

**UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS GRADUAÇÃO
MBE EM MANUFATURA AVANÇADA**

MATHEUS RAMAGE PAZ

**MACHINE LEARNING APLICADO À USINAGEM:
Previsão de informações de um processo de usinagem por Machine Learning
com dados de vibração obtidos com aplicativo Sci Journal.**

**São Leopoldo
2019**

MATHEUS RAMAGE PAZ

MACHINE LEARNING APLICADO À USINAGEM:

**Previsão de informações de um processo de usinagem por Machine Learning
com dados de vibração obtidos com aplicativo Sci Journal.**

Artigo apresentado como requisito parcial
para obtenção do título de Especialista em
Manufatura Avançada, pelo Curso de MBE
em Manufatura Avançada da Universidade
do Vale do Rio dos Sinos – UNISINOS

Orientador: Prof. Me. Marcos Leandro Hoffmann Souza

São Leopoldo

2019

MACHINE LEARNING APLICADO À USINAGEM: Previsão de informações de um processo de usinagem por Machine Learning com dados de vibração obtidos com aplicativo Sci Journal.

MACHINE LEARNING APPLIED TO MACHINING: Predicting information from machining process by Machine Learning with vibration data obtained from the Sci Journal application.

Matheus Ramage Paz

Prof. Me. Marcos Leandro Hoffmann Souza

Resumo: Conhecimento do processo em tempo real é uma das principais vantagens e necessidades da Indústria 4.0. Para isso, se faz necessária a aquisição de dados do processo e de equipamentos industriais por meio de sensores dos mais variados tipos. No processo de usinagem, a vibração resultando do esforço de corte do material pela ferramenta é uma fonte de informações sobre o estado do processo, o estado da ferramenta de corte, as características de qualidade que estão sendo geradas e o estado da máquina operatriz. Para medir a vibração, são utilizados acelerômetros, similares aos existentes nos mais diversos *Smartphones* disponíveis no mercado. Este artigo propõe a utilização dos sensores de aceleração presente em um aparelho de celular comum para obtenção de dados de um processo de usinagem através do aplicativo de coleta de dados *Sci Journal*, para então fornecer informações a um algoritmo de *Machine Learning* em linguagem *Python* do tipo *Decision Tree Regression*, buscando prever informações acerca do processo de usinagem e de qualidade da peça em tempo real baseado nas vibrações medidas.

Palavras-chave: Vibração. Usinagem. *Machine Learning*. *Smartphone*. *Sci Journal*. *Decision Tree Regression*.

Abstract: Real-time process monitoring is one of Industry 4.0's key advantages and needs. This requires the acquisition of process data and industrial equipment data through sensors of various types. In the machining process, the vibration resulting from the cutting effort of the material by the tool is a source of information about the state of the process, the state of the cutting tool, the quality characteristics being generated and the state of the machine tool. To measure vibration, accelerometers are used, similar to those found in many Smartphones available on the market. This paper proposes the use of acceleration sensors present in a common mobile device to obtain data from a machining process through the Sci Journal data collection application. Then, supplying information for a Decision Tree Regression, a Machine Learning algorithm in Python language, with those data seeking to predict information about the machining process and part quality in real time based on the measured vibrations.

Keywords: Vibration. Machining. Machine Learning. Smartphone. Sci Journal. Decision Tree Regression.

1 INTRODUÇÃO

A Indústria 4.0, ou quarta revolução industrial é um movimento mundial de evolução de tecnológica nas indústrias onde a produção e os processos produtivos irão evoluir para um patamar superior de tecnologia devido as máquinas serem capazes de se ajustarem, comunicarem entre si e se auto organizarem (MUHURI; SHUKLA; ABRAHAM, 2019). Esse movimento iniciou-se na Alemanha em 2011 e pode ser definido como a união entre o mundo real e o mundo virtual voltadas para aplicações de engenharia. Esta união ocorre pelas tecnologias que serão e estão sendo motores dessa nova revolução industrial, como a virtualização, a robotização, a automação, a tomada de decisão descentralizada e autônoma, a ciência de dados, a Internet das Coisas (IoT) (KAGERMANN, 2015).

Com todo esse processo de digitalização e virtualização, se faz necessário a obtenção de dados e informações dos processos que estão sendo realizadas nas fábricas, principalmente as informações geradas pelas máquinas operatrizes (BABICEANU; SEKER, 2016). Os dados são a base desta nova revolução industrial, onde a informação habilita a otimização de processos, aumento da produtividade e melhoria da qualidade de processos e de produtos. Sendo o processo de usinagem uma das principais formas de agregação de valor aos produtos industriais, a implantação de conceitos e ferramentas da Indústria 4.0 nesta área se faz importante além de ser uma oportunidade de elevação de patamar da produção no chão de fábrica.

Sendo os dados o principal recurso da Indústria 4.0, é necessário desenvolver formas e utilizar ferramentas para obtenção deste recurso. Essa obtenção de dados pode ser feita por meio de sensores, de dispositivos IoT ou por sistemas existentes nas máquinas produtivas atuais (GITTLER et al., 2019). No viés da usinagem, existem diversas informações que podem ser obtidas durante o processamento do produto, como nível de ruído sonoro, frequência do som, vibrações mecânicas, tensão dos motores elétricos que executam o trabalho da usinagem, temperaturas, dentre outros. As vibrações mecânicas são fontes de dados utilizados para verificação do estado de máquinas no tocante de manutenção, visando a identificação de desgastes, folgas ou falhas nos componentes mecânicos que estão presentes no equipamento analisado. Atualmente, esses dados são obtidos por meio de acelerômetros que são instalados em pontos estratégicos das máquinas.

Hoje em dia, com a popularização dos *Smartphones*, os usuários comuns estão tendo acesso a sensores antes somente encontrado em aplicações específicas da indústria ou áreas tecnológicas. Visando oferecer os mais diversos benefícios aos usuários, esses sensores dos *Smartphones* coletam dados das mais variadas formas, sendo que um dos sensores mais essenciais dos *Smartphones* são os acelerômetros. Estes permitem que o equipamento saiba como está posicionado em diferentes dimensões, se está em movimento, qual a orientação de tela que o usuário está utilizando dentre outras funcionalidades. Desta forma, existem aplicativos criados por desenvolvedores e grandes empresas do ramo de tecnologia, que utilizam ou possibilitam a coleta desses dados de forma que possa ser utilizado pelo fim desejado do usuário. Um destes aplicativos é o *Sci Journal* da Google (Alphabet Inc.), este app permite que o usuário consiga gerar tabelas e gráficos com medições feitas pelos sensores existentes no *Smartphone* que este aplicativo está instalado.

Desta forma, visando unir o benefício do acesso facilitado e extremamente difundido aos *Smartphones* e a necessidade de geração de dados para implantação de ferramentas da Indústria 4.0. Este trabalho se propõe em utilizar dados de vibração obtidos dos acelerômetros de *Smartphones* por meio do *Sci Journal* durante processos de usinagem visando identificar padrões, combinações de parâmetros de usinagem, resultados dimensionais e de qualidade de peças. Outra ferramenta da Indústria 4.0 será utilizada para analisar os dados obtidos e desenvolver um modelo preditivo. Esta ferramenta será o Data Analytics, onde uma árvore de decisão (Decision Tree) as vibrações obtidas pelo *Sci Journal*, e os dados de saída serão informações em tempo real sobre o estado do processo de usinagem e que característica está gerando no produto em processamento.

O objetivo deste trabalho é verificar a eficácia do *Sci Journal* para obtenção de dados que podem gerar melhoria na qualidade, na produtividade e na eficiência de processos de usinagem, sem a necessidade de gastos com equipamentos dedicados, como acelerômetros, controladores lógico-programáveis, células de carga, dentre outros equipamentos de medição.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Aquisição de dados

A aquisição em tempo real de dados de máquinas de usinagem é de grande importância para a evolução da Indústria 4.0, sendo esta obtenção de informações a base para a criação de um Sistema Ciber-físico, onde os dados coletados da máquina servem como entradas do modelo gêmeo digital e possibilitam a utilização de ferramentas analíticas para melhorar o desempenho geral da máquina e do processo (LIU; XU, 2017). Sendo as máquinas de usinagem um conjunto de sistemas mecatrônicos, cada componente pode ser monitorado e fornecer informações significativas sobre o estado do equipamento e do processo. Essas informações podem ser obtidas por diversos tipos de sensores, como termômetros, acelerômetros, amperímetros dentre outros, alocados em posições específicas da máquina (GITTLER et al., 2019).

Os dados obtidos durante a operação do equipamento podem fornecer informações importantes quando ao consumo de energia da máquina, os parâmetros de processos de usinagem, a qualidade da peça que está sendo produzida, o estado atual da ferramenta de corte utilizada, as condições mecânicas de componentes da máquina, dentre outras diversas informações. Com toda essa informação, pode-se utilizar técnicas de Big Data para otimizar e prever características de processo, de qualidade de peça produzida e falhas, tanto do equipamento quanto da usinagem (WANG et al., 2016).

2.2 Monitoramento de processos

Em equipamentos de usinagem, existem vários dados de se obter informações sobre o estado da máquina e do processo. A forma mais usual de monitoramento é através de medições indiretas, feitas em componentes da máquina que não estejam exatamente cortando a peça, como os dados da corrente do motor ou da vibração da máquina. Estas informações podem ser obtidas através de sensores e componentes eletrônicos já presentes nos equipamentos de usinagem, sem a necessidade de gastos com novos sensores e dispositivos. (BAUERDICK et al., 2018).

Estudos de correlação entre dados obtidos sobre o estado da máquina e o reflexo nos parâmetros de saída do processo de usinagem, como qualidade da peça e estado da ferramenta de corte, utilizando Analytics já estão sendo executados na Indústria (LENZ; WUEST; WESTKÄMPER, 2018). Análises holísticas do estado dos estados de equipamentos produtivos estão sendo realizados nas mais diversas indústrias. Na indústria de transformação plástica, sistemas monitoram os parâmetros de injetoras e correlacionam com paradas de máquinas indesejadas, facilitando a identificação da causa-raiz do problema. Desta forma, existe uma redução na quantidade de paradas e evita-se a produção de peças sucata (WANG; GAO, 2006).

Com a evolução das tecnologias para processamento de dados, houve grande avanço no campo de estudo de correlação entre variáveis físicas instantâneas com as suas respectivas saídas do processo. No campo da usinagem, as máquinas podem ser monitoradas e avaliadas em tempo real, com processamento das informações através de redes neurais, prevendo eventos relativos ao estado da máquina e na qualidade da peça produzida. As variáveis físicas mais relevantes para a determinação da performance do processo de usinagem foram determinadas como a emissão acústica, a vibração e o vetor de força (DOWNEY et al., 2016).

Como pode ser visto em Lenz et al., 2018, a estrutura do método de estudo da correlação de variáveis indiretas com os resultados do processo de usinagem podem ser divididas em 3 partes. Primeiro, se analisa o processo In Situ, obtendo dados do comportamento da máquina e do processo. Segundo, com a observação realizada, coletam-se informações referentes as saídas do processo e por último, realiza-se a análise dos dados juntando as informações obtidas na primeira e na segunda etapa. Com esse conjunto de resultados, pode-se desenvolver um sistema que obtenha as informações em tempo real e preveja o resultado em relação a esses dados.

2.3 Processamento de dados – Data Analytics

Com todos os dados disponíveis para o usuário dos equipamentos de usinagem, se faz necessário a utilização de métodos para obtenção de informações relevantes. Alguns desses métodos de Data Analytics usam o *Machine Learning* para classificar e prever informações (HAN; KAMBER; PEI, 2011). Baseado em aplicações nos mais diversos ramos da indústria e da sociedade, o Big Data e Analytics, está sendo aplicado em estratégia de negócios, logística, medicina, monitoramento de

saúde, redes sociais, inteligência de mercado e na indústria. Esses métodos utilizam os dados obtidos para treinar algoritmos que se adaptam e aprendem visando a obter a resposta desejada pelo usuário (CANIZO et al., 2017).

2.4 Modelo Decision Tree Regression

Para utilização de um algoritmo de *Machine Learning* que consiga prever mais de uma informação, deve-se utilizar um modelo que, a partir de diferentes entradas, consiga gerar prever mais de uma saída de dados. Desta forma, um dos algoritmos mais utilizados para situações de múltiplas saídas é o algoritmo Decision Tree Regression (DTR) (SWETAPADMA; YADAV, 2017). O DTR é um algoritmo de regressão que prevê valores a partir de uma ou mais valores de entrada. As vantagens deste algoritmo são a grande precisão, o baixo tempo de aprendizagem e a robustez comparado com outros algoritmos de *Machine Learning* (HAN; KAMBER; PEI, 2011). Para linguagem *Python*, foi desenvolvida a módulo *Scikit-learn*, onde diversos algoritmos para *Machine Learning* foram implementados visando facilitar a utilização por usuários acadêmicos e comerciais (PEDREGOSA et. al, 2011). O algoritmo do modelo DTR utilizado neste trabalho foi baseado no módulo da *Scikit-learn*.

2.5 Sensoriamento via smartphones

Com o advento tecnológico dos *Smartphones*, funcionalidades antes restritas a laboratórios ou aos militares, como o *GPS*, estão na palma da mão. Os sensores disponíveis em *Smartphones* são os mais diversos possíveis, com grande possibilidade de aplicações além de verificar se o aparelho está próximo ao ouvido do usuário ou se a tela está na vertical ou na horizontal. Por isso, a Google desenvolveu a iniciativa *Science Journal* que culminou no aplicativo para celulares *Sci Journal*, disponível nas lojas de aplicativos dos sistemas operacionais Android e iOS. Este aplicativo permite que o usuário tenha acesso aos valores medidos pelos principais sensores presentes no seu aparelho. Pode-se obter dados de pressão atmosférica através de barômetro, volume através do microfone, campo magnético, até a aceleração (*Science Journal*, 2019).

3 MATERIAIS E MÉTODOS

3.1 Método de pesquisa

Para desenvolvimento de um trabalho científico, o método de pesquisa é o procedimento sistemático e racional de encontrar respostas para problemas propostos (Gil, 2007). O método será o caminho a ser percorrido para a construção do conhecimento, servindo de guia para todas as etapas do trabalho científico. Este trabalho será baseado em dados obtidos através de experimentos quantitativos. Estes dados serão a base para uma modelagem através de inteligência artificial do problema analisado. O método de pesquisa deste trabalho será a modelagem computacional do experimento analisado através de algoritmos de Machine Learning. Para este artigo, o modelo escolhido foi *Decision Tree Regression*.

3.2 Materiais

Este trabalho foi executado com experimentos de usinagem feitos em Centro de Usinagem CNC Feeler VMP-30A (figura 1), utilizando como material um bloco de aço SAE 1045 e uma fresa insertada com 2 arestas de corte e 16 mm de diâmetro. Para obtenção de dados, foi utilizado um aparelho *smartphone* iPhone modelo 7 com o aplicativo *Sci Journal* da Google instalado. Para a medição dos parâmetros de qualidade da peça usinada, foi utilizado um Rugosímetro Portátil SJ-310 da fabricante Mitutoyo.

Figura 1 – Centro de Usinagem CNC Feeler VMP-30A.



Fonte: Imagem obtida pelo autor.

3.3 Método de trabalho

3.3.1 Planejamento do experimento

Para obtenção dos dados necessários para o desenvolvimento deste trabalho, organizou-se o experimento de usinagem com os seguintes parâmetros da Tabela 1:

Tabela 1 – Parâmetros de usinagem utilizados no experimento.

Parâmetros de processo	Nível 1	Nível 2	Nível 3
Profundidade [mm]	0,1	0,3	0,5
Avanço [mm/mim]	500	1000	2000
Rotação da ferramenta [RPM]	1000	2500	5000

Com esses parâmetros, foram realizadas usinagens com pares de avanço e rotação, variando as três profundidades de corte, totalizando 9 combinações (3x3). Todas as usinagens percorreram o mesmo percurso de 100 mm no bloco de aço. Para obter mais dados e garantir o treinamento e a validação do algoritmo a ser desenvolvido, cada combinação foi realizada 3 vezes. Desta forma, foram realizadas 27 usinagens para obtenção de dados. Os testes ficaram organizadas conforme a Tabela 2.

Tabela 2 – Organização do experimento.

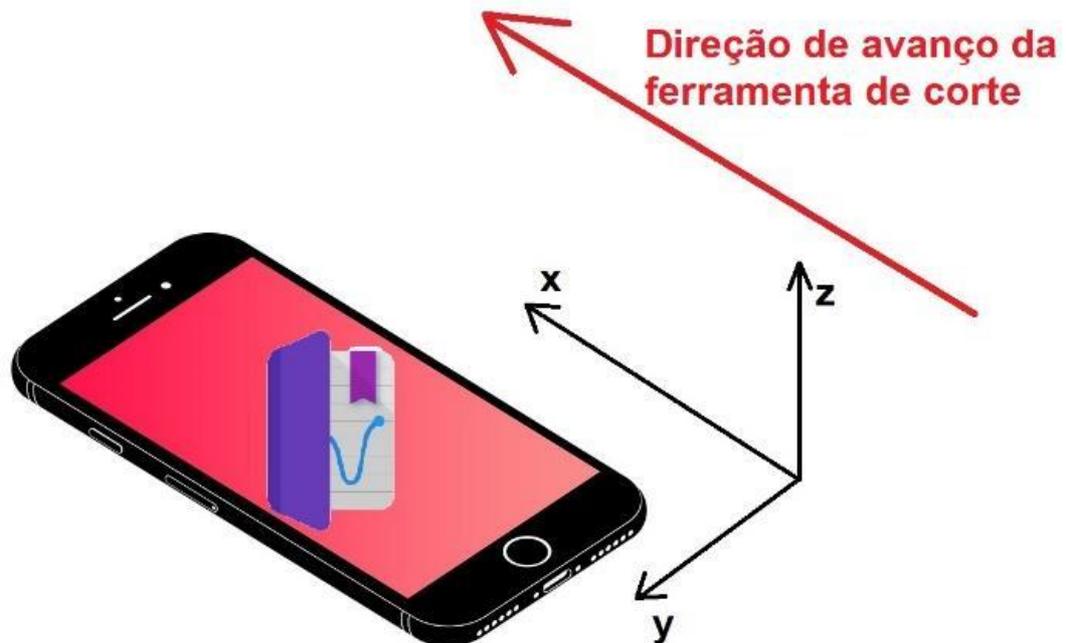
Teste	Profundidade (mm)	RPM	Avanço (mm/min)
1	0,1	2500	1000
2	0,1	2500	1000
3	0,1	2500	1000
4	0,3	2500	1000
5	0,3	2500	1000
6	0,3	2500	1000
7	0,5	2500	1000
8	0,5	2500	1000
9	0,5	2500	1000
10	0,1	5000	500
11	0,1	5000	500
12	0,1	5000	500
13	0,3	5000	500
14	0,3	5000	500
15	0,3	5000	500
16	0,5	5000	500

17	0,5	5000	500
18	0,5	5000	500
19	0,1	1000	2000
20	0,1	1000	2000
21	0,1	1000	2000
22	0,3	1000	2000
23	0,3	1000	2000
24	0,3	1000	2000
25	0,5	1000	2000
26	0,5	1000	2000
27	0,5	1000	2000

3.3.2 Obtenção dos dados

Para a obtenção dos dados, o aparelho *smartphone* iPhone 7 foi fixado junto a morsa de fixação da peça do centro de usinagem, de forma que os eixos utilizados pelo aplicativo Sci Journal para medir vibração ficassem alinhados conforme a Figura 2:

Figura 2 – Orientação dos eixos de medição do app *Sci Journal* e do aparelho iPhone 7 em relação à direção de usinagem.



Fonte: Imagem obtida pelo autor.

O aplicativo foi configurado para que em cada teste fossem gravadas as informações referentes as vibrações nos eixos x, y e z, além da vibração linear. A vibração linear, por definição do *Science Journal*, é a combinação instantânea das vibrações nos 3 eixos descontada a influência da aceleração da gravidade.

3.3.3 Construção do código do modelo de *Decision Tree Regression*

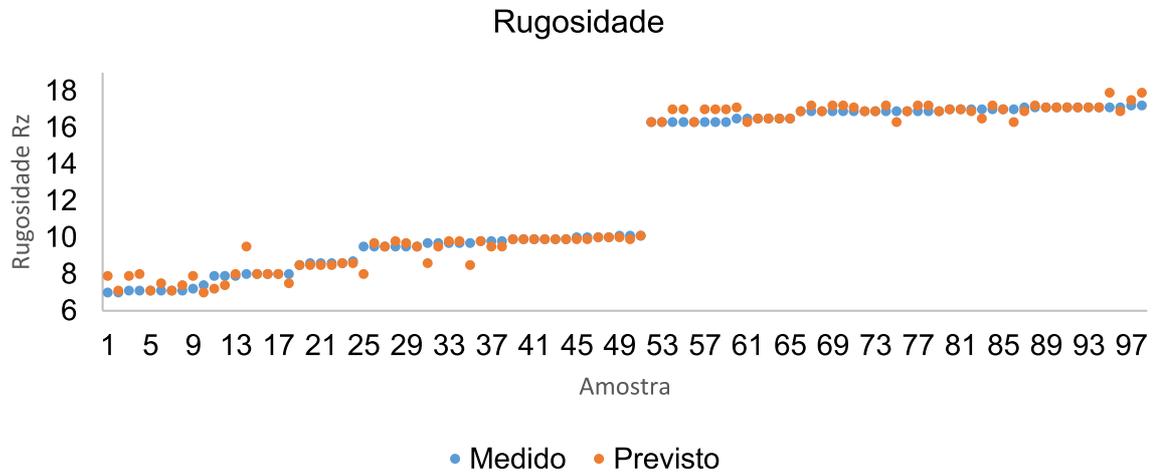
Para executar a modelagem do problema, foi criado um código de programação em linguagem *Python* para a aplicação do algoritmo de *Machine Learning*. Este código foi baseado na plataforma *scikit.learn* com o módulo *decision.tree.regressor*. Como parâmetros do modelo, foi utilizada como cost function o Erro Quadrático Médio (*MSE* em inglês). Como método de treinamento e de teste de validação do modelo, foi utilizada a validação cruzada “stratified k-fold” com 10 divisões, disponível também no *scikit.learn* como módulo *StratifiedKfold*. Cada iteração do código com a sua respectiva divisão de dados de treinamento e de validação, gerava uma única árvore com quantidade máxima de folhas limitada pela pureza dos dados ou por conter apenas uma amostra em cada folha. Demais parâmetros do DTR foram configurados conforme o default do módulo do *scikit.learn*.

Neste trabalho, não foram executadas podas no modelo para regularização ou ajuste de *overfitting*. Para avaliar a acurácia de previsão do algoritmo de regressão, utilizou-se o MAPE (mean absolute percentage error - Média Percentual Absoluta do Erro), onde mede-se em porcentagem o erro da previsão em relação aos dados já conhecidos. O código escrito para este trabalho encontra-se nos anexos.

4 RESULTADOS

Após o planejamento dos experimentos, foram executados 27 testes de usinagem e os dados gravados pelo aplicativo Sci Journal. Com os dados obtidos, disponibilizou-se as informações ao modelo de *Machine Learning* desenvolvido e foi executada a modelagem (treinamento). No Gráfico 1, temos a comparação entre do resultado medido durante o experimento com o resultado previsto pelo modelo de *Decision Tree Regression* para a rugosidade da peça.

Gráfico 1 – Comparação entre os valores de rugosidade obtidos no teste do algoritmo e os valores medidos.



Fonte: Elaborado pelo autor.

Para verificar a eficiência previsão do algoritmo de previsão, foi calculada a precisão por meio da comparação dos valores previstos em relação aos valores reais das principais características de saída do modelo, apresentado na Tabela 3.

Tabela 3 – Precisão dos resultados previstos pelo modelo *Decision Tree Regression*.

Variável de saída	Precisão
Rotação [RPM]	96,78%
Avanço [mm/min]	96,64%
Rugosidade [μm]	96,15%

5 DISCUSSÃO:

Com os resultados obtidos pelo algoritmo *Decision Tree Regression*, observou-se uma precisão do modelo de 96,15% para a previsão da rugosidade da peça a partir das vibrações medidas pelo aplicativo *Sci Journal*. Este erro poderia ser diminuído com o aumento de dados obtidos para o treinamento do algoritmo, já que uma quantidade maior de informações utilizadas para treinar o modelo de *Decision Tree Regression*, torna-o mais robusto e preciso. Além disso, pode-se levar em

consideração erros relativos a incertezas de medição pelo *software* e os sensores utilizados do smartphone utilizado para obtenção das vibrações.

Desta forma, pode-se afirmar que o *Sci Journal* é eficaz para obtenção de dados de máquinas. Sendo a utilização deste aplicativo como protótipo de sistemas dedicados de obtenção de dados. Testando a viabilidade e a relevância dos dados obtidos do processo, diminuindo riscos e gastos desnecessários com sistemas mais precisos e dedicados para coleta de informações. Além disso, conclui-se que o algoritmo de *Machine Learning Decision Tree Regression* pode processar os dados para obtermos um sistema de previsão de parâmetros de qualidade e de determinação de parâmetros de processos a partir de dados de entrada do processo de usinagem, como a vibração.

6 CONCLUSÃO:

Com este trabalho, pode-se afirmar que o aplicativo *Sci Journal* é eficaz para obtenção de dados de máquinas através dos acelerômetros presente em um aparelho de celular comum do mercado. Além disso, conclui-se que o algoritmo de *Machine Learning Decision Tree Regression* pode gerar um modelo com múltiplas saídas a partir do treinamento com dados conhecidos. Neste trabalho, o algoritmo se mostrou eficaz para a previsão de parâmetros de qualidade e de determinação de parâmetros de processos a partir de dados de entrada do processo de usinagem, como a vibração.

7 TRABALHOS FUTUROS:

Este trabalho abre a possibilidade de estudos na área de manutenção de máquinas utilizando a predição por *Machine Learning* com obtenção de dados através de sensores de um *Smartphone*. Também pode-se determinar um parâmetro ótimo para o processo em vista da qualidade e do desempenho do processo, fazendo com que o equipamento realize ajustes automáticos baseado no estado instantâneo do processo de usinagem. E por último, pode-se estudar o desempenho de ferramentas de corte e a determinação do fim de vida útil, visando garantir a qualidade da peça produzida e o máximo desempenho da ferramenta, gerando redução de custo com a utilização máxima que a aresta de corte possibilita. Quanto a metodologia, pode-se testar modelos de previsão diferentes, como Rede Neural e Random Forest.

REFERÊNCIAS

- BABICEANU, R. F.; SEKER, R. Big Data and virtualization for manufacturing cyber-physical systems: A survey of the current status and future outlook. *Computers in Industry*, [s. l.], v. 81, n. 2015, p. 128–137, 2016.
- BAUERDICK, C. J. H. et al. An automated procedure for workpiece quality monitoring based on machine drive-based signals in machine tools. In: *PROCEDIA CIRP 2018, Anais...* [s.l: s.n.] , 2018.
- CANIZO, M. et al. Real-time predictive maintenance for wind turbines using Big Data frameworks. In: *2017 IEEE INTERNATIONAL CONFERENCE ON PROGNOSTICS AND HEALTH MANAGEMENT (ICPHM) 2017, Anais...*: IEEE, 2017.
- DOWNEY, J. et al. Real Time Monitoring of the CNC Process in a Production Environment- the Data Collection & Analysis Phase. *Procedia CIRP*, [s. l.], v. 41, p. 920–926, 2016.
- GIL, A. C. Como elaborar projetos de pesquisa. 4. ed. São Paulo: Atlas, 2007.
- GITTLER, T. et al. A fundamental approach for data acquisition on machine tools as enabler for analytical Industrie 4.0 applications. *Procedia CIRP*, [s. l.], v. 79, p. 586–591, 2019.
- HAN, J.; KAMBER, M.; PEI, J. *Data Mining: Concepts and Techniques (The Morgan Kaufmann Series in Data Management Systems)*. Terceira Ed. [S. l.], Morgan Kaufmann, 2011.
- KAGERMANN, H. Change Through Digitization—Value Creation in the Age of Industry 4.0. In: *Management of Permanent Change*. Wiesbaden: Springer Fachmedien Wiesbaden, 2015. p. 23–45.
- LENZ, J.; WUEST, T.; WESTKÄMPER, E. Holistic approach to machine tool data analytics. *Journal of Manufacturing Systems*, [s. l.], v. 48, p. 180–191, 2018.
- LIU, C.; XU, X. Cyber-Physical Machine Tool – the Era of Machine Tool 4.0. *Procedia CIRP*, [s. l.], v. 63, p. 70–75, 2017.
- MUHURI, P. K.; SHUKLA, A. K.; ABRAHAM, A. Industry 4.0: A bibliometric analysis and detailed overview. *Engineering Applications of Artificial Intelligence*, [s. l.], 2019.
- PEDREGOSA et al., *Scikit-learn: Machine Learning in Python*, *JMLR* 12, [s. l.], p. 2825-2830, 2011.
- SWETAPADMA, A.; YADAV, A. A Novel Decision Tree Regression-Based Fault Distance Estimation Scheme for Transmission Lines. *IEEE Transactions on Power Delivery*, [s. l.], v. 32, n. 1, p. 234–245, 2017.
- WANG, W. et al. Open CNC Machine Tool's State Data Acquisition and Application Based on OPC Specification. In: *PROCEDIA CIRP 2016, Anais...* [s.l: s.n.], 2016.

ANEXOS

```
#Código de Machine Learning com algoritmo DTR – Matheus Ramage Paz
import pandas as pd
import numpy as np
from sklearn import model_selection
features = pd.read_csv('features.csv')
labels = pd.read_csv('rredlabels.csv')
feature_list = list(features.columns)
from sklearn.model_selection import StratifiedKFold
cv=10
kf = StratifiedKFold(n_splits=cv, shuffle=True, random_state=0)
kf.get_n_splits(features, labels)
from sklearn.tree import DecisionTreeRegressor
dtr = DecisionTreeRegressor(criterion='mse', splitter='best', max_depth=None,
min_samples_split=2, min_samples_leaf=1, min_weight_fraction_leaf=0.0, max_features='auto',
random_state=None, max_leaf_nodes=None, min_impurity_decrease=0.0, min_impurity_split=None,
presort=True)
dtr.fit(features,labels)
predictions=dtr.predict(features)
errors = abs(predictions - labels)
mape = 100 * (errors / labels)
from sklearn.model_selection import cross_val_score
score = model_selection.cross_val_score(dtr, features, labels, cv=cv)
print ('This is the cross validation score:', score.mean())
print ('This is the MAPE (mean absolute percentage error) of the regression:', mape.mean())
accuracy = 100 - np.mean(mape)
print('Accuracy:', round(accuracy, 2), '%.')
```