

UTILIZAÇÃO DE UM ALGORITMO DE INTELIGENCIA ARTIFICIAL PARA DETECÇÃO DE DESGASTE EM FERRAMENTAS DE USINAGEM

Fernando da Costa Freitas¹, Ed Cláudio Bordinassi²

¹ Aluno de Iniciação Científica da Escola de Engenharia Mauá (EEM/CEUN-IMT);

² Professor da Escola de Engenharia Mauá (EEM/CEUN-IMT).

Resumo. *O objetivo deste trabalho foi identificar o ponto de troca de um inserto de metal duro em um centro de torneamento, através de dados coletados durante a fabricação, utilizando protocolo de comunicação MTConnect. Foram realizados 80 ensaios através de um planejamento experimental, utilizando delineamento composto central e variando os parâmetros de corte: velocidade de corte (150-200 m/min), avanço (0,2-0,3 mm/rot), profundidade de corte (1-2 mm), fluido de corte (em abundância e sem fluido). Os dados coletados foram as potências nos motores de acionamento dos eixos da máquina (eixo árvore, eixo X e eixo Z), durante o torneamento do aço AISI P20 e aço AISI 1045, com pastilhas novas e com desgaste na aresta principal ($V_b=0,3$ mm). Para analisar os dados foi utilizada a Rede Neural tipo OLAM. Os resultados mostraram uma porcentagem de acerto de 70%, mostrando a aplicação viável para a identificação do ponto de troca. Este modelo pode ser útil no monitoramento da máquina utilizando conceitos da Indústria 4.0, onde um dos principais desafios é encontrar o ponto de troca da ferramenta que na maioria das vezes depende 100% do operador.*

Introdução

A chamada manufatura inteligente das indústrias foi nomeada como a quarta revolução industrial ou a Indústria 4.0, o crescimento e amadurecimento evolutivo das novas Tecnologias de Informação e Comunicação (TIC) aliada a processos e produtos industriais impulsionaram uma modificação de modelo (Lindström et al, 2019). Para a ciência de dados, essa transformação de modelo possibilita a retirada de conhecimento importante de trabalhos monitorados, admissão de procedimentos eficientes de monitoramento e agregação de dados, assim como a utilização de métodos de *Machine learning* e aperfeiçoamento. Um dos fundamentos da ciência de dados nesta situação é antecipar com melhor precisão os procedimentos no maquinário industrial, ferramentas e processos, com isso conseguindo prever eventualidades e danos, que porventura podem causar graves perdas em questões econômicas e de segurança. Nessa situação, a estimativa orientada por dados está gradativamente conquistando atenção em vários setores das indústrias. (Diez-Olivan et al, 2019).

Segundo (Moreira et al, 2019). Recentemente, pesquisadores utilizam novos métodos para obter resultados melhores em usinagens CNC. Abordagens empíricas foram utilizadas como moldes para observar as correlações entre a rugosidade superficial e os parâmetros de usinagem. Inovações empíricas (baseadas em experiências vividas) foram determinadas para que houvesse um avanço de controle otimizado, e grande parte foi formada através do big data e da Inteligência Artificial (IA).

O big data especula vastos conteúdos de dados para conseguir decifrar padrões. Além dos dados, outro elemento do big data é conhecido como “Machine Learning” (ML), conhecida como inteligência artificial (IA). Diversas tecnologias são usadas para reconhecer padrões, partindo dos dados que englobam especificação ou prognóstico de eventos e, em seguida, aplicam a saída de software a um dever específico. Este conhecimento tem sido utilizado com êxito em domínios que, há pouco tempo parecia improvável usar casos, por exemplo, o Jeopardy e o jogo de tabuleiro GO. Sistemas computacionais comuns se diferenciam da IA, à proporção que, no primeiro, as normas são determinadas por especialistas e introduzidas nos computadores como algoritmos simplificados. Com a IA, os dados são sustentados nos

computadores, e estes “desvendam” através de algoritmos sofisticados e, assim, geram as regras. Ademais, os computadores analisam incessantemente as regras e as recalibram de acordo com a necessidade (Reiz et al, 2019).

O “machine learning” vem tendo um rumo cada vez mais conhecido no mundo atual, tendo em vista que seu propósito mais habitual é aprimorar os sistemas, assim possibilitando um uso mais inteligente de produtos e serviços. Na manufatura, o conhecimento das máquinas pode acarretar à uma diminuição de despesa, menor custo com tempo desnecessário, elevação da qualidade e diminuição de desperdício (Preez et al., 2019). Concomitantemente, possibilita que os sistemas sejam criados com o propósito de administrar o comportamento do homem (Shang e You, 2019).

Técnicas de análise de regressão não linear são usadas para estabelecer modelos com o intuito de determinação do desgaste e vida útil da ferramenta em termos da variação de uma razão de componentes de força que atuam na ponta da ferramenta. (Oraby e Hayhurst, 2004)

O objetivo deste trabalho é reconhecer o momento em que se deve efetuar a troca do inserto em um centro de torneamento. Dentro da indústria, em grande parte das vezes só irá depender do operador. Para isso foi necessário criar um banco de dados, por meio de dados coletados antes e no decorrer do processo de fabricação, empregando o protocolo de comunicação MTConnect.

Materiais e métodos

Tabela Composição Química do aço P20

Para a realização dos ensaios foram utilizados os materiais: aço AISI P20 e aço AISI 1045.

Para haver um padrão todos os corpos de prova foram usinados com diâmetro 50 mm e um comprimento 100 mm. A Figura 1 mostra a imagem de um dos corpos de prova




Figura 1 - Corpo de prova utilizado nos ensaios

Para a determinação da dureza de cada material, utilizou-se o teste de dureza de Vickers, e para isso foram feitos 5 ensaios utilizando-se a média, com isso pode-se determinar a dureza de cada material como mostra tabela 1.

Tabela 1 – Resultados de dureza em Vickers para cada material.

Material	Amostra 1	Amostra 2	Amostra 3	Amostra 4	Amostra 5	Média
aço AISI P20	284	294	296	294	284	290,4
aço AISI 1045	221	224	232	233	221	226,2

A Figura 2 mostra o durômetro utilizado para as medições de dureza.




Figura 2 – Durômetro utilizado para realizar o teste de dureza com ponta de diamante

A realização da usinagem foi feita no Centro de Torneamento Mazak QUICK TURN 250 MA. A Figura 3 mostra a máquina utilizada.



Figura 3 – Centro de Torneamento Mazak

Para a coleta de dados foram utilizados insertos novos e com desgaste $V_b=0,3$ mm para simular uma condição de desgaste. O inserto utilizado foi fornecido pela Sandvik, modelo CNMG 120408 PM e suporte Coromant Capto. A Figura 4 mostra imagens para as duas condições de aresta.

Para a avaliação do desgaste ($V_B=0,3$ mm) foi utilizado um microscópio digital com conexão em um computador para o acompanhamento do processo, o mesmo tem uma ampliação de até 500x com escala com divisão de 0,01mm.

Algumas características do inserto:

- Fabricante: Sandvik
- Formato e tamanho da pastilha: CN1204
- Diâmetro do círculo inscrito: 12,7 mm
- Código do formato da pastilha: C
- Comprimento efetivo da aresta de corte: 12,096 mm
- Raio do canto: 0,794 mm
- Sentido: N
- Classe: 4325
- Espessura da pastilha: 4,763 mm
- Peso do item: 0,01 kg



Figura 4 – Inserto novo e aresta com desgaste ($V_b=0,3$ mm)

O suporte da pastilha usado foi o suporte, capto sandvik c4-dclnl-27050-12
Algumas características do suporte:

- Ângulo de posição principal: 95 deg
- Ângulo de ataque da ferramenta: -5 deg

- Balanço máximo: 50 mm
- Pressão de refrigeração: 10 bar
- Diâmetro da conexão: 40 mm
- Comprimento funcional: 50 mm
- Largura funcional: 27 mm
- Torque: 3,9 Nm
- Peso do item: 0,44 kg

Para a coletar os dados da Máquina foi utilizado um código no MatLab®, apresentado abaixo.

```

clc;clear;close all
%%-----%
%-----%

Ensaio=12;           %Número do ensaio
Nome='Pastilha com lubrificação com VB00'; % NOME DO ENSAIO
vc=200 %Velocidade de corte do ensaio
fn=0.334;          %Avanço do ensaio
ap=1.5;           %Profundidade de corte do ensaio.
Tempo=20;         %Tempo de duração do ensaio aproximado em segundos
Amostragem=3;    %Leituras por segundo

%-----%
%%-----%

```

Resultados e discussões

As Tabelas 2 e 3 a seguir mostram uma parcela da coleta de dados realizada. Nelas temos os valores preestabelecidos como velocidade de corte e com isso tivemos os seguintes resultados, carga no eixo arvore (CC), carga no eixo x (CCX), carga no eixo z (CCZ), potência requerida do motor (Pm) e rotação (RPM). Temos a maior rotação no teste 10 da tabela 3 já a menor está no teste 9 da tabela 2.

As Figuras 5 e 6 a seguir mostram exemplos dos dados coletados nas aquisições, para os ensaios 4 com e sem desgaste, nelas temos as cargas em cada eixo e a temperatura na pastilha. Houve uma grande variação das cargas CCX e CCZ (azul claro e preto).

Tabela 2 - Medias de cada ensaio para aço P20 para pastilha lubrificada com VB00.

Teste	PtType	Blocks	vc	f	ap	CC	CCX	CCZ	Pm	RPM
1	1	1	150	0,2	1	19,62	26,37	11	2,16	2512
2	1	1	250	0,2	1	21	27,95	12	2,31	1768
3	1	1	150	0,3	1	19	25	11	2,09	1836
4	1	1	250	0,3	1	33,37	35,69	15,48	3,67	2899
5	1	1	150	0,2	2	26,94	26	15	2,9315	1338
6	1	1	250	0,2	2	42	26	15	4,62	2411
7	1	1	150	0,3	2	52,87	26,2	17,02	4,969	1183
8	1	1	250	0,3	2	41,37	32,24	13,06	4,52	1683
9	-1	1	116	0,25	1,5	32,94	23	16	2,470	758
10	-1	1	116	0,25	1,5	45,13	27,61	11,26	4,96	3930
11	-1	1	200	0,17	1,5	25,6	26,36	14	2,82	2357
12	-1	1	200	0,334	1,5	38	23	15	4,18	1354
13	-1	1	200	0,25	0,659	15	30	9	1,65	1457
14	-1	1	200	0,25	2,341	42,31	29	18	4,65	2053
15	0	1	200	0,25	1,5	31,29	29,97	34,22	3,37	2096
16	0	1	200	0,25	1,5	32,61	26,39	12,61	3,59	3031
17	0	1	200	0,25	1,5	35	27,25	14,25	3,85	2664
18	0	1	200	0,25	1,5	32,67	29,52	17,67	3,51	1428
19	0	1	200	0,25	1,5	34,56	27,06	13,75	3,8	2110
20	0	1	200	0,25	1,5	3033	32,7	20,65	3,32	1344

Tabela 3- Medias de cada ensaio para aço P20 para pastilha não lubrificada com VB00.

Teste	PtType	Blocks	vc	f	ap	CC	CCX	CCZ	Pm	RPM
1	1	1	150	0,2	1	26	22	15	1,959	994
2	1	1	250	0,2	1	27	22	13	2,97	1768
3	1	1	150	0,3	1	24,266	23,5333	34,933	2,497	1847
4	1	1	250	0,3	1	45,058	23,235	11	4,485	4420
5	1	1	150	0,2	2	30,076	21	18	3,308	1460
6	1	1	250	0,2	2	47,333	24,8333	22	5,206	2391
7	1	1	150	0,3	2	61,531	20,0425	20,659	5,792	1190
8	1	1	250	0,3	2	65,285	20	17,571	6,786	1967
9	-1	1	116	0,25	1,5	24,052	27,3684	32	2,446	1872
10	-1	1	116	0,25	1,5	68	23	18	6,619	4520
11	-1	1	200	0,17	1,5	30	24	19	3,3	2122
12	-1	1	200	0,334	1,5	39,941	21,0294	16,470	4,393	1507
13	-1	1	200	0,25	0,65	17,45	24,175	11,825	1,919	1563
14	-1	1	200	0,25	2,34	52,555	21	21	5,781	2273
15	0	1	200	0,25	1,5	39,346	20	16	4,328	2546
16	0	1	200	0,25	1,5	42	23	20	4,62	3031
17	0	1	200	0,25	1,5	38	21	19	4,18	2652
18	0	1	200	0,25	1,5	34	19	17	3,74	1446
19	0	1	200	0,25	1,5	33,475	24,475	21,65	3,682	1697
20	0	1	200	0,25	1,5	33,62	18,94	17,9	3,698	1354




Figura 5 - Gráfico do 4º ensaio para a pastilha com Vb 00 e lubrificada no aço AISI P20




Figura 6 - Gráfico do 4º ensaio para a pastilha com Vb 03 e lubrificada no aço AISI P20

Uma rede neural linear OLAM (optimal linear associative memory) foi programada a partir dos resultados dos testes extraídos na usinagem. O objetivo era prever se o desgaste da ferramenta estava ou não presente durante o processo de usinagem.

Para o modelo OLAM foram coletados dados durante as execuções CC, CCX, CCZ, Pm, RPM mais os parâmetros de entrada do fluido de corte das execuções, vc, f, ap e VB.

A rede neural da OLAM mostrou taxas razoáveis de acertos em geral. O índice foi o mais alto de 90%. O pior caso foi sem fluido de corte e inserto de ferramenta desgastado, o índice foi de 65%, o

que é um excelente resultado, pois a avaliação do desgaste da ferramenta no chão de fábrica nem sempre é fácil para o operador da máquina executar.

Tabela 4 – Media da potência utilizada em cada eixo da máquina e a porcentagem de acerto do programa.

Ensaio	Desvio Padrão				Acertos
	CC	CCX	CCZ	Pm	
Fluído de corte: Não Desgaste: VB=0	11,70	1,48	1,82	1,21	85%
Fluído de corte: Sim Desgaste: VB=0	9,60	3,16	5,25	1,00	90%
Fluído de corte: Não Desgaste: VB=0,3	11,41	6,99	8,10	1,21	65%
Fluído de corte: Sim Desgaste: VB=0,3	14,15	2,19	5,80	1,43	80%

O resultado mais baixo (65%) pode ser explicado pelas pequenas variações do desgaste e também por ser a condição mais crítica nos testes pois a ferramenta já está trabalhando com o desgaste e sem o fluído de corte.

Conclusões

A aplicação do MTConnect na CNC, apesar do sistema ter uma baixa frequência de aquisição de dados (1Hz), ele se mostrou valido para a aplicação.

O sistema conseguiu antecipar os resultados com uma certeza mínima de 65%, apropriada, para o número de testes que foram realizados e as variações quando comparadas as pastilhas com desgaste (VB = 0,3). Com esses resultados pode-se aplicar o sistema para supervisionar e alertar o operador em qual momento deverá ser realizada a troca do inserto em uma máquina. Com isso se ganhará tempo pois haverá uma grande diminuição de paradas para avaliação do inserto, na questão econômica irá haver uma diminuição de peças com defeitos devido ao desgaste e também com um descarte de insertos mais controlado.

Referências

- Diez-Olivan, A.; Ser, J. D.; Galar, D.; Sierra, B. (2019). Data fusion and machine learning for industrial prognosis: Trends and perspectives towards Industry 4.0. *Information Fusion*, 50, 92-111.
- Lindström, J.; Lejon, E.; Kyösti, P.; Mecella, M.; Heutelbeck, D.; Hemmje, M.; Sjödaahl, M.; Birk, W.; Gunnarsson, B. (2019). Towards intelligent and sustainable production systems with a zero-defect manufacturing approach in an Industry4.0 context. *Procedia CIRP*, 81, 880-885.
- Moreira, L. C.; Li, W. D.; X. Lu; Fitzpatrick, M. E. (2019). Supervision controller for real-time surface quality assurance in CNC machining using artificial intelligence. *Computers & Industrial Engineering*, 127, 158-168.
- Preez, A.; Oosthuizen, G. A. (2019). Machine learning in cutting processes as enabler for smart sustainable manufacturing. *Procedia Manufacturing*, 33, 810-817.

- Reiz, A. N.; Sagasti, F. M.; González, M. Á.; Malpica, A. B.; Benítez, J. C. M.; Cabrera, M. N.; Ramírez, A. P.; Perdomo, J. M. G.; Alonso, J. P.; Celi, L. A.; Hoz, M. Á. A.; Deliberato, R.; Paik, K.; Pollard, T.; Raffa, J.; Torres, F.; Mayol, J.; Lombroni, I.; Hernandez, L.; López, L.; Merino, B.; Cabrera, M. F.; Arredondo, M. T.; Bodí, M.; Gómez, J.; Rodríguez, A.; García, M. S. (2019). Big data and machine learning in critical care: Opportunities for collaborative research. *Medicina Intensiva*, 43, 52-57.
- Shang,C.; You,F. (2019). Data Analytics and Machine Learning for Smart Process Manufacturing: Recent Advances and Perspectives in the Big Data Era. *Engineering*, In Press, Corrected Proof.
- Oraby, S.E.; Hayhurst, D.R. (2004). Tool life determination based on the measurement of wear and tool force ratio variation. *International Journal of Machine Tools and Manufacture*, 44, 1261-1269.
- <https://www.sandvik.coromant.com/pt-pt/products/Pages/productdetails.aspx?c=CNMG%2012%2004%2008-PMC%20%20%204325>(acessado em 23/08/19)
- <https://www.sandvik.coromant.com/pt-pt/products/pages/productdetails.aspx?c=C4-DCLNL-27050-12>(acessado em 23/08/19)