



PREVISÃO DE VIBRAÇÕES NO FRESAMENTO UTILIZANDO REDES NEURAIS ARTIFICIAIS

Prediction of vibrations in milling using artificial neural networks

Carlos Henrique Teixeira da Silva¹, Milton Luiz Polli²

RESUMO

Este trabalho envolveu a aplicação de Redes Neurais Artificiais (RNAs) para modelar o comportamento de estabilidade na usinagem, com base em dados gerados a partir do limite de estabilidade analítico, considerando a dinâmica estrutural e o modelo de força. Utilizou-se uma RNA com função de ativação logística binária e função de perda de entropia cruzada. Foram avaliadas diferentes arquiteturas, variando o número de neurônios e a quantidade de épocas de treinamento. Os dados de treinamento e teste foram gerados mediante a aplicação de um algoritmo de estabilidade que considerou parâmetros como rotação do eixo-árvore e largura máxima do cavaco. Os resultados iniciais demonstraram que RNAs treinadas com um conjunto de dados reduzido apresentaram menor acuracidade na previsão do comportamento de estabilidade. A acuracidade variou de acordo com a arquitetura, sendo que modelos mais profundos e estreitos mostraram melhor desempenho. Isso levou à conclusão de que a RNA era capaz de reproduzir de maneira razoável a fronteira de decisão para a estabilidade na usinagem. Entretanto, para pontos próximos aos picos e vales dos lóbulos de estabilidade, as previsões não se mostraram precisas, e tal ima dependeu do número de pontos de treinamento, da arquitetura e da quantidade de épocas de treinamento.

PALAVRAS-CHAVE: fresamento; redes neurais; vibração.

ABSTRACT

This work involved the application of Artificial Neural Networks (ANNs) to model stability behavior in machining based on data generated from the analytical stability limit, considering structural dynamics and force modeling. An ANN with a binary logistic activation function and cross-entropy loss function was employed. Different ANN architectures were evaluated, varying the number of neurons per layer and the number of training epochs. Training and testing data were generated using a stability algorithm that took into account parameters such as spindle speed and maximum chip width. Initial results indicated that ANNs trained with a smaller dataset were less accurate in predicting stability behavior. Accuracy varied with architecture, with deeper and narrower models exhibiting better performance. This led to the conclusion that the ANN reasonably reproduced the decision boundary for machining stability. However, for points near the peaks and valleys of stability lobes, predictions were less accurate and depended on the number of training points, ANN architecture, and the number of training epochs. Overall, the ANN successfully predicted stability behavior after appropriate training.

KEYWORDS: milling; neural network; chatter.

INTRODUÇÃO

No âmbito do setor metal-mecânico, a otimização da produção e a garantia da qualidade das peças usinadas são preocupações essenciais. Uma das questões críticas que afeta a eficiência e a precisão do processo de fresamento é a vibração, que pode acarretar uma série de problemas, incluindo superfícies irregulares, desgaste prematuro da ferramenta e até mesmo danos à máquina. Neste estudo, foi explorado a técnica e a

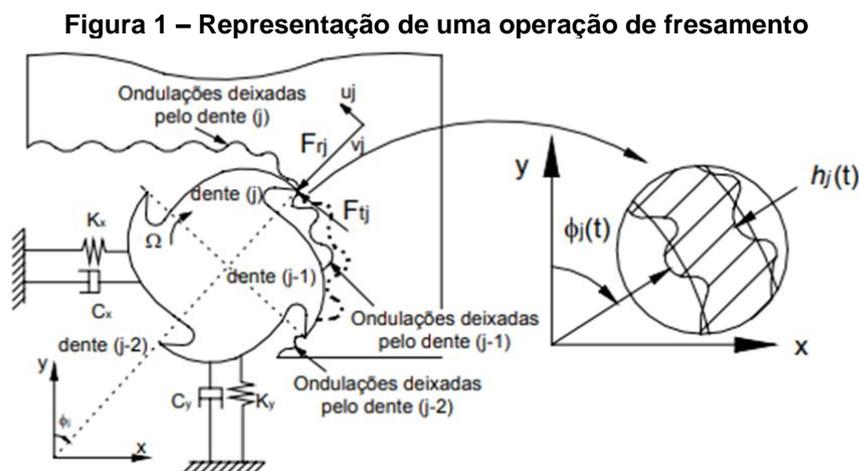
¹ Bolsista do CNPq. Universidade Tecnológica Federal do Paraná, Curitiba, Paraná, Brasil. E-mail: cst.carloshenrique@gmail.com. ID Lattes: 6770866587872454.

² Docente no Curso/Departamento/Programa. Universidade Tecnológica Federal do Paraná, Curitiba, Paraná, Brasil. E-mail: polli@utfpr.edu.br. ID Lattes: 3005966147961108



abordagem utilizadas para prever vibrações durante o processo de fresamento, empregando princípios de inteligência artificial.

O processo de fresamento apresentado na Figura 1 consiste no movimento de uma ferramenta rotativa com arestas de corte definidas, cuja finalidade é a remoção de material, permitindo a obtenção de uma peça com geometrias e dimensões desejadas (STEMMER, 1995). A força de corte variável provoca vibração na ferramenta, resultando em uma superfície ondulada. Isso gera variações no cavaco, o que, por sua vez, produz uma força de corte variável. Dependendo das condições de corte e do alinhamento das ondas, a vibração pode aumentar (corte instável) ou diminuir (corte estável) com as passagens subsequentes dos dentes (ALTINTAS e BUDAK, 1995). O diagrama do lóbulo de estabilidade no fresamento é a representação gráfica de Ω versus b_{lim} , em que Ω (ômega) representa a rotação do eixo-árvore e b_{lim} representa a largura limite do cavaco. Qualquer par (Ω, b_{lim}) que esteja acima do limite indica comportamento instável, enquanto qualquer par abaixo do limite indica comportamento estável (SCHMITZ e SMITH, 2009). A instabilidade resulta em acabamento superficial deteriorado e desgaste de ferramenta (ATSUTA et al, 2023).



Fonte: Analytical prediction of stability lobes in milling (ALTINTAS e BUDAK, 1995).

A abordagem aplicada para a previsão de vibrações segue o modelo de aprendizagem supervisionada, no qual o algoritmo utiliza pares de entrada e saída conhecidos para o treinamento. As Redes Neurais Artificiais (RNA) consistem em um conjunto de unidades básicas denominadas neurônios dispostos em camadas. A primeira camada é a de entrada, as camadas intermediárias são chamadas de ocultas, e a última é a camada de saída (FURTADO, 2019). Na aprendizagem supervisionada, os dados de treinamento (dados de entrada e os dados de saída correspondentes) são usados para treinar o modelo de RNA. O treinamento começa com uma suposição inicial sobre os pesos, e a entrada dos dados é processada pela RNA, prevendo a saída. A partir desse ponto, o erro entre as saídas previstas e as saídas conhecidas é calculado usando uma função de perda (CHERUKURI et al, 2019). Se o erro for propagado da camada de saída até a camada de entrada, a RNA tentará determinar o quanto cada sinapse contribuiu para o erro, e essa informação será usada para ajustá-las (CHAUVIN e RUMELHART, 1995).



A correção dos pesos é efetuada por meio de um ciclo em que os pares entrada-saída do conjunto de treinamento são apresentados no processo, permitindo a aprendizagem. Esse processo é repetido até que o erro seja inferior a um valor pré-selecionado ou até que um número máximo de iterações seja atingido. Quando o treinamento é concluído, o desempenho do modelo é avaliado utilizando dados de teste com saídas conhecidas. Além disso, métodos adicionais de validação cruzada também são empregados para uma avaliação mais precisa do desempenho do modelo. Se as previsões dos dados de teste e as validações cruzadas forem satisfatórias, o modelo de RNA é utilizado para fins preditivos em novos conjuntos de dados de entrada (FURTADO, 2019).

METODOLOGIA

Neste estudo, o conjunto de dados de vibração usado nos treinamentos e testes da rede neural artificial foi obtido a partir de uma simulação utilizando um modelo matemático através do Matlab, considerando o limite de estabilidade analítico, baseado na dinâmica estrutural e no modelo de força. Os parâmetros do modelo matemático considerados foram: $f_n = 500$ Hz, $k = 8 \times 10^3$ N/mm, $K_s = 750$ N/mm² e $\beta = 68$ graus. Os fatores de orientação direcional são $\mu_x = \cos(\beta)$ e $\mu_y = 0$ para fresamento de canais, e a Função de Resposta em Frequência orientada é $FRF_{orient} = \cos(\beta)FRF_x$, e tomando para análise uma liga de alumínio usinada com uma fresa de topo reto de 19 mm de diâmetro, com quatro dentes. Os parâmetros de entrada para a rede neural consistiram na rotação do eixo-árvore e na largura máxima do cavaco. O conjunto de dados foi gerado considerando valores uniformemente distribuídos para os pares (Ω, b_{lim}) no intervalo de 1100 rpm a 5200 rpm e de 0.8 mm a 4.5 mm. Para cada conjunto de valores, o corte foi classificado como estável ou instável (vibração) com base no limite de estabilidade. O número total de pontos no conjunto de treinamento foi variado para avaliar a capacidade preditiva do modelo da RNA. Os conjuntos de treinamento e teste foram primeiramente normalizados utilizando o método de normalização por máximo absoluto, o qual envolve escalar os dados dividindo cada valor pelo valor absoluto máximo no conjunto de dados.

A função de ativação utilizada na rede neural considerada neste trabalho foi a função logística binária, que produz saídas no intervalo de 0 a 1. A função de perda de entropia cruzada foi empregada para calcular o erro. Além disso, com o intuito de investigar ainda mais a sensibilidade do desempenho da rede neural artificial à sua arquitetura, avaliaram-se redes neurais artificiais com diferentes quantidades de neurônios e variados números de épocas. Cada época consiste em um ciclo completo de treinamento, envolvendo a passagem por todos os exemplos de treinamento, o cálculo do erro, a atualização dos pesos e, opcionalmente, a avaliação do desempenho em um conjunto de validação. A quantidade de épocas necessárias para treinar um modelo pode variar consideravelmente e depende da complexidade do problema, do volume de dados disponíveis e da arquitetura da rede neural. Parâmetros de desempenho, como a perda ou a acuracidade, geralmente são monitorados ao longo das épocas para avaliar o progresso do treinamento e determinar quando interromper o treinamento (ou empregar técnicas de parada precoce) para evitar o overfitting (LECUN et al, 1998). O computador utilizado para a simulação do modelo matemático do processo foi um notebook com 8 GB de memória RAM e um processador com 4 núcleos, frequência de 3.6 GHz e turbo de 4 GHz. O algoritmo envolvendo RNA foi implementado e executado em Python utilizando



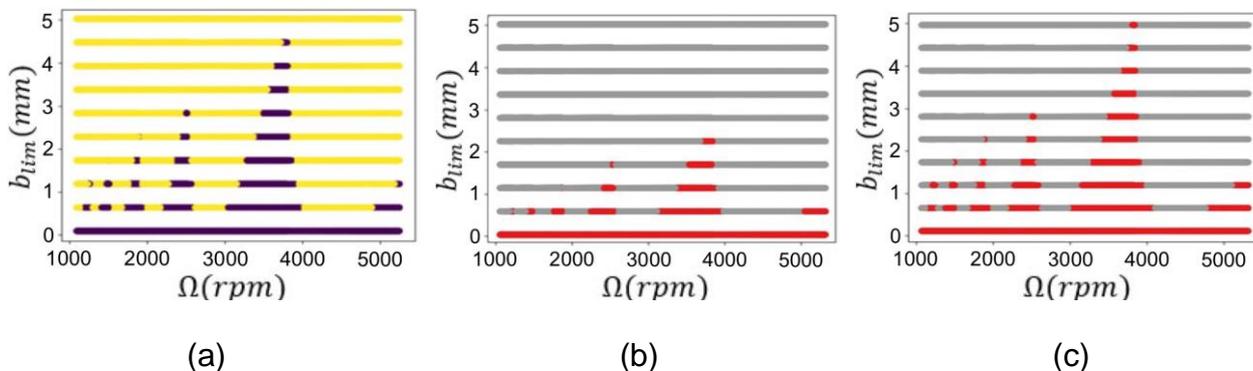
um serviço de nuvem gratuito hospedado pelo Google, o Google Colab, e o código é executado em uma máquina virtual. As principais bibliotecas utilizadas no código foram o *TensorFlow*, *Keras* e *Pandas*. Conforme esperado, o tempo de treinamento aumentou à medida que o tamanho do conjunto de dados e a complexidade da arquitetura da RNA cresceram. Este modelo com duas camadas ocultas demandou entre 45 minutos e duas horas de treinamento.

O propósito do aprendizado de máquina neste estudo é encontrar a fronteira de decisão, que consiste em uma linha, superfície ou limite que separa duas ou mais classes ou categorias distintas em um problema de classificação. Essa fronteira deve se ajustar de forma ideal aos dados de treinamento, de modo que, quando novos pontos de dados forem apresentados ao modelo, ele seja capaz de classificá-los corretamente. A acuracidade da modelagem e das previsões depende da habilidade do modelo em aprender e representar com precisão essa fronteira de decisão.

RESULTADOS

Os resultados representados na Figura 2 correspondem, respectivamente, à fronteira real e às fronteiras de decisão obtidas por meio das previsões dos modelos de RNA treinados com base nesses pontos. O parâmetro utilizado envolve um conjunto de dados composto por 58.300 pontos (Ω, b_{lim}).

Figura 2 – Diagramas de Estabilidade

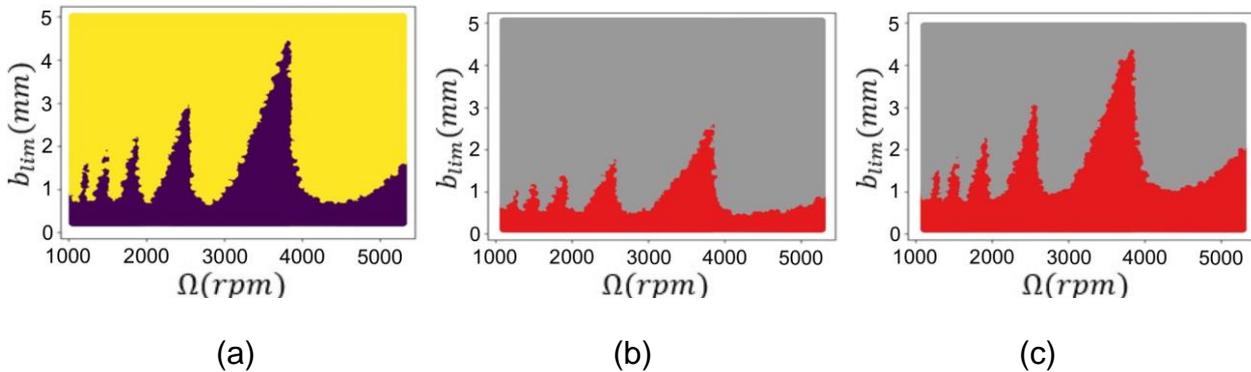


Fonte: Elaborado pelos autores (2023). (a) Fronteira Real; (b) RNA com 128 neurônios por camada; (c) RNA com 8 neurônios por camada.

O primeiro teste foi conduzido com ambas as configurações usando duas camadas ocultas, onde ao analisar a imagem é notória a descontinuidade das curvas de estabilidade devido a diferença na quantidade de pontos Ω e b_{lim} . Na Figura 2(b), foram empregados 128 neurônios em cada camada oculta, com um total de 75 épocas, resultando em uma acuracidade de 90,43%. Por outro lado, na Figura 2(c), foram utilizados 8 neurônios em cada camada oculta, com 70 épocas de treinamento, alcançando uma acuracidade de 97,72%.

O segundo resultado apresentado na Figura 3, foi obtido por meio de um teste que se baseou no mesmo conjunto de dados utilizado no experimento da Figura 2. No entanto, foi realizada uma interpolação adicionando dez pontos entre cada par (Ω, b_{lim}) já existente, totalizando assim 583.000 pontos no conjunto de dados.

Figura 3 - Diagramas de estabilidade



Fonte: Elaborado pelos autores (2023). (a) Fronteira Real; (b) RNA com 128 neurônios por camada; (8) RNA com 6 neurônios por camada.

A arquitetura das RNAs apresentadas na Figura 3 é bastante semelhante, ambas executadas com 75 épocas e duas camadas ocultas, diferenciando-se apenas pelo número de neurônios por camada. Na Figura 3(b), foram utilizados 128 neurônios por camada, enquanto na Figura 3(c), optou-se por seis neurônios por camada. A acuracidade final foi de 88,76% e 94,55%, respectivamente, para essas configurações.

Ao analisar as Figuras 2 e 3, é facilmente perceptível que, com um conjunto de dados maior, os lóbulos de estabilidade começam a ser mais visíveis na fronteira de decisão. Isso permitiu constatar que os modelos de RNA (Rede Neural Artificial) treinados com um menor número de pontos tendem a ser menos precisos. Além disso, é importante notar que as fronteiras de decisão previstas diferem da fronteira real, com muitos lóbulos ausentes completamente. Portanto, as previsões para dados de entrada próximos à fronteira de decisão real podem ser imprecisas. A comparação visual entre as fronteiras de decisão demonstra que a arquitetura do modelo está intimamente relacionada com a acuracidade do modelo.

CONCLUSÕES

Este estudo apresentou conforme os diagramas de lóbulos de estabilidade obtidos, que a fronteira de decisão é razoavelmente reproduzida pelo modelo da RNA (Rede Neural Artificial). Contudo, para pontos próximos aos picos dos lóbulos e alguns vales, a fronteira prevista não é precisa. Portanto, é de se esperar que, ao usar o modelo para fins de previsão, as estimativas possam não ser precisas quando os dados de entrada estiverem próximos a esses picos e vales. No entanto, em regiões afastadas desses locais, pode-se esperar que a acuracidade das previsões seja elevada. Isso é corroborado ao avaliar o desempenho do modelo da RNA por meio de um conjunto de testes. Foi feita uma análise da aplicação de redes neurais artificiais para modelar o comportamento de estabilidade na usinagem. O limite de estabilidade analítico, baseado na dinâmica estrutural e no modelo de força, foi empregado para gerar um conjunto de dados que serviu de treinamento para a RNA. Observou-se que o número e a distribuição



dos pontos de treinamento exercem influência sobre a capacidade da RNA em capturar os lóbulos menores e mais próximos, que ocorrem em velocidades de corte mais baixas. Em geral, a RNA obteve êxito na previsão do comportamento de estabilidade após um treinamento adequado. As redes neurais profundas e estreitas demonstraram maior acuracidade em comparação com as redes neurais rasas e largas. Uma análise sobre a sensibilidade da arquitetura da RNA revelou que o desempenho está diretamente relacionado com o número de camadas ocultas selecionadas, bem como com a quantidade de neurônios por camada e épocas de treinamento. O próximo passo a ser desenvolvido na linha de pensamento deste trabalho seria aplicar a técnica de *transfer learning*, reutilizando um modelo pré-treinado como ponto inicial para resolver um novo problema.

Agradecimentos

Agradecemos ao CNPq pelo apoio financeiro e à UTFPR.

Conflito de interesse

Não há conflito de interesse.

REFERÊNCIAS

STEMMER, C. E. **Ferramentas de Corte II**. 2. Ed. Florianópolis: Editora da UFSC, p. 141-216, 1995.

ALTINTAS, Y.; BUDAK, E. **Analitycal prediction of stability lobes in milling**. *Annals of the CIRP*, v. 44, n. 1, p. 357-362, 1995.

SCHMITZ, T. L.; SMITH, K. S. **Machining Dynamics: Frequency Response to Improved Productivity**. Nova York. Springer, 2009.

ATSUTA, T., YOSHIMURA, H., MATSUMARA, T. **Control of chatter vibration in double inserts turning with phase difference of modulations**. *Precision Engineering*, v. 82, p. 106-115, 2023.

FURTADO, M. I. V. **Redes Neurais Artificiais: Uma abordagem para sala de aula**. Ponta Grossa. Atena Editora, 2019.

CHERUKURI, H.; PEREZ-BERNABEU, E.; SELLES, M. A.; SCHMITZ, T. **Machining Chatter Prediction Using a Data Learning Model**. *Journal of Manufacturing and Material Processing*, v. 34, p. 885 – 992, 2019.

CHAUVIN, Y.; RUMELHART, D. E. **Backpropagation: Theory, Architectures, and Applications**, Lawrence Erlbaum Associates, 1995.

LECUN, Y.; BOTTOU, L; BENGIO, Y.; HAFFNER, P. **Gradient-based learning applied to document recognition**. *Proceedings of the IEEE*, v. 86, n. 11, p. 2278-2324, 1998.