

PARÂMETRO ROBUSTO MULTIVARIADO NA OTIMIZAÇÃO DO TORNEAMENTO DO AÇO ABNT 52100 ENDURECIDO

Paulo Henrique da Silva Campos (UNIFEI)

paulohcampos@bol.com.br

Julian Ignaio Lopez Arcos (UNIFEI)

burack_sa@hotmail.com

Joao Roberto Ferreira (UNIFEI)

jorofe@unifei.edu.br

Vinicius Renó de Paula (UNIFEI)

viniciusrp1702@yahoo.com.br

Pedro Paulo Balestrassi (UNIFEI)

ppbalestrassi@gmail.com



A melhoria da qualidade dos processos de fabricação é eminentemente um problema de otimização multiobjetivo. Nestes processos, é comum que as múltiplas características de qualidade sejam escritas em termos do mesmo conjunto de variáveis de entrada, o que pode originar uma estrutura de correlação capaz de alterar o valor e a precisão dos coeficientes dos termos independentes destas funções de transferência. Este trabalho apresenta um estudo experimental do aço ABNT 52100 endurecido com ferramenta de cerâmica mista ($Al_2O_3 + TiC$) com geometria alisadora, usando o Projeto de Parâmetro Robusto Multivariado (PPRM). A principal característica desta nova abordagem de otimização consiste em considerar um conjunto de variáveis de controle que conduzam todas as variáveis de respostas próximas de seus valores alvos e com mínima variação.

Palavras-chaves: Análise de Componentes Principais (ACP), Erro Quadrático Médio Multivariado (EQMM), Projeto de Parâmetro Robusto Multivariado, Torneamento Duro.

1. Introdução

A qualidade dos produtos obtidos a partir de processos de fabricação como a usinagem, está intrinsecamente relacionada à maneira como as múltiplas características do produto atendem às especificações impostas pelos clientes para as mesmas. Considerando que todo processo pode ser entendido como uma relação entre variáveis de entrada (x) – ou variáveis de processo – e as variáveis de saída ou características de qualidade (Y), tal que $Y=f(x)$, é razoável se admitir que a melhoria da qualidade só possa ser atingida com a definição do melhor conjunto de parâmetros de processo (x) capaz de tornar as características de saída (Y) compatíveis com as especificações impostas, com médias próximas aos alvos estabelecidos e com mínima variação. Muitas vezes, estas funções são conflitantes e a otimização individual de cada uma delas raramente conduz a uma solução global ótima que seja adequada para todas. Verifica-se, portanto, que uma solução adequada só pode ser obtida a partir de uma estratégia de otimização multiobjetivo (CN'NG *et al.*, 2005).

Khuri e Conlon (1981) e Bratchell (1989) alertam que a negligência da estrutura de correlação entre as respostas ou a utilização de métodos de otimização que não a considerem, o processo pode ser conduzido a ótimos inapropriados. O método *Desirability* proposto por Derringer e Suich (1980), o Método de Otimização de Múltiplas Respostas baseado no Erro Quadrático Médio (EQM) proposto por Köksoy (2006), além dos chamados Métodos Duais, como o proposto por Vining e Myers (1990), que também são considerados métodos de múltiplas respostas por buscar a otimização simultânea da média e da variância, são exemplos dos esforços em se estabelecerem métodos de otimização para múltiplas características de qualidade, mas que na maioria das vezes apresentam resultados distorcidos da realidade nos casos multivariados.

Assim, na tentativa de se estabelecer um método de otimização multivariada que considere adequadamente a estrutura de correlação e os alvos estabelecidos para cada função objetivo, apresenta-se neste trabalho a proposição do Erro Quadrático Médio Multivariado (EQMM), que busca uma solução de compromisso entre as variáveis de resposta estudadas, por meio do uso combinado da Metodologia de Superfície de Respostas (MSR) e da Análise de Componentes Principais (ACP).

O objetivo dessa abordagem é apresentar um método capaz de determinar o ponto ótimo, conduzindo as variáveis de resposta a valores próximos de seus alvos, com mínima variação, independentemente da condição de ruído a que o processo com múltiplas características correlacionadas possa estar submetido.

2. Metodologia de superfície de resposta

A Metodologia de Superfície de Resposta (MSR) é um conjunto de técnicas estatísticas e matemáticas que são utilizadas para modelar e analisar problemas para os quais, a priori, não existam modelos determinísticos conhecidos (MONTGOMERY, 2001). Assim, como a MSR utiliza arranjos para modelos quadráticos, a metodologia utiliza os testes de hipótese, a Anova e a Regressão (Mínimos Quadrados Ordinários) para criar os modelos e o cálculo de Gradientes, Lagrangeanas e Hessianas das funções geradas, para a localização de pontos estacionários. Apesar de eficaz, a maioria dos trabalhos em MSR têm utilizado a metodologia

para a modelagem e a otimização de uma única característica (KOKSOY, 2008), solução esta que raramente é suficiente para atender a várias respostas simultaneamente.

Na MSR, geralmente, o relacionamento entre as variáveis dependentes e independentes é desconhecido. Portanto, a primeira etapa da metodologia é encontrar uma razoável aproximação do relacionamento real entre as respostas (y) e o conjunto de variáveis independentes (x). Usualmente, um polinômio de baixa ordem para qualquer região de interesse é empregado. Se a resposta for bem modelada por uma função linear das variáveis independentes, então a função de aproximação será o modelo de primeira ordem, conforme a Equação 2.1.

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (2.1)$$

onde β é o coeficiente polinomial, $K=p$ (número de parâmetros) e ε é o erro.

Entretanto, se existir curvatura no sistema, então a função de aproximação mais usada é um polinômio de segunda ordem, tal como apresentado pela Equação 2.2.

$$\hat{Y} = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i < j} \beta_{ij} x_i x_j + \varepsilon \quad (2.2)$$

Segundo Box e Draper (1987) os dois modelos referidos, de primeira ordem, para sistemas sem curvatura, e de segunda ordem, para sistemas com curvatura, conseguem representar quase todos os problemas relacionados à superfície de respostas. Embora seja improvável que estes modelos representem bem todo o espaço experimental possível, em uma região específica do espaço de solução ela será adequada (MONTGOMERY, 2001).

3. Otimização de múltiplas respostas baseada na análise de componentes principais.

Em se tratando de processos ou produtos que possuam múltiplos atributos de qualidade, é sempre difícil se encontrar um conjunto de parâmetros ótimos para todas as características de interesse a partir da otimização individual de cada função de transferência pré-estabelecida. Além deste tipo de otimização ser de eficácia improvável, as inter-relações entre as várias características podem levar a análise univariada a conclusões equivocadas e sem sentido (WU, 2005).

A existência de correlações entre as várias respostas de um conjunto exerce uma forte influência sobre as funções de transferência utilizadas para representar as características de qualidade. Como o modelo matemático é extremamente importante para a determinação do ponto de ótimo, a negligência da estrutura de correlação pode conduzir a pontos de ótimo inapropriados, fruto de uma inadequação do método dos mínimos quadrados ordinários (BRATCHELL, 1989). A maioria dos estudos nesse sentido passa pela consideração adequada das estruturas de correlação entre as respostas antes que se construam os modelos dos processos.

A Análise de Componentes Principais, ou simplesmente ACP (Principal Component Analysis), é uma técnica estatística multivariada criada por Hotelling (1933) e que se dedica à explicação da estrutura de variância-covariância existente em um conjunto de dados,

utilizando-se combinações lineares das variáveis originais. Segundo Johnson e Wichern (2002), seus objetivos principais são: a redução de dimensionalidade e a interpretação de dados.

4. Projeto de parâmetro robusto multivariado - PPRM

Um problema de otimização multiobjetivo, também considerando restrições de desigualdade, pode ser declarado como Equação 4.1:

$$\begin{aligned} & \text{Minimize} \quad f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_p(\mathbf{x}) \\ & \text{Sujeito a:} \quad g_j(\mathbf{x}) \leq 0, \quad j = 1, 2, \dots, m \end{aligned} \quad (4.1)$$

Suponha que $f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_p(\mathbf{x})$ estão correlacionados com os valores escritos em termos de um vetor aleatório $Y^T = [Y_1, Y_2, \dots, Y_p]$. Supondo-se que Σ é a matriz de variância-covariância associados a este vetor, então Σ pode ser fatorado em pares de autovalores-autovetores $(\lambda_i, e_i), \dots, (\lambda_p, e_p)$ onde $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$ tais como a i -th combinação linear não

correlacionadas pode ser declarado como $PC_i = e_i^T Y = e_{1i} Y_1 + e_{2i} Y_2 + \dots + e_{pi} Y_p$ com

$i = 1, 2, \dots, p$ (JOHNSON e WICHERN, 2002).. Esta combinação não correlacionada linear é chamada de pontuação da componente principal e pode ser obtida usando ACP. Este algoritmo está disponível em muitos pacotes estatísticos. No Minitab, por exemplo, os escores dos componentes principais podem ser armazenados diretamente em uma coluna da planilha.

Segundo Campos et. al (2012), relacionando esses conceitos com a abordagem PPRM acima discutidos, vamos supor que o conjunto de dados múltiplos calculados EQMij pode ser substituído por esta combinação não correlacionadas linear. Então, uma função multiobjetivo pode ser escrita agregando as várias respostas em um índice exclusivo, enquanto mantém sua estrutura de variância-covariância e os desvios individuais de cada alvo. Neste ponto, vamos utilizar o conceito EQMM.

O Erro Médio Quadrático Multivariado (EQMM) é um critério de superfície de resposta multivariada dupla desenvolvida pela substituição da média \hat{y} estimada por uma regressão de pontuação do componente principal (CP_i) e a variância $\hat{\sigma}^2$ estimada pelos respectivos autovalores λ_i . Tomando como alvo ζ_{PC_i} para o componente i -ésima i -th principal, uma formulação de Erro Quadrático Médio Multivariado pode ser definido como:

$$EQMM_i = (CP_i - \zeta_{PC_i})^2 + \lambda_i \quad (4.2)$$

Na Equação 4.2, CP_i é o polinômio de segunda ordem equipado para pontuação da componente principal, ζ_{PC_i} é o valor-alvo de componentes principais, i éimo, que deve manter uma relação direta com as metas do conjunto de dados original. Essa relação pode ser estabelecida usando Equação 4.3, tais como:

$$\zeta_{PC_i} = e_i^T \left[Z(Y_p | \zeta_{Y_p}) \right] = \sum_{i=1}^p \sum_{j=1}^q e_{ij} \left[Z(Y_p | \zeta_{Y_p}) \right] \quad i = 1, 2, \dots, p \quad j = 1, 2, \dots, q \quad (4.3)$$

Na Equação 1.5, e_i são os autovetores associados ao componente i -ésima principal e ζ_{Y_p} representa a meta para cada uma das respostas p original. Com esta transformação, pode ser estabelecido um valor coerente para o alvo do componente i -ésima principal, que é compatível com as metas do problema original.

Supondo agora que $Y_p = EQM_p = (\mu_p - \theta)^2 + \sigma_p^2$. Então, se mais de um componente principal será necessário, usando as funções EQMM cujos autovalores são iguais ou maiores que a unidade, que pode ser um problema multiobjetivo deveria ser escrito da seguinte forma de acordo com a Equação 4.4:

$$\begin{aligned} \text{Minimize } EQMM_T &= \left[\prod_{i=1}^k (EQMM_i | \lambda_i \geq 1) \right]^{\left(\frac{1}{k}\right)} = \left\{ \prod_{i=1}^k \left[(CP_i - \zeta_{PC_i})^2 + \lambda_i | \lambda_i \geq 1 \right] \right\}^{\left(\frac{1}{k}\right)} \\ & \quad i = 1, 2, \dots, k; \quad k \leq p \\ \text{Sujeito a : } \mathbf{x}^T \mathbf{x} &\leq \rho^2 \end{aligned} \quad (4.4)$$

5. Planejamento do experimento

As variáveis de controle adotadas para esse procedimento foram: velocidade de corte (V_c), taxa de avanço (f) e profundidade de corte (a_p). Estas variáveis são reconhecidamente as mais importantes, uma vez que influenciam fortemente o processo de torneamento, principalmente o acabamento da peça e o desgaste de ferramenta. Os ruídos adotados para este trabalho foram: redução da dureza do material e o desgaste da ferramenta, tendo como variáveis de resposta as cinco métricas de rugosidade.

Inicialmente, foram definidos quais valores seriam adotados para cada nível das variáveis de controle e de ruído consideradas neste trabalho. Esta definição é importante para que não sejam adotados valores que inviabilizem a execução do experimento ou que resultem em condições inseguras para sua execução. Para tanto, são consideradas algumas informações de catálogo da máquina, da ferramenta e do material que será usinado. Os valores arbitrados para cada nível das variáveis de controle consideradas neste trabalho estão descritos na Tabela 5.1:

Variáveis de Controle	Níveis				
	-1,682	-1	0	1	1,682
V_c (m/min)	186,4	200	220	240	253,6
f (mm/v)	0,132	0,20	0,30	0,40	0,468
a_p (mm)	0,099	0,150	0,225	0,300	0,351

Tabela 5.1 – Variáveis de controle.

A Tabela 5.2 indica as variáveis de ruído selecionadas para o trabalho, bem como os seus níveis adotados.

Fatores de Ruído	Símbolo	-1	+1
Dureza (HRC)	Z ₁	40	50
Desgaste (mm)	Z ₂	Nova (VB _{max} =0,00 mm)	Desgastada (VB _{max} =0,30 mm)

Tabela 5.2 – Variáveis de ruído selecionadas

5.1. Máquinas, materiais, ferramentas e instrumento de medição

Para cumprir com os objetivos deste trabalho, usinagem a seco do aço ABNT 52100, foram realizados em um torno CNC Nardini Logic 175, com velocidade de rotação máxima de 4.000 rpm e potência de corte de 5,5 kW.

O desgaste de flanco das ferramentas foi medido através de um microscópio óptico (ampliação 40 vezes). As condições de ruído foram utilizadas para simular fenômenos gerais que ocorrem quando se realiza quaisquer operações de torneamento, reproduzindo, de certa forma, a perda de dureza do material da peça simultaneamente com o desgaste da ferramenta.

Obviamente, nestas condições, o valor de rugosidade da peça sofrerá algum tipo de variação, independentemente da configuração de controle.

As peças de trabalho usadas no processo de usinagem foram feitas com dimensões de Ø 49 milímetros × 50 mm. Todas elas foram previamente temperadas e revenidas. Após este tratamento térmico, a dureza era entre 49 e 52 HRC, até uma profundidade de três milímetros abaixo da superfície. O porta-ferramenta utilizado nos experimentos apresentou uma geometria negativa com código ISO DCLNL 1616H12 e com ângulo $\chi_r = 95^\circ$.

Durante os ensaios utilizou-se ferramentas de cerâmica mista alisadora (Al_2O_3+TiC), geometria ISO CNGA 120408 S01525WH revestida com uma camada de nitreto de titânio (TiN).

Na Figura 5.1 é mostrado o processo de torneamento e na Figura 5.2 a peça utilizada no experimento.




Figura 5.1 - Processo de torneamento duro




Figura 5.2 - Corpo de prova do aço ABNT 52100.

O material das peças utilizadas foi o aço ABNT 52100, com a composição química descrita na Tabela 5.3.

C	Si	Mn	Cr	Mo	Ni	S	P
1,03%	0,23%	0,35%	1,40%	0,04%	0,11%	0,00%	0,01%

Tabela 5.3 - Composição do aço ABNT 52100

As medições de rugosidade foram realizadas sempre quatro vezes nos pontos (A, B, e C), conforme esquema ilustrado na Figura 5.2. Após as medições de rugosidade foram realizadas as medidas das médias e variâncias dos valores de rugosidade. Para monitoramento do desgaste da ferramenta foi medido o tempo e o número de passes em cada rodada dos 19 experimentos realizados.

Para a obtenção dos valores de rugosidade de cada corpo de prova, após o torneamento e resfriamento dos mesmos, foi utilizado um rugosímetro portátil Mitutoyo modelo SurfTest SJ-201P. Os valores medidos para as variáveis de resposta Ra, Ry, Rt, Rz e Rt foram obtidos simultaneamente, durante o percurso da unidade de avanço e posteriormente registrados em planilha eletrônica.

6. Resultados e discussão

Através do planejamento experimental discutido anteriormente e dos valores medidos para as variáveis de resposta escolhidas, inicia-se a análise dos resultados em busca do projeto robusto para múltiplas variáveis.

6.1 Modelagem das variáveis de resposta

A Tabela 6.1 apresenta o arranjo experimental com dezenove rodadas em quatro condições de ruído, sendo uma superfície de resposta com cinco pontos centrais e seis pontos axiais, adotando ($\rho = 1,633$). As respostas das quatro medidas de rugosidades Ra1, Ra2, Ra3 e Ra4 foram conseguidas medindo quatro vezes em três pontos diferentes da peça. De cada peça obteve-se doze medidas. No total de dezenove experimentos para cada peça foram feitas novecentos e doze medidas.

Para um melhor entendimento do método e da maneira como as diversas rotinas devem ser construídas, propõe-se o uso de nove procedimentos que serão mostrados a seguir. De acordo com o procedimento 1, que foi o cálculo da média e variância para cada métrica (\hat{y}_i) da rugosidade da peça obtida com uma matriz cruzada. A partir daí obteve-se a média, variância e o Erro Quadrático Médio (EQM), que foi calculado através da Equação 6.1.

$$EQM = (\hat{\mu} - \theta)^2 + \hat{\sigma}^2 \quad (6.1)$$

Alternativamente, supondo que o EQM pode ser calculado com os resultados experimentais para cada corrida experimental na metodologia de superfície de resposta, pode-se estabelecer um modelo para o EQM diretamente. A Equação 6.1 representa o Erro Quadrático Médio de uma única saída. Mas considere agora que os processos de usinagem de aço endurecido têm muitas características a serem melhoradas. Então, a otimização dupla descrita pela Equação 6.1 não é suficiente para promover soluções para todo o conjunto de características. Estendendo do critério EQM para otimizar múltiplas respostas, Kóksoy e Yalcinoz (2008) propuseram a aglutinação do Erro Quadrado Médio de cada resposta usando uma soma

ponderada ou a escolha do EQM da resposta mais importante como função objetivo, enquanto os restantes são mantidos como restrições.

<i>Fatores Controláveis</i>			-1 1 -1 1				Z_1	<i>Fatores de ruído</i>		
			-1 -1 1 1				Z_2			
<i>Fatores Controláveis</i>			<i>Replicações</i>				<i>Propriedades</i>			
V_c	f	a_p	R_{a1}	R_{a2}	R_{a3}	R_{a4}	Média	Variância	EQM	
-1,000	-1,000	-1,000	0,225	0,153	0,288	0,243	0,227	0,003194	0,003493	
1,000	-1,000	-1,000	0,233	0,219	0,383	0,292	0,281	0,005530	0,010637	
-1,000	1,000	-1,000	0,485	0,388	0,432	0,320	0,406	0,004879	0,043312	
1,000	1,000	-1,000	0,463	0,382	0,465	0,236	0,386	0,011554	0,042618	
-1,000	-1,000	1,000	0,252	0,177	0,339	0,252	0,255	0,004414	0,006420	
1,000	-1,000	1,000	0,252	0,173	0,260	0,260	0,236	0,001775	0,002464	
-1,000	1,000	1,000	0,526	0,357	0,408	0,327	0,404	0,007692	0,045393	
1,000	1,000	1,000	0,445	0,412	0,383	0,303	0,386	0,003662	0,034506	
-1,682	0,000	0,000	0,338	0,373	0,289	0,290	0,322	0,001631	0,014240	
1,682	0,000	0,000	0,369	0,358	0,256	0,266	0,312	0,003567	0,014030	
0,000	-1,682	0,000	0,167	0,095	0,365	0,219	0,211	0,013068	0,013070	
0,000	1,682	0,000	0,508	0,534	0,445	0,396	0,471	0,003903	0,071937	
0,000	0,000	-1,682	0,378	0,349	0,283	0,311	0,330	0,001749	0,016249	
0,000	0,000	1,682	0,413	0,416	0,259	0,318	0,351	0,005847	0,025799	
0,000	0,000	0,000	0,348	0,298	0,355	0,285	0,321	0,001222	0,013645	
0,000	0,000	0,000	0,378	0,294	0,296	0,273	0,310	0,002138	0,012138	
0,000	0,000	0,000	0,321	0,308	0,293	0,267	0,297	0,000543	0,008163	
0,000	0,000	0,000	0,339	0,290	0,273	0,263	0,291	0,001159	0,007726	
0,000	0,000	0,000	0,343	0,322	0,306	0,229	0,300	0,002466	0,010566	

Tabela 6.1 – Resultados de Ra: arranjo cruzado, fatores controlados e ruído.

A partir dos dados da Tabela 6.1 realizou-se a análise de variância (ANOVA) que consiste de um teste para comparar médias do fatorial completo, para os três fatores e dois níveis (2^3), com cinco pontos centrais, para a resposta rugosidade Ra.

De acordo com o procedimento 2, que estabelece as equações para \hat{y}_i utilizando os dados experimentais calculados do modelo completo, obtém-se os respectivos coeficientes e R_2 ajustados para cada uma das equações tendo a taxa de avanço como fator mais importante na explicação do comportamento da rugosidade.

Considerando-se então de acordo com o procedimento 3, utilizando-se a minimização restrita de cada equação, tendo os modelos quadrático total, um sistema de otimização não-linear deve ser aplicado pelo fato da dificuldade em otimizar a variância. A Equação 6.2 pode ser implementada onde serão encontrados os alvos, usando como algoritmo de solução o GRG, disponível no pacote Microsoft Excel Solver.

$$\begin{aligned} & \text{Minimize } \hat{y}_i \\ & \text{Sujeito a: } \mathbf{x}^T \mathbf{x} \leq \rho^2 \quad \hat{\sigma}_i^2 \geq 0,001 \end{aligned} \tag{6.2}$$

Alvos: $R_a=0,210$ (μm); $R_z=1,311$ (μm); $R_t=1,504$ (μm); $R_y=1,453$ (μm); $R_q=0,283$ (μm)

Com os alvos já estabelecidos, o procedimento 4 será calcular cada EQM_i para que seja comparados os valores encontrados com os valores alvo (θ_i). Após a obtenção dos valores \hat{y}_{ij} , θ_i e $\hat{\sigma}_{ij}^2$, calcula-se o EQM, tal como:

$$EQM_{ij} = (\hat{y}_{ij} - \theta_i)^2 + \hat{\sigma}_{ij}^2 \quad (6.3)$$

A partir dos valores encontrados de cada EQM, foi construído um modelo quadrático completo através da Metodologia de Superfície de Resposta para cada EQM. Foram encontrados os valores e os alvos dos Componentes Principais utilizando o software Minitab.

De acordo com o procedimento 5, foi estabelecido as metas para EQM_i usando a minimização restrita para cada equação de superfície de resposta. O valor-alvo encontrado para cada EQM_i foi obtido com a minimização restrita descrita pelas Equação 6.4.

$$\begin{aligned} & \text{Minimize } EQM_i \\ & \text{Sujeito a: } \mathbf{x}^T \mathbf{x} \leq \rho^2 \quad EQM_j \geq 0.001 \quad i \neq j \end{aligned} \quad (6.4)$$

De acordo com o procedimento 6, que foi a condução de ACP utilizando a matriz de correlação e de acordo com o procedimento 7 que foi a compilação completa de modelos quadráticos para os escores dos componentes principais.

Os dois primeiros componentes principais representam 99,0% da variância do EQM_i com respectivos autovalores $\lambda_1 = 4,672$ e $\lambda_2 = 0,276$. Em termos práticos, os escores dos componentes principais (CP1(EQM); CP2 (EQM)) são calculados.

Usando a relação $\zeta_{PC_i} = \sum_{i=1}^p \sum_{j=1}^q e_{ij} [Z(Y_p | \zeta_{Y_p})]$ e os valores mínimos de otimização individual de EQM_i podemos concluir o procedimento 8, que é estabelecer as metas dos componentes principais para os escores dos componentes principais, que foram calculados e encontrados estes valores: $\zeta_{PC_1} = -2,1652$ e $\zeta_{PC_2} = 0,1502$.

A minimização da distância entre cada componente principal e seus respectivos alvos pode levar a uma solução de compromisso que atende as metas de todas as cinco respostas correlacionadas.

6.2 .Otimização

Adotando estes aspectos e de acordo com o procedimento 9, que consiste em minimizar o EQMM usando um algoritmo GRG, um sistema de otimização não-linear pode ser escrita em termos do Erro Quadrado Médio Multivariado utilizando, além disso, uma restrição esférica para os níveis do fator. Esta restrição, $\rho^2 = 2,667$ forçará a solução a permanecer dentro da região experimental. Recolhendo as informações anteriores em um sistema de otimização abrangente, é possível escrever as seguintes expressões:

$$\text{Minimize } EQMM_T = \sqrt{[(CP_1 - \zeta_{PC_1})^2 + \lambda_1] \times [(CP_2 - \zeta_{PC_2})^2 + \lambda_2]} \quad (6.5)$$

$$\text{Sujeito a : } \mathbf{x}^T \mathbf{x} \leq \rho^2 = Vc^2 + f^2 + ap^2 \leq 2.667 \quad (6.6)$$

$$\text{Com } \zeta_{PC_i} = e_{1i} [Z(EQM_1 | \zeta_{EQM_1})] + e_{2i} [Z(EQM_2 | \zeta_{EQM_2})] + e_{3i} [Z(EQM_3 | \zeta_{EQM_3})] + e_{4i} [Z(EQM_4 | \zeta_{EQM_4})] + e_{5i} [Z(EQM_5 | \zeta_{EQM_5})] \quad (6.6)$$

$$i = 1, 2, \dots, p. \quad PC_i = b_{0i} + [\nabla f(\mathbf{x})^T]_i + \left\{ \frac{1}{2} \mathbf{x}^T [\nabla^2 f(\mathbf{x})] \mathbf{x} \right\}_i \quad (6.7)$$

Onde $\mathbf{x} = [Vc, f, ap]$ são valores numéricos das metas padronizadas $Z(EQM_i | \zeta_{EQM_i})$, e os autovetores e_{ij} são os valores numéricos.

A Figura 6.1 mostra a melhor solução encontrada com PPRM em unidades codificadas. É possível verificar que esta solução (-1,005; -1,087; -0,469) atende a todas as restrições impostas aos valores para o valor individual de EQM. Em unidades não codificadas, esta solução é $Vc = 199,9$ m/min, $f = 0,191$ mm/v e $ap = 0,190$ mm. Pode-se notar que empregando a abordagem PPRM, a variabilidade é extremamente reduzida, indicando que o algoritmo conseguiu um ponto de ótimo, o que representa uma solução de compromisso para médias e variâncias, mantendo as respostas o mais próximo possível dos seus objetivos.

Portanto, considerando as consequências físicas da configuração otimizada obtida com a abordagem PPRM, acreditamos que $Vc = 199,9$ m/min, $f = 0,191$ mm/v e $ap = 0,190$ mm é uma configuração adequada para a operação de acabamento da superfície do aço ABNT 52100.




Figura 6.1 - Gráfico de Contorno Sobreposto para cada EQM.

7. Ensaios de confirmação

Para analisar a efetividade dos parâmetros ótimos encontrados por meio da abordagem PPRM e para confirmar os resultados da simulação em estudo, um conjunto de testes de confirmação foi executado, procedendo-se ao torneamento de quatro peças para cada uma das quatro condições de ruído. As cinco respostas de rugosidade foram medidas vinte vezes na região

central das peças, resultando em um conjunto de dados de 192 observações para cada estado de acabamento superficial. O principal objetivo dos ensaios de confirmação foi verificar se a variância da rugosidade era mínima com seus valores médios próximos dos alvos estabelecidos. A Figura 7.1 apresenta um intervalo de confiança de 95% para cada rugosidade média obtida, também, nas quatro condições de ruído.

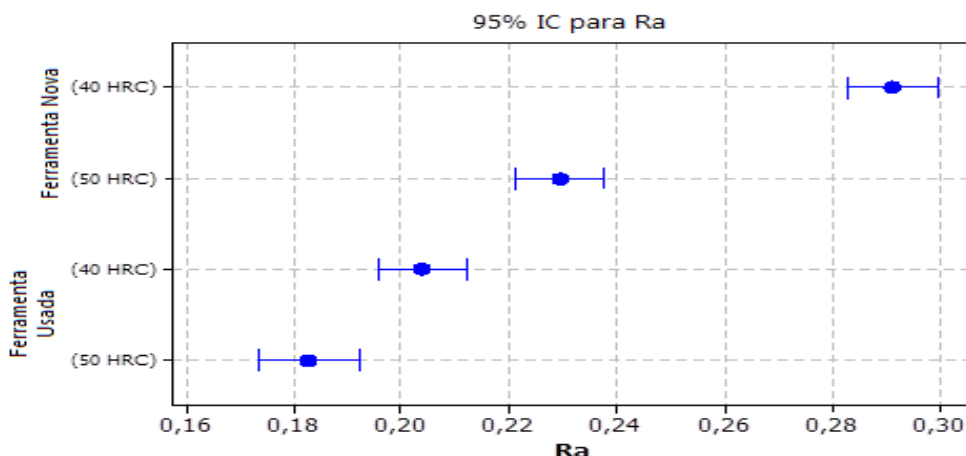


Figura 7.1 – ANOVA *One-Way*: R_a versus condições de ruído

Apesar de que as rugosidades medidas para as quatro condições de ruído são diferentes (P -value < 5%), suas médias foram muito pequenas. Esta variação observada entre as quatro amostras, destacam que a influência do ruído não foi totalmente removida do processo com o *setup* ótimo. Mesmo assim, as variâncias (e o desvio padrão) são notadamente menores com a solução otimizada do que aquelas observadas na experimentação com os valores mínimos para a rugosidade superficial.

A Figura 7.2 mostra uma comparação entre as respostas obtidas experimentalmente (*Exp*) e após o ótimo (*Opt*). Para esse propósito foram escolhidos os resultados da rodada experimental 11, por ser a rodada que apresentou a menor média para R_a . Pode-se observar pelos *box-plots*, que as variâncias obtidas com os parâmetros ótimos são muito menores do que aqueles observados com a rodada experimental número 11.




Figura 7.2 – Comparação entre as variâncias das medidas de rugosidade

De posse dos resultados experimentais, foram realizadas simulações para comparar a qualidade da solução robusta. A Figura 7.3 apresenta a simulação de R_a antes e depois de executada a rotina de otimização.

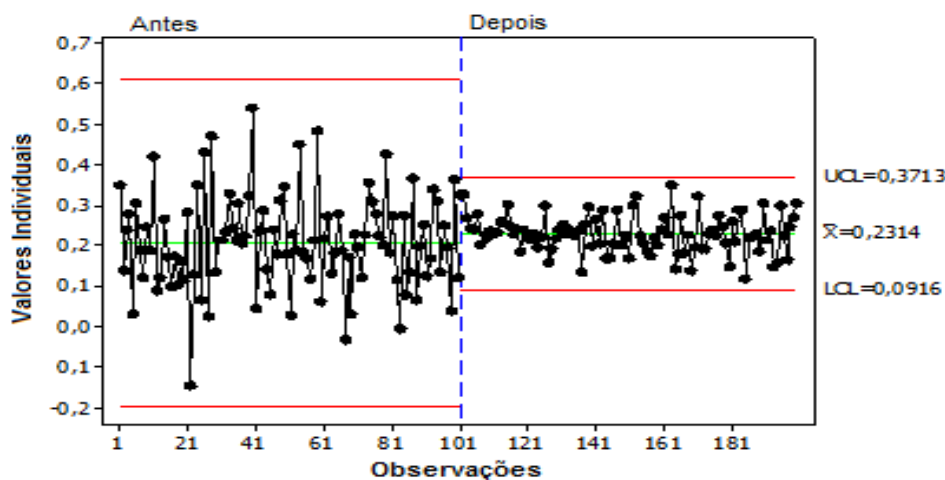


Figura 7.3 – Simulações para condições normais e otimizadas

A presente simulação mostrou que a abordagem proposta foi adequada para o tratamento de média e variância das múltiplas respostas correlacionadas deste caso. Acredita-se que os resultados robustos obtidos estão mais próximos de valores reais do que se fossem utilizadas abordagem voltadas somente para a explicação e otimização das principais características.

8. Conclusões

- A otimização do processo com base na abordagem Projeto de Parâmetro Robusto multivariado (PPRM) em situações em que as múltiplas respostas apresentam um moderado a

elevado grau de correlação, mostrou uma adequação consistente aplicado ao torneamento duro do aço ABNT 52100 com ferramenta de cerâmica alisadora.

- Os resultados de confirmação permitem afirmar que a abordagem PPRM supera as rotinas de otimização individual, com variação mínima para cada métrica de rugosidade. A diferença em relação a média de cada resposta também é extremamente reduzida, com a abordagem PPRM, indicando que o algoritmo conseguiu um ponto de ótimo que representa uma solução de compromisso para médias e variâncias, mantendo as respostas o mais próximo possível dos seus objetivos.

- Na estrutura de correlação das rugosidades, a primeira componente principal foi responsável pela maioria dos valores de variância-covariância nos dados originais associados com as cinco métricas de rugosidade da peça.

- A Otimização simultânea das cinco métricas de rugosidades (R_a , R_z , R_t , R_y e R_q), foi obtida com uma velocidade de corte de $V_c = 199$ m/min, taxa de avanço de $f = 0,191$ mm/v e profundidade de corte de $a_p = 0,190$ mm.

- Para todas as respostas estudadas, os valores médios de rugosidade são baixos e a sua variância foi extremamente reduzida.

9. Agradecimentos

À CAPES, CNPq e FAPEMIG pelos recursos dispensados para realização deste trabalho.

10. Referências bibliográficas

CH'NG, C. K., QUAH, S. H, LOW, H. C. Index Cpm in Multiple Response Optimization. Quality Engineering, n. 17, p. 165-171, 2005.

CAMPOS, P.H.S, Paiva, A. P, Ferreira, J.R, Lopes, L.D.G, Paiva, E.J , Balestrassi, P. P, A multivariate robust parameter design approach for optimization of AISI 52100 hardened steel turning with wiper mixed ceramic tool. International Journal of Refractory Metals & Hard Materials, v. 30, p. 152-163.2012.

KHURI, A. I, CONLON, M. Simultaneous optimization of multiple responses represented by polynomial regression functions. Technometrics, v 23, n 4, pp. 363-375, 1981.

BRATCHELL, N. Multivariate Response Surface Modelling by Principal Components Analysis. Journal of Chemometrics, v 3, pp. 579-588, 1989.

DERRINGER, G, SUICH, R. Simultaneous Optimization of Several Response Variables. Journal of Quality Technology, v 12, n 4, pp.214-219, 1980.

KÖKSOY, O. Multiresponse robust design: Mean square error (MSE) criterion. *Applied Mathematics and Computation*, n.175, pp. 1716-1729, 2006.

VINING, G. G, MYERS, R. H. Combining Taguchi and response surface philosophies: a dual response approach. *Journal of Quality Technology* 22:38-45, 1990.

MONTGOMERY, D. C. Design and analysis of experiments. Fourth ed., Wiley, New York, 2001.

BOX, G. E. P, DRAPER, N. R. Empirical Model-Building and Response Surfaces. John Wiley e Sons, 1 ed., 650p., 1987.

KÖKSOY, O, YALCINOZ, T. Robust design using Pareto type optimization: A genetic algorithm with arithmetic crossover. *Computers e Industrial Engineering*, n. 55, pp. 208-218, 2008.

WU, F. C. Optimization of correlated multiple quality characteristics using desirability function. *Quality Engineering*, v. 17, n. 1, pp. 119-126, 2005.

HOTELLING, H. Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, v. 24, pp. 417-441, 1933.

JOHNSON, R. A, WICHERN, D. W. Applied multivariate statistical analysis, New Jersey: Prentice-Hall Inc., 5 ed., p. 797, 2002.