

OTIMIZAÇÃO MULTIOBJETIVO EVOLUTIVA DO PROCESSO DE TORNEAMENTO INTERNO EM TUBOS DE PEEK

Jéssica Tito Vieira, jessica.tito@hotmail.com¹
Robson Bruno Dutra Pereira, robsondutra@ufs.br²
Lincoln Cardoso Brandão, lincoln@ufs.br²
Carlos Henrique Lauro, carloslauro@ufs.br²
João Roberto Ferreira, jorofe@unifei.edu.br¹

¹Universidade Federal de Itajubá, Av. BPS, 1303, Bairro Pinheirinho, Itajubá – MG

²Universidade Federal de São João del-Rei, Praça Frei Orlando, 170, Centro, São João del-Rei -MG

Resumo: O torneamento interno é uma operação de usinagem que visa aumentar o diâmetro interno de um furo pré-existente e a qualidade desse processo é dependente do sistema composto por máquina, conjunto de fixação, ferramenta e material da peça. Aumentam-se ainda os desafios à obtenção da qualidade desejada com elevada exatidão se o processo de torneamento interno for empregado em materiais inovadores, como os termoplásticos de alto desempenho. O poli éter-éter-ketona (PEEK) é considerado um dos termoplásticos mais importantes e os produtos fabricados com tubos desse material podem suportar temperaturas de serviço na faixa de -50 ° C a 260 ° C, mantendo a alta resistência mecânica. O objetivo do presente trabalho foi estudar a otimização multi-objetivo evolutiva do processo de torneamento interno em tubos de PEEK e comparar o método de modelagem tradicional (metodologia de superfície de resposta) com o método não paramétrico (bagging). Ensaios foram realizados seguindo um planejamento composto central com adição de pontos aleatórios na região experimental, viabilizando a obtenção de modelos de regressão com métodos estatísticos/computacionais mais flexíveis. Os parâmetros de entrada considerados foram a velocidade de corte (v_c), avanço (f) e posição de fixação do tubo na placa (f_p). A resposta analisada foi a rugosidade máxima (R_z) que é uma medida de amplitude do perfil amostrado filtrado. Por meio dos valores de RMSE (Root Mean Squared Error), do coeficiente de determinação R^2 e do MAE (Mean Absolute Error), observou-se que o método baseado em árvores de regressão (bagging) mostrou-se superior à metodologia de superfície de resposta para a modelagem dos dados. Por fim, foi utilizado o método de otimização multi-objetivo evolutivo NSGA-II para determinar um conjunto de soluções pareto ótimas para as respostas de acabamento e de produtividade. As soluções encontradas possibilitam ao experimentador explorar diferentes cenários de qualidade e produtividade, de forma que o experimentador deve selecionar os níveis dos parâmetros ótimos $x^* = [v_c^*, f^*, f_p^*]$ para uma determinada situação de planejamento.

Palavras-chave: torneamento interno, PEEK, aprendizagem estatística, bagging, otimização multiobjetivo evolutiva.

1. INTRODUÇÃO

O torneamento interno é uma operação de usinagem que visa aumentar o diâmetro interno de um furo pré-existente (SUYAMA; DINIZ; PEDERIVA, 2017). A qualidade de uma operação de usinagem interna é determinada pela rigidez, estática e dinâmica, do sistema composto por máquina, sistema de fixação, ferramenta e peça (SUYAMA; DINIZ; PEDERIVA, 2016).

Os tubos de PEEK são fáceis de usinar sem a necessidade de equipamentos especializados. A maioria das aplicações de usinagem interna em tubos de PEEK nas indústrias aeroespacial, biomédica, petróleo e gás necessitam de uma tolerância geométrica e de uma qualidade superficial específica para o bom funcionamento do componente, caso essas especificações não são atingidas, danos e prejuízos podem ser gerados.

No torneamento, ferramentas de corte, parâmetros de corte são os principais parâmetros que afetam a usinabilidade do PEEK e seus compósitos (OZDEN; OTEYAKA; CABRERA, 2021). Assim, modelos adequados para prever as características de saída do processo devem ser desenvolvidos. A modelagem e otimização do processo de torneamento interno são úteis para selecionar os níveis ideais de condições de corte para alcançar a estabilidade do processo e, consequentemente, a capacidade de atender às especificações do produto (VIEIRA et al., 2021).

A metodologia de superfície de resposta (RSM) tem sido amplamente aplicada para modelagem de processos projetados para permitir a otimização. Como os modelos RSM são de regressão múltipla de segunda ordem, eles são baseados na estimativa paramétrica clássica. Para obter a melhor aproximação das saídas e dos parâmetros do processo, a modelagem tem sido realizada por meio de uma abordagem de aprendizado estatístico.

Os métodos de aprendizado se concentram na estimativa de modelos não paramétricos com boa capacidade de generalização, em oposição à metodologia de estimativa de modelos sob suposições estatísticas. A teoria de tais

abordagens é chamada de Teoria da Aprendizagem Estatística ou teoria de Vapnik-Chervonenkis (VC) (CHERKASSKY; MULIER, 2007).

O aprendizado estatístico busca aproximar dados populacionais por meio de poucos, mas suficientes, dados amostrais. Para garantir uma boa precisão das funções estimadas, a validação cruzada é realizada. Por meio da validação cruzada, é possível estimar o modelo por meio da fração amostral reservada para os dados de treinamento e prever a capacidade do modelo com a fração amostral separada para teste.

Métodos baseados em árvore são simples e úteis para interpretação. A abordagem de árvores de classificação e regressão (CART) foi proposta por Breiman et al. (1984). Esses métodos envolvem segmentar o espaço preditor em várias regiões retangulares simples e toma como predição a média ou outra medida simples das observações de treinamento nessa região. Como o conjunto de regras de divisão usado para segmentar o espaço do preditor pode ser resumido em um diagrama semelhante a uma árvore, essas abordagens são conhecidas como métodos de árvore de decisão (JAMES et al., 2013). A Figura 1 ilustra o procedimento de árvore de regressão bagging.




Figura 1. Árvores de regressão bagging.
 (Fonte: próprio autor.)

A maioria dos problemas reais requer a otimização simultânea de múltiplos objetivos e refere-se à otimização de um conjunto de m funções objetivos de interesse. A solução ótima de um problema de otimização multiobjetivo não é única, ela é comumente associada à construção da fronteira de Pareto (MARTÍNEZ et al., 2009).

Os algoritmos evolutivos multiobjetivos são conhecidos por compor abordagens competitivas para problemas de otimização multiobjetivo, uma vez que podem atingir um conjunto ótimo de Pareto em uma única execução, devido à sua estratégia populacional de explorar o espaço de projeto viável (DEB, 2015).

O método NSGA-II (Non-dominated Sorting Genetic Algorithm II) proposto por Deb et al. (2002) é a segunda versão do NSGA de Srinivas e Deb (1994), e foi proposto para resolver problemas multi-objetivos, ou seja, problemas com até três objetivos conflitantes. A estrutura do método é ilustrada na Figura 2, de forma a facilitar o entendimento do processo de otimização.




Figura 2. NSGA II.
 (DEB et al., 2002)

2. MATERIAIS E MÉTODOS

Os experimentos de torneamento interno foram realizados no laboratório de fabricação do DEMEP/UFSJ em um centro de torneamento ROMI GL 240-M com velocidade de avanço rápido longitudinal e transversal de 30 m/min, rotação máxima de 6.000 rpm e potência máxima na árvore de 22,5 kW, sendo programado por um comando CNC Fanuc Oi TD.

A Figura 3 ilustra o setup experimental onde utilizou-se uma barra de mandrilar com o código ISO A20S-STFCL 11 e uma ferramenta para o torneamento interno com o código ISO TCMT 11 03 04-KM H13A. Os corpos de prova utilizados nos experimentos foram provenientes de tubos de PEEK com 1.000 mm de comprimento, 40 mm de diâmetro externo e 25 mm de diâmetro interno. Os tubos foram cortados com 45 mm de comprimento e realizou-se um passe com profundidade de corte de 0,5 mm no diâmetro interno para remoção da camada de oxidação e garantia de uma usinagem mais uniforme.




Figura 3. Setup experimental com (a) placa de fixação do corpo de prova, (b) corpo de prova, (c) barra de mandrilar, (d) ferramenta de torneamento, (e) bucha e suporte de fixação, (f) dinamômetro e (g) ar comprimido.
(Fonte: próprio autor.)

O material empregado no experimento foi o polímero PEEK. O PEEK é um termoplástico de alto desempenho, alta temperatura, semicristalino fabricado pela Ensinger com o uso do polímero PEEK Victrex® 450G ou do polímero Solvay KetaSpire® KT-820.

As variáveis de controle (X) avaliadas foram: a velocidade de corte (v_c), avanço (f) e posição de fixação do corpo de prova (f_p). A velocidade de corte e o avanço são variáveis importantes no torneamento e podem influenciar na produtividade, temperatura, vida da ferramenta, acabamento, dentre outros fatores.

A escolha de controlar a posição de fixação do corpo de prova surgiu com a possibilidade de avaliar o efeito do posicionamento do tubo na placa do torno em relação às respostas analisadas. Os níveis de posição de fixação estão ilustrados na Figura 4, ou seja, corresponde ao comprimento do tubo deixado para fora da placa. A posição de fixação altera o momento atuante no ponto de contato ferramenta/peça, com possíveis consequências na vibração e na qualidade da peça. O efeito desta variável não é bem estudado na literatura do processo de torneamento interno.




Figura 4. Posição de fixação do tubo na placa.
(Fonte: próprio autor.)

Os níveis das variáveis de controle foram definidos considerando pré-testes realizados e recomendações do fabricante da ferramenta, conforme Tabela 1. A profundidade de corte foi mantida em 0,8 mm e comprimento em balanço da ferramenta em 55 mm.

Tabela 1. Variáveis de controle e níveis (Fonte: próprio autor.)

Variáveis de controle		Níveis					unidade
		-1,68	-1	0	1	1,68	
x_1	v_c	107	165	250	335	393	m/min
x_2	f	0,058	0,085	0,125	0,165	0,192	mm/rot
x_3	f_p	1,5	7	15	23	28,5	mm

As respostas (Y) analisadas dos resultados são a rugosidade (R_z) e taxa de remoção de material (MRR) por meio de um modelo determinístico. As medições de rugosidade foram realizadas no laboratório de metrologia do DEMEP/UFSJ. Para medição das respostas de rugosidade dos corpos de prova usinados, foi utilizado um medidor de rugosidade e perfil Form Talysurf Intra da Taylor Hobson® com deslocamento transversal de 50 mm, campo de medição de $\pm 0,5$ mm, velocidade de deslocamento de até 10 mm/s, velocidade de medição de até 0,5mm/s, velocidade de retorno de até 10 mm/s e medição dos parâmetros de rugosidade e ondulação. O medidor é auxiliado por um computador e pelo software Ultra, também da Taylor Hobson®.

As medições de rugosidade foram realizadas em três posições radiais equidistantes de 120° e três posições no sentido da altura medida no furo de 5 mm cada uma e com espaçamento entre as posições de 13 mm. Foi considerado um cut off de 0,8 mm para perfis periódicos, segundo a norma ISO 4288 – 1996 (HOBSON, 2011).

As abordagens de aprendizagem estatística para regressão consideradas foram conduzidas separadamente e independentemente. Os modelos de regressão parametrizados individualmente foram comparados através de validação cruzada via bootstrap. Por fim, o melhor método foi tomado como modelo final e a otimização evolucionária multiobjetivo foi realizada.

O método NSGA-II foi usado para resolver os problemas de dois objetivos, após a resolução foi plotado a fronteira de Pareto. Essa abordagem de aprendizado e otimização estatística pode ser aplicada em outros processos de fabricação.

3. RESULTADOS E DISCUSSÕES

A Tabela 2 apresenta o delineamento experimental com resultados obtidos no torneamento interno de tubos de PEEK. A primeira coluna é a ordem padrão, para entender melhor o projeto. Os 30 testes foram todos conduzidos em ordem aleatória. A segunda à quarta coluna apresenta o projeto experimental CCD considerando combinações dos níveis dos fatores de controle, v_c , f e f_p . A quinta e a sexta colunas estão representadas a resposta média das posições coletadas de rugosidade máxima da superfície e os resultados calculados da taxa de remoção de material, MRR. A rugosidade máxima R_z variou de 9,338 μ m a 25,350 μ m. A taxa de remoção de material variou de 10700 a 39200 mm³/min.

Tabela 2. Planejamento de experimentos com respostas (Fonte: próprio autor.)

Ordem	v_c	f	f_p	R_z	MRR
	[m/min]	[mm/rot]	[mm]	[μ m]	[mm ³ /min]
1	165	0,09	7	10,569	11.220
2	335	0,09	7	11,551	22.780
3	165	0,17	7	19,516	21.780
4	335	0,17	7	23,018	44.220
5	165	0,09	23	11,615	11.220
6	335	0,09	23	14,328	22.780
7	165	0,17	23	19,542	21.780
8	335	0,17	23	21,002	44.220
9	107	0,13	15	13,035	10.700
10	392	0,13	15	17,402	39.200
11	250	0,06	15	9,338	11.545
12	250	0,19	15	25,350	38.454
13	250	0,13	1,5	15,669	25.000
14	250	0,13	28,5	15,680	25.000
15	250	0,13	15	15,310	25.000
16	250	0,13	15	15,911	25.000
17	250	0,13	15	14,111	25.000
18	250	0,13	15	14,472	25.000

19	250	0,13	15	15,780	25.000
20	250	0,13	15	16,308	25.000
21	250	0,13	15	15,005	25.000
22	250	0,13	15	14,984	25.000
23	221	0,11	12,3	12,427	19.742
24	278	0,14	17,6	17,226	30.765
25	183	0,12	19,5	11,523	17.649
26	240	0,15	8,7	22,105	28.266
27	297	0,09	14,1	13,418	22.308
28	202	0,16	15,8	24,365	25.227
29	259	0,10	21,2	12,732	21.295
30	316	0,13	10,5	16,734	32.723

A Tabela 3 resume o desempenho do teste dos métodos. O método de árvore de regressão (BAG) foi o melhor método considerando a média e a mediana de todas as métricas, com o menor RMSE (*Root Mean Squared Error*) e MAE (*Mean Absolute Error*), e maior coeficiente de determinação R^2 , seguido pelo modelo de RSM. A Figura 5 ilustra os gráficos de boxplot relacionados ao desempenho dos métodos.

Tabela 3. Desempenho dos métodos (Fonte: próprio autor.)

	Média			Mediana		
	RMSE	MAE	R^2	RMSE	MAE	R^2
RSM	1,608	1,110	0,836	1,553	1,074	0,849
BAG	1,436	1,021	0,867	1,410	1,007	0,875




Figura 5. Boxplot do desempenho dos métodos.
(Fonte: próprio autor.)

O desempenho do otimismo corrigido foi calculado, o modelo RSM apresentou os melhores resultados corrigidos para todas as métricas. Porém, o modelo BAG foi selecionado como modelo final. A Tabela 4 apresenta o resumo do desempenho do otimismo corrigido.

Tabela 4. Otimismo corrigido dos métodos (Fonte: próprio autor.)

	Média			Mediana		
	RMSE	MAE	R^2	RMSE	MAE	R^2
RSM	1,432	0,985	0,887	1,416	0,971	0,888
BAG	2,284	1,722	0,705	2,229	1,730	0,710

A interpretação do modelo BAG foi realizada através de gráficos de efeitos principais e interação. A Figura 6 mostra o gráfico de efeitos principais para o modelo BAG considerando as três variáveis de entrada, vc, f, e fp na resposta, Rz. Como se tratam de gráficos de funções degrau, é possível observar claramente mudanças quanto ao comportamento da resposta.

A velocidade de corte apresentou efeito linear positivo sobre Rz. Portanto, o aumento da velocidade de corte, acarreta pequenos degraus de aumento em Rz. O avanço também apresentou efeito linear positivo em Rz, o aumento do avanço, f, apresentou altos degraus de aumento em Rz. A posição de fixação apresenta o menor efeito em Rz. Como o peek é um material plástico, é fácil fixar a peça mantendo a estabilidade do processo de torneamento interno. No entanto, é claro que em pequenos níveis de posição de fixação, com a peça quase inteiramente dentro do mandril de três mandíbulas, resultados de pequena rugosidade são obtidos.




Figura 6. Gráficos de efeitos principais para o modelo BAG.
 (Fonte: próprio autor.)

O gráfico de interação da Figura 7 mostra todas as combinações pareadas entre as três variáveis de entrada na resposta Rz para o modelo BAG. O primeiro gráfico $vc * f$, apresentou efeito linear positivo na rugosidade máxima. O menor vc com o menor f acarretou uma diminuição em Rz.

O segundo gráfico $vc * fp$, apresentou diminuição de Rz na menor vc independente do valor de fp, e foi aumentando alguns degraus a medida que a velocidade de corte aumentava. Por fim, o terceiro gráfico $f * fp$, apresentou uma diminuição de Rz no menor f com todos os níveis de fp, e apresentou altos degraus de aumento de Rz a medida que f aumentava.




Figura 7. Gráficos de interação para o modelo BAG.
 (Fonte: próprio autor.)

O problema de otimização bi-objetivo foi resolvido através do método NSGA-II. A Figura 8 mostra a fronteira de Pareto obtida para o problema de dois objetivos para Rz e MRR. Através desta otimização, soluções ótimas de Pareto são obtidas para gerenciar o trade-off entre rugosidade e produtividade. Essas soluções permitem ao experimentador explorar diferentes cenários em relação à rugosidade e a resposta de produtividade, de modo que o experimentador deve selecionar os níveis de parâmetros ótimos $x^* = [vc^*, f^*, fp^*]$ para um determinado subproblema (nsub), a fim de obter os níveis otimizados das respostas.




Figura 8. Fronteira de Pareto para Rz vs MRR.
 (Fonte: próprio autor.)

4. CONCLUSÕES

Este artigo propôs a otimização evolutiva multiobjetivo do torneamento interno do PEEK por meio de aprendizado estatístico. Testes experimentais para torneamento interno em PEEK foram conduzidos seguindo um planejamento composto central. A rugosidade máxima foi mensurada e a taxa de remoção de material também foi medida como resultado de produtividade.

Primeiramente foi realizada uma comparação por meio da validação cruzada via bootstrap, para comparar os dois modelos. Através do teste de desempenho e abordagem corrigida pelo otimismo, o modelo BAG foi selecionado. Gráficos de efeitos principais e de interação são discutidos considerando a cinemática de torneamento interno.

O avanço apresentou maior efeito na rugosidade máxima e a posição de fixação do tubo na placa apresentou um menor efeito, devido a facilidade de fixação do peek e de manter a estabilidade do processo de torneamento interno.

A otimização evolutiva multiobjetivo considerando o modelo BAG e o modelo determinístico MRR foi realizada através do método NSGA-II. Um conjunto de Pareto foi obtido e os resultados foram discutidos considerando a fronteira de Pareto. A abordagem de aprendizado e otimização proposta permitiu a obtenção dos melhores resultados de torneamento interno nos tubos de PEEK e pode ser aplicada a outras aplicações de manufatura inteligente.

5. AGRADECIMENTOS

À Universidade Federal de Itajubá, campus de Itajubá, ao Centro de Inovação em Manufatura Sustentável (CIMS) da Universidade Federal de São João Del Rei, campus de São João Del Rei, CNPq, Fapemig e à Capes pelo apoio para a realização deste trabalho.

6. REFERÊNCIAS

- BREIMAN, L. et al. Classification and regression trees. wadsworth & brooks. Cole Statistics/Probability Series, 1984.
- CHERKASSKY, V.; MULIER, F. M. Learning from data: concepts, theory, and methods. [S.l.]: John Wiley & Sons, 2007.
- DEB, K. Multi-objective evolutionary algorithms. In: Springer handbook of computational intelligence. [S.l.]: Springer, 2015.
- DEB, K. et al. A fast and elitist multiobjective genetic algorithm: Nsga-ii. Trans. Evol. Comp, v. 6, n. 2, p. 182–197, 2002.
- HOBSON, T. Exploring roundness, a fundamental guide to the measurement of cylindrical form.
- JAMES, G. et al. An introduction to statistical learning. [S.l.]: Springer, 2013. v. 112.
- MARTÍNEZ, M. et al. Genetic algorithms optimization for normalized normal constraint method under pareto construction. Advances in engineering software, Elsevier, v. 40, n. 4, p. 260–267, 2009.
- OZDEN, G.; OTEYAKA, M.O.; CABRERA, F. M. Modeling of cutting parameters in turning of peek composite using artificial neural networks and adaptive-neural fuzzy inference systems. Journal of Thermoplastic Composite Materials, SAGE Publications Sage UK: London, England, p. 08927057211013070, 2021.
- SUYAMA, D.; DINIZ, A.; PEDERIVA, R. Tool vibration in internal turning of hardened steel using cbn tool. The International Journal of Advanced Manufacturing Technology, Springer, v. 88, n. 9, p. 2485–2495, 2017.
- SUYAMA, D. I.; DINIZ, A. E.; PEDERIVA, R. The use of carbide and particle-damped bars to increase tool overhang in the internal turning of hardened steel. The International Journal of Advanced Manufacturing Technology, Springer, v. 86, n. 5, p. 2083–2092, 2016.
- VIEIRA, J. T. et al. Multi-objective robust evolutionary optimization of the boring process of aisi 4130 steel. The International Journal of Advanced Manufacturing Technology, Springer, v. 112, n. 5, p. 1745–1765, 2021.

7. RESPONSABILIDADE PELAS INFORMAÇÕES

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

MULTI-OBJECTIVE EVOLUTIONARY OPTIMIZATION OF THE INTERNAL TURNING PROCESS IN PEEK TUBES

Jéssica Tito Vieira, jessica.tito@hotmail.com¹
Robson Bruno Dutra Pereira, robsondutra@ufsj.edu.br²
Lincoln Cardoso Brandão, lincoln@ufsj.edu.br²
Carlos Henrique Lauro, carloslauro@ufsj.edu.br²

João Roberto Ferreira, jorofe@unifei.edu.br¹

¹Federal University of Itajubá, Avenue BPS 1.303, 37.500-903 Itajubá, Minas Gerais, Brazil

²Federal University of São João Del Rei, Frei Orlando Street 170, 36.880-000 São João Del Rei, Minas Gerais, Brazil

Abstract. Internal turning is a machining operation that aims to increase the internal diameter of a pre-existing hole and the quality of this process is dependent on the system composed of machine, clamping set, tool and workpiece material. The challenges to obtaining the desired quality with high accuracy are even greater if the internal turning process is used in innovative materials, such as high-performance thermoplastics. Poly ether-ether-ketone (PEEK) is considered one of the most important thermoplastics and products made with tubes made from this material can survive service temperatures in the range of -50°C to 260°C while maintaining high mechanical strength. The objective of the present work was to study the evolutionary multi-objective optimization of the internal turning process in PEEK tubes and to compare the traditional modeling method (response surface methodology) with the non-parametric method (bagging). Tests were carried out following a central composite design with the addition of random points in the experimental region, making it possible to obtain regression models with more flexible statistical/computational methods. The input parameters considered were cutting speed (v_c), advance (f) and position of tube fixation on the plate (f_p). The analyzed response was the maximum roughness (R_z) which is a measure of the amplitude of the filtered sampled profile. Through the values of RSME (Root Mean Squared Error), the coefficient of determination R^2 and the MAE (Mean Absolute Error), it was observed that the method based on regression trees (bagging) was superior to the surface methodology of response to data modeling. Finally, the NSGA-II evolutionary multi-objective optimization method was used to determine a set of Pareto optimal solutions for the finishing and productivity responses. The solutions found allow the experimenter to explore different quality and productivity scenarios, so that the experimenter must select the optimal parameter levels $x^* = [v_c^*, f^*, f_p^*]$ for a given planning situation.

Keywords: Internal turning; polyetheretherketone; statistical learning; bagging; multi-objective evolutionary optimization.

RESPONSIBILITY NOTICE

The authors are the only responsible for the printed material included in this paper.