CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
MESTRADO PROFISSIONAL EM AUTOMAÇÃO E SISTEMAS

RAFAEL GONÇALVES SOARES

MODELO PREDITIVO BASEADO EM ÁRVORE DE DECISÃO PARA CONTROLE DIMENSIONAL DE CARCAÇAS DE MANCAIS DE DESLIZAMENTO FLANGEADOS

Leopoldina, MG
2023

RAFAEL GONÇALVES SOARES

MODELO PREDITIVO BASEADO EM ÁRVORE DE DECISÃO PARA CONTROLE DIMENSIONAL DE CARCAÇAS DE MANCAIS DE DESLIZAMENTO FLANGEADOS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Automação e Sistemas do Centro Federal de Educação Tecnológica de Minas Gerais, como requisito parcial para obtenção do título de Mestre em Automação e Sistemas.

Orientadora: Prof.ª Doutora Gabriella Castro Barbosa Costa Dalpra
Coorientador: Prof. Doutor Alisson Marques Da Silva

LEOPOLDINA

2023

Soares, Rafael Gonçalves.
S676m Modelo preditivo baseado em árvore de decisão para controle dimensional de carcaças de mancais de deslizamento flangeados / Rafael Gonçalves Soares. – Leopoldina: [s.n.], 2023.
84 f. : il.; fig.

Orientadora: Gabriella Castro Barbosa Costa Dalpra.
Coorientador: Alisson Marques Da Silva.
Dissertação (mestrado) – Centro Federal de Educação Tecnológica de Minas Gerais, Programa de Pós-Graduação em Automação e Sistemas, Leopoldina, 2023.

1. Controle dimensional. 2. Modelo de predição. 3. Mancal de deslizamento. 4. Processo de usinagem. 5. Aprendizado de máquina. 6. Árvore de decisão I. Dalpra, Gabriella Castro Barbosa Costa. II. Silva, Alisson Marques Da. III. Título.

CDU: 681.5

Elaboração da ficha catalográfica pela bibliotecária Luzia Adriana Damasceno, CRB 6º/2305 Cefet/MG *Campus* Leopoldina.

DISSERTAÇÃO DE MESTRADO

"Modelo preditivo baseado em árvore de decisão para controle dimensional de carcaças de mancais de deslizamento flangeados"

AUTOR: **RAFAEL GONÇALVES SOARES**

ORIENTADORA: Professora Doutora Gabriella Castro Barbosa Costa Dalpra

A Banca Examinadora composta pelos membros abaixo aprovou em 06 de julho de 2023 esta Dissertação:

Professora Doutora Gabriella Castro Barbosa Costa Dalpra (ORIENTADORA)
Centro Federal de Educação Tecnológica de Minas Gerais – CEFET/MG

Professor Doutor Alisson Marques da Silva (COORIENTADOR)
Centro Federal de Educação Tecnológica de Minas Gerais – CEFET/MG

Professor Doutor Ângelo Rocha de Oliveira (MEMBRO INTERNO)
Centro Federal de Educação Tecnológica de Minas Gerais – CEFET/MG

Professor Pós-Doutor Jorge Nei Brito (MEMBRO EXTERNO)
Universidade Federal de São João del-Rei – UFSJ

AGRADECIMENTOS

No decorrer deste trabalho, tive o privilégio de contar com o auxílio e a compreensão de muitas pessoas, às quais gostaria de expressar minha gratidão:

A Deus, pela minha vida, e por me permitir ultrapassar todos os obstáculos encontrados ao longo da realização deste trabalho.

A minha esposa e filha, que me incentivaram nos momentos difíceis e compreenderam a minha ausência enquanto eu me dedicava à realização do mestrado.

Aos meus orientadores, pelas correções e ensinamentos que me permitiram apresentar um melhor desempenho ao longo da realização deste trabalho.

Aos professores, por todos os conselhos, pela ajuda e pela paciência com a qual guiaram o meu aprendizado.

Aos meus colegas de curso, com quem convivi intensamente durante os últimos anos, pelo companheirismo e pela troca de experiências.

Ao CEFET-MG, campus Leopoldina, pela capacidade de integrar o ambiente industrial e acadêmico em um programa de mestrado.

A todos da empresa, pela efetiva participação, fornecimento de dados e materiais que foram fundamentais para o desenvolvimento da pesquisa que possibilitou a realização deste trabalho.

RESUMO

A usinagem de precisão e o controle dimensional exigem equipamentos de alto nível tecnológico, porém, observa-se que a interação humana também é utilizada na tomada de decisões como, por exemplo, nos ajustes de parâmetros de processo ou na definição de conformidade de peças produzidas. Essa interação humana é capaz de causar imprevisibilidade nos processos de fabricação por usinagem, acarretando na diminuição da produtividade e o aumento de custos de produção. Neste sentido, esse trabalho apresenta um modelo de predição baseado em árvore de decisão para controle dimensional no processo de fabricação de carcaças de mancais de deslizamento flangeados, conforme a norma técnica DIN 31693. O método que implementa essa aplicação fundamenta-se no monitoramento holístico da geometria da superfície da peça usinada. A abordagem utilizada para a compensação dos desvios dimensionais baseia-se no monitoramento e modelagem do desvio total. A heurística é utilizada para as etapas que compõe o processo de tomada de decisão. O caminho para a implementação do modelo preditivo na linha de produção baseia-se na interação entre a experiência humana e a máquina. É proposto o uso da técnica de aprendizado de máquina baseada em árvores de decisão por regressão, para definição dos parâmetros de deslocamento dos eixos do centro de usinagem a partir dos resultados dimensionais das carcaças. O modelo é validado se o erro médio absoluto for menor ou igual a 0,003mm. Uma comparação entre um modelo de floresta aleatória é realizada para verificar o desempenho entre diferentes modelos preditivos. O modelo desenvolvido resultou em um máximo erro médio absoluto de 0,002042mm. Experimentos foram realizados em uma indústria de fabricação de mancais de deslizamento, posicionada entre as três marcas de maior participação no mercado internacional no ano de 2023, onde um lote com 12 peças foi fabricado e 48 definições de parâmetros foram submetidas ao modelo preditivo, o qual teve seu resultado aplicado em 46 definições. Por fim, a utilização do modelo preditivo foi capaz de reduzir em até 32% o tempo total de execução do processo de controle dimensional de carcaças.

Palavras-chave: Controle Dimensional; Modelo de Predição; Mancal de Deslizamento; Processo de Usinagem; Aprendizado de Máquina; Árvore de Decisão.

ABSTRACT

Precision machining and dimensional control require high-tech equipment. However, it is observed that human interaction is also used in decision-making, such as, for example, in adjusting process parameters or in defining the conformity of produced pieces. This human interaction can cause unpredictability in machining manufacturing processes, leading to decreased productivity and increased production costs. This work presents a prediction model based on a decision tree for dimensional control in the manufacturing process of side flange bearing housings, according to the technical standard DIN 31693. The method used is based on the holistic monitoring of the surface geometry of the machined piece. The approach used to compensate for dimensional deviations is based on monitoring and modeling the total deviation. The heuristic is used for the steps that make up the decision-making process. The way to implement the predictive model in the production line is based on the interaction between the human experience and the machine. A machine learning technique based on regression decision trees is used to define the displacement parameters of the machining center axes based on the dimensional results of the housings. The model is validated if the mean absolute error is less than or equal to 0.003mm. A comparison between a random forest model is performed to verify the performance between different predictive models. The developed model resulted in a maximum mean absolute error of 0.002042mm. Experiments were carried out in a journal-bearing manufacturing industry positioned among the three brands with the highest participation in the international market in 2023, whose batch with 12 pieces was manufactured, and 48 parameter definitions were submitted to the predictive model, which had its result applied to 46 definitions. Finally, the use of the predictive model was able to reduce the total execution time of housings dimensional control process by up to 32%.

Keywords: Dimensional Control; Prediction Model; Journal Bearing; Machining Process; Machine Learning; Regression Decision Trees

LISTA DE ILUSTRAÇÕES

Figura 1 - Principais operações de fresamento 20
Figura 2 - Os três eixos lineares primários: X, Y e Z 22
Figura 3 - Os três planos primários: XY, XZ e YZ 23
Figura 4 - Representação das dimensões de uma peça e seus afastamentos superiores e inferiores 31
Figura 5 - Símbolos para as características toleradas de uma peça 33
Figura 6 - Esquema simplificado de uma MMC 35
Figura 7 - Componentes típicos de um mancal de deslizamento 36
Figura 8 - Modelo conceitual de árvore de decisão 43
Figura 9 - Mancal de deslizamento norma DIN 31693. (a) Mancal montado. (b) Metades superior e inferior da carcaça 53
Figura 10 - Dimensões críticas da metade superior. (a) D1 e D2. (b) D3 e D4. Dimensões críticas da metade inferior. (c) D1 e D2. (d) D3 e D4 55
Figura 11 – Abordagem de desenvolvimento do modelo preditivo 61
Figura 12 - Modelo gráfico para A1 63
Figura 13 - Modelo gráfico para A2 63
Figura 14 - Modelo gráfico para A3 64
Figura 15 - Modelo gráfico para A4 64
Figura 16 - MCH 350 65
Figura 17 - Global S Blue 12.22.10 66
Figura 18 - Posições de usinagem das dimensões críticas da metade superior. (a) D1. (b) D2. (c) D3. (d) D4 67
Figura 19 - Metades superior e inferior da carcaça. (a) Não usinadas (b) Usinadas. 68
Figura 20 - Metades superior e inferior da carcaça em posição de medição 69

LISTA DE TABELAS

Tabela 1 - Resultado da pesquisa de trabalhos relacionados 52
Tabela 2 - Dimensões críticas 56
Tabela 3 - Matriz de relacionamento entre as variáveis 57
Tabela 4 - Parâmetros para simulação na árvore de regressão 61
Tabela 5 - Parâmetros para simulação na floresta aleatória 61
Tabela 6 - Resultados obtidos após simulações na árvore de regressão 62
Tabela 7 - Resultados obtidos após simulações na floresta aleatória 62
Tabela 8 - Variáveis independentes do teste 71
Tabela 9 - Resultado do teste: peças 1 a 6 72
Tabela 10 - Resultado do teste: peças 7 a 12 73

LISTA DE ABREVIATURAS E SIGLAS

CART	Árvores de Classificação e Regressão (*Classification and Regression Trees)*
CN	Controle Numérico
CNC	Controle Numérico Computadorizado
CPU	Unidade Central de Processamento (*Central Processing Unit)*
DIN	Instituto Alemão para Normalização (*Deustches Institut Für Nurming)*
HMC	Centro de Usinagem Horizontal (*Horizontal Machining Center)*
IA	Inteligência Artificial
MAE	Erro Médio Absoluto (*Mean Absolute Error)*
MMC	Máquina de Medição por Coordenadas
MSE	Erro Médio Quadrático (*Mean Squared Error)*
PRL	Ponto de Referência Local
PZP	Ponto Zero Peça
RM	Referência da Máquina
RMSE	Raiz Quadrada do Erro-Médio (*Root Mean Squared Error*)
R^2	Coeficiente de Determinação
SQE	Soma dos Quadrados Explicados
SQR	Soma dos Quadrados dos Resíduos
SQT	Soma dos Quadrados Totais
VCM	Centro de Usinagem Vertical (*Vertical Machining Center)*

SUMÁRIO

1 INTRODUÇÃO 12
1.1 Motivação 12
1.2 Problema, hipótese e questões de pesquisa 13
1.3 Objetivos 15
1.4 Metodologia 15
1.5 Principais contribuições 16
1.6 Estrutura do trabalho 16
2 FUNDAMENTAÇÃO TEÓRICA 17
2.1 Usinagem 18
2.1.1 Fresamento 19
2.1.2 Usinagem CNC 20
2.1.2.1 Coordenadas cartesianas e eixos 22
2.1.2.2 Controle numérico computadorizado 24
2.1.2.3 Programação CNC 25
2.1.3 Características do processo de usinagem 26
2.2 Controle dimensional e geométrico 27
2.2.1 Metrologia 28
2.2.2 Tolerância e intercambialidade 29
2.2.2.1 Tolerância dimensional 31
2.2.2.2 Tolerâncias geométricas 32
2.2.3 Máquina de medição por coordenadas 34
2.3 Mancal de deslizamento 35
2.4 Inteligência artificial: uma abordagem industrial 37
2.4.1 Aprendizado de máquina 39
2.4.1.1 Árvore de decisão por regressão 42
2.4.1.2 Métricas de desempenho 45
2.4.2 Método CRISP-DM 47
3 TRABALHOS RELACIONADOS 48
4 MODELO DESENVOLVIDO 52
4.1 Metodologia para desenvolvimento do modelo 54
4.1.1 Contextualização e definição do problema 54
4.1.2 Definição dos dados brutos 57

4.1.3 Pré-processamento do conjunto de dados 58
4.1.4 Definição do algoritmo 59
4.1.5 Avaliação do modelo em simulação computacional 60
4.1.6 Avaliação do modelo em ambiente industrial 65
5 CONCLUSÃO 75
5.1 Epílogo 75
5.2 Contribuições e Resultados 76
5.3 Trabalhos Futuros 78
REFERÊNCIAS 80

1 INTRODUÇÃO

A presente pesquisa tem como foco principal analisar a aplicação de um modelo de predição no propósito de reduzir a interação cognitiva humana nos processos de fabricação de mancais de deslizamento norma DIN 31693 (DEUSTCHES INSTITUT FÜR NURMING, 1990). Visa discutir a importância desta aplicação para a melhoria dos processos de manufatura existentes, tanto pela automação, como pela forma de desenvolvimento e experimentação no contexto real de produção. A Seção 1.1 apresenta a motivação para o desenvolvimento desta dissertação. Na Seção 1.2 é demonstrado o problema, a hipótese e questões de pesquisa. A Seção 1.3 apresenta os objetivos a serem atingidos. Na Seção 1.4 é demonstrado a metodologia de pesquisa contendo a descrição de cada etapa para desenvolvimento do modelo. A Seção 1.5 apresenta as principais contribuições do trabalho. Na seção 1.6 é demonstrada a estrutura do trabalho.

1.1 Motivação

Os mancais de deslizamento são um dentre os vários elementos que fazem parte construtiva de máquinas e equipamentos, como por exemplo: (i) motores diesel marítimos, ferroviários e estacionários; (ii) equipamentos de cimento e mineração; (iii) compressores, ventiladores e exaustores; (iv) redutores ou multiplicadores de velocidade; (v) turbinas e geradores hidroelétricos; (vi) turbinas a vapor e a gás; (vii) laminadores de aço; (viii) bombas. São componentes projetados para suportar carga enquanto estão em contato com a superfície do eixo (CHAUDHARI *et al*., 2015). Seu funcionamento se baseia no deslizamento entre um eixo que gira livremente apoiado em um invólucro metálico chamado de inserto, que fica alojado em uma carcaça. O inserto garante o alinhamento durante a montagem e que as cargas sejam distribuídas uniformemente. A carcaça protege o conjunto contra contaminantes enquanto mantêm o lubrificante e abriga equipamentos de monitoramento (SRINIVAS *et al*., 2015).

Destaca-se a responsabilidade vinculada aos processos de usinagem e controle dimensional dos mancais de deslizamento, pois depende deles o funcionamento perfeito de sistemas complexos, com tolerâncias estreitas, onde o erro pode comprometer todo o desempenho do conjunto, acarretando riscos operacionais,

de segurança e diversos custos. Os mancais são considerados os principais responsáveis pelas falhas das máquinas e equipamentos, representando 40% das ocorrências (SARAVANJA; GRBESIC, 2019). Quando considerado apenas os motores, deve-se notar que, em geral, os defeitos mecânicos representam cerca de 79% das falhas e defeitos elétricos em torno de 21%. Um dos tipos notáveis de defeitos mecânicos é a falha do mancal, que representa cerca de 69% dos defeitos mecânicos (PILTAN; KIM, 2021).

A usinagem é o principal processo empregado para a fabricação dos mancais de deslizamento o qual exige controle dimensional adequado as normas e requisitos aplicáveis. Neste sentido, a utilização de máquina de medição por coordenadas (MMC) é requerida para determinar dimensão, forma e posição das carcaças de mancais de deslizamento produzidas por processos de usinagem. Uma MMC fornece resultados de medição ultra precisos e são amplamente utilizadas na fabricação de precisão (LI *et al.*, 2022).

Os relatórios dimensionais, produzidos por MMC, são comumente avaliados e interpretados por operadores e programadores que atuam no ajuste do processo de usinagem de mancais de deslizamento. Essa interação humana na análise e interpretação de tais relatórios é capaz de causar imprevisibilidade ao processo produtivo. A habilidade de controlar todas as variáveis do processo de usinagem extrapolou os limites humanos, delegando-se às máquinas e aos sistemas inteligentes boa parte das tarefas que asseguram a fabricação precisa (GEVORKYAN *et al.*, 2022). Diante da limitação apresentada, o emprego de um modelo preditivo baseado em aprendizado de máquina destaca-se como uma possibilidade para atingir a previsibilidade no processo de fabricação de mancais de deslizamento e consequente aumento da competitividade industrial.

1.2 Problema, hipótese e questões de pesquisa

Apesar da aplicação dos modernos sistemas de controle do processo de fabricação de mancais de deslizamento por usinagem, não é incomum encontrar peças com superfícies fora dos limites de tolerância. Durante a fabricação, fenômenos físicos, cinemáticos, o comportamento dinâmico da estrutura da máquina, imperfeição geométrica e dimensional dos componentes do processo, podem influenciar em erros

dimensionais. Não se pode concluir que peças fabricadas por usinagem serão exatamente iguais em forma e dimensão, mas é preciso garantir que suas superfícies estejam dentro dos limites de tolerância (LI *et al*., 2022).

Um grande desafio enfrentado por empresas fabricantes de mancais de deslizamento, no quesito de controle dimensional, está em mapear os dados relevantes para entender as correlações entre as variáveis ao longo dos estágios do processo. Considerando as inter-relações entre vários fatores que compõe o processo de fabricação de carcaça de mancal de deslizamento, as técnicas baseadas em aprendizado de máquina tornaram-se ferramentas relevantes devido à sua velocidade, robustez e características não lineares ao trabalhar com dados. Essas técnicas apoiam a utilização inteligente dos recursos de fabricação e o ajuste adaptativo dos processos de produção que suportam o nível de organização chamado fábricas inteligentes (GEVORKYAN *et al*., 2022). Portanto, o principal problema analisado nesta dissertação é: **como reduzir a interação cognitiva humana nos processos de fabricação de carcaças de mancais de deslizamento?**

Considerando o problema apresentado, tem-se como hipótese que: **aplicação de técnicas de aprendizado de máquina reduz a interação cognitiva humana nos processos de fabricação de carcaças de mancais de deslizamento.**

Com base nessa hipótese, as seguintes questões de pesquisa foram definidas:

a) Questão 1: A holística pode ser utilizada para compensar todas as fontes de erros sistemáticos, independentemente de suas origens, e modelar o desvio dimensional total de carcaças de mancais de deslizamento produzidas por processos de usinagem?
b) Questão 2: A heurística pode ser utilizada como método para definir todas as variáveis que envolvem a tomada de decisão para compensação dos desvios dimensionais de carcaças de mancais de deslizamento produzidas por processos de usinagem?
c) Questão 3: O CRISP-DM é eficaz como método de implementação para um modelo preditivo, baseado em árvore de decisão, em uma linha de produção de mancais de deslizamento?
d) Questão 4: O uso de um modelo de predição baseado em árvore de decisão reduz a interação cognitiva humana nos processos de fabricação de carcaças de mancais de deslizamento?

1.3 Objetivos

O objetivo principal deste trabalho é: **desenvolver um modelo de predição, baseado em árvore de decisão, para controle dimensional no processo de fabricação de carcaças de mancais de deslizamento flangeados, conforme a norma técnica DIN 31693.**

Este objetivo principal pode ser dividido nos seguintes objetivos específicos:

a) automatizar a etapa de análise dos relatórios dimensionais;
b) sugerir parâmetros de ajuste para obter carcaças adequadas em relação às suas dimensões críticas;
c) apoiar a tomada de decisão que resulta em correções no deslocamento dos eixos do centro de usinagem.

1.4 Metodologia

O trabalho é classificado, dentro da cadeia de inovação, como desenvolvimento experimental, pois consiste no processo de transformar e refinar os conhecimentos advindos da pesquisa, investigação e experiência prática com a finalidade de instalação de novos processos e sistemas para a melhoria substancial dos já existentes (CHMURZYNSKI, 2022). O método que implementa essa aplicação é baseado primeiramente na holística, no qual o desvio dimensional total é monitorado e modelado, o que resulta na compensação de todas as fontes de erro sistemático (ZIVIANI; CORRÊA; MUYLDER, 2018). Em segundo lugar é baseado na heurística, no qual são utilizados processos cognitivos para definir todas as variáveis que envolvem a tomada de decisão para compensação dos desvios dimensionais (SILVEIRA, 2021). A carga cognitiva utilizada tem sua origem em 10 profissionais com mais de 15 anos de experiência trabalhando diariamente nesse tipo de tomada de decisão.

Para o desenvolvimento do modelo preditivo proposto aplicou-se uma metodologia baseada no procedimento *Cross-industry standard process for data mining* (CRISP-DM) (BRAZDIL *et al.,* 2022). O módulo *python* de aprendizado de máquina de código aberto *scikit-learn*[1] foi utilizado para as etapas de definição, treino,

[1] https://scikit-learn.org/stable/

validação e teste do algoritmo de aprendizado de máquina. Uma comparação entre o algoritmo de Floresta Aleatória é realizada para verificar o desempenho entre diferentes modelagens preditivas (ROKACH; MAIMON, 2014).

1.5 Principais contribuições

O trabalho proposto contribui diretamente para a melhoria dos processos de manufatura de mancais de deslizamento flangeados norma DIN 31693. O modelo de previsão, através da automação, é capaz de produzir decisões e resultados confiáveis e repetíveis, podendo reduzir os erros dimensionais nas carcaças produzidas por processos de usinagem. Isto poderá causar efeitos de:

a) aumento da produtividade: devido ao menor tempo de máquina fora de produção aguardando a análise e todas as atividades que envolvem a tomada de decisão de processo;
b) redução de custo: com a geração de carcaças não conformes e diminuição de horas de retrabalho.

1.6 Estrutura do trabalho

O trabalho está organizado da seguinte forma: No Capítulo 2 é demonstrado a fundamentação teórica. O Capítulo 3 apresenta uma revisão dos trabalhos relacionados. No Capítulo 4 é demonstrado a metodologia aplicada, com a descrição de cada etapa, para desenvolvimento do modelo, onde é detalhado o processo de fabricação e controle dimensional de carcaças de mancais de deslizamento. No Capítulo 5 têm-se as conclusões que envolvem os resultados obtidos com o desenvolvimento do modelo, limitações do mesmo e propostas de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo é abordado uma revisão da literatura referente aos temas relevantes para o trabalho, que, dispostos de forma ordenada, são capazes de fomentar a interpretação e compreensão tanto da metodologia aplicada para o desenvolvimento do modelo preditivo proposto quanto do próprio modelo criado e avaliado.

Inicialmente, na Seção 2.1, apresenta-se os conceitos de usinagem com ênfase no processo de fresamento, pois este processo é utilizado para formação geométrica das dimensões críticas dos mancais de deslizamento, objeto da pesquisa. O sistema de coordenadas e eixos cartesianos juntamente com o controle numérico computadorizado são descritos por comporem o método que controla os movimentos dos eixos do centro de usinagem pela interpretação direta de instruções codificadas na programação. As características e particularidades do processo de usinagem são discutidas a fim de contextualizar a aplicação.

Na Seção 2.2 apresenta-se a conceituação de metrologia devido aos atributos de intercambialidade, ajustes e tolerâncias, requisitos de projetos, que são a base para o controle dimensional das carcaças. A MMC é abordada pois é por meio desta que as carcaças são medidas e são obtidos os relatórios dimensionais que são a base para o processo de tomada de decisão.

O mancal de deslizamento é detalhado na Seção 2.3 devido a linha de produção ser de carcaças de mancais de deslizamento flangeados. São abordadas sua definição, aplicação, construção, características de fabricação e operação.

Os conceitos relacionados à Inteligência Artificial (IA) no âmbito da indústria, conforme apresentado na Seção 2.4, são apresentados no sentido de permitir melhorias em processos existentes com o objetivo de aumento de competitividade industrial. A conceituação de aprendizado de máquina, e sua componente de predição, são destaques em virtude de sua capacidade de aplicar julgamentos e tomada de decisão, atividades concordantes com as etapas de definição dos parâmetros de deslocamento dos eixos do centro de usinagem. São apresentados os conceitos de árvore de decisão, sua construção e como se relaciona com os tipos de problemas de predição: (i) regressão; (ii) classificação. O *scikit-learn*, juntamente aos hiperparâmetros de regularização para árvores de decisão, são retratados pois

implementam o algoritmo de aprendizado de máquina. Ao final do capítulo é debatido o método CRISP-DM em razão de ter sido empregado para implementação do projeto proposto.

2.1 Usinagem

A usinagem pode ser definida como a operação que, ao conferir à peça forma, dimensões e acabamento, produz cavaco. O cavaco é definido como a porção de material que é retirado da peça para atender a finalidade da usinagem (MACHADO *et al.*; 2015). O processo de usinagem está diretamente relacionado com a mudança de forma, dimensões e certas propriedades de uma peça que está sendo produzida (GEVORKYAN *et al.*, 2022). Esta definição promove a melhor compreensão da metodologia aplicada para o desenvolvimento do modelo preditivo proposto.

O processo de usinagem remove o sobremetal, material excedente, da peça podendo ser executado por máquinas ou ferramentas manuais. O processo de usinagem por máquina exige a utilização de ferramentas de corte. Ferramentas de corte fixadas em máquinas de usinagem podem trabalhar com movimentos rotativos ou parada, neste caso a peça que gira (ROCCA, ALMEIDA; 2015).

Araújo, Mougo e Campos (2020, p. 7) descrevem o processo de usinagem convencional, ou seja, aquele que ocorre pela remoção de material por meio de uma ferramenta de corte como segue:

> Ocorre a retirada de material através de uma ferramenta de corte, com dureza maior que a da peça, que está no estado sólido. A ferramenta se desloca com velocidade específica e remove regiões indesejáveis à geometria final da peça. A ferramenta pode ser formada por um material contínuo com aresta de corte com geometria definida, ou ser composta por partículas abrasivas aglutinadas ou soltas com geometria de corte não definida.

As operações de usinagem são divididas em: (i) usinagem de acabamento; (ii) usinagem de desbaste. A usinagem de acabamento está direcionada a atender os requisitos finais da peça (rugosidade, tolerâncias dimensionais e geométricas). A usinagem de desbaste tem a função de remover o sobremetal a fim de atingir as dimensões próximas as finais (ARAÚJO; MOUGO; CAMPOS, 2020).

Alta precisão e a variedade geométrica quase ilimitada são destacadas como características marcantes das máquinas de usinagem. O desenvolvimento de máquinas cada vez mais produtivas e precisas desempenhou um papel fundamental na formação do progresso em outros setores industriais, tais como: implantes na tecnologia médica, materiais leves e resistentes no setor aeroespacial e sistemas de fabricação cada vez mais produtivos na engenharia automotiva. No contexto atual, os processos de usinagem mantêm sua importância. Demandas cada vez maiores na qualidade da superfície, bem como precisão dimensional, continuarão a tornar a usinagem parte integrante das fábricas do futuro. Precisão, produtividade e confiabilidade, bem como um grau cada vez maior de automação determinam o desenvolvimento dos processos de fabricação por usinagem (DMG MORI, 2021).

2.1.1 Fresamento

Fresamento é uma operação de usinagem em que a ferramenta (fresa) contém arestas cortantes em torno do seu eixo, que gira em movimento uniforme (rotacional) para arrancar cavaco por uma ferramenta giratória denominada fresa de múltiplos insertos cortantes (LOUREIRO, 2020). Durante a operação de fresamento a ferramenta pode girar enquanto a peça, presa à mesa, fica responsável pelos movimentos de avanço longitudinal e transversal. A peça pode ficar estática, enquanto a ferramenta realiza todos os movimentos. Existe a possibilidade do movimento simultâneo entre peça e ferramenta denominado interpolação de usinagem (MACHADO *et al.*; 2015).

Existem duas formas de interseção entre a ferramenta de corte e a matéria prima distinguidas pela direção do eixo da ferramenta em relação à superfície usinada. Essa distinção conduz aos métodos de fresagem tangencial ou periférica e de topo (LOUREIRO, 2020). A operação de fresamento é reconhecida pela versatilidade na produção de geometrias diversas. A variedade de tipos de ferramentas torna o fresamento de larga aplicação para a usinagem de peças além de garantir elevada taxa de remoção de material, visto que a ferramenta (fresa) possui múltiplas arestas de corte no qual cada inserto remove uma pequena quantidade de material em cada revolução do eixo onde a ferramenta é fixada (MACHADO *et al.*; 2015). A Figura 1 apresenta as principais operações de fresamento.

Figura 1 - Principais operações de fresamento

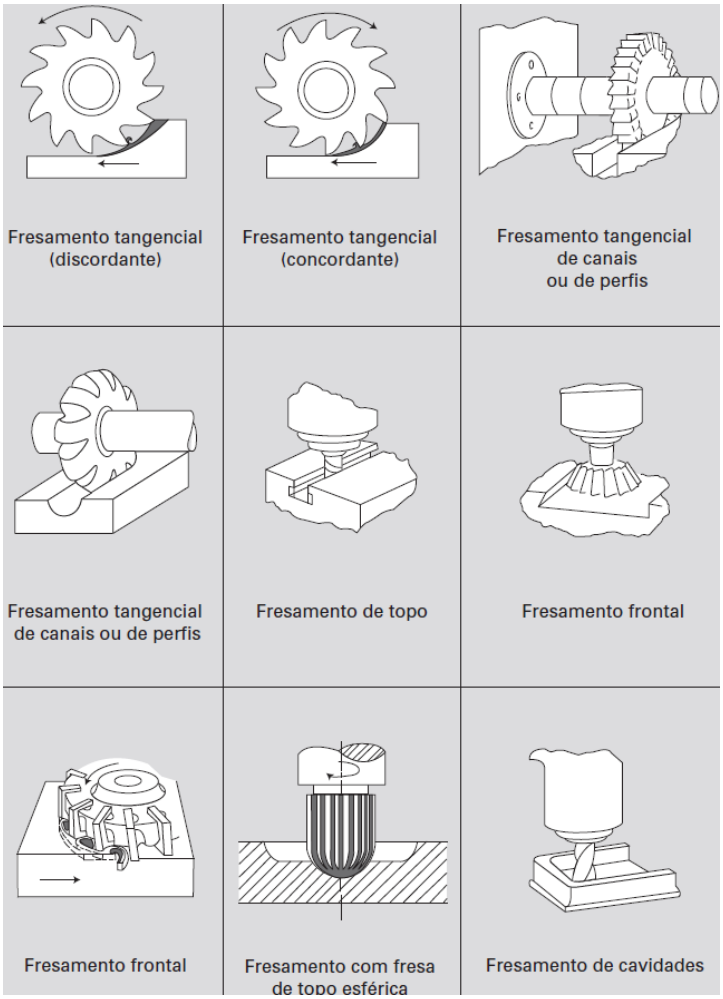

Fonte: Machado *et al.* (2015).

2.1.2 Usinagem CNC

A usinagem CNC revolucionou de certa forma o mercado, principalmente pela sua capacidade de produzir peças usinadas de alta precisão e acabamento ímpar, com repetibilidade permitindo produção em larga escala, em menos tempo e com menos desperdício de material. Destacasse como características: (i) grande produtividade; (ii) flexibilidade; (iii) precisão de execução; (iv) repetitividade; (v) controle rígido de fabricação. No entanto demanda elevados investimentos, além de mão de obra especializada para operação, programação e manutenção (SANTOS, 2017).

A tecnologia CNC abrange a automatização de vários processos de fabricação e pode ser utilizada desde o desenvolvimento até a concepção de um produto. Sua grande aplicabilidade é na área de fabricação, sendo amplamente utilizada nos

processos de usinagem. Permite a realização de tarefas repetitivas e de grande complexidade, possibilitando a reprodutibilidade de produtos de variadas formas geométricas (OLIVEIRA, 2011). A tecnologia CNC é um grande avanço para automação e se apresenta como essencial para o desenvolvimento de sistemas inteligentes nos processos de usinagem (JÚNIOR; SILVA, 2016).

A usinagem CNC pode ser definida por qualquer processo em que uma peça é usinada por uma máquina controlada por um computador. Neste ponto, é apresentado a definição de centros de usinagem CNC: equipamentos tecnológicos que ao realizar os movimentos dos eixos da máquina de forma automática, substituem as máquinas-ferramentas convencionais cujos movimentos são dependentes do operador (SANTOS, 2017). O centro de usinagem CNC nada mais é do que uma máquina que funciona através de controle numérico computadorizado, cuja maior diferença entre uma máquina manual e uma máquina CNC é a forma como elas movem seus eixos (FITZPATRICK; 2013).

O princípio básico de funcionamento de um centro de usinagem CNC é entendido o dividindo em 2 partes: (i) Controle Numérico (CN); (ii) máquina-ferramenta. O CN é composto por uma unidade de recebimento de informações e uma unidade calculadora onde as informações são processadas e retransmitidas as unidades motoras da máquina-ferramenta. Já a máquina-ferramenta tem como objetivo operacionalizar os recursos oferecidos pelo CN (JÚNIOR; SILVA, 2016). O que caracteriza os centros de usinagens no tocante a capacidade de usinagem é a quantidade de eixos motores, ou seja, o número de movimentos independentes de translação e/ou rotação em x, y e z. Quanto maior o número de eixos motores, mais complexas serão as operações permissíveis (LOUREIRO, 2020).

A escolha de um centro de usinagem depende, essencialmente, da forma pretendida para as peças, do material de que estas são feitas e do espaço disponível para a instalação da máquina. O número de eixos e a orientação do cabeçote da ferramenta são características que dependem da complexidade da geometria da peça. A potência e a velocidade de rotação dependem do material a usinar e o espaço depende do tamanho da máquina. Máquinas que possuem 3 eixos de acionamento são denominadas de Centro de Usinagem Vertical ou *Vertical Machining Center* (VCM) e máquinas com 4 eixos de acionamento são denominadas de Centro de Usinagem Horizontal ou *Horizontal Machining Center* (HMC) (SANDVIK, 2018).

Na usinagem vertical se tem uma ferramenta de corte rotativa montada em um cabeçote com orientação vertical. Esse processo é típico de VCM o qual possui um cabeçote rotativo que se aproxima da peça de cima para baixo, normalmente, trabalhando na superfície superior do material. Por outro lado, na usinagem horizontal a ferramenta de corte rotativa é montada em um cabeçote com orientação horizontal. Esse processo é típico de HMC (MAZAK, 2014)

2.1.2.1 Coordenadas cartesianas e eixos

O controle do deslocamento da ferramenta ou da peça que gera a geometria e dimensões desejadas no processo de usinagem CNC é baseado no sistema de coordenadas. Os centros de usinagem assumem a existência de três eixos cartesianos: X, Y e Z. Para o caso em que a máquina possua mais possibilidades de movimento é admitido a existência dos eixos secundários (JÚNIOR; SILVA, 2016):

a) U: linear ou rotacional entorno de X;
b) V: linear ou rotacional entorno de Y;
c) W: linear ou rotacional entorno de Z.

Toda máquina de usinagem CNC possui seu sistema de coordenadas formado por todos os eixos existentes nela e a depender do tipo da máquina é definido a posição do sistema de coordenadas (FITZPATRICK, 2013). A Figura 2 apresenta os três eixos lineares primários: X, Y e Z.

Figura 2 - Os três eixos lineares primários: X, Y e Z

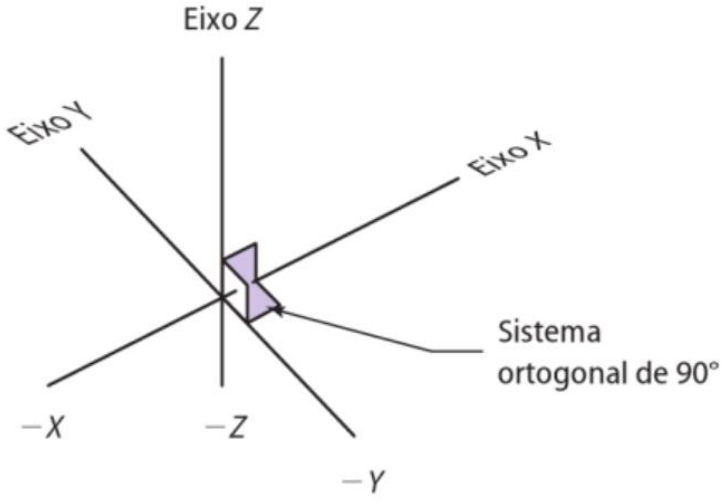

Fonte: Fitzpatrick (2013).

Define-se como superfície plana a combinação entre duas linhas do eixo primário. A partir dessa definição afirmasse haver três planos primários: XY, XZ e YZ (FITZPATRICK, 2013). A Figura 3 apresenta os três planos primários.

Figura 3 - Os três planos primários: XY, XZ e YZ

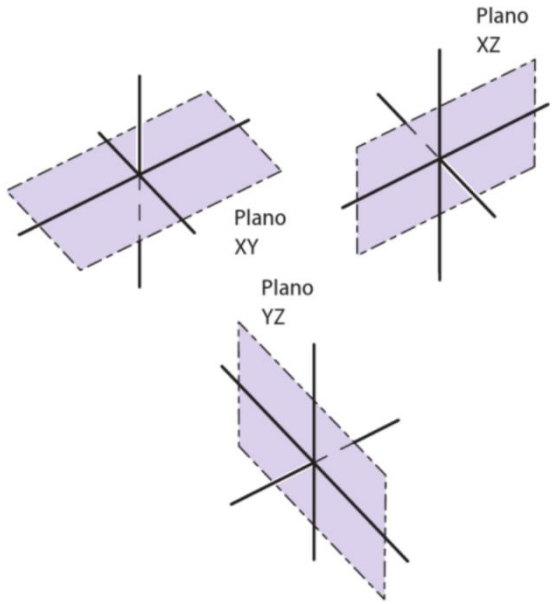

Fonte: Fitzpatrick (2013).

As coordenadas absolutas, aquelas que representam a distância do ponto a partir da origem da máquina (X=0, Y=0 e Z=0), referem-se a um ponto de partida único: a origem local. Essa origem local é definida como ponto zero do programa ou simplesmente Ponto Zero Peça (PZP). A correta definição da localização do PZP é uma decisão muito importante quanto as características geométricas da peça a ser usinada (FITZPATRICK, 2013). O PZP é o ponto em que o controle toma como referência para a definição das coordenadas. A localização da origem do sistema de coordenadas para referenciar a peça, a ferramenta e a máquina, define a chamada posição zero programa (JÚNIOR; SILVA, 2016).

Existem outros dois tipos de pontos de referências utilizados em máquinas CNC (FITZPATRICK, 2013):

a) Referência da Máquina (RM): ponto fixo e exato. Normalmente localizado na posição dos eixos totalmente afastado da placa ou da mesa;
b) Ponto de Referência Local (PRL): ponto não fixo, temporário. É definido a partir de uma distância conhecida em relação ao PZP.

Existe uma correlação importante no que tange o grau de concordância entre os resultados dimensionais obtidos provenientes da peça usinada e as características de repetibilidade do eixo da máquina CNC. Define-se três tipos de características de repetibilidade (FITZPATRICK, 2013):

a) resolução da máquina: menor movimento que o eixo de acionamento pode fazer. É limitado pelos motores de acionamento da máquina;
b) repetibilidade do eixo: capacidade do eixo do acionamento deslocar o fuso ou a ferramenta distante de um local específico e trazê-lo de volta com uma tolerância pequena;
c) repetibilidade da forma: tolerância limite para se manter em uma trajetória curva.

2.1.2.2 Controle numérico computadorizado

Durante muito tempo, as peças usinadas foram criadas pela orientação direta de uma ferramenta por um ser humano. Este tipo de produção foi substituído por máquinas-ferramentas, ou seja, máquinas que guiavam o percurso da ferramenta e assim estabelecem novos padrões de precisão e eficiência. Quando os conceitos de lógica programável de orientação de ferramentas foram introduzidos pela primeira vez na automação de tais máquinas-ferramentas, a história do CN começou (DMG MORI, 2022).

O CN é definido como um equipamento eletrônico que por meio de uma entrada própria de dados é capaz de receber informações, compilá-las e transmiti-las em forma de comando a máquina a fim de que as operações de usinagem sejam realizadas na sequência programada sem a intervenção do operador. O desenvolvimento do CNC, com o CN sendo controlado por um computador, permitiu facilmente realizar alterações nos programas (JÚNIOR; SILVA, 2016). Então, o CN foi completamente substituído pelo CNC. O princípio básico da orientação automatizada permaneceu inalterado, a grande evolução estava na capacidade de enviar instruções codificadas ainda mais precisas de um microprocessador para o controle de uma ferramenta de usinagem. A usinagem se tornou uma das primeiras aplicações práticas da tecnologia computacional. (DMG MORI, 2022)

O CNC como um meio eletrônico pelo qual sinais são enviados a máquina-ferramenta, possibilitou as operações de usinagem serem executadas através de comandos que movimentam de forma automática as ferramentas e outros dispositivos da máquina (SANTOS, 2017). O advento do CNC constituiu em um marco importante para os processos de manufatura. Um sistema computadorizado capaz de controlar simultaneamente vários eixos de uma máquina-ferramenta possibilitou que a usinagem de peças com geometrias complexas fosse simplificada, com grande precisão e com mínima intervenção humana (OLIVEIRA, 2011).

O CNC realiza o controle constante da operação de usinagem comparando a posição física da ferramenta com a posição esperada. Deste modo o CNC é responsável pelos movimentos de corte e pela precisão no posicionamento. Neste certame apresentasse o conceito da Unidade Central de Processamento (CPU) que é o componente que tem a função de decodificar o programa, enviar o comando de movimentação dos eixos, monitorar e ajustar o desenvolvimento da operação de usinagem (FITZPATRICK, 2013).

2.1.2.3 Programação CNC

A programação CNC envolve todo o planejamento de fabricação de uma peça, incluindo desenho, a máquina-ferramenta, dispositivos, ferramentas entre outros. (JÚNIOR; SILVA, 2016). É composto por uma sequência de sentenças lógicas que contém informações geométricas e tecnológicas da tarefa a ser executada em cada operação. Sua produção deve ser baseada em uma linguagem compatível com o sistema operacional (OLIVEIRA, 2011). A maior parte do programa CNC é composta das coordenadas dos pontos que se referem as distâncias para os eixos. Essas coordenadas X, Y e Z tem papel fundamental no processo de usinagem CNC visto que são utilizadas para determinar movimento e posicionamento da ferramenta em relação a peça, bem como para referência (FITZPATRICK, 2013).

A elaboração de um programa CNC requer conhecimentos sobre a peça a ser usinada, ferramentas e máquina utilizada, bem como os conceitos de usinagem. Na maioria dos casos o programa é digitado em um editor de texto no computador e enviado para as máquinas via dispositivos de entrada (SANTOS, 2017). O desenvolvido da programação orientada por softwares, capazes de modificar e

aprovar digitalmente um objeto 2D ou 3D, otimizou a confecção de um programa CNC (DMG MORI, 2022).

2.1.3 Características do processo de usinagem

A usinagem tem a peculiaridade de ser um processo prático que envolve um elevado número de variáveis tornando difícil prever seu desempenho (MACHADO *et al.,* 2015). Vários fatores impactam diretamente no resultado da usinagem: (i) tipo de operação; (ii) o modo de fixação da peça; (iii) o tipo e característica da ferramenta; (iv) condições de manutenção, geometria e conservação da máquina; (v) influência externa (vibrações e temperatura ambiente); (vi) fatores relacionados a competência técnica e experiência do operador (ROCCA; ALMEIDA, 2015).

A usinagem é dita como um processo complexo e simples ao mesmo tempo, de certo modo, imprevisível visto de toda a sistemática que o envolve. A complexidade está em determinar as condições ideais do processo. A simplicidade está no fato de depois de determinada dispensa qualquer intervenção do operador (MACHADO *et al.,* 2015). Por tanto, compreender os fenômenos que se relacionam com processos de fabricação por usinagem possibilita realizar simplificações, porém as inúmeras variáveis combinadas são capazes de gerar variações durante o processo fazendo aflorar tal complexidade (ARAÚJO; MOUGO; CAMPOS, 2020).

As variáveis que influenciam no processo de usinagem resultam em infinitas combinações que podem levar a resultados imprevisíveis. Sugerisse maneiras de lidar com tal complexidade: (i) experiências adquiridas ao longo dos anos; (ii) experimentação; (iii) modelos matemáticos teóricos (MACHADO *et al.*,2015); (iv) controle proativo do processo (DOMÍNGUEZ *et al.*, 2021).

A fabricação por processo de usinagem requer alta precisão e controle adequado, pois está vinculado a fabricação de peças e componentes de montagem de sistemas complexos, com tolerâncias estreitas, onde o erro pode comprometer todo o desempenho do conjunto (SOUZA, 2022). Para tal, é preciso garantir um controle eficiente do processo para evitar erros de fabricação que são responsáveis diretos por problemas relacionados a qualidade superficial, montagem e função do componente (DOMÍNGUEZ *et al.*, 2021).

O monitoramento efetivo das características de um processo de usinagem depende frequentemente da identificação e análise das causas significantes responsáveis por variações que afetam o comportamento do processo. Porém, em muitos casos, as empresas em atividade não conseguem atingir um nível adequado de controle do processo (ROCCA E ALMEIDA, 2015). Para garantir o controle do processo de usinagem, é necessária uma abordagem científica que envolve o processo de identificação e análise de potenciais desafios, análise e compreensão mais profunda dos impactos, bem como o desenvolvimento de métodos para minimizar problemas de precisão dimensional (GEVORKYAN *et al.*, 2022).

2.2 Controle dimensional e geométrico

Para todo produto acabado, parte-se de um material bruto o qual é submetido a um processo de fabricação. Durante o processo de fabricação, várias etapas, como por exemplo: (i) jateamento; (ii) pintura; (iii) usinagem; (iv) soldagem, são realizadas que conferem ao material transformações de forma, de tamanho e propriedades. O método de produção, como por exemplo a utilização de fresagem tangencial ou a fresagem de topo, interfere na aparência, na funcionalidade e nas características gerais do produto acabado (NETO, 2018).

A qualidade esperada do produto é mais fortemente afetada pela decisão do projeto e pelos procedimentos de fabricação. A qualidade de fabricação industrial requer controles dimensionais e geométricos rigorosos para alcançar altos níveis de desempenho funcional. Erros de forma, imperfeições geométricas e erros dimensionais têm influência definitiva no desempenho funcional do produto fabricado (BULUTSUZ; YETILMEZSOY; DURAKBASA, 2015).

O controle dimensional e geométrico é etapa fundamental para a garantia da funcionalidade de peças fabricadas por processo de usinagem, pois estabelece a acurácia e precisão nas medições dimensionais e de forma das peças. Para que isto ocorra com o maior grau de confiabilidade, são empregados instrumentos de medição adequados e calibrados juntamente a profissionais habilitados (JESUS; MARTINS, 2021). Neste contexto, têm-se destaque para as tecnologias de medição por coordenadas, onde é possível integrar equipamento de medição e programa

computacional ao ciclo de desenvolvimento do produto e comparar os pontos medidos diretamente no modelo de projeto (MATTEI; MILANEZ, 2020).

2.2.1 Metrologia

Metrologia pode ser definida como a ciência das medidas e suas aplicações ou como a ciência das medições. Possui a missão de assegurar a precisão exigida nos processos produtivos (NETO, 2018). Engloba todos os aspectos teóricos e práticos da medição, sendo aplicável a qualquer grandeza determinável. Medir é sinônimo de conhecer e, com base em dados, tomar decisões estratégicas. Em contexto industrial, todo o arranjo e processo de medição é utilizado para otimizar os processos de produção (LASERMEC, 2020). Sua aplicação na indústria ocorre através de instrumentos ou máquinas de medição para medir e executar o controle dimensional de peças (MILANEZ, 2020). Esta definição promove a melhor compreensão da metodologia aplicada para o desenvolvimento do modelo preditivo proposto.

A metrologia é responsável pela garantia do atendimento aos requisitos técnicos relativo à unidade de medida, métodos de medição, instrumentos de medição e medidas materializadas. Seu foco principal é prover confiabilidade, credibilidade, universalidade e qualidade às medidas (NETO, 2018). Por ser uma ciência aplicada ao diagnóstico e prevenção, a metrologia é dedicada à identificação e solução de problemas. Nessas condições os dados obtidos em uma medição são cruzados em análises estatísticas e técnicas matemáticas para tomadas de decisão. Nesse tocante a metrologia industrial é uma aliada para aumento da competitividade das empresas relacionando produtividade com qualidade (LASERMEC, 2020).

Medição é o processo pelo qual é determinado o valor de uma grandeza. O valor determinado, sua expressão quantitativa, geralmente é demonstrado na forma de um número multiplicado por uma unidade de medida (NETO, 2018). A medição possibilita realizar coletas de informações de um mundo físico e comparar com padrões acordados. Sensores são usados como elementos primários para responder à variável física sob medição (WEBSTER; EREN, 2014). Existem três propósito de realizar medições: (i) monitorar; (ii) controlar; (iii) investigar. Monitorar é o mesmo que observar. Controlar é comparar com especificações e agir para correção. Investigar é,

descobrir, explicar ou formular os fenômenos (JESUS; MARTINS, 2021). Controlar é o principal propósito aplicado no desenvolvimento do modelo preditivo proposto.

Importantes no estudo da metrologia, exatidão e a precisão são parâmetros qualitativos associados ao desempenho de um sistema. A exatidão é uma métrica que relaciona a concordância entre o resultado da medição e o valor verdadeiro do mensurando. A precisão diz respeito à aptidão de um instrumento de medição para fornecer indicações muito próximas quando se realiza medições sob as mesmas condições (NETO, 2018).

A precisão da medição é uma questão de grande interesse para a indústria de fabricação mecânica. Quando o processo em análise é o de usinagem, fatores adicionais devem ser considerados no que tange a precisão deste processo: (i) tempo de operação para atingir sua condição de operação estável; (ii) líquido refrigerante que torna as superfícies úmidas; (iii) irregularidades da superfície; (iv) desvios geométricos da máquina-ferramenta; (v) repetibilidade do elemento sensor (RAHMAN; MAYER, 2016).

O erro, que tanto pode ser de fabricação ou de medição, é composto por três componentes: (i) uma aleatória; (ii) uma sistemática e (iii) uma grosseira. A primeira compreende o percentual imprevisível desse erro, não pode ser corrigida. A segunda é previsível, podendo ser mensurada e corrigida. Já a terceira é imprevisível, normalmente é causado pela falta de habilidade e pela pouca experiência do operador, porém é de fácil detecção e deve ser controlada (NETO, 2018). A compensação da componente sistemática do erro faz parte do propósito aplicado no desenvolvimento do modelo preditivo.

2.2.2 Tolerância e intercambialidade

Apesar dos reconhecidos avanços tecnológicos nos processos de fabricação por usinagem, ainda não é possível a obtenção de dimensões perfeitamente exatas, ou seja, sem nenhuma liberdade para mais ou para menos em suas dimensões e forma. Devido a isso, é permissível um limite de tolerância nas medições. Tolerância pode ser definida como a diferença entre os valores máximos e mínimos admitidos para uma propriedade mensurável, portanto, é a variação em que a dimensão ou superfície pode oscilar dentro dos limites definidos (AGOSTINHO; RODRIGUES;

LIRANI, 2020). As tolerâncias dimensional e geométrica, além da qualidade, expressam o nível de complexidade do produto (AGOSTINHO, 2018).

A intercambialidade garante que peças fabricadas podem ser montadas, sem necessidades de ajustes, em outra peça qualquer, qualquer que seja o lote, a data ou o local de fabricação. O atendimento a esta condição credencia que o conjunto atingirá o desempenho da peça original (AGOSTINHO, 2018). Para tal, deve haver uma intercambialidade adequada entre componentes para que a montagem ocorra sem esforços excessivos ou ajustes severos (NETO, 2018).

A prática tem demonstrado que as medidas das peças podem variar, dentro de certos limites, para mais ou para menos, sem que isto prejudique a qualidade e intercambialidade entre componentes. Esses desvios aceitáveis nas medidas das peças caracterizam a tolerância dimensional e geométrica aplicado ao processo de usinagem (NETO, 2018). É necessário relacionar o estudo das tolerâncias de fabricação por usinagem com os desvios encontrado durante o processo criando-se uma base de dados e referências que apoie o processo de controle (AGOSTINHO, 2018).

Qualquer processo de fabricação por usinagem apresenta desvios que podem ser para mais ou para menos em relação a medida nominal. Os desvios dimensionais podem ser relacionados com: (i) vibrações durante o processo; (ii) falta de rigidez dos dispositivos de fixação e estrutura da máquina; (iii) da fixação e desgaste da ferramenta; (iv) falta de rigidez das peças (AGOSTINHO; RODRIGUES; LIRANI, 2020); (v) variações na localização da peça; (vi) imprecisão da máquina-ferramenta; (vii) fator humano (AGOSTINHO, 2018).

Os desvios na usinagem referem-se à diferença entre a forma geométrica usinada e as cotas dimensionais com suas correspondentes no projeto. A avaliação correta e precisa dos desvios de usinagem é etapa fundamental para inspeção de qualidade e compensação de erros no processo de usinagem (LI *et al.*, 2022). A correta caracterização dos erros de fabricação e medição, que induzem a medida a sair da faixa de tolerância, tornou-se um tópico de considerável importância para melhorar a precisão da medição, decisões de fabricação e seleção de parâmetros de processo (BULUTSUZ; YETILMEZSOY; DURAKBASA, 2015).

2.2.2.1 Tolerância dimensional

Tolerância dimensional pode ser caracterizada como os desvios, diferença entre valores máximos e mínimos medidos, dentro dos quais a peça possa funcionar corretamente. É a diferença entre a medida máxima e a medida mínima admissíveis. Os desvios admissíveis são denominados afastamentos, ou seja, o afastamento é a diferença entre a medida limite e a medida nominal. Distinguisse os afastamentos como seguem (AGOSTINHO; RODRIGUES; LIRANI, 2020):

a) afastamento superior: diferença entre a medida máxima admissível e a nominal;
b) afastamento inferior: diferença entre a medida mínima admissível e a nominal.

Considerando as definições para afastamento, tolerância pode ser definida como a diferença entre o afastamento superior e o afastamento inferior. A dimensão nominal é aquela da qual são derivadas as dimensões limites pela aplicação dos afastamentos superior e inferior. Já a dimensão efetiva representa o valor real de um elemento obtido pela medição. Na mecânica, normalmente a dimensão nominal é representada em milímetros e os afastamentos em micrômetros (NETO, 2018). Na Figura 4 é demonstrado uma representação das dimensões de uma peça e seus afastamentos superiores e inferiores.

Figura 4 - Representação das dimensões de uma peça e seus afastamentos superiores e inferiores

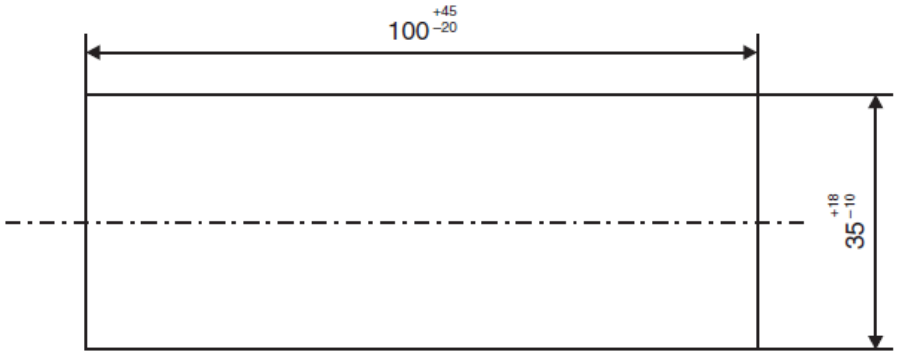

Fonte: Neto (2018).

A relação de acoplamento quando duas peças devem ser montadas é defino como ajuste. O ajuste é determinado pela diferença de medidas entre as peças antes

do acoplamento. Para todo acoplamento sempre haverá ajuste, caracterizado pelas superfícies de contato entre peças e respectivas tolerâncias admitidas (AGOSTINHO; RODRIGUES; LIRANI, 2020). A utilização de sistemas de ajustes padronizados visa garantir critérios consolidados para que os componentes sejam montados e funcionem adequadamente (NETO, 2018).

2.2.2.2 Tolerâncias geométricas

Os componentes de montagem podem estar com tolerância dimensional correta, mas devem ser verificados os limites em relação à posição, à forma e à orientação, que são inerentes às tolerâncias geométricas. As tolerâncias geométricas são variações permissíveis dos limites dentro dos quais os desvios de forma e posição devem estar compreendidos sem prejudicar o funcionamento e a intercambialidade de uma peça ou equipamento (NETO, 2018). As tolerâncias geométricas têm por objetivo impor condições relativas ao controle da forma das superfícies ou do posicionamento entre elas (AGOSTINHO; RODRIGUES; LIRANI, 2020). Um ponto importante no estudo das tolerâncias geométricas é o conhecimento da simbologia e suas aplicações. A Figura 5 demonstra aqueles símbolos indispensáveis para a compreensão das tolerâncias geométricas (NETO, 2018).

O grau em que a peça real difere da projetada, determinado pela qualidade da usinagem, caracteriza a precisão de fabricação. Os desvios da peça original dentro do conceito de tolerância geométrica podem ser enquadrados como segue (AGOSTINHO; RODRIGUES; LIRANI, 2020):

a) desvio de forma: relacionados ao grau de variação das superfícies reais com relação aos sólidos geométricos que as definem;
b) desvio de orientação: relacionado com elementos que têm pontos em comum através de intersecção de suas linhas ou superfícies;
c) desvio de posição: relacionado com a diferença entre uma aresta ou superfície e a posição teórica prescrita pelo projeto da peça;
d) desvio de batimento: relacionado com a variação máxima admitida de um elemento ao completar uma rotação girando em torno de um eixo de referência sem se deslocar axialmente.

Figura 5 - Símbolos para as características toleradas de uma peça

Característica tolerada		Símbolo
Forma	Retitude	
	Planeza	
	Circularidade	
	Cilindricidade	
	Perfil de linha qualquer	
	Perfil de superfície qualquer	
Orientação	Paralelismo	
	Perpendicularidade	
	Inclinação	
Posição	Posição	
	Concentricidade	
	Coaxilidade	
	Simetria	
Batimento	Circular	
	Total	

Fonte: Neto (2018).

As características toleradas de uma peça podem ser enquadradas como segue (NETO, 2018):

a) tolerância de forma: associada aos desvios admissíveis na geometria de uma peça em relação a sua forma ideal;
b) tolerância de orientação: condição de uma linha ou superfície ser equidistante em todos os seus pontos de um eixo ou plano de referência;
c) tolerância de posição: desvio tolerado de um determinado elemento (ponto, reta ou plano) em relação a sua posição teórica;
d) tolerância de batimento: relacionada as superfícies de revolução, essas podem apresentar ovalização, conicidade ou excentricidade em relação ao eixo.

2.2.3 Máquina de medição por coordenadas

Processos produtivos cada vez mais exigentes que requerem alta produtividade, com confiabilidade e eficiência, exigiram a modernização dos processos de medição com o desenvolvimento de máquinas para medição automática sem intervenção do operador (NETO, 2018). A utilização de medição manual e/ou com instrumentos convencionais não é uma prática adequada para processos de precisão, pois este método, além de obsoleto, está sujeito a erros de cálculo por parte dos operadores, perda de calibração devido ao mal uso e perda de produtividade na linha de produção (JESUS; MARTINS,2021).

Para atendimento aos requisitos de automação e confiabilidade dos processos atuais, foi desenvolvida a MMC que é um dispositivo que mede a geometria de objetos físicos detectando pontos discretos na superfície com auxílio de um sensor de contato. Por meio da MMC modernas técnicas de avaliação dimensional podem ser implementadas e estas contribuem para a diminuição de custos, prazos de entrega, perdas de insumos e erros de medição, impulsionam a qualidade e o nível tecnológico do produto e a capacidade de adequação a novas especificações (NETO, 2018).

Demandas por alta precisão, tempos de ciclo cada vez mais curtos, assertividade na determinação dos erros de fabricação e de medição, têm exigido a automatização da etapa de medição. A MMC é a ferramenta de inspeção adequada para determinar a especificação geométrica do produto atendendo aos requisitos de produtividade, flexibilidade e precisão (BULUTSUZ; YETILMEZSOY; DURAKBASA, 2015).

O princípio de funcionamento de uma MMC consiste em determinar as coordenadas dos pontos da peça objeto da medição. Possui movimentação em três eixos (X, Y e Z), no qual o ponto no espaço é projetado no plano de referência, onde se definem duas coordenadas (X e Y), e a terceira corresponde à altura perpendicular a esse plano (Z). Um sensor de contato tem a função de marcar os limites da peça e fornecer os dados geométricos exatos e repetitivos dos pontos (MILANEZ, 2020). Uma MMC de pórtico móvel é demonstrada na Figura 6.

Figura 6 - Esquema simplificado de uma MMC

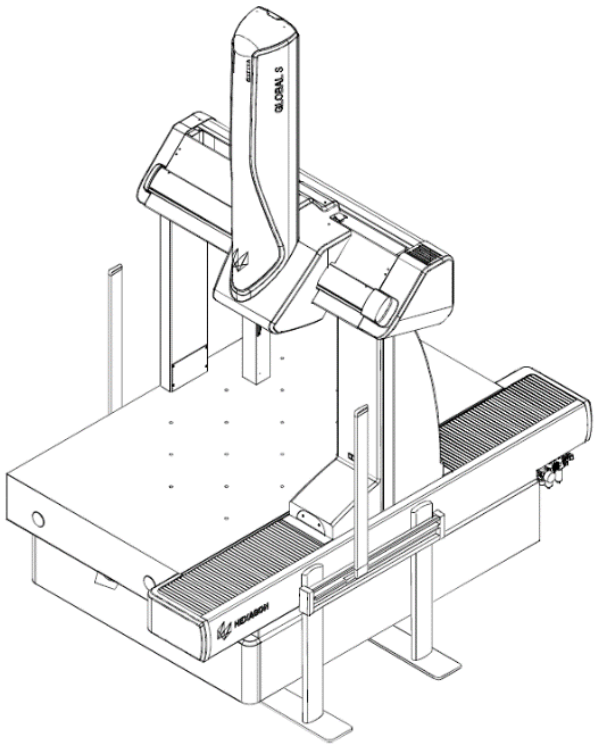

Fonte: Hexagon (2018).

Uma MMC fornece resultados de medição ultra precisos e são amplamente utilizadas na fabricação de precisão. A abordagem de medição por contato, aquela realizada por meio de apalpador por toque, é amplamente utilizada nos processos de medição na indústria por sua eficiência, adaptabilidade e precisão (LI *et al.*, 2022). O apalpador por toque, além de ser fundamental no processo de medição por MMC, possui importante papel nas operações de usinagem, o qual é utilizado para referenciar a peça e para avaliar à precisão das máquinas-ferramenta. A medição com auxílio de apalpadores é uma prática consolidada e estabelecida para maximizar a eficiência, qualidade, capacidade e exatidão em medição de peças usinadas. Incorporadas em modernos comandos CNC simplificam a integração dos ciclos de medição nas operações de usinagem (RENISHAW, 2020).

2.3 Mancal de deslizamento

De forma geral, o mancal de deslizamento é um elemento de máquina que suporta outro elemento de máquina móvel. Ele permite um movimento relativo entre as superfícies de contato, enquanto carrega a carga. Geralmente são alojados em

uma estrutura de ferro fundido (CHAUDHARI *et al*., 2015). A principal função dos mancais de deslizamento, existentes em máquinas e equipamentos, é servir de apoio e guia para eixos girantes. Seu funcionamento se baseia no deslizamento entre um eixo e uma bucha separados por uma película de lubrificante (MELCONIAN, 2019).

O mancal de deslizamento não possui nenhum elemento rotativo, mas um componente deslizante, no qual um eixo gira livremente em um casquilho ou inserto de metal com uma camada de óleo ou graxa separando as duas partes devido aos efeitos fluidodinâmicos. Têm sua aplicação típica para suportar altas cargas radiais e trabalham com baixas e altas rotações (ELYASSAMI, BENJELLOUN; AROUSSI, 2016). Estão sujeitos a força de atrito que surge devido a rotação do eixo. São fabricados em duas partes (bipartidos) com a finalidade de facilitar a instalação e manutenção.

Sua aplicação é ampla no campo de componentes de turbo máquinas, como bombas, compressores e turbinas a gás. Sujeitos às forças de atrito, os mancais de deslizamento devem apresentar um sistema de lubrificação eficiente visto que as forças de atrito geram desgastes e calor e, no caso dos mancais de deslizamento, opõem-se, também, ao deslocamento dos eixos (SRINIVAS *et al*., 2015). Um esquema simplificado com componentes típicos de um mancal de deslizamento é demonstrado na Figura 7.

Figura 7 - Componentes típicos de um mancal de deslizamento

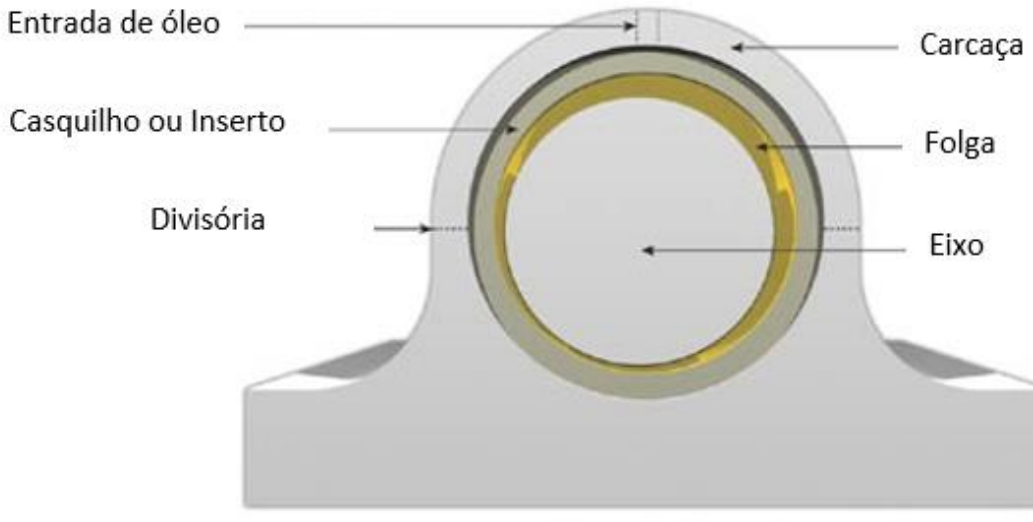

Fonte: Srinivas *et al.* (2015).

2.4 Inteligência artificial: uma abordagem industrial

As tendências recentes das empresas industriais no âmbito da manufatura é a crescente aplicação dos chamados processos de manufatura inteligentes auxiliados por IA (Inteligência Artificial). Essas técnicas estão apoiando a utilização inteligente dos recursos de fabricação e o ajuste adaptativo dos processos industriais. São amplamente utilizadas para resolver problemas complexos através do desenvolvimento de sistemas inteligentes que criam automação nos processos de produção (GEVORKYAN *et al*., 2022).

Abordagens baseadas em IA estão se tornando uma vantagem crítica para aumentar a competitividade industrial ao mesmo tempo que pavimentam o caminho para a transformação digital nas indústrias. Isso decorre devido a flexibilidade e a compreensão profunda de processos complexos de fabricação que elas proporcionam. Suas aplicações estão progredindo em diferentes áreas da fabricação industrial com foco na melhoria do controle da qualidade, eficiência energética, segurança, manutenção e otimização de processos. As razões que motivam a implementação das tecnologias de IA em ambientes industriais são determinadas pela necessidade de automatizar tarefas manuais e cognitivas, e auxiliar na tomada de decisões por meio do aprendizado contínuo de máquina (VERMESAN, 2021).

Os processos de produção modernos na indústria de manufatura e na indústria de processo atingiram um nível crítico de complexidade. A estabilidade operacional e o alto nível de qualidade do produto são atingidos e mantidos apenas por meio de monitoramento, controle e adaptação contínuos. Complexas inter-relações entre as variáveis que compõe os sistemas de produção, instituem as técnicas baseadas em IA como fundamentais no uso dos dados para identificar padrões e tomar decisões com o mínimo de intervenção humana (BULUTSUZ; YETILMEZSOY; DURAKBASA, 2015).

Uma percepção importante no que diz respeito as aplicações de IA é sua componente crucial: a predição. A predição é o principal componente da tomada de decisão. A predição é o processo de preenchimento de informações ausentes através dos dados disponíveis. Portanto, pode-se afirmar que a IA é uma tecnologia de predições, que são insumos para a tomada de decisões (AGRAWAL; GANS; GOLDFARB, 2018).

A aplicação da IA nas indústrias busca promover a colaboração máquina-máquina e homem-máquina para aumentar significativamente a eficiência da fabricação e criar uma conexão versátil entre humanos e máquinas, permitindo monitoramento e interação constantes. O objetivo é combinar a velocidade, precisão, repetibilidade e replicabilidade da operação das máquinas com a visão, tomada de decisão e pensamento crítico e cognitivo do ser humano. Soluções baseadas em IA podem ser aplicadas para conectar ambientes de fabricação físicos e virtuais. Essa convergência possibilita simulações físicas e virtuais em ambientes operacionais nos quais modelos baseados em análise preditiva permitem decisões mais rápidas, precisas e confiáveis (VERMESAN, 2021).

Nem sempre existe uma única resposta correta para as definições que envolvem a escolha da melhor estratégia de IA ou conjunto de técnicas. Esta definição depende dos seguintes dilemas (AGRAWAL; GANS; GOLDFARB, 2018):

a) mais velocidade implica em menos precisão;
b) mais autonomia implica em menos controle;
c) mais dados implica em menos privacidade.

Os dados são o combustível da IA, são a fonte fundamental para responder as questões que envolvem a solução do problema de predição. Ressaltasse que os dados podem ser de dois tipos (MUSSA, 2020):

a) estruturados: são tipicamente valores numéricos, contidos em sistema de gestão e bancos de dados, representados por tabelas organizadas em linhas e colunas;
b) não estruturados: não possuem um modelo de dados predefinido ou não estão organizados de maneira predefinida. Imagens, vídeos e áudios são exemplos de dados não estruturados.

A introdução da IA em uma tarefa não implica necessariamente em sua automação total. A predição é apenas um componente. Em muitos casos, os humanos ainda são necessários para aplicar julgamentos e tomar ações. Quando a IA executa todos os elementos da tarefa, ela é totalmente automatizada e os humanos são completamente removidos do processo. Portanto, as técnicas de IA alteram os fluxos de trabalho das empresas de duas maneiras: primeiro tornam algumas tarefas obsoletas, removendo-as dos fluxos de trabalho. Em segundo lugar, adicionam novas tarefas (AGRAWAL; GANS; GOLDFARB, 2018).

Trabalhadores humanos qualificados continuarão a desempenhar um papel essencial na indústria e, portanto, são o fator mais crítico que precisa ser considerado no processo de definição da estratégia de IA. A efetiva implantação da IA ao utilizar um modelo de aprendizado de máquina deve superar os desafios tecnológicos e metodológicos, envolvidos em um ambiente de produção, ao mesmo tempo deve garantir a aceitação do sistema final pelas pessoas a fim de que as interações homem-máquina possam ocorrer de forma eficiente e inovadora (VERMESAN, 2021).

2.4.1 Aprendizado de máquina

O aprendizado de máquina faz parte do subgrupo de técnicas de IA. Se refere ao uso de modelos estatísticos ou matemáticos, em aplicações específicas para predição de resultados, buscando sempre o máximo desempenho e robustez possível. Para tal, procura-se aplicar o melhor modelo, através de testes e simulações (MUSSA, 2020). Pode ser definido como a ciência da programação de computadores, que evoluiu do estudo de reconhecimento de padrões e da teoria do aprendizado computacional em inteligência artificial, para que eles possam aprender com os dados (GERÓN, 2019). Os dados são valiosos nesta abordagem, pois permitem caracterizar diferentes situações, diferentes grupos e podem ser incorporados a um sistema capaz de ajudar a tomar decisões (BRAZDIL *et al.*, 2022).

O processo de aprendizado de máquina envolve a busca por uma solução que minimize os erros. O objetivo de aplicar técnicas de aprendizado de máquina é fazer com que as máquinas usem linguagem, formem abstrações e conceitos, resolvam tipos de problemas reservados aos humanos, melhorem a si mesmo e, ao final, alcance a eficácia operacional (AGRAWAL; GANS; GOLDFARB; 2018). Ao aplicar técnicas de aprendizado de máquina nos dados registrados, o sistema de controle das máquinas pode receber como informação de feedback os dados relevantes do processo, incluindo os resultados de medições pós-processo e assim os modelos podem prever o comportamento do processo sob possíveis mudanças ou incidentes, tornando-se uma poderosa ferramenta para melhoria de eficiência e desempenho (DOMÍNGUEZ *et al*., 2021).

Os dados são um complemento fundamental para a predição. Predições dependem de dados, mais e melhores dados levam a melhores predições. No

aprendizado de máquina os dados desempenham três funções (AGRAWAL; GANS; GOLDFARB, 2018):

a) dados de entrada: usados para gerar a predição;
b) dados de treinamento: usados para treinar o algoritmo;
c) dados de feedback: usados para melhorar o desempenho do algoritmo através da experiência.

Gerón (2019) classifica o aprendizado de máquina em quatro categorias principais de aprendizado:

a) aprendizado supervisionado: os dados de treinamento fornecidos ao algoritmo incluem as soluções desejadas;
b) aprendizado não supervisionado: os dados de treinamento fornecidos ao algoritmo não incluem as soluções desejadas, ou seja, não são rotulados;
c) aprendizado semi-supervisionado: os dados de treinamento fornecidos são parcialmente rotulados;
d) aprendizado por reforço: capaz de observar o ambiente, selecionar e executar ações e obter recompensas ou penalidades em troca.

A condição para que a aprendizagem de máquina seja categorizada como aprendizado supervisionado ocorre quando é obtido a relação entre dados de entrada e dados de saída, sendo os dados conhecidos. Neste contexto é determinado o que se deve aprender, ou seja, chegar ao resultado. Portanto, é considerado que o aprendizado de máquina está sendo supervisionado. Por outro lado, o aprendizado é considerado não supervisionado quando não é fornecido os dados de resultado (saída). O aprendizado é dito semi-supervisionado quando apenas um pequeno número de exemplos rotulados se encontra disponível. Tem boa aplicabilidade nos casos em que a rotulação dos dados é custosa. Uma quarta categorização apresentada é a de aprendizado por reforço onde é usado um método de recompensa como sinais para indicar quando o algoritmo está agindo positivamente ou negativamente (MUSSA, 2022).

Antes de transformar o modelo de aprendizado de máquina em um produto aplicável, é necessário dividir o conjunto original de dados em três partes: treinamento, teste e validação (IZBICKI; SANTOS, 2020):

a) dados de treinamento: usado para treinar o modelo;
b) dados de teste: usado para avaliar o modelo treinado;

c) dados de validação: usado para comparação de diferentes modelos e parâmetros.

Um típico projeto de aprendizado de máquina é composto pela fase de estudo e análise dos dados, seleção do modelo, treino com os dados de treinamento, simulações com dados de teste e validação com aplicação do modelo para previsões em novos casos. A avaliação do modelo de aprendizado de máquina ocorre por meio do conjunto dos dados de teste. Vários modelos com vários hiperparâmetros, parâmetros cujo valor é usado para controlar o processo de aprendizado, são treinados utilizando o conjunto de dados de treinamento. Seleciona-se o modelo e os hiperparâmetros que atuam melhor no conjunto de teste, e executa-se o teste final, no conjunto de validação, para obter uma estimativa do erro de generalização (GERÓN, 2019).

Uma forma comumente utilizada para composição dos conjuntos de amostras para treinamento, teste e para compor o conjunto de validação é fazê-lo aleatoriamente. Nesse contexto, utiliza-se um gerador de números aleatórios para escolher quais amostras serão usadas para o treinamento e quais serão usadas para a validação. Com esse procedimento espera-se que não ocorram problemas relacionados com a ordenação do conjunto de dados. Uma variação deste método é a validação cruzada, que faz uso de toda a amostra. A validação cruzada k-fold é um método de validação cruzada em que os dados são divididos em lotes disjuntos com aproximadamente o mesmo tamanho. A ideia da validação cruzada k-fold é criar k estimadores da função de regressão (IZBICKI; SANTOS, 2020).

A previsão é o objetivo da maioria das tarefas de aprendizado de máquina, portanto, dada uma série de exemplos de treinamento, o sistema precisa ser capaz de generalizar em exemplos que nunca viu antes. A medição do desempenho nos dados de treinamento é importante, mas insuficiente, o real objetivo é ter um bom desempenho com novos dados. O primeiro passo para construir boas funções de predição é criar um critério para medir o desempenho de uma dada função de predição com novos dados (GERÓN, 2019).

A condição em que o modelo de aprendizado de máquina se ajusta muito bem ao conjunto de dados de treino, mas se mostra ineficaz para prever novos resultados é chamada de sobreajuste. Se o erro de treinamento for baixo, mas seu erro de generalização é alto, significa que o modelo está sobreajustado aos dados de

treinamento. São apresentadas possíveis soluções para evitar o sobreajuste (GERÓN, 2019):

a) simplificar o modelo reduzindo o número de atributos nos dados de treinamento ou restringindo o modelo;
b) coletar mais dados de treinamento;
c) corrigir erros de dados e remover valores atípicos.

Um importante dilema para a criação de um caminho para a implementação do aprendizado de máquina em uma linha de produção é a interação entre a experiência humana e a da máquina. A integração do aprendizado de máquina em futuras linhas e processos de fabricação anuncia uma nova era em que as interações entre pessoas e máquinas se tornam mais integradas e o processo de tomada de decisão é conduzido por dados e pela IA (VERMESAN, 2021).

2.4.1.1 Árvore de decisão por regressão

Uma árvore de decisão é uma importante ferramenta para tomada de decisão. Consiste em uma hierarquia de nós conectados por ramos. O nó, também conhecido como nó decisório, é a unidade de tomada de decisão que avalia através de teste lógico qual será o próximo nó descendente. No último nível da hierarquia é encontrado a folha ou nó terminal que está associado ao valor resultado (ROKACH; MAIMON, 2014).

Em cada nível da árvore, separações nas variáveis independentes são avaliadas. As separações que geram os maiores erros são descartadas e a separação que gera o menor erro é a escolhida. O fato é que as variáveis independentes mais importantes, em geral, ficam localizadas próximos ao topo da árvore. As árvores de decisão possuem a característica de serem autoexplicativas, portanto, são adequadas para aplicações em que a interpretabilidade é almejada. No entanto, elas têm uma tendência ao sobreajuste (HARRISON, 2019). Na Figura 8 é demonstrado um modelo conceitual de árvore de decisão.

Árvores de regressão consistem em uma metodologia não paramétrica que leva a resultados extremamente interpretáveis. Os métodos não-paramétricos buscam ajustar melhor aos dados de treinamento na construção da função de mapeamento, enquanto mantém alguma capacidade de generalizar para dados não vistos. Um

modelo não paramétrico é um modelo que não define limites para parâmetros. Exatamente por isso que métodos não paramétricos são bastante empregados para resolver problemas de regressão e classificação (IZBICKI; SANTOS, 2020). A principal diferença entre uma árvore de regressão para a árvore de classificação é que, em vez de prever uma classe em cada nó, a árvore de regressão prevê um valor (GERÓN, 2019).

Figura 8 - Modelo conceitual de árvore de decisão

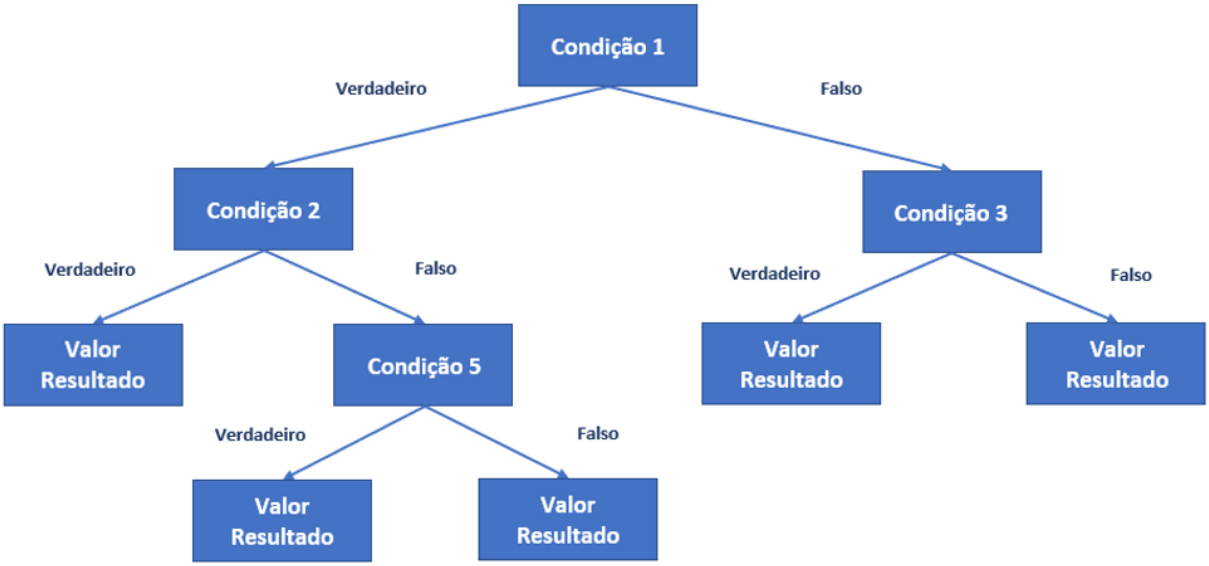

Fonte: Autor (2022).

O objetivo de um modelo de regressão é determinar a relação entre uma variável aleatória Y e um vetor X. A variável Y frequentemente recebe o nome de variável resposta, variável dependente ou rótulo. As variáveis contidas em X são, em geral, chamadas de variáveis explicativas, variáveis independentes, características, atributos, preditores ou covariáveis (IZBICKI; SANTOS, 2020). O método de classificação são aqueles onde se busca encontrar uma classe, dentro das possibilidades limitadas existentes. As árvores de decisão aceitam tarefas tanto de classificação quanto de regressão (HARRISON, 2019).

Uma árvore de decisão cria uma partição do espaço das variáveis independentes em regiões distintas e disjuntas. A previsão do valor da resposta vinculada a variável independente leva em consideração a região a qual o valor da variável independente pertence e, então, é calculado a média dos valores da variável resposta (dependente) das amostras do conjunto pertencentes àquela mesma região.

A maneira como árvores são construídas faz com que as variáveis independentes irrelevantes sejam descartadas. Portanto, a seleção das variáveis relevantes é feita automaticamente. Outra característica importante é que a estrutura de uma árvore naturalmente lida com interações entre variáveis, deste modo, ao contrário de modelos lineares, não é necessário incluir termos de interação adicionais (IZBICKI; SANTOS, 2020).

A criação da estrutura de uma árvore de regressão é composta por duas etapas (IZBICKI; SANTOS, 2020):

a) criação de uma árvore completa e complexa: onde o modelo busca o melhor ajuste aos dados de treino;
b) poda da árvore: tornar a árvore de regressão menor e menos complexa com a finalidade de evitar o sobreajuste aos dados de treino.

Se deixada sem restrições, a estrutura da árvore de decisão se adaptará aos dados de treinamento provavelmente se sobreajustando, comportamento indesejável de aprendizado de máquina. Tal comportamento geralmente ocorre em um modelo não paramétrico, não porque ele não tenha quaisquer parâmetros, mas porque o número de parâmetros não é determinado antes do treinamento, então a estrutura do modelo é livre para ficar próxima aos dados (HARRISON, 2019).

A fim de evitar o sobreajuste nos dados de treinamento, é preciso realizar a regularização, ou seja, restringir a liberdade da árvore de decisão durante o treinamento. Os hiperparâmetros de regularização para o algoritmo de árvore de decisão da biblioteca de aprendizado de máquina de código aberto *scikit-learn*, são os que seguem (GERÓN, 2019):

a) *max_depth*: restringi a profundidade máxima da árvore de decisão;
b) *min_samples_split*: número mínimo de amostras que um nó deve ter antes que possa ser dividido;
c) *min_samples_leaf*: número mínimo de amostras que um nó da folha deve ter;
d) *min_weight_fraction_leaf*: expressa como uma fração do número total de instâncias ponderadas;
e) *max_leaf_nodes*: número máximo de nós da folha;
f) *max_features*: número máximo de características que são avaliadas para divisão em cada nó.

Scikit-learn é uma biblioteca, que contém uma coleção de recursos, que executa parte das tarefas necessárias para desenvolver um projeto de modelagem preditiva. Ele implementa muitos algoritmos de aprendizado de máquina de maneira eficiente, por isso é uma excelente ferramenta para desenvolver programas capazes de aprender com os dados. Nele é possível aplicar muitos dos mesmos modelos de classificação em problemas de regressão. Embora haja semelhanças quanto aos modelos de classificação e os hiperparâmetros, as métricas de avaliação são diferentes no caso de uma regressão (HARRISON, 2019).

O *scikit-learn* utiliza o algoritmo de Árvores de Classificação e Regressão ou *Classification and Regression Trees* (CART), para treinar árvores de decisão que produzem somente árvores binárias, ou seja, as perguntas somente terão respostas sim ou não. O algoritmo primeiro divide o conjunto de treinamento em dois subconjuntos utilizando uma única característica e um limiar que produzem os subconjuntos mais puros. Depois de dividir o conjunto de treinamento em dois, ele divide os subconjuntos utilizando a mesma lógica e assim por diante, recursivamente, até atingir a profundidade máxima, definida pelo hiperparâmetro *max_depth*, ou caso não consiga encontrar uma divisão que reduza o grau de impureza. Os critérios comuns de função de impureza para tarefas de regressão são: o Erro Médio Quadrático (MSE), o desvio de Poisson, bem como o Erro Médio Absoluto (MAE). O *scikit-Learn* utiliza a classe *DecisionTreeRegressor* para construir árvores de regressão (GERÓN, 2019).

2.4.1.2 Métricas de desempenho

Um modelo de regressão básico fornece resultados onde é possível comparar, através de métricas, com outros modelos a fim de determinar o melhor desempenho de predição. O *scikit-learn* inclui métricas para avaliar os modelos de regressão. O coeficiente de determinação (R^2) é uma métrica de regressão comum. Em geral, esse valor está entre 0 e 1 e representa o percentual da variância do valor alvo com o qual as variáveis independentes contribuem. Valores maiores são melhores, mas, de modo geral, é difícil avaliar o modelo exclusivamente a partir dessa métrica (HARRISON, 2019).

O R^2 mede qual a fração da variância de Y é explicada por X, demonstrado na equação (1). A soma dos quadrados explicados (SQE) indica a diferença entre a média das observações e o valor estimado para cada observação, e soma os respectivos quadrados. Quanto menor for a diferença, maior poder explicativo detém o modelo. Já a soma dos quadrados totais (SQT) é a soma dos quadrados das diferenças entre a média e cada valor observado. O R^2 também pode ser definido em termos da fração da variância de Y que não é explicada por X, e nesta condição inclui-se a soma dos quadrados dos resíduos (SQR) que representa as distâncias quadráticas entre os valores observados de Y e seus valores ajustados pelo modelo, demostrado na equação (2) (CHEIN, 2019).

O MAE, também chamado de desvio médio absoluto, é uma medida de desempenho preferencial para tarefas de regressão. É calculado a partir da média dos erros absolutos, demonstrado na equação (3), onde y_i significa o valor observado e $\hat{y}_i$ o valor previsto pelo modelo, ambos para cada amostra do conjunto de dados. É utilizado o módulo de cada erro para evitar a subestimação, visto que há casos em que o erro negativo pode zerar o positivo. É uma forma de medir a distância entre dois vetores: o vetor das previsões e o vetor dos valores alvo. Nele é medido a distância da predição em relação ao valor real, independentemente de ser acima ou abaixo (GERÓN, 2019). Um modelo perfeito teria uma pontuação igual a 0, mas essa métrica não tem limites superiores, de modo diferente do coeficiente de determinação. No entanto, como está em unidades do valor a ser predito, ele é mais interpretável. Essa medida não é capaz de informar quão ruim é um modelo, no entanto, é uma boa métrica a ser usada quando se tem um valor mínimo pré-definido para enquadramento ou quando se quer comparar modelos diferentes (HARRISON, 2019).

$$R^2 = \frac{SQE}{SQT} \tag{1}$$

$$R^2 = 1 - \frac{SQR}{SQT} \tag{2}$$

$$MAE(y, \hat{y}) = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i| \tag{3}$$

2.4.2 Método CRISP-DM

Na ciência de dados a maior parte do esforço é despendido nas várias etapas preparatórias que precedem a construção do modelo. A etapa real de construção do modelo geralmente requer menos esforço. Isso motivou os pesquisadores a desenvolver um método para padronizar as etapas preparatórias e que deu origem à metodologia conhecida como modelo CRISP-DM (*Cross Industry Standard Process for Data Mining* ou Processo Padrão do Mercado para Mineração de Dados). As principais etapas desta metodologia incluem a compreensão do problema e definição do problema, obtenção dos dados, pré-processamento dos dados, construção do modelo e sua avaliação (BRAZDIL *et al.,* 2022).

O CRISP-DM pode ser definido como um processo para fazer mineração de dados que consiste em um conjunto de seis etapas, boas práticas, para se executar um projeto em ciência de dados. São elas (HARRISON, 2019):

a) entendimento do negócio;
b) entendimento dos dados;
c) preparação dos dados;
d) modelagem;
e) avaliação;
f) Implantação.

O modelo CRISP-DM, mesmo que não explicitamente, é o método padrão, conduzidos por profissionais, para implantação de técnicas de aprendizado de máquina na indústria. A preferência pelo método é devida sua aptidão para oferecer respostas precisas para a resolução de problemas, capacidade de adaptar e de ser modificado de acordo com as necessidades do processo, ou seja, pode ser aplicado a qualquer tipo de negócio sem dependência de um software ou serviço para ser executado (CLARK, 2018).

3 TRABALHOS RELACIONADOS

Para realizar o levantamento de trabalhos relacionados, foram definidas as seguintes expressões para pesquisa nas principais bases de busca de trabalhos científicos: “*bearings and machine learning*”, “*manufacturing and machine learning*”, “*machining process and machine learning*” e “*machining error compensation*”. Um processo de filtragem por título e resumo, foi aplicado o que proporcionou 24 trabalhos escolhidos para análise e ponderação em relação ao grau de concordância com o escopo do trabalho proposto. Então, 13 trabalhos foram selecionados para caracterização e comparação. Constatou-se que estes concentraram-se em: (i) abordagem generalista para aplicação de aprendizado de máquina na indústria; (ii) técnicas e metodologias para monitoramento da condição de operação; (iii) detecção e diagnóstico de falha; (iv) otimização de processos e do produto; (v) teoria de usinagem considerando aspectos da cinemática do processo; (vi) condição da ferramenta (vii); fenômenos físicos; (viii) previsão da qualidade de peças fabricadas.

Os trabalhos que concentraram na abordagem generalista para aplicação de aprendizado de máquina na indústria buscaram apresentar uma revisão da literatura de diferentes modelos de aprendizado de máquina e suas principais finalidades, dentre estes destacam-se: (i) Kim *et al.* (2018) que forneceram uma revisão da literatura onde é demonstrado uma tabela com as técnicas de aprendizado de máquina mais utilizadas para cada processo de usinagem e seu respectivo propósito. As finalidades apresentadas variam, desde a otimização dos parâmetros do processo até o monitoramento da integridade da máquina e a melhoria da qualidade do produto. Fresamento e torneamento foram as formas mais proeminentes de processos de usinagem estudados; (ii) Aggogeri, Pellegrini e Tagliani (2021) que apresentaram uma revisão das principais aplicações e os diferentes modelos e configurações de aprendizado de máquina, classificando o tipo de problema, as abordagens aplicadas e os resultados obtidos. A revisão classifica seis macrocategorias de problemas abordados pelo aprendizado de máquina: vibração, rugosidade, qualidade, modelagem, monitoramento da condição da máquina e monitoramento da condição da ferramenta. O trabalho proposto difere destas pesquisas pois a abordagem e o método utilizados foram definidos para solucionar um problema específico da indústria

de fabricação mecânica, restringindo a abrangência da pesquisa ao tema controle dimensional de carcaças de mancais de deslizamento flangeados.

Dentre os trabalhos que concentraram em técnicas e metodologias para monitoramento da condição de operação destacam-se: (i) Manjunatha e Chittappa (2022) que abordaram a classificação das condições de funcionamento do mancal usando uma rede neural artificial. Através do monitoramento dos sinais de vibração um conjunto de características estatísticas foram obtidas. A técnica de árvore de decisão foi utilizada para selecionar as características significativas obtidas. O classificador atingiu 97,5% de precisão para os sinais de vibração extraídos. O trabalho proposto difere desta pesquisa pois nele é aplicado a técnica de aprendizado de máquina para solucionar um problema de regressão; (ii) Moschopoulos, Rossopoulos e Papadopoulos (2021) que apresentaram o desenvolvimento de algoritmos de aprendizado de máquina para prever os índices de desempenho do mancal de deslizamento em estado estacionário em uma ampla gama de valores de carga e velocidade de rotação, utilizando medições de som e vibração. Os algoritmos utilizados foram*: k-Nearest Neighbours, Decision Trees, Random Forest* e *Gradient Tree Boosting*. O trabalho proposto difere desta pesquisa pois nele é aplicado a técnica de aprendizado de máquina para predizer parâmetros de processo fabricação de mancais de deslizamento por usinagem ao invés de predizer parâmetros de operação de mancais de deslizamento.

Dentre os trabalhos que concentraram em detecção e diagnóstico de falha destaca-se: (i) Piltan e Kim (2021) que propuseram a utilização do aprendizado de máquina para detecção de anomalias em mancais e identificação do tamanho de trincas. O algoritmo de máquina de vetores de suporte foi integrado a um gêmeo digital inteligente para identificar os tamanhos de trincas e padrões de falha do mancal. O trabalho proposto difere desta pesquisa pois nele é aplicado a técnica de aprendizado de máquina para solucionar um problema de controle de fabricação por usinagem ao invés de um problema de operação e manutenção.

Dentre os trabalhos que concentraram na otimização de processos e do produto destacam-se: (i) Raval e Joshi (2022) que apresentaram um roteiro para implementação de técnicas modernas para alcançar o conceito de fábrica inteligente em uma indústria de fabricação de mancais. Os impactos demonstrados são a melhoria da produtividade, da qualidade do produto e da eficácia da fábrica. É indicada

a utilização da técnica de inteligência artificial para comunicações de máquina para máquina, robótica avançada, sistemas ciberfísicos e automação industrial; (ii) Viharos *et al.* (2016) que demonstraram uma abordagem de otimização de processo de manufatura através da aplicação de um modelo de previsão de tendências de produção. A solução desenvolvida coleta dados do chão de fábrica e com base nos valores concretos de fabricação define classes de tendência de produção e os resultados para servir de prognóstico de tendência em uma dada situação de manufatura. O trabalho proposto difere desta pesquisa pois a solução de aprendizado de máquina é aplicada para predição em uma célula de produção flexível onde as carcaças são fabricadas, em diversos tamanhos e modelos, por ordem de produção específica; (iii) Domínguez *et al*. (2021) que propuseram o desenvolvimento de modelos de previsão integrados em um gêmeo digital para melhorar o desempenho de uma linha de produção multiestágios de mancais. Através da implementação, os modelos de previsão foram capazes de determinar as condições ideais de operação e o ajuste final do mancal sob diferentes condições de usinagem. O modelo selecionado foi o de regressão exponencial quando comparado a outros 12 algoritmos como árvores de decisão, máquina de vetores de suporte ou outras regressões de processo gaussianas. O trabalho proposto difere desta pesquisa na metodologia utilizada que aborda a holística para avaliar a geometria da peça.

Dentre os trabalhos que concentraram na teoria de usinagem considerando aspectos da cinemática do processo destaca-se: (i) Marinescu *et al.* (2011) que propuseram uma abordagem de compensação do desvio dimensional pela programação adaptativa do percurso da ferramenta de corte. Uma análise experimental comparativa para implementação do método demonstrou que o algoritmo adaptativo-ótimo apresentou melhor resultado de precisão. No entanto, ele não deve ser aplicado às primeiras 10 a 15 amostras do lote, para tal é indicado o algoritmo adaptativo-preditivo. O trabalho proposto difere desta pesquisa no critério heurístico para as etapas definição e ajuste do processo.

Dentre os trabalhos que concentraram na condição da ferramenta destaca-se: (i) Pantage e Jegadeeshwaran (2020) que abordaram a aplicação de aprendizado de máquina para classificação da condição da ferramenta. As condições foram categorizadas usando seis diferentes algoritmos baseados em árvore de decisão: *Decision tree classifier, Logistic model tree classifier, Random Forest classifier, Best*

First tree classifier, Functional tree classifier e *Simple CART classifier*. O algoritmo *Best First Tree* atingiu a maior precisão de 97% e o menor tempo de resposta de 0,2 segundos. O trabalho proposto difere desta pesquisa pois nele é aplicado a técnica de aprendizado de máquina para solucionar um problema de regressão com foco fabricação de carcaças de mancais de deslizamento por usinagem.

Dentre os trabalhos que concentraram na avaliação de fenômenos físicos destaca-se: (i) Wąsik e Kolka (2017) que abordaram a influência da variação da temperatura externa e interna da máquina-ferramenta no fenômeno de deformação térmica na usinagem de alta precisão de peças com paredes finas e geometrias complexas. O método de elementos finitos foi utilizado para simulação numérica. O trabalho proposto difere desta pesquisa pois é utilizada uma abordagem para a compensação dos desvios dimensionais baseado no monitoramento e modelagem do desvio total independentemente das fontes e componentes do erro.

Dentre os trabalhos que concentraram na previsão da qualidade de peças fabricadas destacam-se: (i) Krauß *et al.* (2019) que focaram na melhoria de processo com base na previsão da qualidade do produto em uma cadeia de processos de fluxo contínuo. Para cada processo, o algoritmo CART foi treinado para classificar se o produto correspondente estaria dentro ou fora da especificação no final da cadeia de processo. O trabalho proposto difere desta pesquisa devido a utilização do algoritmo CART para um problema de regressão ao contrário do proposto pelo autor que utilizou para um problema de classificação; (ii) Frye e Schmitt (2019) que desenvolveram um modelo de previsão para controle de processo de produção que evite condições críticas no processo de fresamento com objetivo de garantir a qualidade do produto. Os algoritmos de *Random Forest, Gradient Boosting* e *Long Short Term Memory* foram testados e o *Long Short Term Memory* apresentou o menor valor da Raiz Quadrada do Erro-Médio ou *Root Mean Squared Error* (RMSE). O trabalho proposto difere desta pesquisa pois nele é aplicado a técnica de aprendizado de máquina a partir do monitoramento das medidas das dimensões contidas nos relatórios dimensionais produzidos por MMC ao invés do monitoramento da amplitude de vibração.

A partir da revisão apresentada, constata-se a busca por maneiras e meios de aplicar modelos preditivos nos processos de usinagem em diferentes perspectivas. Nesse cenário, este trabalho concentra-se em validar a técnica de aprendizado de máquina baseada em árvores de decisão por regressão para controle dimensional de

carcaças de mancais de deslizamento flangeados, através de uma abordagem holística para monitoramento da geometria da superfície da peça usinada, heurística para as etapas que compõe a tomada de decisão e empregando o módulo *python* de aprendizado de máquina de código aberto *scikit-learn*. Na tabela 1 estão contidos os resultados da pesquisa de trabalhos relacionados.

Tabela 1 - Resultado da pesquisa de trabalhos relacionados

Ano	Autor	Categoria	Modelo/Técnica
2011	Marinescu *et al.*	Teoria de usinagem considerando aspectos da cinemática do processo	Algoritmo adaptativo-ótimo; Algoritmo adaptativo-preditivo
2016	Viharos *et al.*	Otimização de processos e do produto	Rede neural artificial
2017	Wąsik e Kolka	Fenômenos físicos	Método de elementos finitos
2018	Kim *et al.*	Abordagem generalista para aplicação de aprendizado de máquina na indústria	Revisão da literatura
2019	Krauß *et al.*	Previsão da qualidade de peças fabricadas	Árvores de Classificação e Regressão
2019	Frye e Schmitt	Previsão da qualidade de peças fabricadas	*Random Forest; Gradient Boosting; Long Short-Term Memory*
2020	Pantage e Jegadeeshwaran	Condição da ferramenta	*Decision Tree Classifier; Logistic Model Tree Classifier; Random Forest Classifier; Best First Tree Classifier; Functional Tree Classifier; Simple CART Classifier*
2021	Domínguez *et al.*	Otimização de processos e do produto	*Exponential GPR; Rational Quadratic GPR; Matern 5/2 GPR; Fine tree*
2021	Aggogeri, Pellegrini e Tagliani	Abordagem generalista para aplicação de aprendizado de máquina na indústria	Revisão da literatura
2021	Moschopoulos, Rossopoulos e Papadopoulos	Técnicas e metodologias para monitoramento da condição de operação	*k-Nearest Neighbors; Decision Trees; Random Forest; Gradient Tree Boosting*
2021	Piltan e Kim	Detecção e diagnóstico de falha	Máquina de vetores de suporte
2022	Manjunatha e Chittappa	Técnicas e metodologias para monitoramento da condição de operação	Rede neural artificial
2022	Raval e Joshi	Otimização de processos e do produto	Roteiro de técnicas da Indústria 4.0

Fonte: Autor (2023).

4 MODELO DESENVOLVIDO

As carcaças de mancais de deslizamento, linha *standard* norma DIN 31693, são fabricadas em metades, superior e inferior, com a finalidade de facilitar a instalação e manutenção. Estas carcaças são produzidas em ferro fundido nodular e possuem flange para montagem final na máquina ou equipamento a qual é destinado. O acento esférico garante o alinhamento durante a montagem e que as cargas serão distribuídas uniformemente na metade inferior. Possuem canais para vedação além de orifícios de rosca para monitoramento da temperatura, entrada e saída de óleo, bem como para o nível de óleo. A metade superior da carcaça possui um visor, que permite a visualização do anel de óleo. O design básico pode ser alterado, se necessário, para incorporar tubos de resfriamento, aquecedor de cárter de óleo, sensores de vibração horizontal, vertical, axial e dispositivos de aterramento. O mancal de deslizamento montado é demonstrado na Figura 9(a). As metades superior e inferior da carcaça são demonstradas na Figura 9(b).

Figura 9 - Mancal de deslizamento norma DIN 31693. (a) Mancal montado. (b) Metades superior e inferior da carcaça

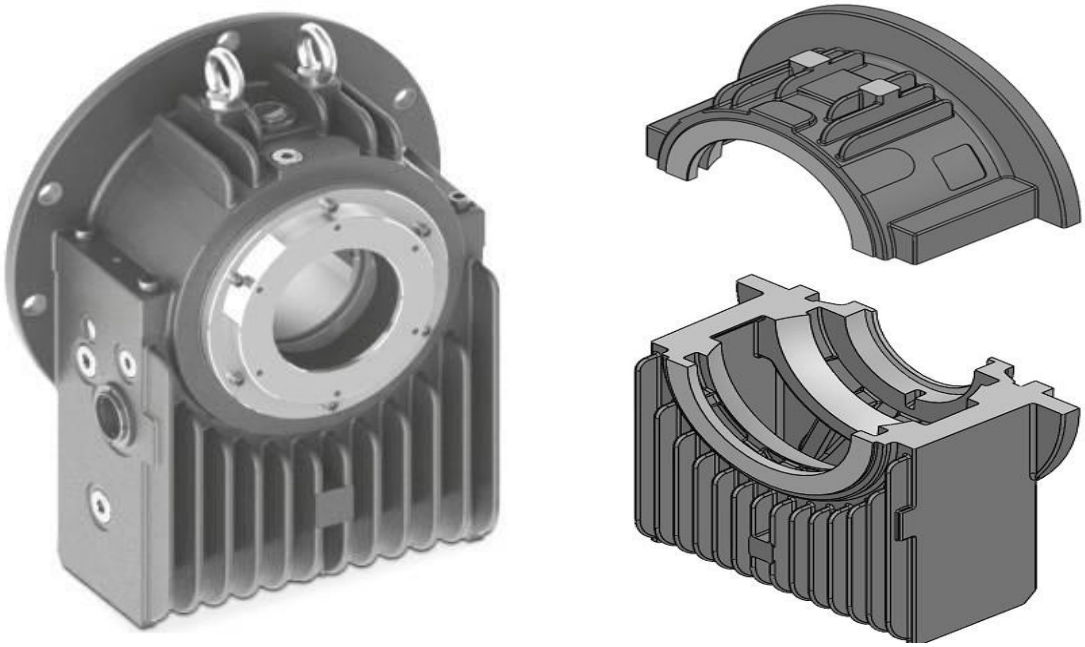

(a) (b)

Fonte: Autor (2022).

Para a fabricação das carcaças é utilizado o processo de usinagem por fresamento, furação e rosqueamento, composto por centro de usinagem horizontal universal, programa de usinagem CNC e operador. Cada metade fabricada tem seu controle dimensional realizado por processo metrológico composto por MMC, programa de medição e operador.

O processo de usinagem fornece a peça a qual será medida e controlada no processo metrológico. O processo metrológico resulta no relatório do qual se obtém os desvios dimensionais referentes as dimensões críticas que são objeto de avaliação por profissionais qualificados. A avaliação dos profissionais qualificados resulta nos ajustes, no programa de usinagem CNC, para os parâmetros de deslocamento dos eixos do centro de usinagem com o objetivo de compensar todas as fontes de erros sistemáticos.

4.1 Metodologia para desenvolvimento do modelo

Para o desenvolvimento do modelo preditivo foi aplicado uma metodologia baseada no procedimento CRISP-DM. Seis etapas fundamentais, cada uma com suas particularidades e funcionalidades foram seguidas. As três primeiras etapas tiveram como objetivo a contextualização, a coleta e organização dos dados a serem analisados. Nelas estão contidas a definição do problema, a definição dos dados brutos e o pré-processamento do conjunto de dados. As últimas três etapas tiveram como objetivo a criação do modelo, baseado nas etapas anteriores, e a colocação deste modelo em prática. Estas são a definição do algoritmo, validação do modelo e implantação. Este conjunto de etapas predefinidas, ordenadas em fluxo, objetivaram garantir a correta transcrição do escopo do projeto em um produto capaz de implementar melhorias em um processo existente.

4.1.1 Contextualização e definição do problema

Com base na descrição do processo de fabricação e controle dimensional foi definido o tamanho de carcaça correspondente à faixa de diâmetro de eixo de 160 a 220 mm e as dimensões críticas D1, D2, D3 e D4 para a fase de desenvolvimento do modelo preditivo. A dimensão crítica D1 corresponde a medida do raio do esférico

onde é apoiado o inserto. A dimensão D2 corresponde a medida do centro do esférico até a divisória da carcaça. A dimensão D3 corresponde a distância do centro do esférico até a face flangeada. A dimensão D4 corresponde a distância do centro do esférico até a face oposta a face flangeada. O critério de escolha destas dimensões foi pautado nos quesitos de tolerâncias dimensionais, complexidade do processo de usinagem e montagem do conjunto. As dimensões críticas D1, D2, D3 e D4 da metade superior e metade inferior estão demonstradas na Figura 10.

Figura 10 - Dimensões críticas da metade superior. (a) D1 e D2. (b) D3 e D4. Dimensões críticas da metade inferior. (c) D1 e D2. (d) D3 e D4

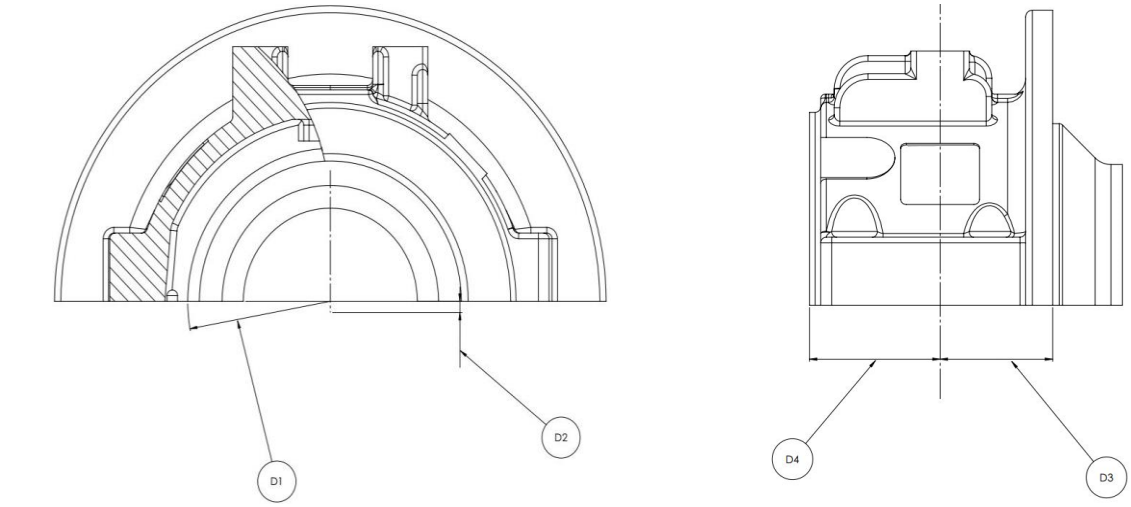

(a) (b)

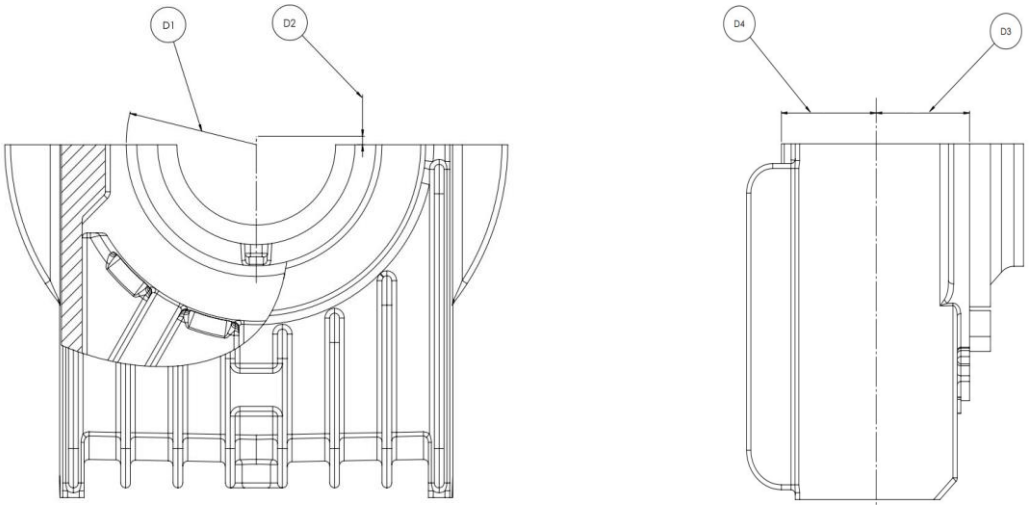

(c) (d)

Fonte: Autor (2023).

Para o detalhamento das características e requisitos das dimensões críticas foi realizado uma análise das informações técnicas contidas nos projetos de fabricação das carcaças, relatórios de controle dimensional e suas relações com a etapa de análise e tomada de decisão de processo. Após, foi possível identificar e descrever os dados para utilização no modelo proposto. Neste ponto, destaca-se que a sensibilidade do centro de usinagem é de 0,001 mm. Na Tabela 2 estão contidas as dimensões críticas e respectivas informações de usinagem e de geometria.

Tabela 2 - Dimensões críticas

DIMENSÃO	**PROCESSO DE USINAGEM**	**TOLERÂNCIA DE MEDIDA (MM)**	**TOLERÂNCIA GEOMÉTRICA**	
			CARACTERÍSTICA	**TOLERÂNCIA (MM)**
D1	Fresamento Interpolação Circular	0,029	Concentricidade	0,010
D2	Fresamento Interpolação Linear	0,020	Planeza Perpendicularidade Simetria	0,050 0,050 0,050
D3	Fresamento Interpolação Circular	0,040	Perpendicularidade Paralelismo	0,050 0,100
D4	Fresamento Interpolação Circular	0,040	Perpendicularidade Paralelismo	0,050 0,100

Fonte: Autor (2023).

4.1.2 Definição dos dados brutos

Os dados de interesse para elaboração do modelo foram obtidos nos relatórios dimensionais, no histórico dos ajustes no programa de usinagem CNC, no registro de temperatura ambiente no momento da usinagem e na condição de equalização térmica da peça no momento da medição.

Como premissa para análise de causa e efeito (definição de variáveis relevantes), foi utilizado o conhecimento e experiência de 10 profissionais com mais de 15 anos de experiência trabalhando diariamente nesse tipo de tomada de decisão como base para criar uma matriz de relacionamento entre as variáveis dependentes e independentes exibida na Tabela 3.

Tabela 3 - Matriz de relacionamento entre as variáveis

VARIÁVEL INDEPENDENTE	**VARIÁVEL DEPENDENTE**			
	A1	A2	A3	A4
Temperatura	X	X	X	X
Climatizada	X	X	X	X
Desvio (D1)	X	X	-	-
Fora de Tolerância (D1)	X	-	-	-
Desvio (D2)	X	X	-	-
Fora de Tolerância (D2)	-	X	-	-
Desvio (D3)	-	-	X	-
Fora de Tolerância (D3)	-	-	X	-
Desvio (D4)	-	-	-	X
Fora de Tolerância (D4)	-	-	-	X

Fonte: Autor (2023).

Esta matriz apresenta as variáveis dependentes A1, A2, A3 e A4, que são os ajustes dos parâmetros de deslocamento dos eixos do centro de usinagem das respectivas dimensões críticas D1, D2, D3 e D4, e as seguintes variáveis independentes:

a) temperatura: trata-se do valor de medida da temperatura ambiente no momento da usinagem final das carcaças;
b) climatizada: refere-se à condição em que a peça tem sua temperatura equalizada com a MMC antes de ser medida. A temperatura de equalização é de 21± 1ºC;
c) desvio: representa a diferença entre o valor medido e a medida nominal de uma determinada dimensão crítica;
d) fora de tolerância: representa o valor que excede os limites de tolerância de medida de uma determinada dimensão crítica.

Verifica-se que as variáveis independentes Temperatura e Climatizada têm influência em todas as variáveis dependentes (A1, A2, A3 e A4). A variável independente Desvio, das dimensões críticas D1 e D2, possuem relacionamento entre si. Este fato indica que a definição do ajuste A1 depende das medidas de D1 e D2 e a mesma condição é aplicada para a definição do ajuste A2.

4.1.3 Pré-processamento do conjunto de dados

Para a obtenção de dados úteis e eficientes a partir dos dados originais, realizou-se um conjunto de atividades de preparação, organização e estruturação dos dados. Essa etapa é de grande importância, pois é determinante para a qualidade final dos dados que serão analisados. Ela pode, inclusive, impactar no modelo de previsão gerado.

Inicialmente os dados, vistos na Seção 4.1.2, foram avaliados em relação a sua estrutura. Verificou-se que os dados apresentavam um padrão pré-definido, uma estrutura bem definida e rígida podendo ser representados por uma coleção de linhas e colunas organizadas dentro de tabelas. Estas características definem o conjunto de dados como estruturado. O conjunto de dados foi analisada em relação a ausência de dados, dados irrelevantes, identificação e remoção de valores discrepantes e a

resolução de inconsistências. Os dados estavam em formatos apropriados e adequados para a realização das análises e testes.

4.1.4 Definição do algoritmo

A definição do algoritmo levou em consideração as seguintes condições:

a) relações não lineares: as variáveis contidas na matriz, visto na Seção 4.1.2, não possuem relações lineares;
b) capacidade de definir fronteiras de decisão: a modelagem das fronteiras de decisão deve reproduzir a tomada de decisão dos profissionais;
c) velocidade de execução: decisões rápidas geram menor tempo de parada de produção;
d) métrica da previsão: deve estar na mesma unidade de medida do valor resultado e ser adequada para comparação com o critério predefinido pelos profissionais;
e) interpretabilidade do algoritmo: é fundamental para a aprovação do modelo, visto que acarretará mudanças no processo principal da indústria;
f) conhecimento do domínio: o conhecimento do processo, que foi construído pela empresa, deve ser integrado pelo algoritmo.

A árvore de decisão é um poderoso algoritmo construído sobre o processo básico de tomada de decisão humana com base em alguns critérios ou limites. Modelos baseados em árvore de decisão estão entre os de resposta mais rápida, além de apresentar, de forma visual, um conjunto de regras “se-então” para melhoria da compreensão e interpretação dos resultados. Essa característica é fundamental pois o modelo será aplicado em um ambiente de manufatura onde o relacionamento homem-máquina é muito intenso. Os problemas e os conjuntos de dados correspondentes, objetos da tomada de decisão, são específicos do domínio. Portanto, o processo de escolha do algoritmo levou em consideração a experiência dos membros da equipe envolvidos.

Em vez de implementar nossa própria versão do algoritmo, foi definido a utilização do módulo *python scikit-learn* para desenvolvimento do modelo preditivo. Esta definição foi motivada em razão do módulo integrar uma ampla variedade de algoritmos de aprendizado de máquina de última geração mantendo uma interface

fácil de uso totalmente integrada à linguagem *python*. Além de usar uma versão otimizada do algoritmo CART caracterizada por construir árvores binárias usando o recurso e o limite que geram o maior ganho de informação em cada nó, sendo que, no caso de regressão, procura por divisões que minimizem o R^2 da previsão.

4.1.5 Avaliação do modelo em simulação computacional

O *dataset* utilizado para treino e validação do modelo foi baseado em 62 peças fabricadas entre maio e dezembro de 2022. O *scikit-learn* fornece algumas funções para dividir conjuntos de dados em vários subconjuntos de diversas maneiras. A função mais simples é *train_test_split*, no entanto o método de validação cruzada denominado *k-fold* foi utilizado para dividir o conjunto total de dados em 5 subconjuntos mutuamente exclusivos do mesmo tamanho e, a partir daí, 5 rodadas de treinamento e teste foram realizadas. Em cada rodada definiu-se um subconjunto para teste e os outros 4 subconjuntos para treino. Essa sistemática foi seguida para as outras rodadas variando o subconjunto de validação.

O algoritmo floresta aleatória foi utilizado para comparação de performance ao modelo de árvore de regressão proposto. A Floresta aleatória usa muitas árvores de decisão individuais que são criadas ao randomizar a divisão em cada nó da árvore de decisão. É muito eficiente para analisar grandes conjuntos de dados multidimensionais. No entanto, devido à sua natureza aleatória, nem sempre é intuitivo e compreensível para o usuário. O MAE foi definido como métrica para análise dos erros e consequente avaliação do resultado do modelo. A figura 11 demonstra a abordagem de desenvolvimento do modelo preditivo.

A execução das simulações foi pautada no escalonamento como método para melhoria incremental da performance do modelo e consequente definição das variáveis independentes que realmente contribuem para a melhoria de seu desempenho. Foi definido os seguintes parâmetros para escalonamento: (i) *min_samples_split*; (ii) *min_samples_leaf*; (iii) *kfold_split*: número de subconjuntos para treino, teste e validação; (iv) *n_estimators*: número de árvores na floresta. Nas tabelas 4 e 5 estão demonstrados a configuração dos parâmetros selecionados para a realização da simulação.

Figura 11 – Abordagem de desenvolvimento do modelo preditivo

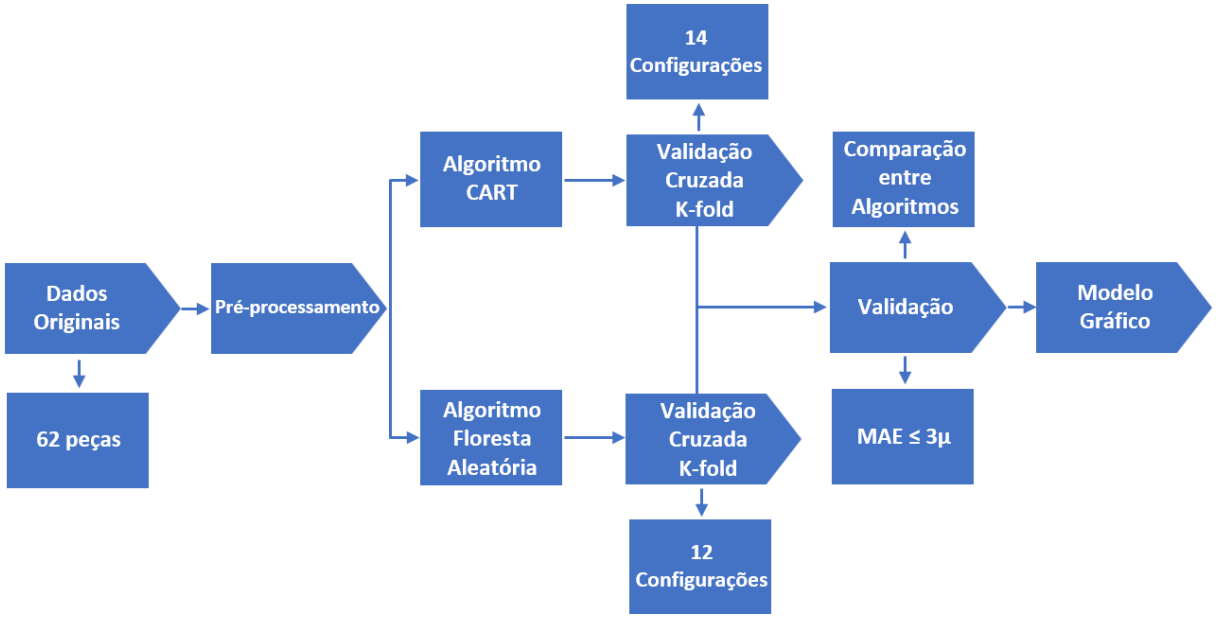

Fonte: Autor (2023).

Tabela 4 - Parâmetros para simulação na árvore de regressão

CONDIÇÃO	A	B	C	D	E	F	G	H	I	J	K	L	M	N
min_samples_split	2	3	4	5	2	2	2	3	3	4	4	4	5	5
min_samples_leaf	2	2	2	2	3	4	5	3	4	3	4	5	4	5
Kfold_split	5	5	5	5	5	5	5	5	5	5	5	5	5	5

Fonte: Autor (2023).

Tabela 5 - Parâmetros para simulação na floresta aleatória

CONDIÇÃO	A	B	C	D	E	F	G	H	I	J	K	L
n_estimators (D1)	10	10	10	10	35	35	35	35	310	310	310	310
n_estimators (D2)	10	10	10	10	55	55	55	55	300	300	300	300
n_estimators (D3)	3	3	3	3	29	29	29	29	47	47	47	47
n_estimators (D4)	3	3	3	3	7	7	7	7	11	11	11	11
min_samples_leaf	2	3	4	5	2	3	4	5	2	3	4	5
Kfold_split	5	5	5	5	5	5	5	5	5	5	5	5

Fonte: Autor (2023).

A primeira rodada de simulação foi realizada fixando a variável dependente e alternando a variável independente de forma separada. O melhor resultado da rodada foi fixado para a realização da próxima rodada. Essa sistemática decorreu até que todas as variáveis independentes fossem avaliadas individualmente em cada rodada de simulação. Ao final do processo, foi obtido o modelo de árvore de decisão de regressão e o modelo de floresta aleatória e respectivos conjuntos de correlações de variáveis com o menor MAE para cada ajuste da respectiva dimensão crítica. Nas tabelas 6 e 7 é demonstrado os resultados com menor valor de erro médio absoluto após simulações.

Tabela 6 - Resultados obtidos após simulações na árvore de regressão

AJUSTE	ALGORÍTMO	CONDIÇÃO	MAE (mm)
A1	Árvore de Regressão	E / H / J	0,001495
A2	Árvore de Regressão	E / H / J	0,002042
A3	Árvore de Regressão	E / H	0,001456
A4	Árvore de Regressão	D	0,001121

Fonte: Autor (2023).

Tabela 7 - Resultados obtidos após simulações na floresta aleatória

AJUSTE	ALGORÍTMO	CONDIÇÃO	MAE (mm)
A1	Floresta Aleatória	A	0,001312
A2	Floresta Aleatória	C	0,002011
A3	Floresta Aleatória	A	0,001226
A4	Floresta Aleatória	E	0,001186

Fonte: Autor (2023).

De posse dos resultados obtidos, através da etapa de simulação que culminou na definição das variáveis e parâmetros ótimos para cada modelo preditivos relativo a cada ajuste de dimensão crítica, foi gerado o modelo gráfico de árvore de regressão para melhoria da compreensão e interpretação dos resultados pelos operadores. As Figuras 12, 13, 14 e 15 demonstram o modelo gráfico para cada variável de ajuste.

Figura 12 - Modelo gráfico para A1

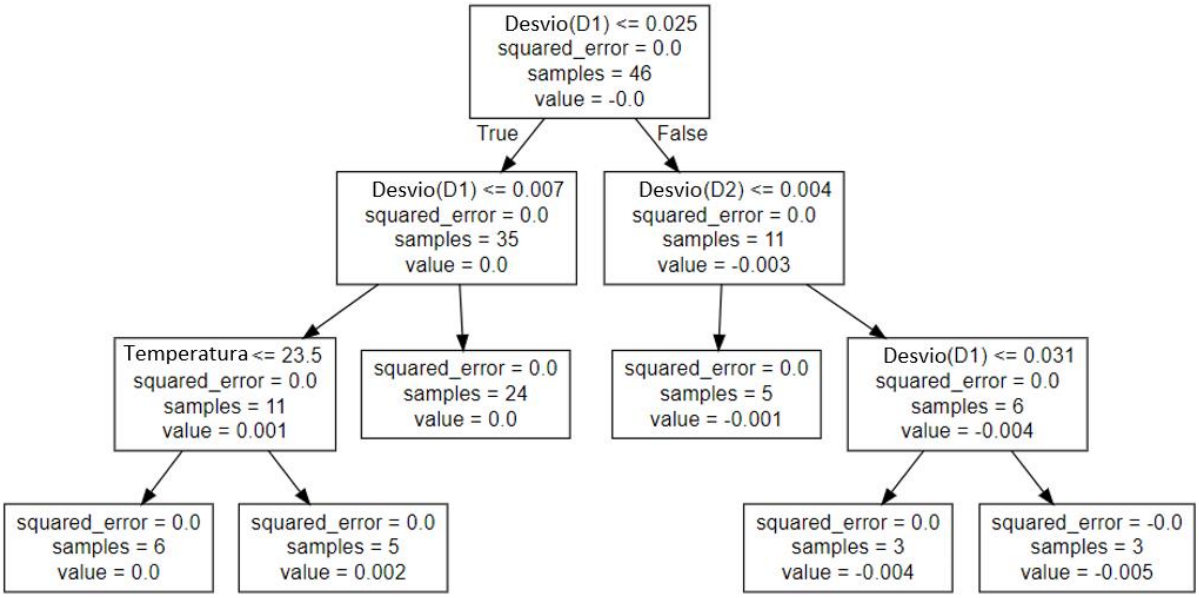

Fonte: Autor (2023).

Figura 13 - Modelo gráfico para A2

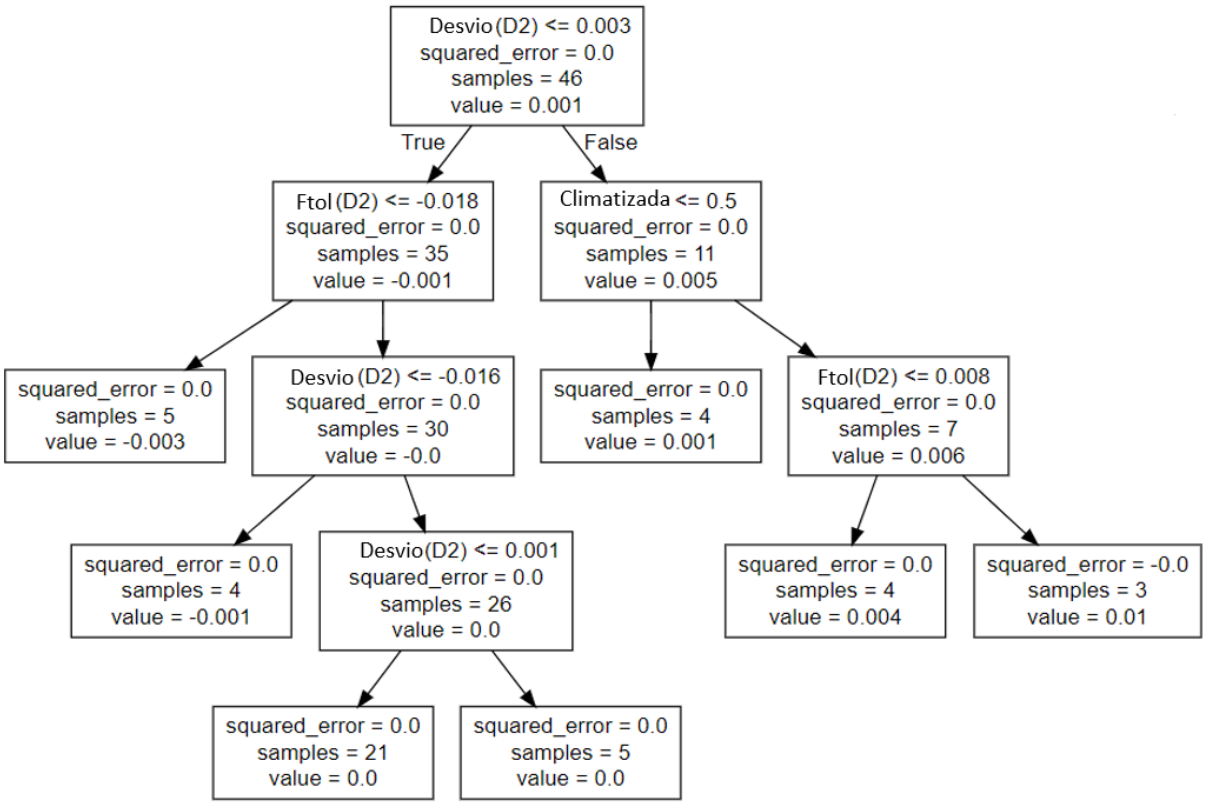

Fonte: Autor (2023).

Figura 14 - Modelo gráfico para A3

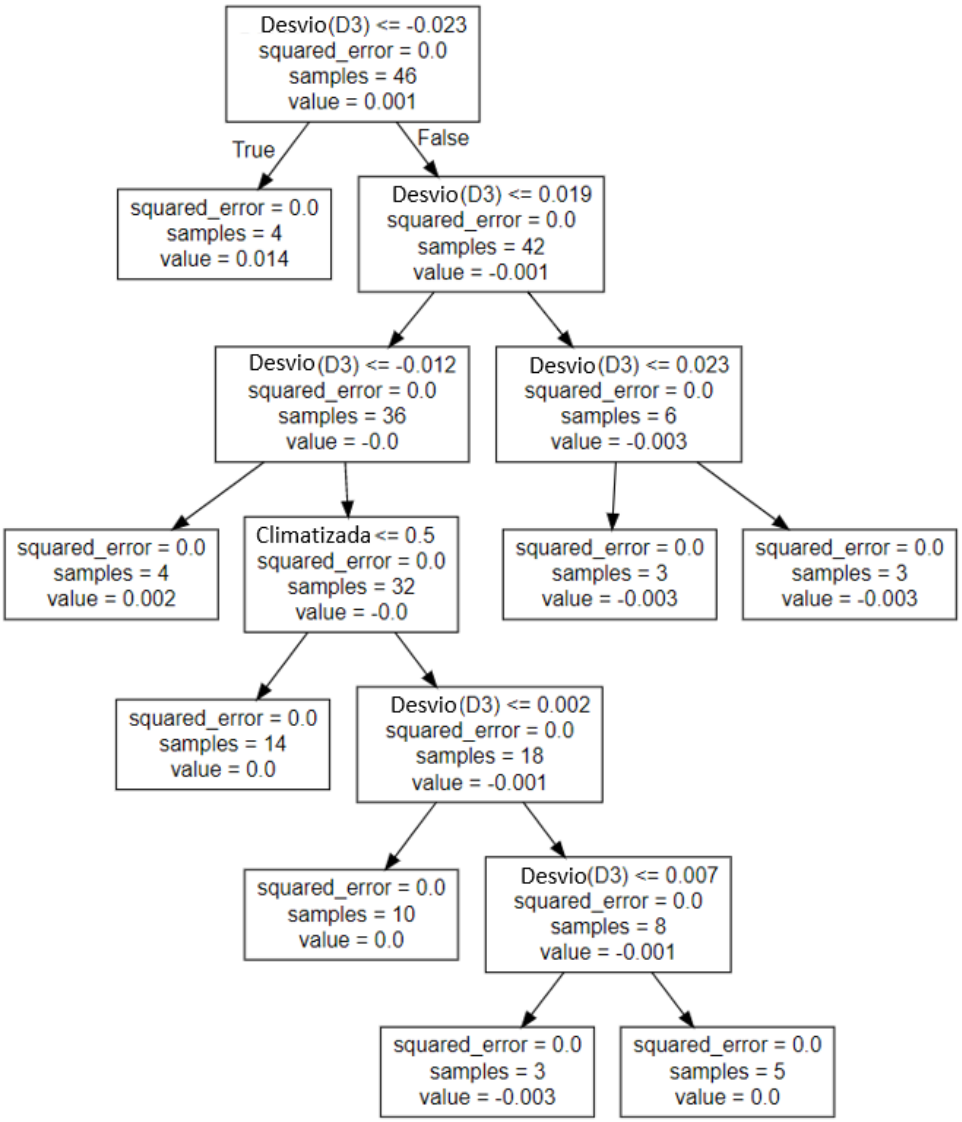

Fonte: Autor (2023).

Figura 15 - Modelo gráfico para A4

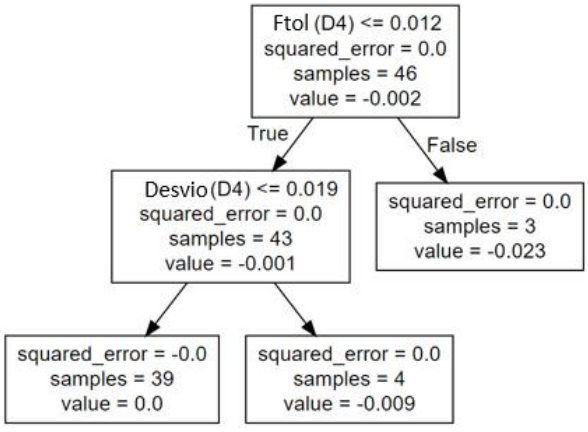

Fonte: Autor (2023).

4.1.6 Avaliação do modelo em ambiente industrial

Para a realização da etapa de teste foi selecionado um lote de 12 peças composto por 6 metades superiores e 6 metades inferiores. O teste decorreu em dois turnos de trabalhos, com 2 operadores de MMC e 2 operadores de HMC. Um documento impresso contendo os modelos gráficos de árvore de decisão e orientações de utilização foram entregues aos 4 profissionais a fim de norteá-los para a correta utilização do modelo. Os profissionais foram orientados, prioritariamente, a utilizarem a decisão do modelo, exceto quando identificassem que a ação poderia ocasionar peça não conforme. Todas as peças experimentaram a mesma condição de teste: (i) usinagem em um HMC tipo MCH 350 com comando Siemens Sinumerik 840D SL, ano de fabricação 2015, fabricada pela Heller Máquinas Operatrizes; (ii) medição em uma MMC modelo Global S Blue 12.22.10, capacidade em X=1200 mm, Y=2200 mm e Z=1000 mm, ano de fabricação 2018, fabricada pelo grupo Hexagon Manufacturing Intelligence, juntamente ao software PCDMIS para avaliação e emissão dos relatórios dimensionais. As Figuras 16 e 17 demonstram respectivamente as máquinas MCH 350 e Global S Blue 12.22.10.

Figura 16 - MCH 350

Fonte: Autor (2023).

Figura 17 - Global S Blue 12.22.10

Fonte: Autor (2023).

Antes de iniciar a usinagem, objeto deste projeto, as peças foram submetidas a processos preliminares que, além de serem requisitos do produto, garantem a perfeita fixação da peça no dispositivo que é preso no palete do HMC, e auxiliam na correta definição da localização do PZP. São eles: (i) jateamento; (ii) pintura; (iii) usinagem preliminar. A sequência de usinagem decorreu como segue: (i) a primeira metade superior foi fixada no HMC e teve seu ciclo de usinagem realizado a qual todas as operações referentes as dimensões críticas foram executadas, apresentado na Seção 4.1.1. Destaca-se que um ciclo de usinagem de uma peça divide-se em: (i) colocação da peça de trabalho; (ii) usinagem da peça de trabalho; (iii) retirada da peça de trabalho. Na Figura 18 são demonstradas as posições de usinagem das dimensões críticas da metade superior.

Figura 18 - Posições de usinagem das dimensões críticas da metade superior. (a) D1. (b) D2. (c) D3. (d) D4

(a) 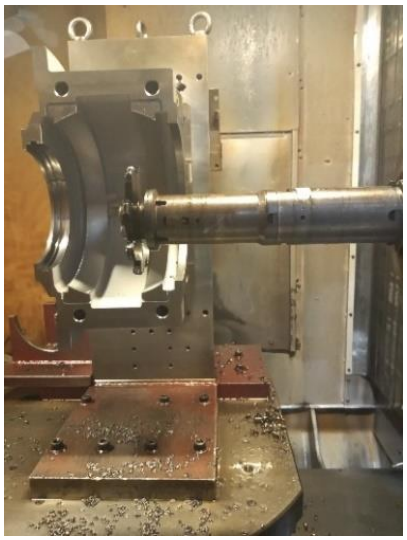

(b)

(c)

(d)

Fonte: Autor (2023).

O HMC é equipado com dois paletes, cada um deles com um dispositivo de fixação, que pode receber uma ou mais peças de trabalho. Enquanto um dos paletes estiver na área de trabalho onde está sendo usinada uma peça, o outro fica na estação de carga de peças, podendo ser carregado com a próxima peça de trabalho a usinar. Durante a usinagem da primeira metade superior, o operador colocou a segunda peça, metade inferior, na estação de carga e fixou-a com o dispositivo, em seguida fechou a porta de proteção e quitou o processo no painel principal de operação. Desta forma a segunda peça ficou preparada para a troca automática com a peça de trabalho usinada.

A usinagem foi processada automaticamente de acordo com o programa CNC relativo às características da peça. As metades superior e inferior não usinadas são demonstradas na Figura 19(a). As metades superior e inferior usinadas na Figura 19(b).

Figura 19 - Metades superior e inferior da carcaça. (a) Não usinadas (b) Usinadas

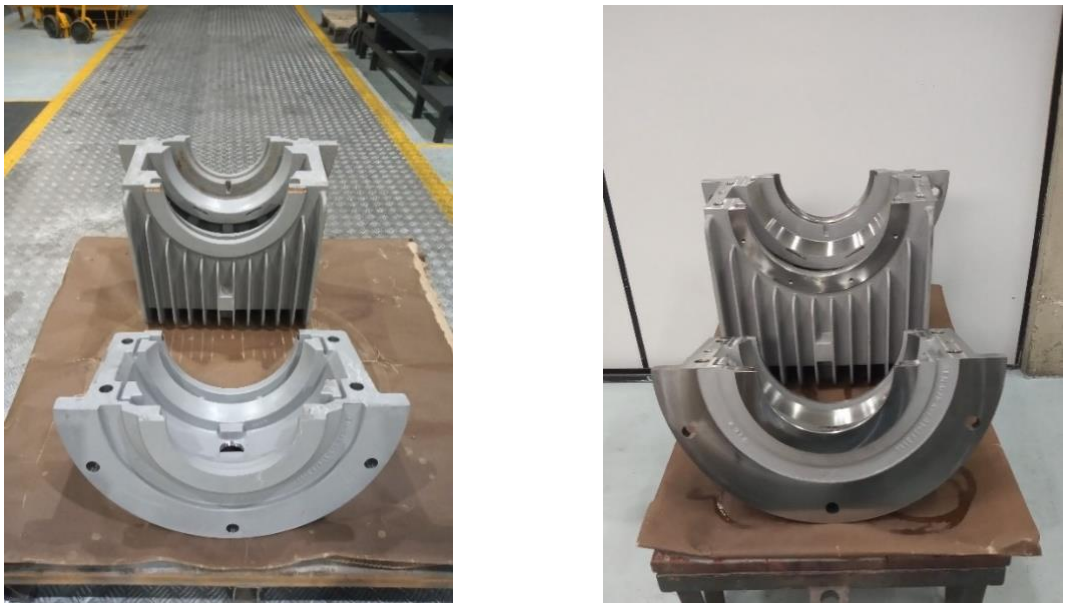

(a) (b)

Fonte: Autor (2023).

O ciclo de usinagem foi baseado no sistema de coordenadas formado por todos os eixos existentes no HMC, como descrito na seção 2.1.2.1. Os deslocamentos dos eixos da MCH 350 estão demonstrados a seguir:

a) deslocamentos lineares dos eixos: a mesa giratória desloca-se no eixo Z saindo da posição de troca, levando a peça a ser usinada para a posição de trabalho. A unidade que suporta a ferramenta fica em posição horizontal, ela executa o movimento axial no sentido eixo Y e mediante a coluna da máquina, em sentido eixo X. A mesa giratória executa o movimento Z;
b) deslocamentos giratórios para usinagem circular e de lados múltiplos: a mesa giratória, eixo rotativo B, como indicado pelo nome, é rotativa e a peça de trabalho pode ser usinada em toda a sua periferia.

Após a usinagem da metade superior, foi realizado a troca de paletes. O palete com a segunda peça, peça não usinada, foi colocado na área de trabalho sobre uma mesa giratória a qual foi fixado. Após a troca de paletes, a metade superior, peça

usinada, ficou locada na estação de carga. Em seguida, o operador deu início ao ciclo de usinagem da segunda peça e se dirigiu à estação de carga onde condicionou a peça usinada para o processo de medição mediante a retirada de quinas vivas e limpeza.

A MMC GLOBAL S é uma máquina de medição com eixos cartesianos, uma arquitetura de pórtico e um eixo Z vertical. O sistema de referência da máquina de medição consiste em três eixos cartesianos, X, Y e Z. A mesa de trabalho é um único bloco de granito, que funciona tanto como mesa de trabalho, quanto como suporte para as partes móveis da máquina. A peça a ser medida e qualquer equipamento de fixação necessário são colocados na mesa de trabalho. O carro principal, ou pórtico da MMC, representa o eixo Y e desloca-se ao longo da mesa de trabalho. O carro central representa o eixo X e desloca-se ao longo do carro principal. O eixo Z desloca-se verticalmente dentro do carro central. Os três eixos da máquina se movem independentemente um do outro, permitindo assim que o sensor de contado se mova livremente em qualquer direção dentro do volume de medição. As metades superior e inferior da carcaça em posição de medição na mesa da MMC são demonstradas na Figura 20.

Figura 20 - Metades superior e inferior da carcaça em posição de medição

Fonte: Autor (2023).

Os dispositivos de apoio a peça, que permitem fixar a peça na posição de medição, foram preparados e fixados na mesa de trabalho pelo operador da MMC. A peça foi colocada na mesa de trabalho de granito sobre os dispositivos. O operador realizou o processo de referência da peça na máquina, o qual tem a função de mapear a posição da peça dentro do volume de medição, por intermédio do apalpador HP-S-X1H. A medição foi processada automaticamente de acordo com o programa de medição e o sensor de contato moveu automaticamente de acordo com o ciclo programado. A medição realizada foi do tipo ponto a ponto. O sensor de contato recolheu os pontos na peça e forneceu os dados para uma avaliação precisa dos recursos da peça, incluindo a localização, forma e tamanho.

Encerrado o ciclo de medição da máquina foi gerado o relatório dimensional da peça. Em seguida, o relatório foi analisado pelo operador da MMC o qual realizou anotações de sugestões para ajuste do programa CNC. Posteriormente, o operador do HMC recebeu o relatório impresso do operador da MMC e iniciou a etapa de análise e avaliação para a tomada de decisão dos ajustes no programa CNC. Pondera-se que o ciclo de usinagem da segunda peça havia se encerrado antes do recebimento do relatório de medição o que gerou parada na produção.

A etapa de análise do relatório e tomada de decisão foi realizada priorizando a utilização do modelo de predição, exceto se identificado que a ação poderia ocasionar peça não conforme. Inicialmente foram coletadas as informações relativas as variáveis independentes, contidas na matriz de relacionamento visto na Seção 4.1.2. Em seguida, as informações foram aplicadas aos modelos gráficos de árvore de decisão e identificado o valor resposta do modelo. Após, o operador do HMC analisou os dados das variáveis independentes da peça a fim de decidir se o valor resposta fornecido pelo modelo poderia ou não ser aplicado para a realização do ajuste real. Na Tabela 7 estão contidos os valores das variáveis independentes paras as 12 peças do lote. Nas tabelas 8 e 9 estão contidos os resultados do teste para as peças 1 a 6 e 7 a 12 respectivamente.

Tabela 8 - Variáveis independentes do teste

PEÇA	METADE	VARIÁVEL INDEPENDENTE	
1	Superior	Temperatura (°C)	30,1
		Climatizada	Sim
2	Inferior	Temperatura (°C)	30,5
		Climatizada	Não
3	Superior	Temperatura (°C)	25,5
		Climatizada	Não
4	Inferior	Temperatura (°C)	24,2
		Climatizada	Não
5	Superior	Temperatura (°C)	24,3
		Climatizada	Não
6	Inferior	Temperatura (°C)	27,4
		Climatizada	Não
7	Superior	Temperatura (°C)	27,2
		Climatizada	Sim
8	Inferior	Temperatura (°C)	23,1
		Climatizada	Sim
9	Superior	Temperatura (°C)	22,6
		Climatizada	Não
10	Inferior	Temperatura (°C)	25,7
		Climatizada	Sim
11	Superior	Temperatura (°C)	26,9
		Climatizada	Sim
12	Inferior	Temperatura (°C)	24,0
		Climatizada	Sim

Fonte: Autor (2023).

Tabela 9 - Resultado do teste: peças 1 a 6

PEÇA	DIMENSÃO CRÍTICA	DESVIO (mm)	FORA DE TOLERÂNCIA (mm)	AJUSTE MODELO (mm)	AJUSTE REAL (mm)
1	D1	0,008	0,000	0,000	0,000
	D2	0,016	0,016	0,010	0,010
	D3	0,002	0,000	0,000	0,000
	D4	0,060	0,000	0,000	0,000
2	D1	0,002	0,000	0,002	0,002
	D2	-0,007	-0,007	0,000	0,000
	D3	0,002	0,000	0,000	0,000
	D4	-0,013	0,000	0,000	0,000
3	D1	0,009	0,000	0,000	0,000
	D2	-0,021	-0,021	-0,003	-0,003
	D3	0,026	0,006	-0,003	-0,010
	D4	0,010	0,000	0,000	0,000
4	D1	0,014	0,000	0,000	0,000
	D2	-0,009	-0,009	0,000	0,000
	D3	0,007	0,000	0,000	0,000
	D4	0,035	0,015	-0,023	-0,010
5	D1	0,021	0,000	0,000	0,000
	D2	-0,006	-0,006	0,000	0,000
	D3	-0,003	0,000	0,000	0,000
	D4	0,024	0,004	-0,009	-0,009
6	D1	0,026	0,000	-0,001	-0,001
	D2	-0,005	-0,005	0,000	0,000
	D3	0,006	0,000	0,000	0,000
	D4	0,000	0,000	0,000	0,000

Fonte: Autor (2023).

Tabela 10 - Resultado do teste: peças 7 a 12

PEÇA	DIMENSÃO CRÍTICA	DESVIO (mm)	FORA DE TOLERÂNCIA (mm)	AJUSTE MODELO (mm)	AJUSTE REAL (mm)
7	D1	0,021	0,000	0,000	0,000
	D2	-0,002	-0,002	0,000	0,000
	D3	0,008	0,000	0,000	0,000
	D4	0,004	0,000	0,000	0,000
8	D1	0,008	0,000	0,000	0,000
	D2	-0,012	-0,012	0,000	0,000
	D3	-0,005	0,000	0,000	0,000
	D4	0,012	0,000	0,000	0,000
9	D1	0,022	0,000	0,000	0,000
	D2	0,005	0,005	0,001	0,001
	D3	0,003	0,000	0,000	0,000
	D4	0,003	0,000	0,000	0,000
10	D1	0,015	0,000	0,000	0,000
	D2	0,006	0,006	0,004	0,004
	D3	0,010	0,000	0,000	0,000
	D4	-0,005	0,000	0,000	0,000
11	D1	0,019	0,000	0,000	0,000
	D2	0,013	0,013	0,010	0,010
	D3	0,017	0,000	0,000	0,000
	D4	0,021	0,001	-0,009	-0,009
12	D1	0,010	0,000	0,000	0,000
	D2	-0,014	-0,014	0,000	0,000
	D3	0,019	0,000	0,000	0,000
	D4	-0,003	0,000	0,000	0,000

Fonte: Autor (2023).

Verificou-se que em dois momentos o operador realizou o ajuste real diferente do sugerido pelo modelo: (i) na dimensão crítica D3 da peça 3; (ii) na dimensão crítica D4 da peça 4. Diante disso, foi realizado um trabalho investigativo para definir a causa do problema, no qual identificou-se que na usinagem das peças 3, 4 e 5 foram utilizadas pastilhas de corte reaproveitadas para as operações D3 e D4. Este evento ocorreu devido a um atraso no fornecimento de pastilhas novas. Portanto, a causa do problema foi definida como evento aleatório, condição fora do escopo do modelo preditivo desenvolvido.

5 CONCLUSÃO

Neste capítulo é apresentado as considerações finais capazes de sintetizar os principais temas abordados no trabalho, refletir sobre os resultados alcançados, limitações, obtenção das respostas das questões de pesquisa, hipóteses, objetivos propostos, direcionamento para pesquisas futuras e contribuições para as comunidades acadêmica e industrial.

5.1 Epílogo

Elaborou-se um modelo de predição baseado em árvore de decisão para controle dimensional no processo de fabricação de carcaças de mancais de deslizamento flangeados, conforme a norma técnica DIN 31693. Foi utilizado a holística para monitorar a geometria da superfície da peça usinada, modelar o erro sistemático e compensar o desvio total independentemente de sua origem. Empregou-se a heurística como método para definir todas as variáveis que envolvem a tomada de decisão para compensação dos desvios dimensionais. O modo de implementação baseou-se na interação entre a experiência humana e a máquina, o qual utilizou-se a carga cognitiva de 10 profissionais com mais de 15 anos de experiência nesse tipo de tomada de decisão.

O CRISP-DM foi aplicado para a implementação do modelo preditivo que lidou com as etapas de contextualização e definição do problema, definição e pré-processamento dos dados, definição do algoritmo, validação e teste. A definição do algoritmo foi pautada na característica de interpretabilidade e de ser autoexplicativo devido o contexto de intensa interação da experiência humana com relação a máquina e ao processo existente, logo, a árvore de decisão foi selecionada. O problema foi caracterizado como de regressão, então, o método de regressão foi utilizado com objetivo de prever um valor numérico específico. Utilizou-se 2 métricas para a validação do modelo: (i) MAE menor ou igual a 0,003mm, premissa definida na fase de contextualização e definição do problema; (ii) verificação do desempenho entre diferentes modelos preditivos através da comparação com o modelo de floresta aleatória. A fase de teste foi realizada através da fabricação de um lote com 12 peças que gerou 48 definições de parâmetros que foram submetidos ao modelo preditivo.

5.2 Contribuições e Resultados

Os resultados mostram que a técnica de aprendizado de máquina baseada em árvores de decisão por regressão é eficaz para o controle dimensional de carcaças de mancais de deslizamento, conforme norma DIN 31693. Além disso, os modelos desenvolvidos para as dimensões críticas D1, D2, D3 e D4 resultaram nos ajustes A1, A2, A3 e A4, com MAE máximo de 2,042µm, ou seja, valor abaixo da métrica de validação definida para o projeto de MAE menor que 3 µm.

A estratégia de avaliação de desempenho entre o algoritmo de árvore de decisão por regressão e a floresta aleatória mostrou-se adequada para o propósito comparativo. Verificou-se que ambos os resultados se enquadraram na métrica de validação do projeto. O algoritmo de floresta aleatória apresentou resultados ligeiramente melhores para as dimensões críticas D1, D2 e D3 e ligeiramente pior para a D4. Como a facilidade de compreensão e interpretação dos resultados das predições foram definidos como requisitos mandatórios para a estratégia de implantação do modelo de aprendizado de máquina, a utilização do algoritmo de floresta aleatória é inviável devido à sua natureza aleatória, nem sempre intuitiva e compreensível para o usuário.

A variável independente Desvio foi definida como representativa para todos os quatro modelos treinados. O modelo de D1 foi complementado com as variáveis independentes desvio(D2) e temperatura. A interrelação entre as dimensões D1 e D2 confirma a análise de causa e efeito realizada, utilizando do conhecimento e experiência dos profissionais qualificados, como base para criar a matriz de relacionamento entre as variáveis dependentes e independentes, visto na Seção 4.1.2. A variável temperatura tem grande influência na deformação do esférico, o que justifica sua seleção pelo modelo. O modelo de D2 apresentou, além do desvio (D2), as variáveis climatização e fora de tolerância (D2). O modelo de D3 apresentou além do desvio (D3), a variável climatização. Portanto, climatizar a peça antes da medição na MMC é relevante paras as dimensões críticas D2 e D3. O modelo D4 foi composto pelas variáveis desvio (D4) e fora de tolerância (D4). Portanto podemos afirmar que o modelo de D4 é exclusivamente geométrico.

Na fase de testes do modelo proposto, um lote com 12 peças foi fabricado e 48 definições de parâmetros foram submetidas ao modelo preditivo. Cada ajuste do

programa CNC foi realizado priorizando o valor resultante do modelo, o qual teve seu resultado aplicado em 46 ocorrências. As exceções ocorreram apenas duas vezes, quando os operadores do HMC identificaram que a ação poderia ocasionar peça não conforme: (i) na dimensão crítica D3 da peça 3; (ii) na dimensão crítica D4 da peça 4.

Um trabalho investigativo demonstrou que esses eventos decorreram por motivo de utilização da ferramenta fresa, para usinagem das dimensões D3 e D4, em condições de desgaste excessivo devido ao atraso na entrega de pastilhas novas pelo fornecedor. As peças 3, 4 e 5 foram usinadas com a ferramenta fresa com desgaste excessivo nas pastilhas. Portanto, foi evidenciado que o modelo resultou em ajustes adequados para dez peças do lote e que as duas exceções foram causadas por uma componente aleatória vinculada a ferramenta. Portanto, foi demonstrado que uma condição não homologada do processo conduziu a resultados incertos pelo modelo. Por conseguinte, constata-se que aplicação do modelo é conveniente para as condições homologadas do processo.

Durante a execução da fase de teste foi medido o tempo despendido para conclusão das etapas de geração do relatório dimensional, análise e tomada de decisão. Este levantamento quantitativo revelou que a utilização do modelo preditivo, para automatizar tais etapas, é capaz de reduzir em até 32% o tempo total de execução do processo de controle dimensional de carcaças. A constatação que o modelo preditivo resultou em ajustes adequados para as condições homologadas do processo sugere que o uso do modelo de predição é capaz de gerar os efeitos de redução de custo com a diminuição de carcaças não conformes e horas de retrabalho.

Com base nos resultados experimentais, as respostas as questões de pesquisa foram definidas: (i) a estratégia de compensação é baseada em uma abordagem holística, onde os efeitos de todas as fontes de erros sistemáticos são compensados independentemente de sua origem; (ii) o critério para definir todas as variáveis que envolvem a tomada de decisão para compensação dos desvios dimensionais de carcaças de mancais de deslizamento produzidas por processos de usinagem é baseado em uma abordagem heurística; (iii) a utilização do CRISP-DM como método para implementação do modelo preditivo é eficaz; (iv) a redução da interação cognitiva humana nos processos de fabricação de carcaças de mancais de deslizamento é obtida com o uso de um modelo de predição baseado em árvore de decisão.

Considerando as respostas obtidas das questões de pesquisa, a hipótese que a aplicação de técnicas de aprendizado de máquina reduz a interação cognitiva humana nos processos de fabricação de carcaças de mancais de deslizamento é validada. Os objetivos do projeto: (i) automatizar a etapa de análise dos relatórios dimensionais; (ii) sugerir parâmetros de ajuste para obter carcaças adequadas em relação às suas dimensões críticas; (iii) apoiar a tomada de decisão que resulta em correções no deslocamento dos eixos do centro de usinagem; foram alcançados. Por tanto, o desenvolvimento experimental realizado colabora para a melhoria do processo existente.

Como resultado adicional, o trabalho desenvolvido gerou um artigo que foi submetido ao periódico *International Journal of Advanced Manufacturing Technology* (JAMT), com o título *Decision tree predictive model for dimensional control of side flange bearing housings*, com o código JAMT-D-23-01096. O artigo recebeu retorno do editor, que menciona que este poderá ser considerado para publicação caso incorpore as revisões sugeridas pelos avaliadores.

5.3 Trabalhos Futuros

Os resultados obtidos na fase de teste do modelo preditivo, baseado em árvore de decisão por regressão, para controle dimensional de carcaças de mancais de deslizamento flangeados através de uma abordagem holística e heurística, utilizando o método CRISP-DM, empregando o módulo *python* de aprendizado de máquina de código aberto *scikit-learn*, confirma a possibilidade de implementar a metodologia na linha de produção e colabora para avanços futuros no desenvolvimento de um software dedicado para controle em tempo real.

A abordagem holística aplicada no desenvolvimento do modelo busca a abrangência que pode ocasionar a não identificação e possível convivência com os problemas existentes nas condições da máquina e do processo. A heurística é conveniente para reduzir as muitas questões diferentes para facilitar a resolução de problemas. No entanto, pode levar a respostas imperfeitas a perguntas difíceis e complexas. A árvore de decisão é um modelo facilmente interpretável. No entanto, é extremamente dependente dos dados de treinamento. Uma pequena mudança pode modificar toda a árvore.

Em resumo, outros trabalhos podem ser desenvolvidos futuramente conforme apresentado a seguir:

a) desenvolvimento de um software dedicado para controle em tempo real;
b) desenvolvimento de abordagens que potencializam o método holístico: além de compensar, podem reduzir o erro sistemático;
c) realização de estudos que examinem a ponderação da carga cognitiva empregada;
d) desenvolvimento de abordagens para garantir a estabilidade da árvore de decisão a partir da inserção de novos dados;
e) realização de estudos quantitativos para avaliar os efeitos do aumento de produtividade e redução de custos;
f) validação do modelo preditivo para controle dimensional de peças fabricadas por outros processos de usinagem como: (i) retificação; (ii) torneamento;
g) validação do modelo preditivo para controle dimensional de peças com diferentes tipos de materiais, fabricadas por processo de usinagem, tais como: (i) metálicos não ferrosos; (ii) não metálicos orgânicos; (iii) não metálicos inorgânicos.

REFERÊNCIAS

AGGOGERI, F.; PELLEGRINI, N.; TAGLIANI, F. L. Recent advances on machine learning applications in machining processes. **Applied Sciences**, Brescia, v. 11, n. 18, p. 8764, set. 2021.

AGOSTINHO, O. L. **Engenharia de fabricação mecânica**. 1. ed. Rio de Janeiro: Elsevier, 2018.

AGOSTINHO, O. L.; RODRIGUES, A. C. S.; LIRANI, J. **Tolerâncias, ajustes, desvios e análise de dimensões**: Princípios de engenharia de fabricação mecânica. 2. ed. São Paulo: Blucher, 2020.

AGRAWAL, A.; GANS, J.; GOLDFARB, A. **Prediction machines**: The simple economics of artificial intelligence. 1. ed. Boston: Harvard Business Review Press, 2018.

ARAÚJO, A.C.; MOUGO, A. L.; CAMPOS, F. O. **Usinagem para engenharia: um curso de mecânica do corte**. 1. ed. Rio de Janeiro: E-papers, 2020.

BRAZDIL, P.; RIJN, J. N.; VANSCHOREN, J.; SOARES, C. M. **Metalearning: applications to automated machine learning and data mining**. 2. ed. Cham: Springer Nature, 2022.

BULUTSUZ, A. G.; YETILMEZSOY, K.; DURAKBASA, N. Application of fuzzy logic methodology for predicting dynamic measurement errors related to process parameters of coordinate measuring machines. **Journal of Intelligent & Fuzzy Systems**, Istambul, v. 29, n. 4, p. 1619-1633, out. 2015.

CHAUDHARI, C.P; THAKARE, B; PATIL, S; GUNJAL, グ; SHRIKANT, ス. A study of bearing and its types. **International journal of advance research in science and engineering**, Nashik, v. 4, p. 1674-1681, mar. 2015.

CHEIN, F. **Introdução aos modelos de regressão linear**. 1. ed. Brasília: ENAP, 2019.

CHMURZYNSKI, G. **O que são projetos de pesquisa, desenvolvimento e inovação (PD&I)?**. Brasília: Agência de Notícias da Indústria, 17 nov. 2022. Disponível em: https://noticias.portaldaindustria.com.br/noticias/inovacao-e-tecnologia/o-que-sao-projetos-de-pesquisa-desenvolvimento-e-inovacao-pdi/. Acesso em: 27 nov. 2022.

CLARK, A. The machine learning audit-CRISP-DM Framework. **Isaca Journal**, Washington DC, v. 1, p. 42-47, jan. 2018.

DEUSTCHES INSTITUT FÜR NURMING DIN 31693: Pedestal plain bearings; side flange bearing. Berlin, 1990.

DMG MORI. **CNC and NC - history and importance of (computer) numerical controls**. Bielefeld: DMG MORI, 20 jun. 2022. Disponível em: https://br.dmgmori.com/news-and-media/blog-and-stories/blog/cnc-and-nc. Acesso em: 13 ago. 2022.

DMG MORI. **The machine tool as the mother of all machines**. Bielefeld: DMG MORI, 29 nov. 2021. Disponível em: https://br.dmgmori.com/news-and-media/blog-and-stories/blog/the-machine-tool-as-the-mother-of-all-machines. Acesso em: 13 ago. 2022.

DOMÍNGUEZ, J.; ESTEBAN, A.; ROMEO, J. A.; CEBRIÁN, F; DOMINGO, S; AGUILAR, J. J. Development of machine Learning prediction models for their integration in a digital twin for a tapered roller bearing production line. **IOP conference series: materials science and engineering**, Gijón, v. 1193, p. 1-10, out. 2021.

ELYASSAMI, Y.; BENJELLOUN, K.; AROUSSI, M. Sleeve bearing fault diagnosis and classification. **WSEAS transactions on signal processing**, Rabat, v. 12, p. 163-170, dez. 2016.

FITZPATRICK, M. **Introdução a usinagem com CNC**. 2. ed. rev. Porto Alegre: AMGH, 2013.

FRYE, M.; SCHMITT, H. Quality improvement of milling processes using machine learning-algorithms. **IMEKO - International Measurement Confederation**, Berlin, n. 16, p. 142-147, set. 2019.

GERÓN, A. **Hands-on machine learning with Scikit-Learn, Keras, and Tensorflow**: concepts, tools, and techniques to build intelligent systems. 2. ed. atual. Sebastopol: O'Reilly Media, 2019.

GEVORKYAN, E. S.; RUCKI, M.; NERUBATSKYI, V.P.; ŻUROWSKI, W.; SIEMIĄTKOWSKI, Z.; MOROZOW, D.; KHARATYAN, A.G. **Remanufacturing and advanced machining processes for new materials and components:** remanufacturing and advanced machining processes. 1. ed. Boca Raton: Taylor & Francis, 2022.

HARRISON, M. **Machine learning pocket reference**: working with structured data in Python. 1. ed. Sebastopol: O'Reilly Media, 2019.

HEXAGON MANUFACTURING INTELLIGENCE. **Global S**: User manual. Grugliasco: Hexagon, 2018.

IZBICKI, R.; SANTOS, T. **Aprendizado de máquina:** uma abordagem estatística. 1. ed. São Carlos: UICLAP, 2020.

JESUS, A. R.; MARTINS, P. R. Metrologia aplicada à produção industrial: mensurando medições em usinagem de peças. **Brazilian Journal of Development**, Curitiba, v. 7, n. 1, p. 8246-8263, jan. 2021.

JÚNIOR, M. A. O.; SILVA, S. D. **Programação e operação de centro de usinagem**. 1. ed. São Paulo: SENAI-SP, 2016.

KRAUß, J.; FRYE, M.; BECK, G.T.D.; SCHMITT, R.H. Selection and application of machine learning - algorithms in production quality. **Machine Learning for Cyber Physical Systems**, Berlin, v. 9, p. 46-57, dez. 2019.

KIM, D.; KIM, T. J. Y.; WANG, X; KIM, M.; QUAN, Y. J.; OH, J. W.; MIN, S. H.; KIM, H.; BHANDARI, B.; YANG, I.; AHN, S. H. Smart machining process using machine learning: a review and perspective on machining industry. **International Journal of Precision Engineering and Manufacturing-Green Technology**, Seoul, v. 5, n. 4, p. 555-568, ago. 2018.

LASERMEC (SP). **Metrologia industrial: conheça os benefícios e como implementar**. São Paulo: Lasermec, 29 jun. 2020. Disponível em: https://blog.lasermec.com.br/metrologia-industrial/. Acesso em: 27 ago. 2022.

LI, J.; REN, J.; REN, M.; ZHENG, Y.; LE, X. Neural process enhanced machining error evaluation for coordinate measuring machines. **IEEE transactions on instrumentation and measurement,** Shanghai, v. 71, p. 1-12, jul. 2022.

LOUREIRO, P. A. M. Fresagem: Operações de fresagem. *In*: LOUREIRO, P. A. M. **Otimização da utilização de ferramentas de corte em fresagem CNC**. Orientador: Abílio Manuel Pinho de Jesus. Dissertação (Mestrado Integrado em Engenharia Mecânica) - Universidade do Porto, Porto, 2020. p. 5-6.

MACHADO, A. R.; ABRÃO, A. M.; COELHO, R. T.; SILVA, M. B. **Teoria da usinagem dos materiais**. 3. ed. rev. e atual. São Paulo: Blucher, 2015.

MANJUNATHA, G.; CHITTAPPA, H. Bearing fault classification using statistical features and machine learning approach. **Journal of Mines, Metals and Fuels**, Bengaluru, v. 70, n. 4, p. 104-107, mar. 2022.

MARINESCU, V.; CONSTANTIN, I.; APOSTU, C.; MARIN, F. B.; BANU, M.; EPUREANU, A. Adaptive dimensional control based on in-cycle geometry monitoring and programming for CNC turning center. **The International Journal of Advanced Manufacturing Technology**, Galati, v. 55, p. 1079-1097, fev. 2011.

MATTEI, M.; MILANEZ, A. Análise dos erros geométricos e dimensionais na usinagem de peças com geometria complexa utilizando splines na geração dos esboços no cad 3d. **Repositório institucional SATC**, Criciúma, jul. 2020.

MAZAK. **Horizontal**: What is horizontal machining?. Florence: Mazak, 8 mar. 2014. Disponível em: https://www.mazakusa.com/machines/process/horizontal/. Acesso em: 13 ago. 2022.

MELCONIAN, S. **Elementos de máquinas**. 11. ed. rev. São Paulo: Érica, 2019.

MOSCHOPOULOS, M.; ROSSOPOULOS, G.; PAPADOPOULOS, C. Journal bearing performance prediction using machine learning and octave-band signal analysis of sound and vibration measurements. **Polish Maritime Research**, Atenas, v. 28, n. 3, p. 137-149, out. 2021.

MUSSA, A. **Inteligência Artificial - mitos e verdades**: As reais oportunidades de criação de valor nos negócios e os impactos no futuro do trabalho. 1. ed. São Paulo: Saint Paul, 2020.

NETO, J. C. S. **Metrologia e controle dimensional: conceitos, normas e aplicações**. 2. ed. rev. e aum. Rio de Janeiro: Elsevier, 2018.

OLIVEIRA, C. A. L. **Uma metodologia de integração CAD/CAM através da aplicação de ciclos de usinagem na programação CNC**. Orientador: Alexandre Dias da Silva. Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal de Santa Maria, Santa Maria, 2011.

PANTAGE, A. D.; JEGADEESHWARAN, R. A machine learning approach for vibration-based multipoint tool insert health prediction on vertical machining centre (VMC). **Measurement**, Chennai, v. 173, p. 108649, out. 2020.

PILTAN, F.; KIM, J. Bearing anomaly recognition using an intelligent digital twin integrated with machine learning. **Applied Sciences**, Ulsan, v. 11, p. 4602, maio 2021.

RAHMAN, M. M.; MAYER, J.R.R. Measurement accuracy investigation of touch trigger probe with five-axis machine tools. **Polish Academy of Sciences**, Montreal, v. 63, n. 4, p. 495-510, dez. 2016.

RAVAL, M. B.; JOSHI, H. Categorical framework for implementation of industry 4.0 techniques in medium-scale bearing manufacturing industries. **Materials Today: Proceedings**, Ahmedabad, v. 65, n. 8, p. 3531-3537, jun. 2022.

RENISHAW. **Probing systems for CNC machine tools**. Wotton-under-Edge: Renishaw, 2020.

ROCCA, J. E.; ALMEIDA, P. S. Fundamentos técnicos dos processos de usinagem. *In*: ROCCA, J.E.; ALMEIDA, P.S. **Processos de usinagem**. 1. ed. São Paulo: Érica, 2015. cap. 1.

ROKACH, L.; MAIMON, O. Z. **Data mining with decision trees**: theory and applications. 2. ed. rev. e aum. Singapore: World Scientific, 2014.

SANDVIK. **Machining centers**. Sandviken: Sandvik, 19 dez. 2018. Disponível em: https://www.sandvik.coromant.com/en-us/knowledge/machine-tooling-solutions/machines/pages/machining-centres.aspx. Acesso em: 13 ago. 2022.

SANTOS, E. P. **CAD/CAM/Usinagem CNC integrado a engenharia reversa**. Orientador: Ruis Camargo Tokimatsu. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2017.

SARAVANJA, D.; GRBESIC, M. Application of vibration analysis in journal bearing problems diagnostics. **International symposium on intelligent manufacturing and automation**, Viena, n. 30, p. 100-106, out. 2019.

SILVEIRA, E. L. **Princípios heurísticos para uma abordagem holística na criação de sistema produto+serviço sustentável (SPSS)**. Orientador: Aguinaldo dos Santos. Tese Doutorado em Design (Área de Concentração: SPU) - Universidade Federal do Paraná, Curitiba, 2021.

SOUZA, H. C. O. Tecnologia, um auxílio ao ofício de fabricar com precisão. **Máquinas e metais**, São Paulo, ano 58, n. 621, p. 4, Junho/Julho 2022. Disponível em: https://www.arandanet.com.br/revista/mm/edicao/2022/junho. Acesso em: 30 jul. 2022.

SRINIVAS, M. Y.; YUNUS M., MUNSHI, S. M.; HUSSAIN I. H. Performance evaluation of hydrodynamic journal bearing using gearbox and engine oil (SAE90 and SAE20w50) by experimental and theoretical methods. **International journal of mechanical engineering and information technology**, Chik Ballapur, v. 3, ed. 11, p. 1573-1583, nov. 2015.

VERMESAN, O. **Artificial intelligence for digitising industry**: applications. 1. ed. Gistrup: River Publishers, 2021.

VIHAROS, Z. J.; CSANAKI, J.; NACSA, J.; EDELÉNYI, M.; PÉNTEK, C.; BALÁZS, K.; FODOR A.; CSEMPESZ, J. Production trend identification and forecast for shop-floor business intelligence. **IMEKO - International Measurement Confederation**, Milan, n. 14, p. 300-306, jun. 2016.

WĄSIK, M.; KOLKA, W. Machining accuracy improvement by compensation of machine and workpiece deformation. **International Conference on Flexible Automation and Intelligent Manufacturing**, Modena, v. 11, p. 2187-2194, jun. 2017.

WEBSTER, J. G.; EREN, H. **Measurement, instrumentation, and sensors handbook**: Spatial, mechanical, thermal, and radiation measurement. 2. ed. atual. e aum. Boca Raton: CRC Press, 2014.

ZIVIANI, F.; CORRÊA, F.; MUYLDER, C. F. A gestão do conhecimento rumo a uma abordagem holística: indicação de aspectos a serem contemplados em modelos de gerenciamento do conhecimento. **Revista Digital Biblioteconomia e Ciência da Informação**, Campinas, v. 17, p. 1-28, nov. 2018.