

PREDIÇÃO DA FORÇA DE USINAGEM EM FRESAMENTO ATRAVÉS DE REDE NEURAL ARTIFICIAL

Lucas Balduino Moda, Lmoda@ita.br
Anderson Vicente Borille, borille@ita.br
Antonio Jorge Abdalla, ajorgeabdalla@gmail.com

Instituto Tecnológico de Aeronáutica – ITA. Pç. Marechal Eduardo Gomes, 50 – Vila das Acácias – São José dos Campos – SP.
CEP 12228-900. IEM/CCM.

Resumo: O fresamento é um processo de fabricação por usinagem amplamente utilizado nos dias de hoje, principalmente nos setores aeroespacial, automobilístico, molde e matrizes, bélico, entre outros. Sua grande vantagem de utilização está na capacidade de trabalhar com ferramentas de corte com múltiplas arestas cortantes, o que permite uma alta taxa de remoção de material. Entretanto, os requisitos de fabricação de peças estão se tornando cada vez mais apertados e complexos, com novos materiais sendo utilizados e tolerâncias cada vez menores. Dessa forma, o estudo dos parâmetros envolvidos neste processo se tornou essencial no que tange o desenvolvimento da tecnologia de usinagem e de novos equipamentos e ferramentas. Um dos principais parâmetros estudados é a força de usinagem, ela está diretamente ligada a projetos de novas máquina-ferramentas, a usinagem de materiais mais resistentes, a criação de novas ferramentas de corte, sendo então imprescindível saber sobre a sua forma de atuação e comportamento durante a usinagem. E indo além disso, a capacidade de se poder prevê-la. O método convencional para modelar a força de usinagem é através de equações ou modelos matemáticos, que mesmo com sua comprovada utilidade, são considerados estáticos e não englobam grande parte das variáveis presentes no processo. Sendo assim, este trabalho teve como objetivo aplicar técnicas mais recentes para conseguir prever a força de usinagem no processo de fresamento, através de modelos de aprendizado de máquina, como as redes neurais artificiais (RNA). Se utilizou dos parâmetros de corte a_p , f_z e a_e como valores de entrada para os modelos (inputs) e a força resultante de usinagem (F_U) como valor de saída (output). Foram executados ensaios experimentais de fresamento para a obtenção desses conjuntos de dados. Duas técnicas foram utilizadas para treinamento e validação do modelo de RNA. Para a RNA foram obtidos erros de predição MAPE de 7,01% e 5,61%, para as diferentes técnicas utilizadas. Ambos os erros de predição foram considerados excelentes para o objetivo proposto.

Palavras-chave: Fresamento; Usinagem; Força; Rede neural artificial; Aprendizado de máquina.

1. INTRODUÇÃO

A indústria da usinagem é geralmente caracterizada pelo seu alto nível de concorrência, onde os usuários são sempre instigados a obter as melhores margens operacionais, em decorrência de uma demanda cada vez mais exigente por parte do mercado consumidor (PONTES, 2011). A exigência na obtenção de superfícies cada vez mais complexas, somada a necessidade de fabricação de novos materiais mais resistentes, torna o campo da pesquisa em novas soluções de manufatura um terreno fértil.

Nesse aspecto, o processo de fresamento é usualmente utilizado devido à sua reconhecida característica de versatilidade na produção de diversos tipos de geometrias, além de ser um processo que garante elevadas taxas de remoção de material, por utilizar ferramentas com múltiplas arestas de corte (MACHADO *et al.*, 2011). Quando se fala sobre o estudo de processos de fabricação como o fresamento, um dos principais aspectos avaliados são as forças de usinagem. Essas forças são de extrema importância, porque agem diretamente sobre a cunha cortante da ferramenta e, quando são conhecidas, permitem estimar valores como a potência necessária para o corte, saber sobre a atuação nos elementos mecânicos da máquina-ferramenta e o desgaste da ferramenta, os quais influenciam diretamente na viabilidade econômica da operação (MACHADO *et al.*, 2011).

Uma das grandes questões envolvendo as forças de usinagem é a capacidade de se poder modelá-las e prevêê-las, visto que isto provê bases de dados para o planejamento de processo, o desenvolvimento de novas máquinas-ferramentas, otimização geométrica de ferramentas de corte, avaliação da usinabilidade de novos materiais, além do monitoramento e controle em tempo real das condições do processo (DAVE; RAVAL, 2010). Além disso, conhecer as forças envolvidas no processo de usinagem são fundamentais para o entendimento do processo de corte, otimização das operações de fresamento e a identificação de instabilidades que podem prejudicar o resultado da operação (ZUPERL *et al.*, 2016).

Entretanto, a modelagem da força de usinagem é um trabalho complexo, devido ao grande número de variáveis encontradas, como: deflexões na interface ferramenta-material, quebras e lascamentos, desgastes e vibrações, entre outros fatores que resultam em perturbações e peças mal-acabadas (VAISHNAV *et al.*, 2019). Uma das maneiras de se modelar

e buscar a predição dos valores de força é através de aproximações matemáticas, ou modelos teóricos. Um dos modelos mais comumente citados na literatura é o modelo de forças de *Kienzle*, Eq. (1) (STEMMER, 1995). Este modelo procura representar uma relação exponencial, aproximada, entre a força específica de corte e a espessura do cavaco, para isso utiliza-se os valores de pressão específica de corte ($k_{c1,1}$) e a espessura do cavaco (h) elevada a uma constante tabelada para diferentes tipos de materiais.

$$F_c = k_{c1,1} \cdot a_p \cdot h^{1-m_c} \quad (1)$$

Onde:

F_c – Força de corte (N);

a_p – Profundidade de corte (mm);

$k_{c1,1}$ – Pressão específica de corte para $A=1 \times 1$ mm, esta varia de acordo com o material (N/mm²);

h – Espessura do cavaco (mm);

m_c – Fator de ajuste tabelado para cada tipo de material.

Entretanto, esse modelo é considerado estático, e não cobre características intrínsecas ao processo de fresamento como a espessura variável do cavaco (que não é constante no processo de fresamento, igual ao torneamento), além da influência de outros parâmetros de corte (MACHADO *et al.*, 2011). Sendo assim é necessária uma adaptação desse modelo, para utilizá-lo no cálculo da força de usinagem em fresamento. Além da modelagem ainda representar um desafio aos pesquisadores, as abordagens teóricas propostas demonstram uma limitação de acurácia e possibilidade de generalização, devido à dificuldade em representar alguns dos fenômenos do processo de fresamento, de forma matemática (DAVE; RAVAL, 2010). Dessa forma, observa-se um potencial altíssimo da aplicação de novas tecnologias, principalmente as relacionadas ao advento da Indústria 4.0, que pregam por uma primeira etapa de observação do processo, afim de entendê-lo, e assim desenvolver uma capacidade de predição dos fenômenos ali presentes. Quando se relaciona a tecnologia de aprendizado de máquina, a um processo já bem conhecido e estudado pela literatura como o fresamento, pode-se obter avanços significativos na capacidade de predição de parâmetros fundamentais aos processos.

Pesquisas recentes demonstram excelentes resultados na aplicação de Redes Neurais Artificiais (RNA), na classificação e identificação de padrões presentes, seja em um processo ou em um estudo isolado. Inspirado na biologia humana, essa tecnologia possui grande relevância, devido a sua capacidade de aprender e de se modelar, baseado em sua própria experiência (ZHANG; PATUWO; HU, 1998). Neste ponto, as RNAs podem ser então utilizadas para a modelagem e predição das forças de usinagem em processos de manufatura como o fresamento, visto que são compatíveis com a complexidade envolvida nesta tarefa. As RNAs apresentam como grande vantagem a não necessidade de se formular, de modo preciso, todas as variáveis intrínsecas ao processo, necessitando apenas de sua elaboração experimental (DAVE; RAVAL, 2010).

A construção de uma RNA envolve um processo complexo de entendimento da linguagem de programação utilizada, o que envolve uma curva de aprendizado por parte do pesquisador, além da aplicação de uma extensa sequência de testes e variações dos hiperparâmetros referentes ao modelo construído, de forma que ele fique o mais bem ajustado ao objetivo proposto. Esse teste, afim de encontrar as melhores condições para a rede, é conhecido como *Tuning*, e engloba parâmetros de arquitetura (como a quantidade de *inputs*, *outputs*, neurônios, camadas ocultas) e parâmetros de rede (como otimizadores, funções de ativação, tamanho de *batch*, algoritmo de treinamento, entre outros).

1.1. Objetivo geral

O objetivo principal deste trabalho é contribuir para o entendimento da aplicação de técnicas relacionadas à temática de aprendizado de máquina (em inglês, *machine-learning*), na construção e utilização de modelos capazes de realizarem a predição da força de usinagem para o processo de fresamento. Sendo mais preciso, através da utilização de redes neurais artificiais.

1.2. Objetivos específicos

Para atingir o objetivo geral acima descrito, e auxiliar na condução das atividades desenvolvidas neste trabalho, foram definidos os seguintes objetivos específicos:

- Estabelecer um planejamento de experimentos (DOE) para o ensaio experimental de fresamento, a fim de obter os dados necessários para o treinamento da rede neural;
- Propor um novo método para tratamentos dos dados de força adquiridos no ensaio de fresamento, para que estes sejam posteriormente empregados nos modelos de predição;

- Propor um modelo de rede neural artificial capaz de prever a força de usinagem no processo de fresamento, a partir das práticas encontradas na literatura;
- Executar a validação do modelo proposto, a partir de dados experimentais não visualizados na etapa de treinamento.

2. METODOLOGIA

Esta seção foi dividida em três tópicos principais. O primeiro tópico descreve as operações necessárias para preparação do experimento de usinagem principal, como a pré-usinagem do material de estudo e a definição dos parâmetros de cortes e seus respectivos valores, que serão empregados na parte experimental. Esta etapa é importante para a definição dos parâmetros utilizados como valores de entrada para o modelo de rede neural artificial.

No segundo tópico, são descritas as etapas do experimento de usinagem por fresamento. Este inclui a definição do planejamento experimental que será utilizado, quais serão os fatores, níveis e suas variações. O terceiro tópico trata da rotina proposta para o tratamento dos dados obtidos na fase experimental, para que esses dados possam ser posteriormente empregados no modelo de rede neural selecionado. Também neste tópico é tratado sobre a maneira de seleção e definição dos hiperparâmetros e técnicas empregadas no modelo de aprendizado de máquina utilizado. A Figura 1 procura ilustrar todas as etapas e tarefas presentes neste capítulo.




Figura 1. Fluxograma de desenvolvimento das atividades do trabalho.

2.1. Preparação para o experimento de fresamento

Neste trabalho utilizou-se como material de estudo para a usinagem o aço VPATLAS. Este é um aço de elevada resistência mecânica, boa usinabilidade e polibilidade desenvolvido pela Villares Metals. Esse material é indicado para a manufatura de moldes e componentes que demandem superior resistência, tanto mecânica quanto ao desgaste, em relação aos fabricados em P20 e 1.2738 (Villares Metals, 2022). Este material não pertence a nenhuma classe padronizada de aços, porém é indicado em substituição aos aços pré-endurecidos para 40 HRC, como o DIN 1.2711 e suas versões modificadas. A Tabela 1 apresenta a composição química do material.

O material disponibilizado para estudo encontrava-se, após seu forjamento, em um lingote de medidas 100 x 170 x 810 mm, para ser possível sua colocação no dinamômetro foi necessário cortá-lo em uma parte menor com 100 x 170 x 90 mm e executar uma pré-usinagem, a fim de se obter as medidas necessárias para sua fixação no equipamento. Além disso, foi necessária a usinagem de dois rebaixos no material, para passagem dos parafusos que fixam a matéria-prima ao dinamômetro da empresa Kistler®.

Tabela 1. Composição química do material utilizado para o experimento de fresamento (Villares Metals, 2022).

Composição química VpAtlas (% em peso)										
C	Si	Mn	P	S	Cr	Mo	Ni	V	Al	H
0,27	0,30	1,58	0,007	0,0057	1,86	0,72	0,57	0,08	<0,005	0,00012

2.2. Definição dos parâmetros de entrada (*inputs*)

A definição dos parâmetros de corte que foram utilizados no ensaio de fresamento se iniciaram pela escolha da ferramenta a ser utilizada. Para isso, foi realizada uma consulta junto ao fabricante de ferramentas Sandvik, sobre qual a ferramenta mais indicada para a usinagem de aços, no caso do aço em estudo com 42 HRC. Estes parâmetros foram posteriormente utilizados como dados de entrada para os modelos de predição.

Para a finalidade deste trabalho, foi recomendado e disponibilizado pela empresa a fresa com pastilhas intercambiáveis da linha CoroMill® 390 com diâmetro de 12 mm, de código R390-012A12-07L, para dois insertos de código 390R-070208M-PM. Na Figura 2 é possível observar a haste e o inserto utilizados. Para determinar os parâmetros de corte do experimento, foram respeitados os limites definidos pelo fabricante da ferramenta. Trabalhos relacionados a este tema e que já se encontram disponível na literatura, também foram utilizadas como base para a escolha dos parâmetros (PENG *et al.*, 2019; BALASUBRAMANIAN; YADAV; TIWARI, 2019; WANG *et al.*, 2021; DAVE; RAVAL, 2010; VAISHNAV *et al.*, 2019).

Tendo como base os trabalhos revisados, se observou a predominância das variações dos parâmetros de profundidade de corte (67% dos trabalhos revisados), penetração de trabalho (38% dos trabalhos revisados), e avanço por dente (95% dos trabalhos utilizados). Estes três parâmetros foram então definidos como objetos de estudo no delineamento experimental deste trabalho (Tabela 2) e, conseqüentemente, como *inputs* para o modelo de aprendizado de máquina. Associado a eles, os valores de v_c e rotação foram mantidos constantes, baseados na recomendação do fabricante da ferramenta e na literatura, que trata da baixa influência desses parâmetros na força de usinagem (STEMMER, 1995; MACHADO *et al.*, 2011; YEGANEFAR, NIKMAN, ASADI, 2019).

Dessa forma, os valores de avanço foram definidos com base na recomendação do fabricante da ferramenta e os valores de profundidade e penetração de trabalho foram escolhidos baseando-se na literatura pesquisada, principalmente pela usinagem previamente executada por Bacalhau (2012), no qual o autor utilizou o mesmo material deste estudo. Todos os parâmetros foram combinados entre si para a execução do experimento, totalizando 27 séries de ensaio, ou como foi denominado no trabalho, 27 corridas.

Tabela 2. Parâmetros de corte definidos para o 1º ensaio de fresamento.

Fatores	Níveis		
	1	2	3
a_p (mm)	0,50	0,80	1,10
f_z (mm/dente)	0,05	0,07	0,09
a_e (mm)	3,60	5,40	7,20
Rotação (RPM) 7600 - Constante			
v_c 285 m/min - Constante			

Como parte do planejamento experimental, a usinagem de um bloco completo contendo 27 corridas foi repetida 2 vezes, tendo então um delineamento experimental 3^3 com duas réplicas, totalizando 81 corridas no ensaio total, com uma sequência de execução aleatória.

Uma segunda série de ensaios de fresamento foi executada, com o objetivo de servirem como dados de validação para o modelo de predição analisado. Para isto, foram propostos parâmetros de corte intermediários aos apresentados na Tab. 2, de forma que o modelo fosse submetido a executar predições com parâmetros ainda não visualizados. A Tabela 3 apresenta as condições de cortes experimentadas para a validação do modelo de RNA, o fresamento de cada série foi repetido 3 vezes, e os parâmetros não foram combinados entre si, totalizando 9 dados amostrais.




Figura 2. Ferramenta de corte utilizada.

Tabela 3. Parâmetros de corte definidos para o 2º ensaio de fresamento.

Fatores	Níveis		
	1	2	3
a_p (mm)	0,65	0,95	1,30
f_z (mm/dente)	0,06	0,08	0,11
a_e (mm)	4,44	6,24	8,40
RPM 7600 - Constante			
V_c 285 m/min - Constante			

2.3. Ensaio experimental de fresamento

Com todos os procedimentos anteriormente descritos concluídos, pode-se dar início ao ensaio de fresamento. A Figura 3 procura ilustrar a execução do fresamento e a composição da direção das forças no material usinado. Os experimentos foram executados utilizando o fluido de corte da empresa Blaser, Vasco 7000®, pelo método de inundação sob alta pressão. Todos os cortes foram executados no sentido concordante.

Ao fim de cada série de 27 corridas, o inserto da ferramenta foi trocado para um novo gume ainda não utilizado, para que na nova repetição fossem mantidas as condições de contorno. Como o objetivo deste trabalho é a aquisição das forças presentes no corte, não foi medida e levada em consideração a rugosidade do material após cada passada da ferramenta, além do desgaste de flanco do inserto. Na Figura 4 é possível observar o conjunto experimental montado para o ensaio. Após o fim dos ensaios experimentais, os dados obtidos foram submetidos a uma rotina automatizada de tratamento, descrito no tópico seguinte.




Figura 3. Ensaio experimental de fresamento na máquina Romi D800.




Figura 4. Equipamentos e máquina utilizados no experimento de fresamento.

2.4. Rotina de tratamento dos dados

As forças de corte brutas, obtidas após os ensaios de fresamento, são expressas em forma de sinais, ou também denominadas de curvas. Esses dados não se encontram no formato correto para serem utilizados no modelo de predição proposto, visto que na literatura é consenso a utilização de valores nominais como parâmetros de entrada e saída para modelos de regressão, como os estudados neste trabalho. Sendo assim, é necessário executar o tratamento desses dados e transformá-los em valores nominais de força, para a componente avaliada, no caso a força resultante de usinagem. Tendo como base os trabalhos revisados, foi proposto uma estratégia de tratamento dos dados obtidos nos ensaios, onde o objetivo foi selecionar a média aritmética dos picos da força resultante de usinagem em cada corrida e utilizar esse valor nominal como parâmetro de saída para os modelos de predições. O cálculo da força resultante foi feito através da Eq. 2.

$$F_U = \sqrt{(F_X)^2 + (F_Y)^2 + (F_Z)^2} \quad (2)$$

Após a definição da força resultante para cada ponto no tempo aquisitado, foi plotado um gráfico de F_U para cada corrida ensaiada. Esses valores foram então exportados para um ambiente no software *Matlab*, onde foram submetidos a uma rotina de tratamento programada, com o objetivo de filtrar os valores de forças de acordo com a frequência natural de passagem dos dentes da ferramenta (300 Hz), além da seleção de apenas 80% do sinal total, para que não sejam considerados picos causados pela entrada e saída da ferramenta no material. Através do algoritmo programado, foram selecionados os picos de força dentro do intervalo definido, e posteriormente, calculado o valor médio dos picos, sendo este definido com o valor de F_U para a respectiva corrida em análise. A Figura 5 procura ilustrar esse processo.




Figura 5. Tratamento e seleção dos picos de força pelo algoritmo programado.

2.5. Construção do modelo de RNA

Com os dados tratados de entrada e saída em mãos, o próximo passo foi explorar os recursos disponíveis para a definição e construção do modelo, capaz de prever o valor de força de usinagem em fresamento, tendo como referência os parâmetros de corte, como entrada. O modelo de RNA é denominado como *Data-driven*, na tradução literal “guiado por dados”, ou seja, são embasados na coleta e análise de dados para futura tomada de decisão, sendo este um dos principais conceitos ligados a Indústria 4.0. Todas as programações foram executadas no ambiente *Google Colab*®, através da linguagem de programação *Python*.

Os modelos de redes neurais artificiais são bastante conhecidos por sua extrema flexibilidade, porém essa característica também é um de seus principais empecilhos, devido ao grande número de hiperparâmetros que existem para serem ajustados (GÉRON, 2021). As denominações utilizadas na literatura, para definir os tipos de redes neurais, são bastante confusas. No caso deste trabalho, se trabalhou como definição para a rede utilizada, como sendo uma rede *Perceptron* Multicamadas (“*Multilayer Perceptron – MLP*”), que consiste em uma rede que possui no mínimo três camadas: uma de entrada, uma oculta e uma de saída, com o uso do algoritmo de treinamento de retropropagação (“*Backpropagation – BP*”).

O primeiro passo na construção do modelo de rede neural foi carregar os dados definidos nos tópicos anteriores, no espaço Colab®, e dividi-los em dados de entrada (*inputs*) e dados de saída (*output*). Sendo assim, a rede já conta com três neurônios na primeira camada (a_p , a_e , f_z) e um neurônio na última camada (F_U), essa condição é imutável. Posteriormente, os dados de entrada e saída foram divididos em dois conjuntos, um conjunto que foi utilizado para o treinamento da rede e o outro conjunto que foi utilizado para teste. Esse método é conhecido como *Hold-out*. Se utilizou uma função do pacote *scikit-learn*, a função *train_test_split*, para divisão dos 81 dados em 85% para treinamento e 15% para teste. Na sequência, os dados de entrada precisam ser escalonados para todos ficarem dentro da mesma amplitude de

valores, para isso se utilizou uma função da biblioteca *Scikit-learn*, chamada *StandardScaler*. Esse processo é chamado de *Standardization* (em português, padronização), nele o algoritmo calcula a média dos dados em 0 e o desvio padrão em 1, e então transforma esses dados de acordo com esse filtro calculado, para que todos fiquem dentro de uma distribuição normalizada.

O ajuste dos hiperparâmetros ainda é uma área de pesquisa muito ativa (GÉRON, 2021) e não há um consenso formado sobre a melhor sequência de variações a serem executadas. Portanto, a sequência de otimização dos parâmetros de rede seguida, foi adaptada a partir dos trabalhos revisados (DAVE; RAVAL, 2010; VAISHNAV *et al.*, 2019; ZUPERL *et al.*, 2016; BALASUBRAMANIAN; YADAV; TIWARI, 2019; WANG *et al.*, 2020) e teve como primeiro parâmetro trabalhado, a arquitetura de rede. A Tabela 4 demonstra os níveis de camadas ocultas e quantidade de neurônios avaliados e a Tab. 5 lista os demais hiperparâmetros avaliados para definição do modelo mais ajustado.

Tabela 4. Arquiteturas avaliadas para construção do modelo de RNA.

Hiperparâmetros	Níveis avaliados				
Nº camadas ocultas	1	2			
Nº neurônios por camada oculta	4	8	16	32	64
Arquiteturas avaliadas	3-4-1	3-8-1	3-16-1	3-32-1	3-64-1
	3-4-4-1	3-8-4-1	3-16-8-1	3-32-16-1	3-64-32-1
	3-64-64-1				

Tabela 5. Hiperparâmetros avaliados para definição do modelo mais ajustado de RNA.

Hiperparâmetros	Níveis avaliados				
Otimizador	<i>RMSprop</i>	<i>Adam</i>	<i>Nadam</i>		
Taxa de aprendizado	0.1	0.01	0.001		
Tamanho do <i>batch</i>	2	5	10	20	30

A função de ativação é outro hiperparâmetro importante na construção de uma RNA, porém se optou por não testar sua variação, devido ao consenso que existe na literatura que a função *ReLU* é uma das mais empregadas e a opção de utilizar outra função é comumente requerida somente em casos especiais (GÉRON, 2021).

2.6. Validação do modelo de RNA

Para executar a validação do modelo, a rede foi treinada novamente, agora utilizando os 81 dados disponíveis. Como descrito no escopo desse trabalho, se utilizou poucos dados experimentais para treinamento, dessa forma, o retreinamento utilizando todos os dados teve a premissa de fornecer o máximo de informações para a rede, a fim de melhorar o seu poder de predição, utilizando os hiperparâmetros mais adequados definidos anteriormente.

Neste caso, já não é mais necessário separar os dados em conjuntos de treino e teste. Foi executada a função de predição para este conjunto inicial, que já haviam sido visualizados previamente pelo modelo de RNA, tendo então os pesos definidos pelo algoritmo, salvos. Posteriormente, foi feita a validação desse modelo construído, no segundo conjunto de dados experimentais (Tab. 3), o qual é composto de dados 7 dados (devido à quebra do inserto utilizado, não foi possível executar as 2 últimas réplicas), diferentes do primeiro conjunto experimental. Dessa forma, a rede é validada ao tentar fazer predições em dados que ela ainda não visualizou ou que não foram utilizados durante a fase de treinamento. Dessa forma, se procura avaliar sobre a capacidade de generalização do modelo proposto.

3. RESULTADOS

Os resultados foram divididos em dois grupos, o primeiro relacionado a variação e testes dos hiperparâmetros e arquitetura da rede neural proposta e o segundo grupo em relação aos resultados de predição obtidos.

3.1. Resultados para definição do melhor modelo de RNA

Em relação aos testes de variação de hiperparâmetros, os resultados de cada quesito em avaliação foram comparados em relação aos erros obtidos (MSE e MAPE), em relação ao conjunto de dados utilizados para treinamento e teste. Cada resultado observado, se refere a uma média simples, de 5 réplicas utilizadas. Conforme ilustrado na Fig. 6, em relação aos testes para definição da melhor arquitetura de rede, o modelo 3 – 64 – 1 (3 camadas, sendo uma oculta, com 64 neurônios) apresentou os menores erros para predição no conjunto de treinamento e teste. Esse erro, quanto mais próximo

de zero, mais bem feita está sendo a generalização do modelo e predição do valor em questão. Não foi encontrada uma relevância positiva na utilização de duas camadas ocultas, tendo os resultados ficado próximos em relação aos testes com apenas uma camada oculta. Sendo assim, se optou por otimizar o modelo final, visto que o acréscimo de camadas ocultas também resulta em um tempo maior de processamento, principalmente quando se trabalha com muitos dados.




Figura 6. Modelo de RNA 3-64-1, definido pelos testes como o modelo mais bem ajustado ao objetivo do trabalho.

Após a definição da arquitetura, os hiperparâmetros foram comparados e avaliados, a fim de identificar qual combinação apresentaria os melhores resultados de predição para o conjunto de dados de treinamento e teste. Primeiramente, se avaliou a combinação de tipos de otimizadores (*RMSprop*, *ADAM* e *NADAM*) e taxa de aprendizado (0.1, 0.01 e 0.001), para os erros MSE e MAPE. Para os 3 otimizadores utilizados, a taxa de aprendizado de 0.001 apresentou os melhores resultados. Sendo assim, para definir o otimizador mais adequado, foi realizada uma outra comparação entre os três otimizadores definidos, todos com a mesma taxa de aprendizado (0.001). Neste teste, o otimizador *ADAM* apresentou os menores valores de erros, sendo este definido como mais ajustado ao modelo proposto.

Na sequência, foram avaliados os diferentes níveis de tamanho de *Batch*. Os resultados obtidos para este hiperparâmetro foram bem próximos para os diferentes níveis, dessa forma se optou por relacionar também o número de épocas necessárias para o processamento de cada tamanho de *batch*. Dessa maneira, se buscou relacionar os menores níveis de erro com a quantidade de épocas treinadas, visto que esta impacta no tempo de processamento. O tamanho de *Batch* de 10 apresentou um valor de MAPE inferior aos demais (e um MSE ligeiramente inferior), com uma quantidade de épocas abaixo de mil, justificando assim sua escolha para o modelo final. A Tabela 6 ilustra os hiperparâmetros definidos como mais adequados para a aplicação da predição pelo modelo de RNA.

Tabela 6. Hiperparâmetros com os melhores resultados para a função determinada da RNA.

Arquitetura	Camadas Ocultas (CO)	Neurônios na CO	Otimizador	Taxa de aprendizado	Tamanho de <i>Batch</i>	Função de ativação
3-64-1	1	64	<i>ADAM</i>	0.001	10	<i>ReLU</i>

3.2. Resultados para predição da força de usinagem em fresamento

A Figura 7 ilustra os valores preditos (pontos) pelos valores medidos experimentalmente (reta), o gráfico A demonstra a predição para os 15% (dos 81 dados) para os pesos obtidos durante o treinamento com a técnica de *Hold-out* e o gráfico B demonstra a predição para o segundo conjunto (7 dados), destinado a validação do modelo em análise. Enquanto no conjunto de treinamento, os valores preditos demonstram uma distribuição próxima a reta (quanto mais próximo melhor), com um bom nível de MAPE (7%), os valores para o gráfico de validação mostram uma distância considerável da reta, apresentando um MAPE de 35%, significando que o modelo não demonstrou uma boa generalização para dados de entrada (inputs) diferentes dos treinados.

Para se consolidar uma possível melhoria na utilização de todos os dados, foi realizada a predição dos valores de força para os dois conjuntos de dados (neste caso, como não houve separação em treino/teste, a predição para o conjunto de treinamento foi realizada para todos os dados de entrada). Os resultados estão expressos na Fig. 8 e mostram uma melhor distribuição dos pontos preditos junto a reta (demonstrando que houve um bom nível de predição para a figura A), além de uma melhora na generalização da rede para dados diferentes. É possível observar que a utilização de todos

os dados disponíveis para o treinamento da rede, proporcionou menores valores de erro quando comparado a técnica *Hold-out* (MAPE 5.61% contra 7,03% e MAE 18.55 contra 22.31).




Figura 7. Resultados de predição para os valores de força pela técnica de *Hold-out*. A) Predição para o conjunto de dados de treinamento/teste e B) Predição para o conjunto de dados de validação.




Figura 8. Resultados de predição para os valores de força ao utilizar todos dados para treinamento. A) Predição para o conjunto de dados de treinamento e B) Predição para o conjunto de dados de validação, utilizando os pesos do modelo retreinado.

4. CONCLUSÕES

Ambas as técnicas apresentaram excelentes resultados de MAPE para o conjunto de treinamento (7.03% e 5.61%), quando comparado aos resultados obtidos por outros autores nos trabalhos revisados. Onde foram encontrados resultados de MAPE variando de 5% - 15%. Dessa forma, se pode dizer que o modelo proposto cumpriu com o objetivo de realizar a predição com resultados satisfatórios, através da quantidade de dados gerados para estudo. Ambas as técnicas não apresentaram bons resultados de generalização dos seus modelos, para quando submetidos a tarefa de predizer dados de entrada diferentes dos treinados. Isso pode ser consequência da baixa quantidade de dados utilizadas para treinamento, se supõe que, para se atingir um nível melhor de generalização e externar a utilização da rede, seja necessário aumentar a quantidade de dados para treino.

A observação acima descrita pode ser corroborada pelo resultado obtido ao utilizar todos os dados disponíveis para treinamento (fornecendo 15% a mais que a técnica de *Hold-out*). Neste caso, ao externar a predição para dados não vistos, a técnica sem separação obteve um MAPE de 27.97% e um MAE de 130 contra 35% e 204 da técnica *Hold-out*. Evidenciando que a utilização de mais dados para treinamento, faz diferença na generalização do modelo e que o retreinamento com todos os dados disponíveis trouxe um efeito positivo para a predição.

Em síntese, pode-se concluir que o modelo desenvolvido neste trabalho é capaz de prever a força de usinagem em fresamento com um bom nível de confiança, além de se mostrar uma ferramenta poderosa para modelar as relações existentes entre os parâmetros envolvidos no processo.

5. AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

6. REFERÊNCIAS

- Balasubramanian, A. N.; Yadav, N.; Tiwari, A. Analysis of cutting forces in helical ball end milling process using machine learning. *Materials Today: Proceedings*, 2019. Disponível em: <https://doi.org/10.1016/j.matpr.2020.02.098>. Acesso em: 26 Set. 2022.
- Dave, H. K e Raval, H. K. Modeling of cutting forces as a function of cutting parameters in milling process using regression analysis and artificial neural network. *Int. J. Machining and Machinability of Materials*, v. 8, p. 198-208, Jan. 2010.
- Géron, Aurélien. *Mãos à obra: Aprendizado de máquina com Scikit-Learn, Keras & TensorFlow*. 2ª ed. Rio de Janeiro: Alta Books, 2021.
- Machado, A. *et al.* Teoria da usinagem dos materiais. 2ª ed. São Paulo: Blucher, 2011.
- Stemmer, C. E. *Ferramentas de corte I*. 4ª ed. Florianópolis: Editora da UFSC, 1995.
- Peng, B. *et al.* A hybrid approach using machine learning to predict the cutting forces under consideration of the tool wear. *17th CIRP Conference on Modelling of Machining Operations*, v. 82, p. 302-307, 2019.
- Pontes, F. J. Projeto otimizado de redes neurais artificiais para predição da rugosidade em processos de usinagem com a utilização da metodologia de projeto de experimentos. 2011. 259 f. Tese de Doutorado, Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2011.
- Vaishnav, S. *et al.* Machine learning-based instantaneous cutting force model for end milling operation. *Journal of Intelligent Manufacturing*, v. 31, p. 1353-1366. Dez., 2019.
- Villares Metals. VPATLAS. Disponível em: <https://villaresmetals.com.br>. Acesso em: 26 Set. 2022.
- Wang, J. *et al.* Milling force prediction model based on transfer learning and neural network. *Journal of Intelligent Manufacturing*, v. 32, p. 947-956, Junho, 2020.
- Yeganefar, A.; Nikman, S. A.; Asadi, R. The use of support vector machine, neural network, and regression analysis to predict and optimize surface roughness and cutting forces in milling. *The international Journal of Advanced Manufacturing Technology*, v. 105, p. 951-965, 2016.
- Zhang, G.; Patuwo, B. E.; HU, M. Y. Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, v. 14, p. 35-62. Julho, 1998.
- Zuperl, Uros *et al.* Prediction of cutting forces in ball-end milling of multi-layered metal materials. *Journal of Mechanical Engineering*, v. 62, p.340-350. Abril, 2016.

7. RESPONSABILIDADE PELAS INFORMAÇÕES

Os autores são os únicos responsáveis pelas informações incluídas neste trabalho.

PREDIÇÃO DA FORÇA DE USINAGEM EM FRESAMENTO ATRAVÉS DE REDE NEURAL ARTIFICIAL

Lucas Balduino Moda, Lmoda@ita.br
Antonio Jorge Abdalla, ajorgeabdalla@gmail.com
Anderson Vicente Borille, borille@ita.br

Abstract. Milling is a machining manufacturing process widely used nowadays, especially in the aerospace, automotive, mold and die, and war industries, among others. Its great advantage of use lies in its ability to work with cutting tools with multiple cutting edges, which allows for a high material removal rate. However, part manufacturing requirements are becoming increasingly tighter and more complex, with new materials being used and ever tighter tolerances. Therefore, the study of the parameters involved in this process has become essential in the development of machining technology and new equipment and tools. One of the main parameters studied is the machining force, which is directly linked to the design of new machine tools, the machining of more resistant materials, the creation of new cutting tools, so it is essential to know how it acts and behaves during machining. And going beyond that, the ability to predict it. The conventional method to model the machining force is through equations or mathematical models, which even with their proven usefulness, are considered static and do not encompass most of the variables present in the process. Therefore, this work aimed to apply more recent techniques to predict the machining force in the milling process, through machine learning models, such as artificial neural networks (ANN). The cutting parameters a_p , a_e and f_z were used as input values for the models (inputs) and the resulting machining force (F_U) as an output value. Experimental milling trials were performed to obtain these data sets. Two techniques were used for training and validation of the ANN model. For the ANN, MAPE prediction errors of 7.01% and 5.61% were obtained for the different techniques used. Both prediction errors were considered excellent for the proposed objective.

Keywords: milling, force, machining, artificial neural network, machine learning.