

Cutting Parameters and Material Classification using Multinomial Logistic Regression

Leonardo Bonacini , Ingrid Lorena Argote Pedraza , Alexandre Padilha Senni , and Mário Luiz Tronco 

Abstract—In the context of the new industrial revolution - Industry 4.0, smart factory concept brought, to manufacturing, the idea of using large amounts of data acquired from a machining process and a set of mathematical techniques, discovering correlations, patterns or trends in this database. Thus, machine tools are the focus of research in order to monitor and analyze the quality of the machining process based on data from embedded sensors. Based on this strategy, a signature process was created, that consists in capturing behavior patterns of a machine, such as machining conditions, machining quality or tool wear. This article deal with a comparison between three Multinomial Logistic Regressions: the first using only time domain data, the second using only frequency domain data, and finally, the third using time and frequency domain data to identify the pattern of feed rate, depth of cut, and material being machined. It was observed that the methods had a precision of 96.25%, 37.92% and 99.58%, respectively, showing that this methodology has a great predictive efficiency and could be used to monitor the cutting parameters and material studied in this paper.

Index Terms—Manufacturing, Monitoring, Acceleration, Sound, Temperature, Supervised Machine Learning.

I. INTRODUÇÃO

O setor industrial tem um papel de extrema importância na economia de um país, o que implica na grande significância da manufatura ao analisar o desenvolvimento econômico [1]. Este fator pode ser observado e avaliado tanto em países desenvolvidos quanto em países em desenvolvimento [2]. Esse é um dos panoramas que tornaram o setor industrial foco de inúmeras pesquisas para implantar sensores, sistemas de informação e aprendizado de máquina para mudar o conceito tradicional da manufatura, com o objetivo de torná-la mais eficiente. Esse cenário, no Brasil é denominado Manufatura Avançada e vem de encontro com às premissas estabelecidas no contexto da Indústria 4.0 [3].

Observa-se, na literatura, uma tendência para o desenvolvimento da manufatura inteligente, a qual consiste na implantação de sistemas de monitoramento em máquinas-ferramentas para controlar e gerenciar seus processos. A Aplicação destes sistemas em máquinas-ferramentas é bastante ampla como, por exemplo, consumo de energia [4], desgaste da ferramenta [5], [6] e qualidade superficial da peça [7], [8].

Para realizar as aplicações descritas anteriormente, faz-se necessário a utilização de algoritmos de aprendizado de máquina. A posteriori, pode ser aplicado uma tomada de decisão baseado em um determinado modelo de negócio [9].

Leonardo Bonacini, Ingrid Lorena Argote Pedraza, Alexandre Padilha Senni and Mário Luiz Tronco are with the São Carlos School of Engineering, University of São Paulo, Av. Trabalhador São Carlense 200, São Carlos, SP - Brazil email: leobonacini@usp.br

Na Fig. 1 é apresentado um sistema de manufatura inteligente, no qual as variáveis de entrada para o modelo de aprendizado de máquina podem vir da máquina-ferramenta: avanço (f), profundidade de corte (ap), velocidade de corte (v_c) e rotação (n); do corpo usinado: diâmetro (\varnothing) e material; e, por fim, do sistema de monitoramento (dados dos sensores): aceleração (\ddot{x}), som (μ), força específica de corte (F) e temperatura (θ). E todos esses dados, podem sofrer algum tipo de processamento para se extrair as melhores características, de modo a realizar uma previsão ou diagnóstico de uma dada variável.

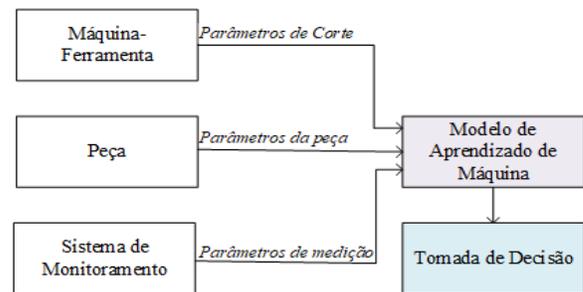


Fig. 1. Diagrama de um sistema de um sistema de monitoramento inteligente.

Existem muitos parâmetros de entrada em um sistema de manufatura inteligente. Para um algoritmo de aprendizado de máquina, em geral, o problema de pesquisa é quem define quais são as melhores escolhas. De maneira geral, as principais variáveis de entrada com relação aos parâmetros de corte das máquinas-ferramentas são o avanço e a profundidade de corte [10].

Em função do cenário descrito anteriormente, pode-se afirmar que, para a implementação de sistemas de monitoramento inteligente no contexto da manufatura avançada é necessário obter parâmetros de corte e parâmetros da peça. Tais informações são coletadas por operadores, utilizando uma interface de comunicação entre a máquina-ferramenta e a rede de comunicação de dados da planta industrial. Entretanto, existem máquinas manuais (as quais não possuem controle de parâmetros de corte) e máquinas que não possuem interface de comunicação (as quais não possuem capacidade de enviar os parâmetros de corte através de algum protocolo de rede) [11], [12]. Desta forma, os parâmetros de corte para estas máquinas devem coletados manualmente. A hipótese a ser respondida neste trabalho é a possibilidade de classificar avanço, profundidade de corte e material usinado a partir de

dados de aceleração, som e temperatura. Portanto, propõe-se o desenvolvimento de um sistema que determine variáveis de entrada para os algoritmos de aprendizado de máquina em locais nos quais as máquinas-ferramentas não tenham a capacidade de fornecer tais configurações.

II. MÉTODOS

A metodologia deste trabalho foi construída em quatro etapas, sendo elas: (a) Sistema de Monitoramento, a qual descreve o sistema de monitoramento utilizado nos experimentos; (b) Variáveis preditoras, a qual apresenta as variáveis utilizadas para prever o comportamento da variável resposta; (c) Definição do Experimentos, a qual apresenta a máquina-ferramenta e a ferramenta de corte utilizada nos experimentos, além disso, indica as condições da variável resposta que foram investigadas e a máquina-ferramenta; (d) Algoritmo de Aprendizado de Máquina, a qual discorre sobre os procedimentos matemáticos para gerar os modelos de predição e como fazer comparações entre diferentes modelos.

A. Sistema de Monitoramento

Existem diversos trabalhos que relatam o monitoramento de máquinas-ferramentas utilizando sinais de vibração, som e temperatura [13]–[15]. Assim, optou-se pela medição destas três grandezas, para que o sistema proposto se adéque à maioria dos sistemas de monitoramento citados na literatura.

Para medir a vibração, utilizou-se o acelerômetro 780B, fabricado pela empresa *Wilcoxon Research*. Por se tratar de um dispositivo uniaxial, foram realizados testes preliminares para verificar qual eixo da máquina-ferramenta estava mais susceptível à vibração. Concluiu-se, nestes testes, que ao fixar o transdutor no suporte da ferramenta, paralelo ao eixo de avanço, obteve-se maior relação entre sinal e ruído. Portanto, esse foi o posicionamento definido para este dispositivo.

Para medir a temperatura de corte foi utilizado um termopar do tipo K. Como visto em [16], a distância do termopar em relação à região de corte e ao suporte da ferramenta são fatores que afetam na distribuição da temperatura ao longo da ferramenta. Portanto, fixou-se o transdutor na ferramenta a uma distância de 4 mm da aresta de corte com o preenchimento da cavidade com pasta térmica para auxiliar na condução do calor e evitar a perda do mesmo.

Para medir o som emitido durante o processo de usinagem foi utilizado um microfone de eletreto. Para este transdutor também foram realizados experimentos preliminares para verificar em qual posição haveria menor influência do ambiente externo. Desta forma, posicionou-se o dispositivo a uma distância de 700 mm da zona de corte, pois resultou em uma maior relação entre sinal e ruído.

O diagrama com a representação do sistema de monitoramento utilizado neste trabalho pode ser visto na Fig. 2. Cada sensor foi conectado a um microcontrolador (modelo Tiva C) responsável por realizar a aquisição dos dados e enviá-los, via rede local, a uma plataforma microprocessada (microprocessador Raspberry Pi). O microprocessador foi responsável por solicitar a aquisição dos dados e receber e armazenar os mesmos no banco de dados.

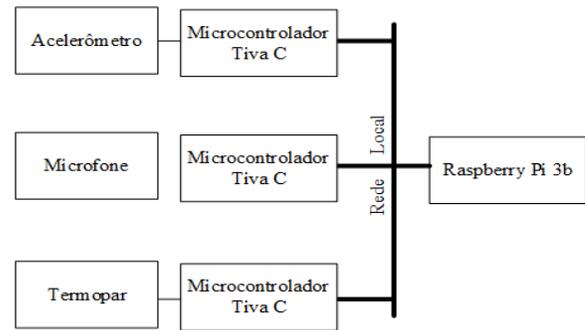


Fig. 2. Diagrama do sistema de monitoramento.

B. Variáveis Preditoras

Analisando-se a literatura, encontram-se inúmeras variáveis de entrada ou preditoras para os algoritmos de aprendizado de máquina, as quais estão em dois domínios: tempo e frequência [17], [18].

Para este experimento foram adotadas as variáveis preditoras que estão dispostas na Tab. I. No domínio do tempo existem 5 variáveis preditoras: amplitude e valor eficaz para o sinal de aceleração e som e a magnitude da temperatura da ferramenta. No domínio da frequência existem 6 variáveis preditoras: as 3 primeiras frequências com maior magnitude no sinal de aceleração e som.

TABELA I
VARIÁVEIS PREDITORAS.

Variável Preditora	Nomenclatura	Unidade
Amplitude de Aceleração	$amp(\ddot{x})$	mV
RMS de Aceleração	$rms(\ddot{x})$	mV
Amplitude de som	$amp(\ddot{u})$	mV
RMS do som	$rms(\ddot{u})$	mV
Temperatura da ferramenta	θ	$^{\circ}C$
Primeira frequência com maior magnitude na aceleração	$f_1(\ddot{x})$	Hz
Segunda frequência com maior magnitude na aceleração	$f_2(\ddot{x})$	Hz
Terceira frequência com maior magnitude na aceleração	$f_3(\ddot{x})$	Hz
Primeira frequência com maior magnitude no som	$f_1(\ddot{u})$	Hz
Segunda frequência com maior magnitude no som	$f_2(\ddot{u})$	Hz
Terceira frequência com maior magnitude no som	$f_3(\ddot{u})$	Hz

C. Definição do Experimento

Os experimentos foram realizados em um torno ROMI Centur 30D e a ferramenta de corte foi a TNGG160408R-C NS530 da fabricante *Tungaloy*. Tal ferramenta é projetada para operar com avanços de até 0,3 mm/rev e velocidade de corte de até 220 m/min. Para a realização dos experimentos, adotou-se um torneamento externo ao longo de 200mm, com os parâmetros que estão apresentados na Tab. II.

Os parâmetros constantes durante os experimentos foram: a velocidade de corte e o diâmetro externo do material. Os parâmetros variáveis foram: profundidade de corte, avanço e material usinado. Por se tratar de três variáveis e duas classes

TABELA II
PARÂMETROS UTILIZADOS DURANTE OS EXPERIMENTOS.

Parâmetros de corte		Parâmetros da peça		
Velocidade de corte (v_c) [m/min]	Profundidade de corte (a_p) [mm]	Avanço (f) [mm/rot]	Diâmetro (\varnothing) [mm]	Material
200,00	0,30 1,00	0,10 0,25	25,40	Alumínio SAE 1020

para cada uma, obteve-se uma variável dependente com 8 classes.

D. Algoritmo de Aprendizado de Máquina

Os algoritmos de aprendizado de máquina podem ser classificados em modelos não supervisionados e supervisionados. Os algoritmos não supervisionados têm como foco correlacionar os dados e, portanto, não é possível realizar previsões com os mesmos. Por outro lado, os algoritmos supervisionados relacionam uma variável dependente com variáveis preditoras e, assim, existe a possibilidade de o algoritmo ser utilizado para fazer previsões.

O grupo de algoritmos determinado *Generalized Linear Models* (GLM) possui inúmeras técnicas com o propósito de relacionar a variável dependente com as variáveis preditoras por um modelo linear. Em geral, as técnicas são escolhidas dependendo da natureza e da distribuição da variável dependente.

Neste experimento, a variável resposta é de natureza categórica contendo a informação do avanço, da profundidade de corte e do material e, os experimentos formam uma distribuição Binomial. Baseado neste cenário, o algoritmo de GLM que lida com esta natureza e distribuição é a Regressão Logística Multinomial (RLM). A equação para este modelo de regressão pode ser vista nas Eq.(1) e Eq.(2).

$$P_{ref} = \frac{1}{1 + \sum_{c=2}^C e^{\alpha_c + \vec{\beta}_c \vec{X}_i}} \quad (1)$$

$$P_c = \frac{e^{\alpha_c + \vec{\beta}_c \vec{X}_i}}{1 + \sum_{c=2}^C e^{\alpha_c + \vec{\beta}_c \vec{X}_i}} \quad (2)$$

Nestas equações, P_{ref} é a probabilidade de ocorrência da categoria de referência para a amostra i , P_c a probabilidade de ocorrência da classe c para a amostra i , α é o intercepto e $\vec{\beta}$ é o vetor contendo os coeficientes angulares de cada variável preditora que está contida no vetor \vec{X} e C indica a quantidade de classes da variável resposta.

Para estimar o intercepto (α) e o vetor de coeficientes angulares ($\vec{\beta}$), utilizou-se o método do Estimador de Máxima Verossimilhança que está representado na Eq.(3).

$$LL = \sum_{i=1}^n \sum_{c=1}^C \left\{ Y_{ic} \left[\ln \left(\frac{e^{\alpha_c + \vec{\beta}_c X_i}}{\sum_{c=1}^C e^{\alpha_c + \beta_c X_i}} \right) \right] \right\} \quad (3)$$

Onde n é o número de observações e Y_{im} é um valor binário que indica a presença ou a ausência da classe c para a observação i .

Após a estimação dos coeficientes, utiliza-se o procedimento *Stepwise* para seleção de variáveis preditoras que beneficiam a capacidade preditiva do modelo. Tal procedimento consiste em fazer iterações removendo e adicionando variáveis preditoras no modelo, observando quando há a redução do *Akaike Information Criterion* (AIC), que indica um aumento da capacidade preditiva. Este critério é calculado através da Eq.(4).

$$AIC = -2LL + 2[(C - 1)v] \quad (4)$$

Nesta equação, v é a quantidade de variáveis preditoras, incluindo o intercepto (α).

Como os modelos podem possuir quantidade de variáveis preditoras diferentes devido ao procedimento *Stepwise*, utilizou-se o teste de hipótese denominado Teste de Razão de Verossimilhança (TRV), que está apresentado na Eq.(5), para comparar os modelos, neste a hipótese nula indica que os modelos possuem a mesma capacidade preditiva e a hipótese alternativa é que não possuem a mesma capacidade preditiva.

$$TRV = -2(LL(\text{Modelo}_1) - LL(\text{Modelo}_2)) \quad (5)$$

O valor TRV é comparado com uma distribuição χ^2 com Graus de Liberdade (GDL) igual à diferença da quantidade de variáveis preditoras dos modelos em comparação, multiplicado pela quantidade de classes menos uma da variável resposta. Adotou-se, para este experimento, um intervalo de confiança de 95%.

III. RESULTADOS

Com o objetivo de determinar o melhor modelo para classificar um processo de usinagem desconhecendo o avanço, a profundidade de corte e o material usinado, propôs-se três modelos de RLM: o primeiro contendo variáveis preditoras no domínio do tempo, outro contendo variáveis dependentes no domínio da frequência e, por último, um modelo com variáveis preditoras no domínio do tempo e da frequência. Para a aplicação do método de máxima verossimilhança, a categoria de referência foi avanço de 0,25 mm/rot, profundidade de corte de 1,00 mm e aço (f025_ap100_aco).

A. Domínio do Tempo

Foram obtidos dois modelos, Modelo Total (o qual possui todas as variáveis preditoras no domínio do tempo) e o Modelo *Stepwise* (o qual possui apenas as variáveis que reduzem o valor de AIC), as características de cada um destes modelos podem ser vistas na Tab. III.

O Modelo Total gerou LL de -25,59 e AIC de 135,18. Ao realizar o procedimento *Stepwise*, obteve-se LL de -30,25 e AIC de 116,51. Portanto, houve diminuição dos dois parâmetros, podendo-se inferir que os modelos apresentam informações contraditórias, pois o modelo mais simples (Modelo *Stepwise*) não apresenta o maior logaritmo de verossimilhança. Nestas condições não se pode afirmar que um modelo é melhor que o outro para fins preditivos. Ao realizar o teste TRV para determinar se os modelos possuem diferenças para fins preditivos, obteve-se um p-valor de 0,81 que é superior a 0,05; isto implica que não se pode rejeitar a hipótese nula de que

TABELA III
COMPARAÇÃO ENTRE MODELOS NO DOMÍNIO DO TEMPO.

Características	Modelo Total	Modelo <i>Stepwise</i>
<i>amp</i> (\ddot{x})	✓	✓
<i>rms</i> (\ddot{x})	✓	✓
Variáveis <i>amp</i> (μ)	✓	-
<i>rms</i> (μ)	✓	-
θ	✓	✓
AIC	135,18	116,51
LL	-25,59	-30,25
GDL	42	28
TRV: valor-p	0,81	

os modelos possuem a mesma capacidade preditiva para um nível de significância de 5%.

Como determinou-se que os modelos possuíam a mesma capacidade preditiva, optou-se pelo Modelo *Stepwise* por ser o modelo mais simples. Com isto, observa-se que, do ponto de vista estatístico, as variáveis amplitude e valor eficaz relacionadas ao som não influenciam na determinação das condições de avanço, profundidade de corte e material usinado quando utilizado apenas variáveis no domínio do tempo.

Na Tab. IV apresentam-se os coeficientes (α e β) para o Modelo *Stepwise* para as variáveis preditoras em cada uma das classes. Abaixo de cada coeficiente, entre parênteses, encontra-se o valor-p dos mesmos, o qual indica a possibilidade de tal coeficiente ser nulo, dado um nível de significância. Nota-se que as variáveis amplitude e valor eficaz relacionadas à aceleração apresentam baixa significância estatística, devido ao alto p-valor, entretanto, a remoção das mesmas não gerou aumento do AIC. A acurácia do melhor modelo com variáveis no domínio do tempo (Modelo *Stepwise*) foi de 96,25%, indicando que este possui uma alta capacidade de prever as classes determinadas no experimento.

B. Domínio da Frequência

Foram obtidos dois modelos, Modelo Total (o qual possui todas as variáveis preditoras no domínio da frequência) e o Modelo *Stepwise* (o qual possui apenas as variáveis que reduzem o valor de *AIC*), as características de cada um podem ser vistas na Tab. V.

O Modelo Total gerou *LL* de -387,67 e *AIC* de 873,34. Ao realizar o procedimento *Stepwise*, obteve-se, para este modelo, *LL* de -397,20 e *AIC* de 864,39. Portanto, houve diminuição dos dois parâmetros, podendo-se inferir que os modelos apresentam informações contraditórias, pois o modelo mais simples (Modelo *Stepwise*) não apresenta o maior logaritmo de verossimilhança. Portanto não se pode afirmar que um modelo é melhor que o outro para fins preditivos. Ao realizar o teste TRV para determinar se os modelos possuem diferenças para fins preditivos, obteve-se um p-valor de 0,16 que é superior ao valor de 0,05; isto implica que não se pode rejeitar a hipótese nula de que os modelos possuem a mesma capacidade preditiva para um nível de significância de 5%.

Como determinou-se que os modelos possuíam a mesma capacidade preditiva, optou-se pelo Modelo *Stepwise*, concluindo que, do ponto de vista estatístico, as variáveis segunda frequência de maior intensidade relacionada à aceleração e a

terceira frequência de maior intensidade relacionada ao som não influenciam na determinação das condições de avanço, profundidade de corte e material usinado.

Na Tab. VI apresentam-se os coeficientes (α e β) para o Modelo *Stepwise* para as variáveis preditoras em cada uma das classes. Nota-se, a partir do p-valor, que alguns coeficientes possuem significância estatística para uma classe e para as demais não. Por exemplo, para a classe *f010_ap030_al* as variáveis relacionadas ao som possuem mais capacidade de prever a classe do que as relacionadas à aceleração por ter um p-valor acima de 0,05, o que indica que os coeficientes podem ser nulos. Pode-se inferir, também, que tal característica e a baixa acurácia (37,92 %) indicam que este modelo não possui uma boa capacidade preditiva.

C. Domínio do Tempo e da Frequência

Foram obtidos dois modelos, Modelo Total (o qual possui todas as variáveis preditoras no domínio do tempo e da frequência) e o Modelo *Stepwise* (o qual possui apenas as variáveis que reduzem o valor de *AIC*) as características de cada um podem ser vistas na Tab. VII.

O Modelo Total gerou *LL* de -36,55 e *AIC* de 241,11. Ao realizar o procedimento *Stepwise*, obteve-se que *LL* de -6,91 e *AIC* de 97,82. Portanto, como Modelo *Stepwise* possui maior *LL* e menor *AIC* comparado com o Modelo Total, pode-se inferir que este é o melhor para fins preditivos. Ao realizar o teste TRV para determinar se os modelos possuem diferenças para fins preditivos, obteve-se um p-valor de 0,04 que é inferior ao valor de 0,05; isto implica em poder rejeitar a hipótese nula de que os modelos possuem a mesma capacidade preditiva para um nível de significância de 5%.

Do ponto de vista estatístico, as variáveis no domínio do tempo que apresentam relevância são relacionadas à aceleração e à temperatura; para o domínio da frequência, as variáveis são relacionadas à aceleração e ao som. A acurácia do modelo em questão foi de 99,58%, indicando que este possui uma alta capacidade de prever as condições de avanço, profundidade de corte e material usinado.

Na Tab. VIII apresentam-se os coeficientes (α e β) para o Modelo *Stepwise* para as variáveis preditoras em cada uma das classes. Observa-se, comparando com o modelo com as variáveis no domínio do tempo e com o modelo com as variáveis no domínio da frequência, que se removeu a variável valor eficaz relacionada à aceleração e a segunda frequência de maior intensidade relacionada ao som. Infere-se também, neste modelo, que como todos os p-valor estão abaixo de 0,05, os mesmos não estão próximo de serem nulos e, conseqüentemente, são importantes para a determinação de todas as classes.

IV. CONCLUSÕES

Neste trabalho investigou-se a hipótese de classificar parâmetros de corte (avanço, profundidade de corte) e parâmetro da peça (material), para permitir que máquinas-ferramentas sem interface de rede possam ser utilizadas em locais que implementam a filosofia da manufatura avançada.

TABELA IV
COEFICIENTES DO MODELO FINAL COM VARIÁVEIS PREDITORAS NO DOMÍNIO DO TEMPO.

Experimento	α	$\beta_{amp}(\ddot{x})$	$\beta_{rms}(\ddot{x})$	$\beta_{amp}(\mu)$	$\beta_{rms}(\mu)$	β_{θ}
f010_ap030_al	971,48 (0,00)	0,19 (0,60)	0,42 (0,66)	- (-)	- (-)	-23,82 (0,00)
f010_ap030_ac	793,06 (0,00)	0,19 (0,61)	0,068 (0,93)	- (-)	- (-)	-17,08 (0,00)
f010_ap100_al	286,91 (0,00)	-0,17 (0,59)	3,87 (0,91)	- (-)	- (-)	-14,15 (0,00)
f010_ap100_ac	538,42 (0,00)	0,26 (0,53)	-0,02 (0,97)	- (-)	- (-)	-10,77 (0,00)
f025_ap030_al	737,37 (0,00)	0,23 (0,52)	0,50 (0,59)	- (-)	- (-)	-16,84 (0,00)
f025_ap030_ac	443,16 (0,00)	0,25 (0,56)	0,01 (0,99)	- (-)	- (-)	-8,81 (0,00)
f025_ap100_al	208,86 (0,00)	0,26 (0,54)	-0,00 (0,99)	- (-)	- (-)	-4,69 (0,00)
Acurácia (%)	96,25					

TABELA V
COMPARAÇÃO ENTRE MODELOS NO DOMÍNIO DA FREQUÊNCIA.

Características	Modelo Total	Modelo <i>Stepwise</i>
Variáveis		
$f_1(\ddot{x})$	✓	✓
$f_2(\ddot{x})$	✓	-
$f_3(\ddot{x})$	✓	✓
$f_1(\mu)$	✓	✓
$f_2(\mu)$	✓	✓
$f_3(\mu)$	✓	-
AIC	873,34	864,39
LL	-387,67	-397,20
GDL	49	35
TRV: valor-p	0,16	

TABELA VI
COEFICIENTES DO MODELO FINAL COM VARIÁVEIS PREDITORAS NO DOMÍNIO DA FREQUÊNCIA.

	α	$\beta_{f_1}(\ddot{x})$	$\beta_{f_2}(\ddot{x})$	$\beta_{f_3}(\ddot{x})$	$\beta_{f_1}(\mu)$	$\beta_{f_2}(\mu)$	$\beta_{f_3}(\mu)$
f010_ap030_al	-24,0569 (0,00)	0,0002 (0,51)	- (-)	0,0007 (0,06)	-0,0226 (0,00)	0,0276 (0,00)	- (-)
f010_ap030_ac	-2,4534 (0,00)	-0,0007 (0,01)	- (-)	0,0015 (0,00)	0,0056 (0,22)	-0,0061 (0,13)	- (-)
f010_ap100_al	-9,6511 (0,00)	-0,0016 (0,00)	- (-)	0,0004 (0,23)	-0,0296 (0,00)	0,0245 (0,00)	- (-)
f010_ap100_ac	-15,9579 (0,00)	0,0002 (0,39)	- (-)	0,0000 (0,92)	-0,0252 (0,00)	0,0264 (0,00)	- (-)
f025_ap030_al	-16,8548 (0,00)	0,0002 (0,48)	- (-)	-0,0000 (0,96)	-0,0227 (0,00)	0,0256 (0,00)	- (-)
f025_ap030_ac	-14,5658 (0,00)	-0,0003 (0,16)	- (-)	-0,0001 (0,82)	-0,0239 (0,00)	0,0258 (0,00)	- (-)
f025_ap100_al	-12,9913 (0,00)	0,0005 (0,08)	- (-)	-0,0005 (0,16)	-0,0242 (0,00)	0,0251 (0,00)	- (-)
Acurácia (%)	37,92						

O modelo no domínio do tempo apresentou alta capacidade preditiva ao obter uma acurácia de 96,25%. Pode-se inferir com este modelo que as variáveis relacionadas ao som não apresentaram significância estatística para determinar a condição de avanço, profundidade de corte e material usinado em um torneamento externo nas condições do experimento.

Por outro lado, o modelo com variáveis no domínio da frequência apresentou uma baixa capacidade preditiva com uma acurácia de 37,92%. Pode-se, portanto, afirmar que a utilização das 3 frequências com maior intensidade de aceleração e som não gera um modelo capaz de classificar o avanço, a profundidade de corte e o material usinado.

TABELA VII
COMPARAÇÃO ENTRE MODELOS NO DOMÍNIO DO TEMPO E DA FREQUÊNCIA.

Características	Modelo Total	Modelo <i>Stepwise</i>
$amp(\ddot{x})$	✓	✓
$rms(\ddot{x})$	✓	-
$amp(\mu)$	✓	-
$rms(\mu)$	✓	-
θ	✓	✓
Variáveis $f_1(\ddot{x})$	✓	✓
$f_2(\ddot{x})$	✓	-
$f_3(\ddot{x})$	✓	✓
$f_1(\mu)$	✓	✓
$f_2(\mu)$	✓	-
$f_3(\mu)$	✓	-
AIC	241,11	97,82
LL	-36,55	-6,91
GDL	84	42
TRV: valor-p		0,04

TABELA VIII
COEFICIENTES DO MODELO FINAL COM VARIÁVEIS PREDITORAS NO DOMÍNIO DO TEMPO E DA FREQUÊNCIA.

	α	$\beta_{amp(\ddot{x})}$	$\beta_{rms(\ddot{x})}$	$\beta_{amp(\mu)}$	$\beta_{rms(\mu)}$	β_{θ}	$\beta_{f_1(\ddot{x})}$	$\beta_{f_2(\ddot{x})}$	$\beta_{f_3(\ddot{x})}$	$\beta_{f_1(\mu)}$	$\beta_{f_2(\mu)}$	$\beta_{f_3(\mu)}$
f010_ap030_al	6800,63 (0,00)	1,54 (0,00)	- (-)	- (-)	- (-)	-245,17 (0,00)	-0,05 (0,00)	- (-)	0,68 (0,00)	1,16 (0,00)	- (-)	- (-)
f010_ap030_ac	5413,49 (0,00)	0,94 (0,01)	- (-)	- (-)	- (-)	-189,65 (0,00)	-0,04 (0,01)	- (-)	0,66 (0,00)	1,13 (0,00)	- (-)	- (-)
f010_ap100_al	1723,08 (0,00)	1,35 (0,00)	- (-)	- (-)	- (-)	-57,74 (0,00)	-0,06 (0,00)	- (-)	0,33 (0,00)	0,36 (0,00)	- (-)	- (-)
f010_ap100_ac	3763,98 (0,00)	2,05 (0,00)	- (-)	- (-)	- (-)	-131,31 (0,00)	-0,10 (0,00)	- (-)	0,58 (0,00)	0,63 (0,00)	- (-)	- (-)
f025_ap030_al	5202,55 (0,00)	2,25 (0,00)	- (-)	- (-)	- (-)	-195,58 (0,00)	-0,07 (0,04)	- (-)	0,65 (0,00)	1,15 (0,00)	- (-)	- (-)
f025_ap030_ac	2517,61 (0,00)	1,36 (0,00)	- (-)	- (-)	- (-)	-72,36 (0,00)	-0,06 (0,00)	- (-)	0,33 (0,00)	0,39 (0,00)	- (-)	- (-)
f025_ap100_al	1389,02 (0,00)	1,37 (0,00)	- (-)	- (-)	- (-)	-52,28 (0,00)	-0,06 (0,00)	- (-)	0,33 (0,00)	0,37 (0,00)	- (-)	- (-)
Acurácia (%)						99,58						

Por fim, o modelo que apresentou a melhor capacidade preditiva, para classificar avanço, profundidade de corte e material usinado, foi o modelo que possuía variáveis predictoras no domínio do tempo e da frequência, o qual obteve uma acurácia de 99,58%.

Tanto para o modelo com variáveis no domínio do tempo quanto para o modelo com variáveis no domínio do tempo e da frequência, as variáveis obtidas da grandeza som, não foram relevantes para a predição de avanço, profundidade de corte e material usinado.

Baseado nisto, observa-se que as variáveis predictoras no domínio do tempo e da frequência permitiram com que um modelo de Regressão Logística Multinomial seja capaz de classificar parâmetros de corte e parâmetro da peça. Com isto, este método se mostra promissor para ser uma etapa de identificação de parâmetros do processo de torneamento externo para locais que queiram implementar manufatura avançada, nos quais as máquinas-ferramentas não possuem interface com protocolo de rede. Pois as grandezas mensuradas pelo sistema de monitoramento é capaz de prever os parâmetros de corte e parâmetro da peça.

AGRADECIMENTOS

Os autores agradecem o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES)

pelos suportes financeiros para o desenvolvimento do presente trabalho.

REFERÊNCIAS

- [1] N. Haraguchi, C. F. C. Cheng, and E. Smeets, "The importance of manufacturing in economic development: Has this changed?," *World Development*, vol. 93, pp. 293–315, 2017.
- [2] N. Marconi, C. F. de Borja Reis, and E. C. de Araújo, "Manufacturing and economic development: The actuality of kaldor's first and second laws," *Structural Change and Economic Dynamics*, vol. 37, pp. 75–89, 2016.
- [3] R. Y. Zhong, X. Xu, E. Klotz, and S. T. Newman, "Intelligent manufacturing in the context of industry 4.0: a review," *Engineering*, vol. 3, no. 5, pp. 616–630, 2017.
- [4] X. Chen, C. Li, Y. Tang, and Q. Xiao, "An internet of things based energy efficiency monitoring and management system for machining workshop," *Journal of cleaner production*, vol. 199, pp. 957–968, 2018.
- [5] B. Zhang, C. Katinas, and Y. C. Shin, "Robust tool wear monitoring using systematic feature selection in turning processes with consideration of uncertainties," *Journal of Manufacturing Science and Engineering*, vol. 140, no. 8, p. 081010, 2018.
- [6] A. Caggiano, "Tool wear prediction in ti-6al-4v machining through multiple sensor monitoring and pca features pattern recognition," *Sensors*, vol. 18, no. 3, p. 823, 2018.
- [7] E. G. Plaza and P. N. López, "Application of the wavelet packet transform to vibration signals for surface roughness monitoring in cnc turning operations," *Mechanical Systems and Signal Processing*, vol. 98, pp. 902–919, 2018.
- [8] M. Kuntoğlu, A. Aslan, H. Sağlam, D. Y. Pimenov, K. Giasin, and T. Mikolajczyk, "Optimization and analysis of surface roughness, flank wear and 5 different sensorial data via tool condition monitoring system in turning of aisi 5140," *Sensors*, vol. 20, no. 16, p. 4377, 2020.

- [9] A. Angelopoulos, E. T. Michailidis, N. Nomikos, P. Trakadas, A. Hatzifremidis, S. Voliotis, and T. Zahariadis, "Tackling faults in the industry 4.0 era—a survey of machine-learning solutions and key aspects," *Sensors*, vol. 20, no. 1, p. 109, 2020.
- [10] D.-H. Kim, T. J. Kim, X. Wang, M. Kim, Y.-J. Quan, J. W. Oh, S.-H. Min, H. Kim, B. Bhandari, I. Yang, *et al.*, "Smart machining process using machine learning: A review and perspective on machining industry," *International Journal of Precision Engineering and Manufacturing-Green Technology*, vol. 5, no. 4, pp. 555–568, 2018.
- [11] D. Mourtzis, N. Milas, and N. Athinaios, "Towards machine shop 4.0: a general machine model for cnc machine-tools through opc-ua," *Procedia CIRP*, vol. 78, pp. 301–306, 2018.
- [12] W. Liu, C. Kong, Q. Niu, J. Jiang, and X. Zhou, "A method of nc machine tools intelligent monitoring system in smart factories," *Robotics and computer-integrated manufacturing*, vol. 61, p. 101842, 2020.
- [13] V. Nasir, M. Kooshkbaghi, J. Cool, and F. Sassani, "Cutting tool temperature monitoring in circular sawing: measurement and multi-sensor feature fusion-based prediction," *The International Journal of Advanced Manufacturing Technology*, vol. 112, no. 9, pp. 2413–2424, 2021.
- [14] M. de Oliveira Moreira, A. M. Abrão, R. A. Ferreira, and M. P. Porto, "Temperature monitoring of milling processes using a directional-spectral thermal radiation heat transfer formulation and thermography," *International Journal of Heat and Mass Transfer*, vol. 171, p. 121051, 2021.
- [15] L. Bonacini, "Sistema dedicado de aquisição de dados para obtenção de assinaturas de processo em torno cnc," Master's thesis, Universidade de São Paulo.
- [16] A. K. Kaminise, G. Guimarães, and M. B. da Silva, "Development of a tool-work thermocouple calibration system with physical compensation to study the influence of tool-holder material on cutting temperature in machining," *The International Journal of Advanced Manufacturing Technology*, vol. 73, no. 5-8, pp. 735–747, 2014.
- [17] Y. S. Ahmed, A. Arif, and S. C. Veldhuis, "Application of the wavelet transform to acoustic emission signals for built-up edge monitoring in stainless steel machining," *Measurement*, vol. 154, p. 107478, 2020.
- [18] Y. Zhou, B. Sun, W. Sun, and Z. Lei, "Tool wear condition monitoring based on a two-layer angle kernel extreme learning machine using sound sensor for milling process," *Journal of Intelligent Manufacturing*, pp. 1–12, 2020.



Alexandre Padilha Senni Graduated in Electrical Engineering from Universidade Paulista (2012), a Master's in Mechanical Engineering at University of São Paulo (2016) and a PhD in Mechanical Engineering at University of São Paulo (2022). Has experience in Electrical Engineering, with emphasis on Electronic Circuits, working mainly on the following topics: FPGA, Navigation and Computer Vision.



Mário Luiz Tronco Graduated in Electrical Engineering with emphasis in Electronics at University of São Paulo (1988), a Master's in Mechanical Engineering at University of São Paulo (1993) and a PhD in Mechanical Engineering at University of São Paulo (1999). Has experience with: autonomous mobile robots, artificial neural networks, computer vision, manufacturing automation and high-speed networking applications.



Leonardo Bonacini Graduated in Technology in Industrial Mechatronics from the Federal Institute of São Paulo (2014) and a master's degree in Mechanical Engineering from the School of Engineering of São Carlos (2017). Has experience in Instrumentation, 4.0 Industry, Agricultural Mobile Robotics, Embedded Systems and Machine Learning.



Ingrid Lorena Argote Pedraza Graduated in Electronic Engineering from the Universidad de los Llanos (2011) and a master's degree in Mechanical Engineering from the University of São Paulo (2015) and a PhD in Mechanical Engineering at University of São Paulo (2021). Has experience in Electrical Engineering, with emphasis on Electrical, Magnetic and Electronic Measurements; Instrumentation. Acting mainly on the following topics: Precision Agriculture, Citroculture, Vision system, Agricultural systems.