.3.3 Pesquisas com o uso de Algoritmos Genéticos (GA)

Os algoritmos genéticos também mantêm um padrão de ter mais artigos na parte de fresamento, porém, no geral, os processos encontram-se mais balanceados. Na Figura 21 é possível ver a porcentagem total dos processos com uso de GA.

**Figura 21:** Gráfico da porcentagem do uso de GA em conjunto com os processos de usinagem.



Fonte: O autor.

O uso de GA está relacionado com a sua capacidade de explorar de forma eficiente grandes espaços de busca e otimizar múltiplos parâmetros para melhorar tanto o desempenho quanto formas práticas no processo de usinagem selecionado. Um exemplo disso é o artigo (Número 96 na tabela de dados) "*A combination of the particle swarm optimization-artificial neurons network algorithm and genetic algorithm to optimize technological parameters during milling 2017A alloy*" (BOUSNINA et al., 2023), focando principalmente na aplicação do GA no processo de fresamento. O estudo focou na otimização de parâmetros no fresamento da liga 2017A, com o objetivo de minimizar o consumo de energia, desgaste de ferramenta e custos de usinagem. A metodologia combinou um algoritmo híbrido PSO-ANN com o GA na realização da otimização, obtendo resultados notáveis como diminuição de 78,27% no consumo total de energia, 44,57% de custos totais e 39,77% na rugosidade superficial, além de também

identificar os melhores parâmetros de corte para resultados otimizados. Uma observação interessante sobre o GA, exposta no próprio artigo de Bousnina et al. (2023), é que quanto maior o número da população e de variáveis de entrada, maior o tempo de execução do algoritmo, mostrando que é necessário balanceamento de diversos fatores para o uso eficiente da GA.

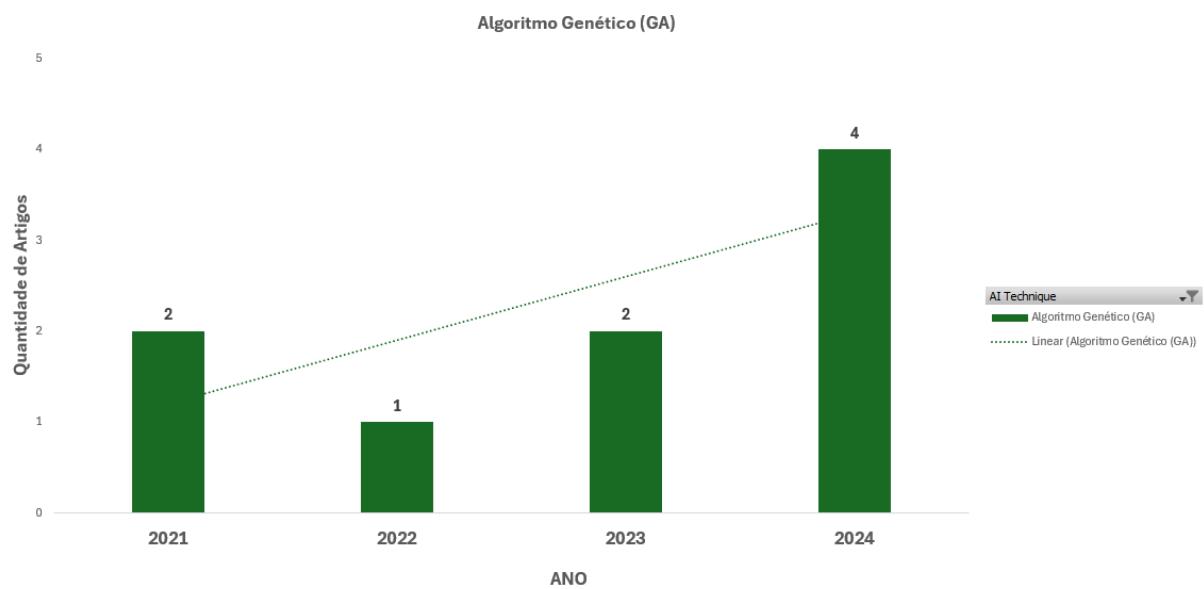
Em processos de usinagem de alta performance, a temperatura que é gerada na interface ferramenta-peça é um fator crítico que influencia diretamente o desempenho do processo e vida útil da ferramenta. O torneamento CNC é um processo de usinagem de alta performance, e o estudo do artigo (Número 25 da tabela de dados) "*Optimizing CNC turning of AISI D3 tool steel using Al<sub>2</sub>O<sub>3</sub>/graphene nanofluid and machine learning algorithms*" (GEMECHU et al., 2024) exemplifica a aplicação de Algoritmos Genéticos na otimização do processo de qualidade superficial e gerenciamento da temperatura na ponta da ferramenta. Foi aplicado nanofluido híbrido (Al<sub>2</sub>O<sub>3</sub>/grafeno) no experimento, impactando a temperatura na ponta da ferramenta em 42,5%, enquanto as técnicas de IA otimizaram parâmetros como a velocidade de corte e taxa de avanço, as quais demonstraram ser as variáveis com maior impacto na rugosidade superficial da peça. Os valores de otimização revelaram uma melhoria substancial em comparação com as condições iniciais, o que prova que Algoritmos Genéticos tem uma capacidade excelente em encontrar configurações que visam aprimorar qualidade de processo e vida útil da ferramenta no contexto da usinagem sustentável (GEMECHU et al., 2024).

É possível ver que o uso de GA permite tomadas de decisões estratégicas, melhoria de qualidade e eficiência e a otimização de múltiplos objetivos e restrições, o que é evidente no artigo (Número 68 na tabela de dados) "*Tri-objective constrained optimization of pulsating DC sourced magnetic abrasive finishing process parameters using artificial neural network and genetic algorithm*" (AHMAD et al., 2021), aplicando o uso de GA no processo de acabamento abrasivo magnético pulsante DC (PDC-MAF), uma forma de retificação. Em conjunto com ANN, o Algoritmo Genético foi usado na otimização multi-objetivo sob restrições, sendo que foi descoberto que a variação da rugosidade superficial é diretamente proporcional à corrente e inversamente proporcional ao *gap* de usinagem, e a microdureza aumenta com a corrente e diminui com o *gap*, o módulo de elasticidade também aumenta com a corrente e diminui com o *gap* (AHMAD et al., 2021). O processo de otimização com GA ocasionou na melhoria de 12,5% no desempenho geral em comparação com otimizações de objetivo único.

Finalmente, é possível concluir que o uso de GA facilita amplamente tomadas de decisão que influenciam fatores importantes para um processo com maior desempenho, sendo essencial na demanda industrial crescente por otimização e sustentabilidade. Na Figura 22, é possível perceber que 40% das pesquisas são de 2024, demonstrando um aumento no interesse

por esse tipo de técnica e também na questão da evolução computacional, já que GA necessita de amplo poder computacional para ser utilizado de forma eficiente, através de otimizações de código, paralelização, e, como foi visto, combinação com modelos preditivos de IA mais rápidos, que ajudam a acelerar uma avaliação de função de aptidão. Isso demonstra que quanto mais a tecnologia evolui, mais avançadas as técnicas vão se tornando, à medida que o custo computacional dos modelos fica mais intenso.

**Figura 22:** Gráfico da tendência de uso de GA ao longo dos anos.

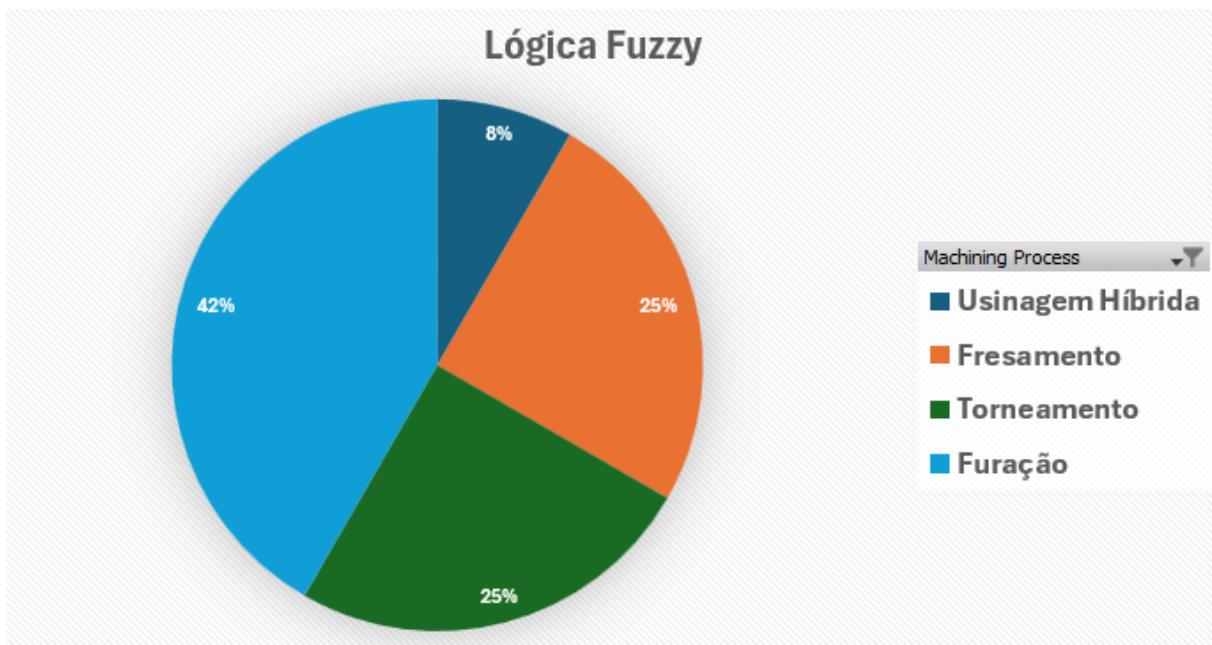


Fonte: O autor.

### 5.3.4 Pesquisas com o uso de Lógica Fuzzy (FL)

O uso da lógica difusa nas pesquisas de usinagem não seguiu o mesmo padrão das outras técnicas, onde o fresamento era o principal foco de pesquisa, nesse caso o maior volume de pesquisa foi para a furação, com 42% dos artigos selecionados. É possível visualizar na Figura 23 esse padrão, que pode estar relacionado com diversos fatores, já que a furação é um processo que lida com muita imprecisão e incerteza durante o processo, já que existem fatores como delaminação e formação de rebarbas, e a FL permite modelar relações complexas de forma mais intuitiva e robusta.

**Figura 23:** Gráfico da porcentagem do uso de FL em conjunto com os processos de usinagem.



Fonte: O autor.

Nos processos de furação é essencial que os modelos sejam interpretáveis e capazes de lidar com a imprecisão e incerteza inerentes ao processo, e o artigo (Número 32 na tabela de dados) "*A vibration based automatic fault detection scheme for drilling process using type-2 fuzzy logic*" (PAUL et al., 2022), demonstra como é importante o monitoramento da condição da ferramenta e detecção de falhas. No estudo é proposto um esquema de detecção de falhas automático para o processo de furação, o qual utiliza um sistema de lógica fuzzy do tipo 2, baseada em vibração para identificar anomalias. Os resultados da pesquisa demonstraram uma excelente eficácia da abordagem em tempo real, pois o sistema foi capaz de detectar

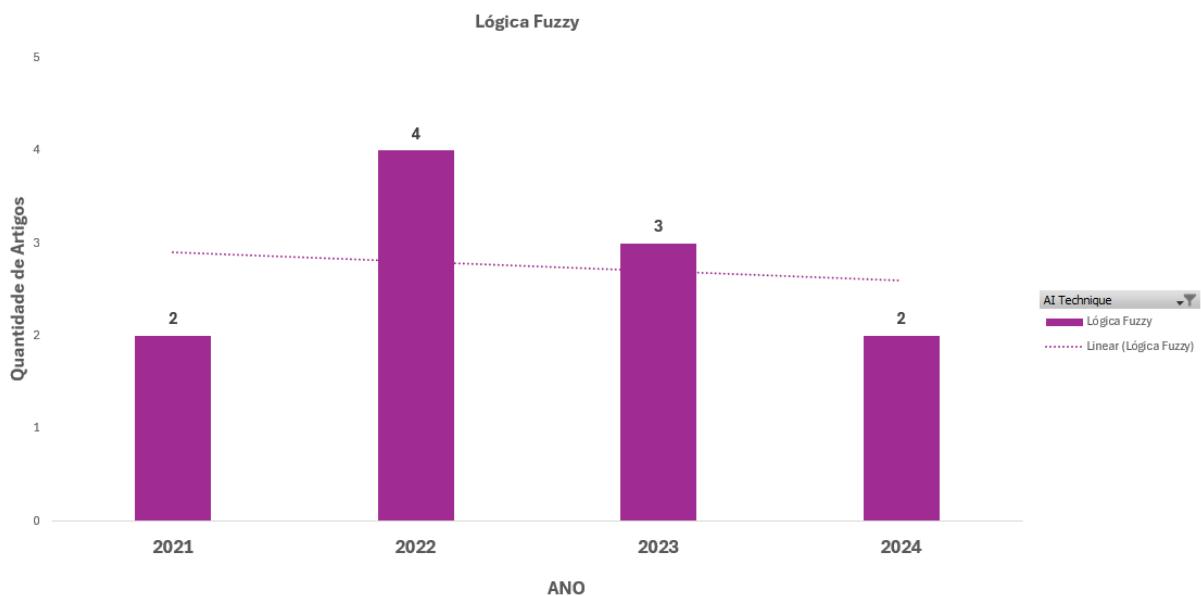
instantaneamente alterações no sinal de vibração induzidas por falhas, emitindo um alarme e prevenindo danos à peças, sendo algo de extremo valor no campo de manutenção. Essa capacidade de detecção imediata é crucial para o aprimoramento de produtividade e qualidade durante o processo de usinagem, minimizando tempo de inatividade de equipamento e custos de manutenção (PAUL et al., 2022).

A lógica difusa também demonstra excelentes resultados no processo de torneamento, e o artigo (Número 30 na tabela de dados) "*An interpretable predictive modelling framework for the turning process by the use of a compensated fuzzy logic system*" (ALALAWIN et al., 2022), é um bom exemplo dessa tendência. No estudo, foi proposto uma estrutura de modelagem preditiva e interpretável no processo de torneamento, em conjunto com um sistema de Lógica Fuzzy (FLS) e um modelo de Mistura Gaussiana (GMM), sendo que os principais parâmetros que influenciaram os resultados foram a velocidade de corte, profundidade de corte, taxa de avanço e o uso ou não de lubrificante. Ao utilizar uma abordagem que foca na interpretabilidade, o modelo não apenas permite uma previsão de alta acurácia, também permite uma compreensão melhor por toda a lógica nas previsões (ALALAWIN et al., 2022). Os resultados do modelo demonstraram que o uso de um sistema com a lógica difusa melhorou a previsão em 7% para a força de corte e em 8% na rugosidade superficial, em comparação a um sistema não compensado (ALALAWIN et al., 2022).

O sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS) foi utilizado em diversas publicações analisadas nesta revisão bibliométrica, sendo uma ferramenta extremamente poderosa na otimização de processos de usinagem. Por ter uma capacidade de modelar sistemas complexos com muita incerteza, as regras “SE-ENTÃO” nos conjuntos de dados tornam o método ideal para lidar com esse tipo de processo com natureza multifatorial e não linear. O artigo (Número 92 na tabela de dados) "*Sustainable Cooling Strategies in End Milling of AISI H11 Steel Based on ANFIS Model*" (BALASUADHAKAR et al., 2025), demonstra como essa integração reflete na crescente tendência por abordagens de usinagem mais sustentáveis. Nesse estudo, que investiga o fresamento de topo de aço AISI H11, teve foco na otimização de estratégias de refrigeração sustentáveis, como o MQL (Mínima Quantidade de Lubrificante) e com adição de SiO<sub>2</sub> e Al<sub>2</sub>O<sub>3</sub>. A pesquisa envolveu a análise de diversas variáveis de desempenho críticas, sendo que chegaram a resultados de R<sup>2</sup> de 0.999 para a rugosidade superficial e de 0.998 no desgaste da ferramenta, permitindo chegar a parâmetros que diminuíram em 62.5% a temperatura de corte e 68.6% a rugosidade superficial. Com esses resultados, foi possível aumentar a vida útil da ferramenta em 23%, e reduzir o impacto ambiental ao mesmo tempo (BALASUADHAKAR et al., 2025).

Finalmente, é possível definir a Lógica Fuzzy como extremamente poderosa para lidar com situações em que há incerteza e imprecisão. Porém, ao analisar a tendência anual da lógica, na Figura 24, é possível perceber que a maioria dos artigos foram publicados no ano de 2022, o que pode ser explicado por alguns fatores. Analisando o todo, as técnicas de *Deep Learning* parecem ter capturado mais a atenção da comunidade de pesquisa, já que no geral, as variações mais avançadas de ANNs, são frequentemente mais eficazes em extraír padrões complexos de grande conjuntos de dados, especialmente com a maior disponibilidade de poder computacional, como é exposto no artigo (Número 38 na tabela de dados) “*Tool wear prediction in face milling of stainless steel using singular generative adversarial network and LSTM deep learning models*” (SHAH et al., 2022), o qual teve que gerar 29,000 escalogramas a mais para melhorar o treino da rede. Além disso, a lógica fuzzy raramente é utilizada sozinha, sendo uma técnica que muitas vezes não necessariamente foi o destaque da pesquisa, mas sim como um complemento de um sistema híbrido mais amplo, como é possível ver no artigo (Número 77 na tabela de dados) “*Analysis, modelling, and optimization of force in ultra-precision hard turning of cold work hardened steel using the CBN tool*” (ELLY et al., 2024), onde a alta performance do ANFIS é destacada, mas serve como uma ferramenta de predição para o MOPSO realizar a otimização, não sendo o foco central do estudo.

**Figura 24:** Gráfico da tendência do uso de FL ao longo dos anos.

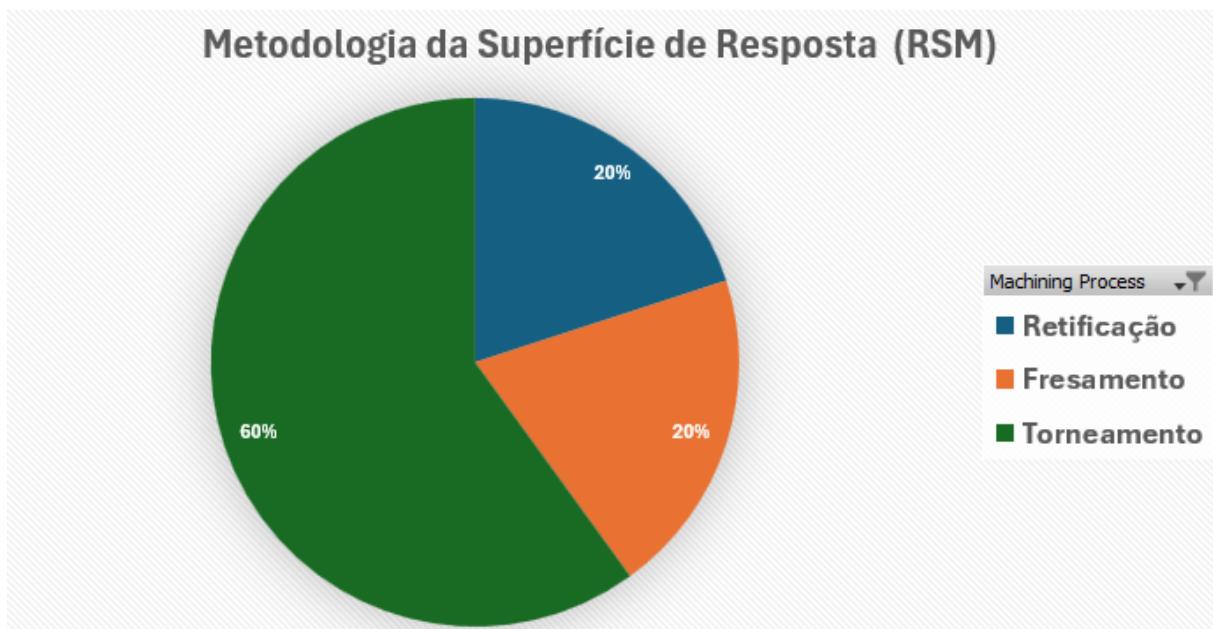


Fonte: O autor.

### 5.3.5 Pesquisas com o uso de Metodologia da Superfície de Resposta (RSM)

O uso de RSM está ligado com uma coleção de técnicas matemáticas e estatísticas para a modelagem e análise de problemas em que a resposta de interesse é influenciada por diversas variáveis, o que está diretamente ligado aos processos de usinagem. Como no caso da Lógica Fuzzy (FL), o RSM também é muito utilizado de forma híbrida, sendo frequentemente empregado com o uso de outras técnicas de IA em conjunto. Na análise da Figura 25, é possível perceber que 60% dos casos, em que o RSM foi destaque, são de torneamento, sendo que provavelmente foi mais utilizado devido a menos variáveis de usinagem e uma geometria de corte mais controlável do que outros processos como o fresamento.

**Figura 25:** Gráfico da porcentagem do uso de RSM em conjunto com os processos de usinagem.



Fonte: O autor.

A sinergia que o RSM tem com outras técnicas e seu uso no torneamento é exposto no artigo (Número 44 na tabela de dados) “*Integration of Hybrid Machine Learning and Multi-Objective Optimization for Enhanced Turning Parameters of EN-GJL-250 Cast Iron*” (KARMI et al., 2025). Esse estudo se concentra no torneamento de ferro fundido EN-GJL-250, sendo que a metodologia central utiliza o RSM para o design do experimento, sendo uma base na otimização de parâmetros. Com essa base, foi aplicado um modelo avançado de Redes Neurais Profundas (DNN) e algoritmos de otimização como o *Multi-Objective Grey Wolf Optimization*

(MOGWO), sendo que a validação dos modelos demonstrou que os resultados do RSM foram consistentes com os de modelos mais complexos, com altos valores de  $R^2$  de 0,94 para a força de corte, com 0,92 para rugosidade superficial e 0,95 para o consumo de energia. Então, o RSM permitiu que modelos de ML subsequentes sejam treinados com dados de alta qualidade e relevância, o que permitiu a identificação de configurações quase-ótimas de parâmetros de usinagem, comprovando que a integração de RSM é de suma importância na pesquisa de usinagem com a integração de IA (KARMI et al., 2025).

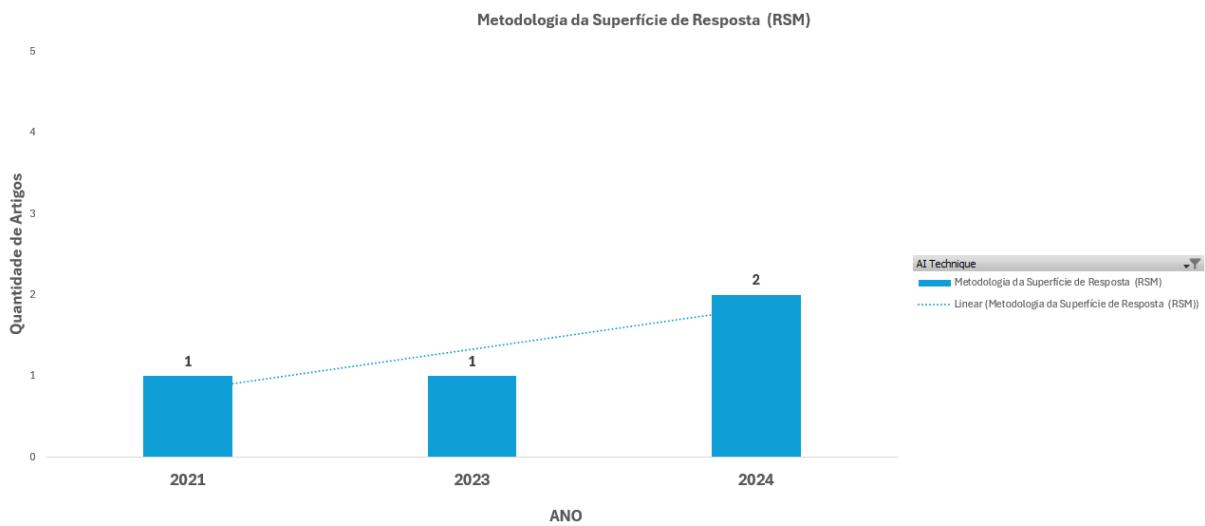
As soluções de IA em conjunto com os diversos processos de usinagem, permitem uma vasta aplicação em diferentes campos da indústria, cada um com seus próprios desafios, como no artigo (Número 103 na tabela de dados) "*Prediction of specific cutting energy consumption in eco-benign lubricating environment for biomedical industry applications: Exploring efficacy of GEP, ANN, and RSM models*" (SEN et al., 2024), onde o estudo é focado na predição do consumo específico de energia de corte (SCEC) no torneamento de Hastelloy C276 (é uma liga muito utilizada para a fabricação de instrumentos cirúrgicos e equipamentos biomédicos) em um ambiente de lubrificação eco-benigna, tendo uma aplicação relevante na indústria biomédica. Foram comparados três modelos diferentes, GEP, ANN e um modelo empírico baseado em RSM, e embora o modelo GEP apresentou uma maior acurácia ( $R^2$  de 0.985), o modelo de RSM também teve um desempenho competitivo, com o  $R^2$  de 0.952. Esses resultados demonstram que o RSM foi utilizado como uma linha de comparação para o desempenho de modelos mais complexos de IA, pois o número limitado de experimentos permitiu uma modelagem das relações entre velocidade de corte, taxa de avanço e profundidade de corte (SEN et al., 2024).

No aspecto de controle de qualidade, a utilização das técnicas de RSM em conjunto com ML, permite prever e monitorar características críticas da peça, sendo que o artigo (Número 80 na tabela de dados) "*Application of machine learning techniques in environmentally benign surface grinding of Inconel 625*" (KISHORE et al., 2023), investiga o desempenho da retificação superficial de Inconel 625 (IN 625) sob condições secas, úmidas e de mínima quantidade de lubrificação (MQL). No estudo, o RSM foi utilizado na análise de processo, enquanto os modelos de ML atuam na predição de variáveis como força tangencial e rugosidade superficial. O modelo KNN atingiu um resultado de alta precisão ( $R^2 > 0.95$ ), permitindo que ajustes proativos sejam feitos nos parâmetros, pois a análise das características como a morfologia dos cavacos e o desgaste da aresta possibilitam desvios do desempenho ideal. Como conclusão, foi destacado que a retificação com MQL resultou em uma melhor morfologia de cavacos e um desgaste de aresta quase insignificante se comparado com a usinagem a seco,

contribuindo na afirmação que os modelos de IA ajudam a manter um controle de qualidade superior (KISHORE et al., 2023).

Ao analisar a menção dos artigos sobre RSM, ao longo dos anos analisados, percebemos que essa técnica é utilizada mais como uma forma de planejamento experimental, pois a metodologia estatística serve mais para o design e otimização, atuando de forma complementar com outros modelos. De forma parecida com a lógica difusa, essa técnica demonstra quanto a hibridização está sendo utilizada nas pesquisas de hoje, interligando diversas técnicas e metodologias para chegar em melhores experimentos para ter uma melhor qualidade de dados e, consequentemente, resultados mais próximos dos considerados ideais. É evidenciado na pesquisa (Número 88 na tabela de dados) "*A combination of the particle swarm optimization-artificial neurons network algorithm and response surface method to optimize energy consumption and cost during milling of the 2017A alloy*" (BOUSNINA et al., 2024), que a utilização do RSM é uma técnica estatística mais tradicional, mas é uma ferramenta eficaz na otimização de parâmetros, servindo como *benchmark* para avaliação de performance de abordagens de IA mais complexas. Na Figura 26 é possível observar a tendência anual do RSM.

**Figura 26:** Gráfico da quantidade do uso de RSM ao longo dos anos.



Fonte: O autor.

#### 5.4 Características Gerais dos Temas de Pesquisa dos Artigos

Ao longo do período de obtenção do material de base para a confecção desta revisão bibliométrica, 85 artigos foram selecionados, abrangendo as mais diversas possibilidades de pesquisa dentro do campo de processos de usinagem e o uso de IA para o auxílio dos mesmos. Na Tabela 3 abaixo, é possível ver o número de artigos por processo de usinagem.

**Tabela 3:** Quantidade de Artigos por Processo de Usinagem ao longo de 2021-2025.

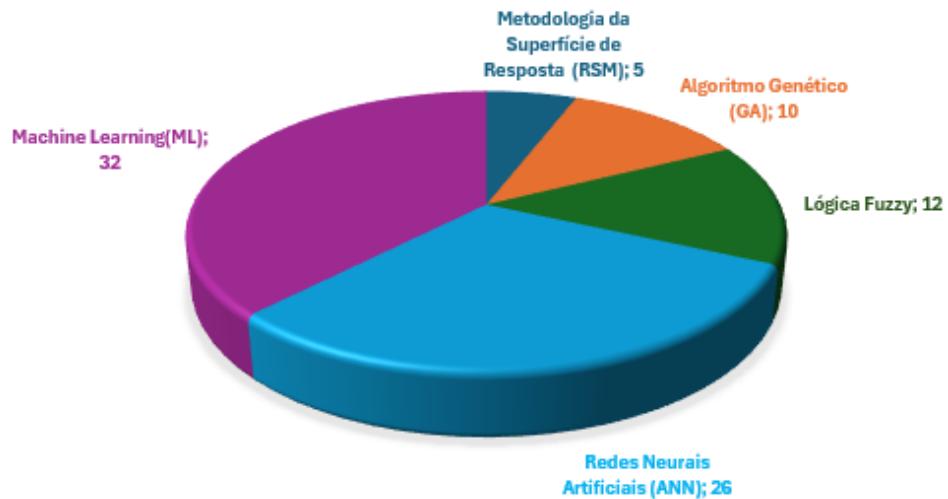
Processo De Usinagem	Quantidade de Artigos (2021-2025)
<i>Grinding</i> (Retificação)	10
<i>Hybrid Machining</i> (Usinagem Híbrida)	11
<i>Drilling</i> (Furação)	12
<i>Turning</i> (Torneamento)	23
<i>Milling</i> (Fresamento)	29
<b>TOTAL</b>	<b>85</b>

Fonte: O autor.

Já na Figura 27, o gráfico de pizza relaciona a quantidade de técnicas de IA utilizadas em relação ao total de artigos selecionados.

**Figura 27:** Gráfico da Quantidade de Artigos por Técnica de IA utilizada.

**TÉCNICAS DE IA - QUANTIDADE DE ARTIGOS  
(2021-2025)**



Fonte: O autor.

É possível perceber que dos artigos selecionados, o processo de Fresamento (*Milling*) teve a maior quantidade de pesquisa publicada ao longo dos anos de 2021 até 2025, com vinte e nove artigos publicados, seguido pelo processo de Torneamento (*Turning*), com vinte e três artigos publicados. Os outros processos, Furação (*Drilling*), Usinagem Híbrida (*Hybrid Machining*) e Retificação (*Grinding*), tiveram uma quantidade de pesquisa mais equilibrada no mesmo período.

Em relação às técnicas, é notável o maior uso de técnicas de Aprendizado de Máquina (ML) e Redes Neurais (ANN), já as outras técnicas tiveram um pouco menos de destaque, mas uma análise mais profunda sobre cada caso foi discutida ao longo dos resultados dos artigos no tópico 5.3.

Os *Key Findings* (Principais Conclusões) dos artigos também foram de extrema importância para averiguar o tópico discutido e quais áreas do uso de IA com processos de usinagem estão sendo mais exploradas no mundo acadêmico e industrial. Na Tabela 4 é possível perceber uma grande discrepância entre os números, sendo que os motivos serão abordados de forma que seja possível se relacionar com o cenário atual.

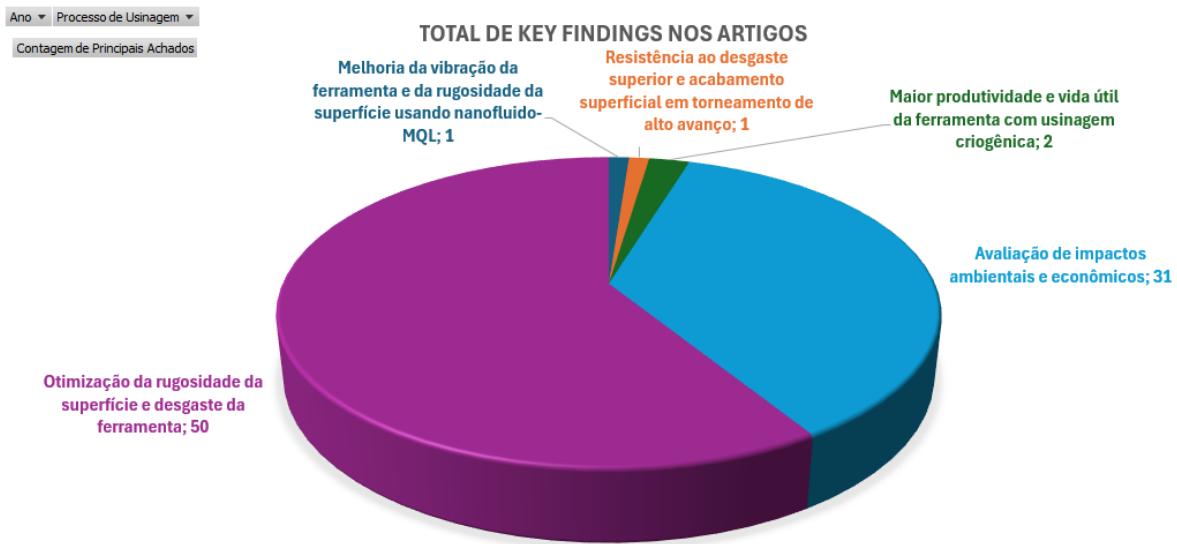
**Tabela 4:** Quantidade de Artigos por *Key Finding* de 2021-2025.

Principais Conclusões	Qtd.
Melhoria da vibração da ferramenta e da rugosidade da superfície usando nanofluido-MQL	1
Resistência ao desgaste superior e acabamento superficial em torneamento de alto avanço	1
Maior produtividade e vida útil da ferramenta com usinagem criogênica	2
Avaliação de impactos ambientais e econômicos	31
Otimização da rugosidade da superfície e desgaste da ferramenta	50
<b>TOTAL</b>	<b>85</b>

Fonte: O autor.

Para ilustrar de forma mais visual, a Figura 28 representa a Tabela 3.

**Figura 28:** Gráfico de Artigos por *Key Finding* de 2021-2025.



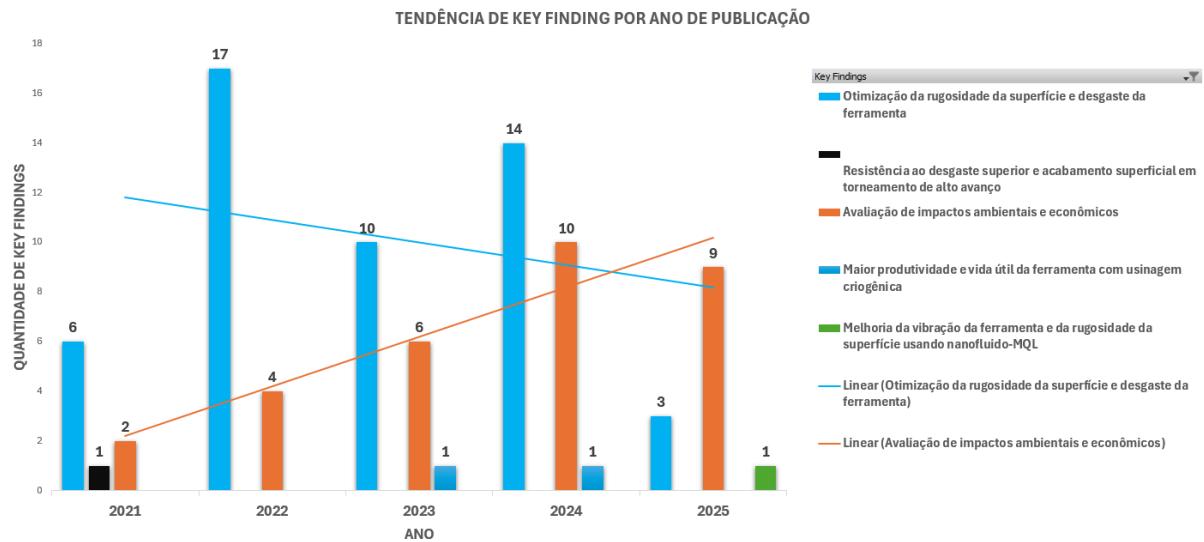
Fonte: O autor.

A diferença na quantidade de conclusões é notável, sendo que a otimização da rugosidade da superfície e desgaste de ferramenta em conjunto com a avaliação dos impactos ambientais e econômicos fazem parte de 95% dos resultados encontrados, com 50 e 31 artigos, respectivamente. Enquanto isso, *Key Findings* mais específicos ficaram nos 5% restantes do resultado devido a um maior nicho de pesquisa e certa dificuldade experimental por custos elevados e *setups* experimentais complexos, sendo que um bom exemplo dessas dificuldades está explicitado no artigo (Número 5 na tabela de dados) de Zhang e Xu (2021), o qual teve como *Key Finding* a resistência superior ao desgaste e acabamento superficial em torneamento de alta taxa de avanço, abordando diretamente a dificuldade de otimização de parâmetros em um contexto que é “altamente dependente de métodos matemáticos complexos e demorados”. Nesse artigo, fica explicitado as dificuldades intrínsecas ao processo de torneamento de alta velocidade, tendo em vista que um modelo de ML foi utilizado, o Processo Gaussiano (GPR), conseguiu atingir resultados com boa precisão, porém a usinagem apresenta desafios significativos devido à complexidade e natureza não linear entre parâmetros de entrada e saídas, o que exige modelos preditivos acurados e estáveis que são capazes de lidar com incertezas e garantir uma eficiência computacional de baixo custo para aplicabilidade em ambientes industriais de ritmo acelerado (ZHANG; XU, 2021).

Os Artigos que discutem sobre a otimização da rugosidade superficial e do desgaste da ferramenta são maioria, com 59% dos resultados obtidos ao longo dos 85 artigos analisados. Um dos motivos para essa categoria ser a mais proeminente é porque a qualidade da superfície e a vida útil da ferramenta são indicadores de desempenho cruciais nos diversos processos de usinagem, pois impactam de forma direta a qualidade do produto, custos de produção e eficiência, justificando o alto número de publicações no período analisado. Na pesquisa do artigo (Número 98 na tabela de dados) de Dedeakayoğulları, Kaçal e Keser (2022), foi desenvolvido um modelo para prever a rugosidade superficial na furação de peças fabricadas com pré-furos SLM-Ti6Al4V, uma liga de titânio processada através de um método conhecido como *Selective Laser Melting* (SLM), onde a obtenção de uma rugosidade superficial ( $R_a$ ) precisa é essencial para atender aos rigorosos requisitos industriais. Na pesquisa, foi utilizada Redes Neurais Artificiais (ANN) em conjunto Sistemas de Inferência Neuro-Fuzzy Adaptativos (ANFIS) para prever a rugosidade superficial, utilizando parâmetros como o tipo de broca, velocidade de corte e avanço, dos diversos tipos de técnicas utilizadas, o modelo de MLP (*Multilayer Perceptron*) obteve a maior acurácia de predição da  $R_a$ , com um  $R^2$  (Coeficiente de Determinação) de 0.998 e MAPE (Erro Percentual Absoluto Médio) de 0.206%, demonstrando uma excelente capacidade de aprendizado e otimização dos parâmetros de furação ideais, os quais melhoraram o processo e qualidade final da peça, que são exigidos pela indústria, garantindo maior eficiência de fabricação ao reduzir a necessidade de testes empíricos e retrabalho (DEDEAKAYOĞULLARI; KAÇAL; KESER, 2022).

Já os artigos que falam sobre impacto econômico e ambiental fazem parte de 36% dos resultados totais, demonstrando uma crescente demanda industrial e regulatória para processos de fabricação que são mais sustentáveis, energeticamente eficazes e econômicos. O uso da IA é de grande auxílio para a otimização de tais impactos, sendo possível ver uma grande tendência de mais pesquisas relacionadas a esses tópicos ao longo dos anos, sendo evidenciado na Figura 29, onde a linha laranja mostra que com o passar dos anos, a pesquisa envolvendo os impactos econômicos e ambientais teve um crescimento notável, conseguindo ultrapassar até mesmo o *Key Finding* de otimização superficial e desgaste de ferramenta (linha azul de tendência) no ano de 2025, o que também deixa evidente que a pesquisa sobre otimização superficial e desgaste de ferramenta está aos poucos sendo saturada, abrindo oportunidades de pesquisa para outros campos.

**Figura 29:** Gráfico de tendência de *Key Finding* por ano de publicação de artigo.



Fonte: O autor.

Tendo em vista essa tendência de pesquisa relacionada com a avaliação de impactos ambientais e econômicos e a diferença que a Inteligência Artificial faz na otimização de parâmetros de usinagem com foco na sustentabilidade e eficiência econômica, um exemplo de publicação que proeminentemente discute sobre as aplicações da IA nesse âmbito é o artigo publicado em 2024 (Número 61 na tabela de dados) onde os autores afirmam que “A presente pesquisa foca em estabelecer um paradigma de manufatura sustentável” (SEN et al., 2024, p. 4575). O estudo nesse artigo focou na usinagem de torneamento de superligas (Inconel 690) sob condições de Mínima Quantidade de Lubrificação (MQL), sendo que a metodologia deles envolveu o uso de técnicas híbridas de aprendizado de máquina (ML) com algoritmos genéticos (GA), especificamente *Gene Expression Programming* (GEP) e *Particle Swarm Optimization* (PSO) para a otimização. O foco principal foi a avaliação de cinco indicadores-chave de sustentabilidade: consumo total de energia, emissão total de carbono, custo total da usinagem, rugosidade superficial e desgaste da ferramenta. A pesquisa investigou a eficiência e sustentabilidade da usinagem das superligas através do uso de lubrificantes à base de óleo de girassol dopados com sílica, sendo que a proporção ótima de nanopartículas foi de 0,6% de sílica, melhorando significativamente a condutividade térmica e viscosidade dinâmica do nanolubrificante. Utilizando o GEP e PSO foi possível estabelecer a modelagem de correlações entre os parâmetros de usinagem e métricas de sustentabilidade, sendo que comparado ao meio seco, houve uma redução de 20% no consumo de energia, 18,68% na redução de emissões de carbono e uma redução de custos de aproximadamente 11,76%, além da diminuição notável na rugosidade superficial em 20,21% e redução de 31,71% no desgaste da ferramenta (SEN et al.,

2024). Esse artigo demonstra como a IA é fundamental para quantificar e impulsionar ganhos mensuráveis em eficiência, custo e impacto ambiental no cenário de manufatura moderna.

## 6 CONCLUSÃO

A Revisão Bibliométrica realizada confirmou a solidez do campo de pesquisa sobre a aplicação de IA nos processos de usinagem, tendo base na análise de 85 artigos que foram publicados entre 2021 e 2025. O estudo demonstrou a dominância de certas abordagens e revelou os principais desafios e direções promissoras para a área.

Segue abaixo as principais conclusões e deduções lógicas do trabalho.

**Dominância de Processos e Técnicas:** O fresamento (29 Artigos) e o torneamento (21 artigos) foram os processos de usinagem mais investigados. As técnicas de ML e ANN são as mais populares, com 32 e 26 artigos, respectivamente, frequentemente utilizadas em conjunto com outras metodologias como FL e RSM para aumentar a confiabilidade dos modelos.

**Foco de Pesquisa:** O principal foco dos artigos (59%) é a otimização da rugosidade superficial e do desgaste da ferramenta. No entanto, uma tendência crescente (36%) aponta para a avaliação de impactos ambientais e econômicos, indicando uma mudança no interesse acadêmico e industrial em direção a uma manufatura mais eficiente e sustentável. Quanto as lacunas de pesquisa, fica notável uma escassez de publicações que documentam estudos de caso diretamente da indústria, muitos resultados e desenvolvimentos de IA em ambientes de fabricação reais são considerados confidenciais ou proprietários, criando uma lacuna entre pesquisa acadêmica e aplicação industrial. Além disso, a revisão bibliométrica revelou que tópicos mais específicos, como a melhoria da vibração da ferramenta usando nanofluídos ou a usinagem criogênica, recebem poucas publicações, indicando áreas de nicho com potencial inexplorado.

**Desafios do Cenário:** Foram identificados desafios persistentes, como a gestão do “Big Data”, que exige o processamento de volumes massivos de dados heterogêneos. A coleta de dados para métricas específicas, como a vida útil e fadiga de ferramentas, é cara e demorada, o que limita a robustez dos modelos. Além disso, a falta de “generalização” dos modelos de IA, ou seja, a incapacidade de manter a precisão em diferentes máquinas ou materiais, sendo um dos obstáculos críticos para a implementação em larga escala.

**Inovações e Futuros Trabalhos:** A pesquisa destacou a ascensão de soluções inovadoras para mitigar esses problemas, como as abordagens híbridas (combinando simulação com ML) e os “Gêmeos Digitais” (*Digital Twins*), que possibilitam aprimorar a generalização

e o controle de qualidade em tempo real. Como sugestão para melhoria da revisão e para trabalhos futuros, propõe-se expandir o escopo para incluir mais processos, técnicas e identificar os principais autores e pesquisas mais relevantes no cenário acadêmico, para criar uma base de dados detalhada dos resultados, o que permitirá análises comparativas aprofundadas das melhores técnicas para cada tipo de processo.

Em suma, o campo da IA na usinagem é maduro em otimização de qualidade e desgaste, mas aponta para novas e promissoras direções. A transição para a manufatura inteligente, com a IA no seu núcleo, é o caminho para alcançar a máxima eficiência, qualidade e sustentabilidade na produção industrial.

## REFERÊNCIAS

YE, Ronan. **Turning vs. Milling**: What's the Difference?. [S. l.], 8 maio 2025. Disponível em: <https://www.3erp.com/blog/turning-vs-milling/>. Acesso em: 21 de jul. 2025.

YE, Ronan. **What is CNC Drilling**: Definition, Types, Applications, Machines & Characteristics. [S. l.], 4 março 2024. Disponível em: <https://www.3erp.com/blog/cnc-drilling/>. Acesso em: 21 de jul. 2025.

YE, Ronan. **What is Grinding**: Definition, Process, Types & Specifications. [S. l.], 23 janeiro 2024. Disponível em: <https://www.3erp.com/blog/what-is-grinding/>. Acesso em: 21 de jul. 2025.

BROWN, Sara. **Machine learning explained**. Cambridge, MA: MIT Sloan, 21 abril 2021. Disponível em: <https://mitsloan.mit.edu/ideas-made-to-matter/machine-learning-explained>. Acesso em: 22 jul. 2025.

CHEN, Michael. **O que é machine learning?** Redwood Shores, CA: Oracle, 25 nov. 2024. Disponível em: <https://www.oracle.com/br/artificial-intelligence/machine-learning/what-is-machine-learning/>. Acesso em: 22 jul. 2025.

QAMAR, Roheen; ZARDARI, Baqar Ali. Artificial Neural Networks: An Overview. **Mesopotamian Journal of Computer Science**, [S. l.], v. 2023, p. 124-133, 2 ago. 2023. DOI: 10.58496/MJCSC/2023/015. Disponível em: <https://mesopotamian.press/journals/index.php/cs/article/view/118>. Acesso em: 22 jul. 2025.

Shweta. Neural Networks: A Beginner's Guide. **Towards Data Science**, 23 ago. 2018. Disponível em: [https://towardsdatascience.com/neural-networks-a-beginners-guide-7b374b66441a/](https://towardsdatascience.com/neural-networks-a-beginners-guide-7b374b66441a). Acesso em: 22 jul. 2025.

BISCONTINI, Tyler. **Genetic algorithm (GA)**. [S. l.]: EBSCO Research Starters, 2022. Disponível em: <https://www.ebsco.com/research-starters/computer-science/genetic-algorithm-ga>. Acesso em: 23 jul. 2025.

MATANGA, Yves. **Genetic Algorithms**. [S. l.]: ML Insights Central, [s.d.]. Disponível em: <https://mlinsightscentral.com/index.php/genetic-algorithms/>. Acesso em: 23 jul. 2025.

FERRER, Josep. **Fuzzy Logic in AI**. [S. l.]: DataCamp, 16 jan. 2025. Disponível em: <https://www.datacamp.com/tutorial/fuzzy-logic-in-ai>. Acesso em: 24 jul. 2025.

RESPONSE SURFACE METHODOLOGY (RSM) Overview & Applications. [S. l.]: Neural Concept, [s.d.]. Disponível em: <https://www.neuralconcept.com/post/response-surface-methodology-overview-applications>. Acesso em: 25 jul. 2025.

HASHEMI-POUR, Cameron; BOTELHO, Bridget; BIGELOW, Stephen J. **What is big data? Definition, characteristics, key technologies and examples.** Newton, MA: TechTarget, 21 mar. 2024. Disponível em: <https://www.techtarget.com/searchdatamanagement/definition/big-data>. Acesso em: 08 ago. 2025.

SALESFORCE. **Big Data: o que é, importância e exemplos.** [S. l.]: Salesforce, 08 fev. 2024. Disponível em: <https://www.salesforce.com/br/blog/big-data/>. Acesso em: 08 ago. 2025.

WCM COMPONENTES USINADOS. **Furação e Rosqueamento.** [S. l.], [s.d.]. Disponível em: <https://www.wcmcomponentes.com.br/servico/furacao-e-rosqueamento>. Acesso em: 11 ago. 2025.

WOLF BRASIL. **Fresamento:** Melhores Práticas. [S. l.], [s.d.]. Disponível em: <https://wolfbrasil.com.br/fresamento-melhores-praticas>. Acesso em: 11 ago. 2025.

RETIFICADORA CANADENSE. **Serviços.** [S.l.], [s.d.]. Disponível em: <https://retificadoracanadense.com.br/servicos>. Acesso em: 11 ago. 2025.

PASSAS, Ioannis. Bibliometric Analysis: The Main Steps. **Encyclopedia**, Basel, Switzerland, v. 4, n. 2, p. 1014-1025, jun. 2024. DOI: 10.3390/encyclopedia4020065. Disponível em: <https://discovery.researcher.life/article/bibliometric-analysis-the-main-steps/72c39d46342b32178debf1b543802988>. Acesso em: 15 ago. 2025.

ABAZA, Bogdan Felician; GHEORGHITA, Vlad. **Artificial Neural Network Framework for Hybrid Control and Monitoring in Turning Operations.** Applied Sciences, v. 15, n. 7, p. 3499, 2025. doi: [10.3390/app15073499](https://doi.org/10.3390/app15073499).

ABD-ELWAHED, Mohamed S. **Multi-Objective Optimization of Drilling GFRP Composites Using ANN Enhanced by Particle Swarm Algorithm.** Processes, v. 11, n. 8, p. 2418, 2023. doi: [10.3390/pr11082418](https://doi.org/10.3390/pr11082418).

ABYANEH, Mohsen Dehghanpour; NARIMANI, Parviz; HADAD, Mohammadjafar; et al. **Using machine learning and optimization for controlling surface roughness in grinding of St37.** doi: [10.22059/ees.2023.2000614.1424](https://doi.org/10.22059/ees.2023.2000614.1424)

AHMAD, Shadab; SINGARI, Ranganath M.; MISHRA, R.S. **Tri-objective constrained optimization of pulsating DC sourced magnetic abrasive finishing process parameters using artificial neural network and genetic algorithm.** Materials and Manufacturing Processes, v. 36, n. 7, p. 843–857, 2021. doi: [10.1080/10426914.2020.1866196](https://doi.org/10.1080/10426914.2020.1866196).

AKPUDO, Ugochukwu Ejike; HUR, Jang-Wook. **Exploring the Efficiencies of Spectral Isolation for Intelligent Wear Monitoring of Micro Drill Bit Automatic Regrinding In-Line Systems.** Algorithms, v. 15, n. 6, p. 194, 2022. doi: [10.3390/a15060194](https://doi.org/10.3390/a15060194).

ALALAWIN, Abdallah; ALALAWEEN, Wafa' H.; SHBOOL, Mohammad A.; et al. **An interpretable predictive modelling framework for the turning process by the use of a compensated fuzzy logic system.** Production & Manufacturing Research, v. 10, n. 1, p. 89–107, 2022. doi: [10.1080/21693277.2022.2064359](https://doi.org/10.1080/21693277.2022.2064359).

ALQAHTANI, Khaled N.; NASR, Mustafa M.; ANWAR, Saqib; et al. **Integrated Intelligent Method Based on Fuzzy Logic for Optimizing Laser Microfabrication Processing of GnPs-Improved Alumina Nanocomposites.** Micromachines, v. 14, n. 4, p. 750, 2023. doi: [10.3390/mi14040750](https://doi.org/10.3390/mi14040750).

ASILTÜRK, İlhan; İNCE, Mehmet Alper. **Fuzzy Logic Modelling Of The Effect Of Tool Tip Radius On Surface Roughness In Machining Co28Cr6Mo Wrought Steels In CNC Turning.** European Journal of Science and Technology, 2022. doi: [10.31590/ejosat.1223563](https://doi.org/10.31590/ejosat.1223563).

ASLAN, Abdullah. **Machine learning models and machinability analysis for comparison of various cooling and lubricating mediums during milling of Hardox 400 steel.** Tribology International, v. 198, p. 109860, 2024. doi: [10.1016/j.triboint.2024.109860](https://doi.org/10.1016/j.triboint.2024.109860).

AWAN, Muhammad Rizwan; GONZÁLEZ ROJAS, Hernán A.; HAMEED, Saqib; et al. **Machine Learning-Based Prediction of Specific Energy Consumption for Cut-Off Grinding.** Sensors, v. 22, n. 19, p. 7152, 2022. doi: [10.3390/s22197152](https://doi.org/10.3390/s22197152).

BAGGA, Prashant J.; MAKHESANA, Mayur A.; DARJI, Pranav P.; et al. **Tool life prognostics in CNC turning of AISI 4140 steel using neural network based on computer vision.** The International Journal of Advanced Manufacturing Technology, v. 123, n. 9–10, p. 3553–3570, 2022. doi: [10.1007/s00170-022-10485-9](https://doi.org/10.1007/s00170-022-10485-9).

BALASUADHAKAR, A.; THIRUMALAI KUMARAN, S.; UTHAYAKUMAR, M. **Machine learning prediction of surface roughness in sustainable machining of AISI H11 tool steel.** Smart Materials in Manufacturing, v. 3, p. 100075, 2025. doi: [10.1016/j.smmf.2025.100075](https://doi.org/10.1016/j.smmf.2025.100075).

BALASUADHAKAR, Arumugam; KUMARAN, Sundaresan Thirumalai; ALI, Saood. **Sustainable Cooling Strategies in End Milling of AISI H11 Steel Based on ANFIS Model.** Machines, v. 13, n. 3, p. 237, 2025. doi: [10.3390/machines13030237](https://doi.org/10.3390/machines13030237).

BHATTACHARYA, Mangolika; O’NEILL, Pat; SOUTHERN, Mark; et al. **Training and Tuning of Neuro - Fuzzy Control Laws for the Machining of Prosthetics.** Procedia Computer Science, v. 217, p. 1057–1065, 2023. doi: [10.1016/j.procs.2022.12.304](https://doi.org/10.1016/j.procs.2022.12.304).

BHATTACHARYA, Mangolika; O’NEILL, Pat; SOUTHERN, Mark; et al. **Use of Artificial Neural Networks in the Design of Adaptive Fuzzy Logic Controllers in the manufacturing of Prosthetic Knees.** Procedia Computer Science, v. 218, p. 2820–2829, 2023. doi: [10.1016/j.procs.2023.01.253](https://doi.org/10.1016/j.procs.2023.01.253).

BILAL, Mühenad; PODISHETTI, Ranadheer; GIRISH, Tangirala Sri; et al. **CNN-Based Classification of Optically Critical Cutting Tools with Complex Geometry: New Insights for CNN-Based Classification Tasks.** Sensors, v. 25, n. 5, p. 1575, 2025. doi: [10.3390/s25051575](https://doi.org/10.3390/s25051575).

BOUKREDERA, Farouk Said; YOUSSEFI, Mohamed Riad; HADJADJ, Ahmed; et al. **Enhancing the drilling efficiency through the application of machine learning and optimization algorithm.** Engineering Applications of Artificial Intelligence, v. 126, p. 107035, 2023. doi: [10.1016/j.engappai.2023.107035](https://doi.org/10.1016/j.engappai.2023.107035).

BOUSNINA, Kamel; HAMZA, Anis; BEN YAHIA, Noureddine. **A combination of PSO-ANN hybrid algorithm and genetic algorithm to optimize technological parameters during milling 2017A alloy.** Journal of Industrial and Production Engineering, v. 40, n. 7, p. 554–571, 2023. doi: [10.1080/21681015.2023.2243312](https://doi.org/10.1080/21681015.2023.2243312).

BOUSNINA, Kamel; HAMZA, Anis; YAHIA, Noureddine Ben. **A combination of the particle swarm optimization-artificial neurons network algorithm and response surface method to optimize energy consumption and cost during milling of the 2017A alloy.** Energy Exploration & Exploitation, v. 42, n. 2, p. 727–746, 2024. doi: [10.1177/01445987231217134](https://doi.org/10.1177/01445987231217134).

BUJ-CORRAL, Irene; SENDER, Piotr; LUIS-PÉREZ, Carmelo J. **Multi-objective optimization of tool wear, surface roughness, and material removal rate in finishing honing processes using adaptive neural fuzzy inference systems.** Tribology International, v. 182, p. 108354, 2023. doi: [10.1016/j.triboint.2023.108354](https://doi.org/10.1016/j.triboint.2023.108354).

CHAKRAVARTHY, V. V. Kalyan; RAJMOHAN, T.; VIJAYAN, D.; et al. **Application of grey-ANFIS system to optimize the drilling characteristics of nano SiC reinforced Al matrix composites.** International Journal on Interactive Design and Manufacturing (IJIDeM), v. 17, n. 6, p. 3117–3131, 2023. doi: [10.1007/s12008-023-01328-2](https://doi.org/10.1007/s12008-023-01328-2).

DANISH, Mohd; GUPTA, Munish Kumar; IRFAN, Sayed Ameenuddin; et al. **Machine learning models for prediction and classification of tool wear in sustainable milling of additively manufactured 316 stainless steel.** Results in Engineering, v. 22, p. 102015, 2024. doi: [10.1016/j.rineng.2024.102015](https://doi.org/10.1016/j.rineng.2024.102015).

DEDEAKAYOĞULLARI, Hakan; KAÇAL, Alaattin; KESER, Kübra. **Modeling and prediction of surface roughness at the drilling of SLM-Ti6Al4V parts manufactured with pre-hole with optimized ANN and ANFIS.** Measurement, v. 203, p. 112029, 2022. doi: [10.1016/j.measurement.2022.112029](https://doi.org/10.1016/j.measurement.2022.112029).

DUBEY, Vineet; SHARMA, Anuj Kumar; VATS, Prameet; et al. **Study of a Multicriterion Decision-Making Approach to the MQL Turning of AISI 304 Steel Using Hybrid Nanocutting Fluid.** Materials, v. 14, n. 23, p. 7207, 2021. doi: [10.3390/ma14237207](https://doi.org/10.3390/ma14237207).

EBRAHIMI ARAGHIZAD, Arash; PASHMFOROUSH, Farzad; TEHRANIZADEH, Faraz; et al. **Improving milling force predictions: A hybrid approach integrating physics-based simulation and machine learning for remarkable accuracy across diverse unseen materials and tool types.** Journal of Manufacturing Processes, v. 114, p. 92–107, 2024. doi: [10.1016/j.jmapro.2024.02.001](https://doi.org/10.1016/j.jmapro.2024.02.001).

EFA, Dame Alemayehu; DEJENE, Naol Dessalegn; IFA, Dejene Alemayehu; et al. **Improving computer numerical control (CNC) turning performance of AISI D2 steel with nanofluid composites and advanced machine learning techniques.** The International Journal of Advanced Manufacturing Technology, v. 138, n. 2, p. 511–539, 2025. doi: [10.1007/s00170-025-15536-5](https://doi.org/10.1007/s00170-025-15536-5).

ELLY, Ogunu Isaya; ADIZUE, Ugonna Loveday; TURA, Amanuel Diriba; et al. **Analysis, modelling, and optimization of force in ultra-precision hard turning of cold work hardened steel using the CBN tool.** Journal of the Brazilian Society of Mechanical Sciences and Engineering, v. 46, n. 10, p. 624, 2024. doi: [10.1007/s40430-024-05167-4](https://doi.org/10.1007/s40430-024-05167-4).

ERDOĞAN, Beytullah; GÜNEŞ, Abdulsamed; KILIÇ, İrfan; et al. **Predicting Thermal Conductivity of Nanoparticle-Doped Cutting Fluid Oils Using Feedforward Artificial Neural Networks (FFANN).** Micromachines, v. 16, n. 5, p. 504, 2025. doi: [10.3390/mi16050504](https://doi.org/10.3390/mi16050504).

FERTIG, A.; WEIGOLD, M.; CHEN, Y. **Machine Learning based quality prediction for milling processes using internal machine tool data.** Advances in Industrial and Manufacturing Engineering, v. 4, p. 100074, 2022. doi: [10.1016/j.jaime.2022.100074](https://doi.org/10.1016/j.jaime.2022.100074).

GEMECHU, Leta Daba; EFA, Dame Alemayehu; ABEBE, Robsan. **Optimizing CNC turning of AISI D3 tool steel using Al<sub>2</sub>O<sub>3</sub>/graphene nanofluid and machine learning algorithms.** Heliyon, v. 10, n. 24, p. e40969, 2024. doi: [10.1016/j.heliyon.2024.e40969](https://doi.org/10.1016/j.heliyon.2024.e40969).

HAMEED, Sarmad; JUNEJO, Faraz; AMIN, Imran; et al. **An Intelligent Deep Learning Technique for Predicting Hobbing Tool Wear Based on Gear Hobbing Using Real-Time Monitoring Data.** Energies, v. 16, n. 17, p. 6143, 2023. doi: [10.3390/en16176143](https://doi.org/10.3390/en16176143).

HANCHATE, Abhishek; BUKKAPATNAM, Satish T.S.; LEE, Kye Hwan; et al. **Explainable AI (XAI)-driven vibration sensing scheme for surface quality monitoring in a smart surface grinding process.** Journal of Manufacturing Processes, v. 99, p. 184–194, 2023. doi: [10.1016/j.jmapro.2023.05.016](https://doi.org/10.1016/j.jmapro.2023.05.016).

ISIK, Birhan; GULTEKIN, Mehmet Sah; FIDAN, Ismail; et al. **Optimum Cutting Parameters for Carbon-Fiber-Reinforced Polymer Composites: A Synergistic Approach with Simulated Annealing and Genetic Algorithms in Drilling Processes.** Processes, v. 12, n. 7, p. 1477, 2024. doi: [10.3390/pr12071477](https://doi.org/10.3390/pr12071477).

KAID, Husam; DABWAN, Abdulmajeed; ALQAHTANI, Khaled N.; et al. **Optimization of the Effect of Laser Power Bed Fusion 3D Printing during the Milling Process Using Hybrid Artificial Neural Networks with Particle Swarm Optimization and Genetic Algorithms.** Processes, v. 11, n. 10, p. 2892, 2023. doi: [10.3390/pr11102892](https://doi.org/10.3390/pr11102892).

KALIYANNAN, Devarajan; THANGAMUTHU, Mohanraj; PRADEEP, Pavan; et al. **Tool Condition Monitoring in the Milling Process Using Deep Learning and Reinforcement Learning.** Journal of Sensor and Actuator Networks, v. 13, n. 4, p. 42, 2024. doi: [10.3390/jsan13040042](https://doi.org/10.3390/jsan13040042).

KARMI, Yacine; BOUMEDIRI, Haithem; REFFAS, Omar; et al. **Integration of Hybrid Machine Learning and Multi-Objective Optimization for Enhanced Turning Parameters of EN-GJL-250 Cast Iron.** Crystals, v. 15, n. 3, p. 264, 2025. doi: [10.3390/crust15030264](https://doi.org/10.3390/crust15030264).

KIM, Yunhan; KIM, Taekyung; YOUN, Byeng D.; et al. **Machining quality monitoring (MQM) in laser-assisted micro-milling of glass using cutting force signals: an image-based deep transfer learning.** Journal of Intelligent Manufacturing, v. 33, n. 6, p. 1813–1828, 2022. doi: [10.1007/s10845-021-01764-5](https://doi.org/10.1007/s10845-021-01764-5).

KISHORE, Kamal; CHAUHAN, Sant Ram; SINHA, Manoj Kumar. **Application of machine learning techniques in environmentally benign surface grinding of Inconel 625.** Tribology International, v. 188, p. 108812, 2023. doi: [10.1016/j.triboint.2023.108812](https://doi.org/10.1016/j.triboint.2023.108812).

KORKMAZ, Mehmet Erdi; GUPTA, Munish Kumar; ÇELIK, Enes; et al. **Tool wear and its mechanism in turning aluminum alloys with image processing and machine learning methods.** Tribology International, v. 191, p. 109207, 2024. doi: [10.1016/j.triboint.2023.109207](https://doi.org/10.1016/j.triboint.2023.109207).

KUREK, Jarosław; KRUPA, Artur; ANTONIUK, Izabella; et al. **Improved Drill State Recognition during Milling Process Using Artificial Intelligence.** Sensors, v. 23, n. 1, p. 448, 2023. doi: [10.3390/s23010448](https://doi.org/10.3390/s23010448).

KUREK, Jarosław; ŚWIDERSKA, Elżbieta; SZYMANOWSKI, Karol. **Tool Wear Classification in Chipboard Milling Processes Using 1-D CNN and LSTM Based on Sequential Features.** Applied Sciences, v. 14, n. 11, p. 4730, 2024. doi: [10.3390/app14114730](https://doi.org/10.3390/app14114730).

LAKSHMANA KUMAR, S.; JACINTHA, V.; MAHENDRAN, A.; et al. **A Machine Learning Approach to Optimize, Model, and Predict the Machining Factors in Dry Drilling of Nimonic C263.** Advances in Materials Science and Engineering, v. 2022, p. 1–11, 2022. doi: [10.1155/2022/4856089](https://doi.org/10.1155/2022/4856089).

LEE, Sangkyoung; CHEN, Zhuoxiao; LUO, Yadan; et al. **Enhanced prediction accuracy in high-speed grinding of brittle materials using advanced machine learning techniques.** Journal of Intelligent Manufacturing, 2024. doi: [10.1007/s10845-024-02532-x](https://doi.org/10.1007/s10845-024-02532-x).

LEE, Stephen K. H.; MONGAN, Patrick G.; FARHADI, Ahmad; et al. **In-situ evaluation of hole quality and cutting tool condition in robotic drilling of composite materials using machine learning.** Journal of Intelligent Manufacturing, 2025. doi: [10.1007/s10845-024-02528-7](https://doi.org/10.1007/s10845-024-02528-7).

LI, Shuhang; LI, Meiqiu; GAO, Yingning. **Deep Learning Tool Wear State Identification Method Based on Cutting Force Signal.** Sensors, v. 25, n. 3, p. 662, 2025. doi: [10.3390/s25030662](https://doi.org/10.3390/s25030662).

M, Ganesh; ARUNKUMAR, N; SIVA, M; et al. **Experimental investigation on sustainable machining of monel using vegetable oils as cutting fluids and machine learning-based surface roughness prediction.** Engineering Research Express, v. 6, n. 4, p. 045505, 2024. doi: [10.1088/2631-8695/ad7d67](https://doi.org/10.1088/2631-8695/ad7d67).

MAHMOOD, Jawad; MUSTAFA, Ghulam-e; ALI, Muhammad. **Accurate estimation of tool wear levels during milling, drilling and turning operations by designing novel hyperparameter tuned models based on LightGBM and stacking.** Measurement, v. 190, p. 110722, 2022. doi: [10.1016/j.measurement.2022.110722](https://doi.org/10.1016/j.measurement.2022.110722).

MONDAL, Nripen; BANIK, Soumil; PAUL, Sumitava; et al. **ANFIS-TLBO-based optimization of drilling parameters to minimize burr formation in aluminum 6061.** Multiscale and Multidisciplinary Modeling, Experiments and Design, v. 7, n. 4, p. 3607–3623, 2024. doi: [10.1007/s41939-024-00433-3](https://doi.org/10.1007/s41939-024-00433-3).

MUTHURAM, N.; FRANK, F. Christo. **Optimization of machining parameters using artificial Intelligence techniques.** Materials Today: Proceedings, v. 46, p. 8097–8102, 2021. doi: [10.1016/j.matpr.2021.03.045](https://doi.org/10.1016/j.matpr.2021.03.045).

NGUYEN, Anh-Tu; NGUYEN, Van-Hai; LE, Tien-Thinh; et al. **Multiobjective Optimization of Surface Roughness and Tool Wear in High-Speed Milling of AA6061 by Machine Learning and NSGA-II.** Advances in Materials Science and Engineering, v. 2022, p. 1–21, 2022. doi: [10.1155/2022/5406570](https://doi.org/10.1155/2022/5406570).

OKWU, M.O.; OTANOCHA, O.B.; EDWARD, B.A.; et al. **Investigating the Accuracy of Artificial Neural Network Models in Predicting Surface Roughness in Drilling Processes.** Procedia Computer Science, v. 232, p. 1982–1990, 2024. doi: [10.1016/j.procs.2024.02.020](https://doi.org/10.1016/j.procs.2024.02.020).

PATANGE, Abhishek; SOMAN, Rohan N; PARDESHI, Sujit; et al. **Milling cutter fault diagnosis using unsupervised learning on small data: A robust and autonomous framework.** Eksplotacja i Niezawodność – Maintenance and Reliability, v. 26, n. 1, 2024. doi: [10.17531/ein/178274](https://doi.org/10.17531/ein/178274).

PATURI, Uma Maheshwara Reddy; CHERUKU, Suryapavan; PASUNURI, Venkat Phani Kumar; et al. **Modeling of tool wear in machining of AISI 52100 steel using artificial neural networks.** Materials Today: Proceedings, v. 38, p. 2358–2365, 2021. doi: [10.1016/j.matpr.2020.06.581](https://doi.org/10.1016/j.matpr.2020.06.581).

PAUL, Satyam; TURNBULL, Rob; KHODADAD, Davood; et al. **A Vibration Based Automatic Fault Detection Scheme for Drilling Process Using Type-2 Fuzzy Logic.** Algorithms, v. 15, n. 8, p. 284, 2022. doi: [10.3390/a15080284](https://doi.org/10.3390/a15080284).

PEDRAMMEHR, Siamak; HEJAZIAN, Mahsa; CHALAK QAZANI, Mohammad Reza; et al. **Machine Learning-Based Modelling and Meta-Heuristic-Based Optimization of Specific Tool Wear and Surface Roughness in the Milling Process.** Axioms, v. 11, n. 9, p. 430, 2022. doi: [10.3390/axioms11090430](https://doi.org/10.3390/axioms11090430).

POURMOSTAGHIMI, Vahid; ZADSHAKOYAN, Mohammad; KHALILPOURAZARY, Saman; et al. **A hybrid particle swarm optimization and recurrent dynamic neural network for multi-performance optimization of hard turning operation.** Artificial Intelligence for Engineering Design, Analysis and Manufacturing, v. 36, p. e28, 2022. doi: [10.1017/S0890060422000087](https://doi.org/10.1017/S0890060422000087).

QU, Dongyue; GU, Chaoyun; ZHANG, Hao; et al. **Research on Critical Quality Feature Recognition and Quality Prediction Method of Machining Based on Information Entropy and XGBoost Hyperparameter Optimization.** Applied Sciences, v. 14, n. 18, p. 8317, 2024. doi: [10.3390/app14188317](https://doi.org/10.3390/app14188317).

RAGAI, Ihab; ABDALLA, Abdallah S.; ABDELTAWAB, Hussein; et al. **Toward smart manufacturing: Analysis and classification of cutting parameters and energy consumption patterns in turning processes.** Journal of Manufacturing Systems, v. 64, p. 626–635, 2022. doi: [10.1016/j.jmsy.2022.04.016](https://doi.org/10.1016/j.jmsy.2022.04.016).

ROSS, Nimel Sworna; MASHININI, Peter Madindwa; MISHRA, Priyanka; et al. **Enhancing surface quality and tool life in SLM-machined components with Dual-MQL approach.** Journal of Materials Research and Technology, v. 31, p. 1837–1852, 2024. doi: [10.1016/j.jmrt.2024.06.183](https://doi.org/10.1016/j.jmrt.2024.06.183).

SAMSINGH, Vimal; RAMACHANDRAN, Achyuth; SELVAM, Anirudh; et al. **Python implementation of fuzzy logic for artificial intelligence modelling and analysis of important parameters in drilling of hybrid fiber composite (HFC).** IOP Conference Series: Materials Science and Engineering, v. 1012, n. 1, p. 012037, 2021. doi: [10.1088/1757-899X/1012/1/012037](https://doi.org/10.1088/1757-899X/1012/1/012037).

SEN, Binayak; BHOWMIK, Abhijit; PRAKASH, Chander; et al. **Prediction of specific cutting energy consumption in eco-benign lubricating environment for biomedical industry applications: Exploring efficacy of GEP, ANN, and RSM models.** AIP Advances, v. 14, n. 8, p. 085216, 2024. doi: [10.1063/5.0217508](https://doi.org/10.1063/5.0217508).

SEN, Binayak; DEBNATH, Shantanu; BHOWMIK, Abhijit. **Sustainable machining of superalloy in minimum quantity lubrication environment: leveraging GEP-PSO hybrid optimization algorithm.** The International Journal of Advanced Manufacturing Technology, v. 130, n. 9–10, p. 4575–4601, 2024. doi: [10.1007/s00170-024-12962-9](https://doi.org/10.1007/s00170-024-12962-9).

SHAH, Milind; VAKHARIA, Vinay; CHAUDHARI, Rakesh; et al. **Tool wear prediction in face milling of stainless steel using singular generative adversarial network and LSTM deep learning models.** The International Journal of Advanced Manufacturing Technology, v. 121, n. 1–2, p. 723–736, 2022. doi: [10.1007/s00170-022-09356-0](https://doi.org/10.1007/s00170-022-09356-0).

SINHA, Manoj Kumar; KISHORE, Kamal; ARCHANA; et al. **Hybrid approach for modelling and optimizing MQL grinding of Inconel 625 with machine learning and MCDM techniques.** International Journal on Interactive Design and Manufacturing (IJIDeM), v. 18, n. 7, p. 4697–4713, 2024. doi: [10.1007/s12008-024-01738-w](https://doi.org/10.1007/s12008-024-01738-w).

SOLEYMANI, Mehdi; HADAD, Mohammadjafar. **Applying Acoustic Signals to Monitor Hybrid Electrical Discharge-Turning with Artificial Neural Networks.** Micromachines, v. 16, n. 3, p. 274, 2025. doi: [10.3390/mi16030274](https://doi.org/10.3390/mi16030274).

STAVROPOULOS, Panagiotis; SOUFLAS, Thanassis; PAPAIOANNOU, Christos; et al. **An adaptive, artificial intelligence-based chatter detection method for milling operations.** The International Journal of Advanced Manufacturing Technology, v. 124, n. 7–8, p. 2037–2058, 2023. doi: [10.1007/s00170-022-09920-8](https://doi.org/10.1007/s00170-022-09920-8).

STEPHEN, Deborah Serenade; PRABHU, Sethuramalingam. **Experimental investigation of cutting forces in dry grinding of Ti-6Al-4V alloy using CNT nano grinding tool.** Journal of the Brazilian Society of Mechanical Sciences and Engineering, v. 46, n. 6, p. 384, 2024. doi: [10.1007/s40430-024-04980-1](https://doi.org/10.1007/s40430-024-04980-1).

SZWAJKA, Krzysztof; ZIELIŃSKA-SZWAJKA, Joanna; TRZEPIECIŃSKI, Tomasz. **The Use of a Radial Basis Function Neural Network and Fuzzy Modelling in the Assessment of Surface Roughness in the MDF Milling Process.** Materials, v. 16, n. 15, p. 5292, 2023. doi: [10.3390/ma16155292](https://doi.org/10.3390/ma16155292).

TABASZEWSKI, Maciej; TWARDOWSKI, Paweł; WICIAK-PIKUŁA, Martyna; et al. **Machine Learning Approaches for Monitoring of Tool Wear during Grey Cast-Iron Turning.** Materials, v. 15, n. 12, p. 4359, 2022. doi: [10.3390/ma15124359](https://doi.org/10.3390/ma15124359).

TOUATI, Sofiane; BOUMEDIRI, Haithem; KARMI, Yacine; et al. **Performance analysis of steel W18CR4V grinding using RSM, DNN-GA, KNN, LM, DT, SVM models, and optimization via desirability function and MOGWO.** Heliyon, v. 11, n. 4, p. e42640, 2025. doi: [10.1016/j.heliyon.2025.e42640](https://doi.org/10.1016/j.heliyon.2025.e42640).

TRAN, Cong Chi; NGUYEN, Van Tuu. **Surface roughness prediction for CNC-turned C45 steel utilising adaptive neuro-fuzzy inference systems.** Journal of Mechanical Engineering and Sciences, p. 10222–10232, 2024. doi: [10.15282/jmes.18.4.2024.1.0807](https://doi.org/10.15282/jmes.18.4.2024.1.0807).

TRAN, Minh-Quang; ELSISI, Mahmoud; VU, Viet Q.; et al. **Effective Optimization Based on Equilibrium Optimizer for Dynamic Cutting Force Coefficients of the End-Milling Process.** Mathematics, v. 10, n. 18, p. 3287, 2022. doi: [10.3390/math10183287](https://doi.org/10.3390/math10183287).

TWARDOWSKI, Paweł; TABASZEWSKI, Maciej; TABASZEWSKI, Mateusz; et al. **Application of machine learning algorithms for recognizing the wear of the cutting tool during precision milling of hardened tool steel.** Advances in Science and Technology Research Journal, v. 19, n. 2, p. 365–382, 2024. doi: [10.12913/22998624/196706](https://doi.org/10.12913/22998624/196706).

VAL, Sonia; LAMBÁN, María Pilar; LUCIA, Javier; et al. **Analysis and Prediction of Wear in Interchangeable Milling Insert Tools Using Artificial Intelligence Techniques.** Applied Sciences, v. 14, n. 24, p. 11840, 2024. doi: [10.3390/app142411840](https://doi.org/10.3390/app142411840).

WU, Rui; ZHENG, Jianxin; YIN, Xiyan. **Dynamic Scheduling for Multi-Objective Flexible Job Shops with Machine Breakdown by Deep Reinforcement Learning.** Processes, v. 13, n. 4, p. 1246, 2025. doi: [10.3390/pr13041246](https://doi.org/10.3390/pr13041246).

XU, Long-Hua; HUANG, Chuan-Zhen; NIU, Jia-Hui; et al. **Prediction of cutting power and surface quality, and optimization of cutting parameters using new inference system in high-speed milling process.** Advances in Manufacturing, v. 9, n. 3, p. 388–402, 2021. doi: [10.1007/s40436-020-00339-6](https://doi.org/10.1007/s40436-020-00339-6).

XUN, Cheng; WU, Pengcheng. **A Generic Multi-Objective Optimization of Machining Processes Using an End-to-End Evolutionary Algorithm.** Machines, v. 12, n. 9, p. 635, 2024. doi: [10.3390/machines12090635](https://doi.org/10.3390/machines12090635).

YANG, Qian; PATTIPATI, Krishna R.; AWASTHI, Utsav; et al. **Hybrid data-driven and model-informed online tool wear detection in milling machines.** Journal of Manufacturing Systems, v. 63, p. 329–343, 2022. doi: [10.1016/j.jmsy.2022.04.001](https://doi.org/10.1016/j.jmsy.2022.04.001).

YUAN, Dezhi; GUO, Hao; LIN, Xin; et al. **Hybrid Knowledge-Based Digital Twin for Cutters of Machine Tools.** IEEE Transactions on Industrial Informatics, v. 21, n. 7, p. 5612–5621, 2025. doi: [10.1109/TII.2025.3556067](https://doi.org/10.1109/TII.2025.3556067).

YURTKURAN, Hakan; KORKMAZ, Mehmet Erdi; GUPTA, Munish Kumar; et al. **Prediction of power consumption and its signals in sustainable turning of PH13-8Mo steel with different machine learning models.** The International Journal of Advanced Manufacturing Technology, v. 133, n. 5–6, p. 2171–2188, 2024. doi: [10.1007/s00170-024-13867-3](https://doi.org/10.1007/s00170-024-13867-3).

ZHANG, Jianlei; ZENG, Yukun; STARLY, Binil. **Recurrent neural networks with long term temporal dependencies in machine tool wear diagnosis and prognosis.** SN Applied Sciences, v. 3, n. 4, p. 442, 2021. doi: [10.1007/s42452-021-04427-5](https://doi.org/10.1007/s42452-021-04427-5).

ZHANG, Yiwei; YAN, Mengke; LAI, Yushu; et al. **Considering the Bottom Edge Cutting Effect of the Carbon Fiber Reinforced Polymer Milling Force Prediction Model and Optimization of Machining Parameters.** Materials, v. 17, n. 23, p. 5844, 2024. doi: [10.3390/ma17235844](https://doi.org/10.3390/ma17235844).

ZHANG, Youdong; XIAO, Guijian; MA, Ji; et al. **A hybrid approach of process reasoning and artificial intelligence-based intelligent decision system framework for fatigue life of belt grinding.** The International Journal of Advanced Manufacturing Technology, v. 130, n. 1–2, p. 311–328, 2024. doi: [10.1007/s00170-023-12597-2](https://doi.org/10.1007/s00170-023-12597-2).

ZHANG, Yun; XU, Xiaojie. **Machine learning cutting force, surface roughness, and tool life in high speed turning processes.** Manufacturing Letters, v. 29, p. 84–89, 2021. doi: [10.1016/j.mfglet.2021.07.005](https://doi.org/10.1016/j.mfglet.2021.07.005).

ZHAO, Shengqiang; PENG, Fangyu; SU, Juntong; et al. **A self-adaptive agent for flexible posture planning in robotic milling system.** Journal of Manufacturing Systems, v. 75, p. 228–245, 2024. doi: [10.1016/j.jmsy.2024.06.009](https://doi.org/10.1016/j.jmsy.2024.06.009).

**APÊNDICE A – TABELA DE DADOS DA REVISÃO****Tabela TCC Revisão  
IA Português.xlsx**

A planilha original em formato Excel encontra-se disponível junto ao material suplementar.