

OTIMIZAÇÃO DE PARÂMETROS DE USINAGEM UTILIZANDO PROJETO DE PARÂMETROS ROBUSTOS BASEADO EM ANÁLISE DE CAPACIDADE

Braga, L.F – luizfernando@unifei.edu.br

Brito, T.G – tgbrito@unifei.edu.br

Nadae, J. – jeniffer.nadae@unifei.edu.br

Palavras-chave: Fresamento de Topo; Metodologia de Superfície de Resposta (MSR); Índice de Capacidade; Otimização.

1. INTRODUÇÃO

No processo de fresamento de topo de aços, controla-se as variáveis de resposta de rugosidade de superfície por meio do índice de capacidade (C_{pk}), entretanto, a rugosidade é afetada por variáveis de ruído. Afim de minimizar o impacto dessas variáveis, Taguchi (1986) propõe uma análise por meio de Projeto de Parâmetros Robustos (PPR). Esta abordagem é mais econômica do que tratar diretamente as causas da variação (Tiwari et al., 2023; Brito et al., 2014; Paiva et al., 2014).

O material em estudo é o aço inoxidável Duplex UNS S32205, de acordo com Oliveira, (2022); Diniz et al., (2014), destacam a necessidade de ensaios preliminares para reconhecer o comportamento do material e estabelecer parâmetros adequados, visto que as configurações de catálogo podem não se aplicar devido ao desgaste acelerado da ferramenta e à baixa usinabilidade do material

Diante do exposto, esta pesquisa visa otimizar o Índice de Capacidade (C_{pk}) para rugosidade média (R_a) e rugosidade total (R_t) no processo de fresamento de topo do aço inoxidável Duplex UNS S32205.

2. DESENVOLVIMENTO

2.1 Projeto de Parâmetro Robusto (PPR)

O PPR é uma ferramenta estatística essencial que busca aumentar a robustez dos processos produtivos, identificando e controlando os efeitos das variáveis de

ruído, de forma a projetar sistemas que permaneçam estáveis frente a flutuações externas.

A Metodologia de Superfície de Resposta (MSR) é empregada para descrever a influência dos fatores de controle sobre as variáveis de resposta do processo e para viabilizar a análise de robustez obtida pelo PPR (Montgomery, 2020; Chen et al., 2020; Tiwari et al., 2023).

A combinação de PPR e MSR pode ser feita por meio do arranjo cruzado (Taguchi, 1986), Tabela 1, separando os fatores em dois conjuntos experimentais: um arranjo interno, contendo as variáveis controláveis, e um arranjo externo, composto pelas variáveis de ruído. Diversos estudos aplicam o PPR em processos de fresamento, para a rugosidade de superfície como resposta principal (Arruda et al., 2019; Khan e Ali, 2022; Rani e Kumar, 2022).

Tabela 1- Matriz cruzada

Arranjo Interno				Arranjo Externo		
Corrida	X ₁	X ₂	X ₃	Z ₁	Z ₂	Z ₃
1	-1	-1	-1			
2	-1	-1	1			
3	-1	1	-1			
4	-1	1	1			
5	1	-1	-1			
6	1	-1	1			

Fonte: Montgomery (2017).

2.2 Otimização Multiobjetivo e o Índice de Capacidade (Cpk)

Quando um processo envolve mais de uma variável de resposta, aplica-se a Otimização Multiobjetivo, que por meio de estratégias de priorização ou de aglutinação, que integra todas as respostas em uma única função objetiva ponderada (Rodrigues et al., 2019; Chaudhry et al., 2023).

A Análise de Capacidade do Processo avalia o desempenho do processo em relação à variabilidade aceitável (Montgomery, 2012; Cairo e D'Arcy, 2021; Bertolini et al., 2022). O Índice de Capacidade (C_p) é utilizada para medir a capacidade potencial do processo, Equação 1:

$$C_p = \frac{USL - LSL}{6\sigma} \quad (1)$$

Os limites de especificação USL (Limite Superior de Especificação) e LSL (Limite Inferior de Especificação) são calculados, sendo σ o desvio padrão do processo. Para processos com apenas limite superior ou inferior, os índices de capacidade são calculados conforme as Equações 2 e 3, onde μ representa a média do processo, desta forma a avaliação da capacidade de processos não centralizados, utiliza-se o índice C_{pk} .

$$C_{pu} = \frac{USL - \mu}{3\sigma} \quad (2)$$

$$C_{pl} = \frac{\mu - LSL}{3\sigma} \quad (3)$$

2.3 Metodologia PPR - C_{pk}

Segundo Montgomery (2013) na modelagem define-se os objetivos do experimento, as variáveis de entrada e de resposta e o ruído, calcula-se μ , σ e C_{pk} , o desvio padrão pode ser obtido a partir da média das amplitudes ($\bar{R}$) e do fator d_2 , determinado pelo número de observações na amostra, Equação 4.

$$\sigma = \frac{\bar{R}}{d_2} \quad (4)$$

Na otimização, define-se os pesos das variáveis de resposta, com valores entre 0 e 1, cuja soma deve ser igual a 1, refletindo a importância relativa de cada resposta. A etapa final aplica o algoritmo Gradiente Reduzido Generalizado (GRG), que busca maximizar o C_{pk} geral e identificar a solução ótima. O GRG é um método iterativo de programação matemática que utiliza o gradiente reduzido da função objetivo e das

restrições para direcionar a busca da solução, minimizando a discrepância entre o ponto atual e o ideal (Bazaraa; Sherali; Shetty, 2006), Equação 5.

$$\text{Maximizar: } C_{pk \text{ overall}} = \sum_{i=1}^k w_i C_{pk} (Y_k) \quad (5)$$

Sujeito a: $\gamma_{i(-)} \leq x_i \leq \gamma_{i(+)}$

2.4 Definição dos Parâmetros

As seguintes variáveis de controle(x): velocidade de corte (v_c), avanço por dente (f_z), profundidade de corte (a_p) e penetração de trabalho (a_e) segundo Diniz et al., (2014), e os valores das variáveis de controle para os níveis -1, 0 e 1, são demonstrado na Tabela 2.

Tabela 2 - Variáveis de entrada e níveis experimentais

Parâmetro	Símbolo	Unidade	Níveis		
			-1	0	+1
Velocidade de corte	v_c	m/min	60	75	90
Avanço por dente	f_z	mm/dente	0,1	1,5	0,2
Penetração de trabalho	a_e	mm	15	16,5	18
Profundidade de corte	a_p	mm	1	1,25	1,5

Fonte: Autor

As variáveis de ruído selecionadas foram: desgaste de ferramenta (V_b), a vazão de fluido (Q) e a concentração do fluido de corte (C). Os níveis adotados para as variáveis de ruído foram definidos considerando observações realizadas durante os ensaios preliminares, Tabela 3.

Tabela 3 - Variáveis de ruído

Parâmetro	Símbolo	Unidade	Níveis		
			-1	0	1
Desgaste do flanco da ferramenta	V _b	mm	0	0,15	0,3
Vazão do fluido de corte	Q	l/min	0	10	20
Concentração de fluido	C	%	0	10	20

Fonte: Autor

2.5 Definição da Matriz Experimental – Arranjo Cruzado

Utilizou-se o arranjo cruzado em um projeto fatorial completo, composto por 20 pontos fatoriais, 16 pontos axiais e 4 pontos centrais, totalizando 20 experimentos. A análise estatística foi conduzida no software Minitab® (2019) para a construção do DOE, Figura 1.

Figura1 - Planejamento Experimental

Experimentos	Variáveis de controle				Variáveis de Ruído		
	vc	fz	ae	ap	Vb	Q	C
	(m/min)	(mm/dent e)	(mm)	(mm)	(mm)	(l/min)	%
1	60	0,1	15	1	0	0	0
2	60	0,2	15	1	0,3	20	20
3	60	0,1	15	1,5	0	0	0
4	60	0,2	15	1,5	0,3	20	20
5	90	0,1	15	1	0	0	0
6	90	0,2	15	1	0,3	20	20
7	90	0,1	15	1,5	0	0	0
8	90	0,2	15	1,5	0,3	20	20
9	60	0,1	18	1	0	0	0
10	60	0,2	18	1	0,3	20	20
11	60	0,1	18	1,5	0	0	0
12	60	0,2	18	1,5	0,3	20	20
13	90	0,1	18	1	0	0	0
14	90	0,2	18	1	0,3	20	20
15	90	0,1	18	1,5	0	0	0
16	90	0,2	18	1,5	0,3	20	20
17	75	0,15	16,5	1,25	0,15	10	10
18	75	0,15	16,5	1,25	0,15	10	10
19	75	0,15	16,5	1,25	0,15	10	10
20	75	0,15	16,5	1,25	0,15	10	10

Fonte: Autor

3. RESULTADOS E DISCUSSÃO

3.1 Modelagem das Respostas R_a e R_t

Os resultados permitiram modelar as relações entre a rugosidade e os parâmetros de processo controlados, apesar de as variáveis de ruído terem sido consideradas durante os experimentos, elas não foram incluídas no modelo final (limitação da estratégia de arranjo cruzado), conforme demonstrado nas Figura 2.

Figura 2- Análise de variância para μR_a e μR_t


Fonte	GL	SQ (Aj.)	QM (Aj.)	Valor F	Valor-P
Modelo	16	0,510691	0,031918	82,02	0,002
Linear	4	0,251923	0,062981	161,85	0,001
fz	1	0,001731	0,001731	4,45	0,125
ap	1	0,200349	0,200349	514,85	0,000
vc	1	0,041336	0,041336	106,22	0,002
ae	1	0,008506	0,008506	21,86	0,018
Interações de 2 fatores	6	0,176871	0,029479	75,75	0,002
fz*ap	1	0,157080	0,157080	403,66	0,000
fz*vc	1	0,004198	0,004198	10,79	0,046
fz*ae	1	0,001597	0,001597	4,10	0,136
ap*vc	1	0,010134	0,010134	26,04	0,015
ap*ae	1	0,003043	0,003043	7,82	0,068
vc*ae	1	0,000819	0,000819	2,11	0,243
Interações de 3 fatores	4	0,078166	0,019542	50,22	0,004
fz*ap*vc	1	0,008134	0,008134	20,90	0,020
fz*ap*ae	1	0,023902	0,023902	61,42	0,004
fz*vc*ae	1	0,018276	0,018276	46,96	0,006
ap*vc*ae	1	0,027854	0,027854	71,58	0,003
Interações de 4 fatores	1	0,001856	0,001856	4,77	0,117
fz*ap*vc*ae	1	0,001856	0,001856	4,77	0,117
Curvatura	1	0,001875	0,001875	4,82	0,116
Erro	3	0,001167	0,000389		
Total	19	0,511858			

Fonte	GL	SQ (Aj.)	QM (Aj.)	Valor F	Valor-P
Modelo	16	11,1899	0,69937	20,86	0,014
Linear	4	6,0754	1,51884	45,30	0,005
fz	1	0,4696	0,46957	14,00	0,033
ap	1	5,4721	5,47209	163,20	0,001
vc	1	0,0036	0,00357	0,11	0,766
ae	1	0,1301	0,13014	3,88	0,143
Interações de 2 fatores	6	4,1294	0,68823	20,53	0,016
fz*ap	1	4,0030	4,00300	119,39	0,002
fz*vc	1	0,0701	0,07009	2,09	0,244
fz*ae	1	0,0073	0,00727	0,22	0,673
ap*vc	1	0,0000	0,00002	0,00	0,983
ap*ae	1	0,0113	0,01129	0,34	0,602
vc*ae	1	0,0377	0,03773	1,13	0,367
Interações de 3 fatores	4	0,2960	0,07400	2,21	0,271
fz*ap*vc	1	0,1779	0,17787	5,30	0,105
fz*ap*ae	1	0,0834	0,08338	2,49	0,213
fz*vc*ae	1	0,0078	0,00779	0,23	0,663
ap*vc*ae	1	0,0270	0,02698	0,80	0,436
Interações de 4 fatores	1	0,3835	0,38347	11,44	0,043
fz*ap*vc*ae	1	0,3835	0,38347	11,44	0,043
Curvatura	1	0,3057	0,30566	9,12	0,057
Erro	3	0,1006	0,03353		
Total	19	11,2905			

Fonte: Minitab 2019

A ANOVA confirmou o bom ajuste do modelo, com o R^2_{aj} superior a 70%. Os resultados mostraram que (a_p) exerce maior influência sobre R_a , sendo que sua minimização é alcançada com os menores valores de a_p . As variáveis (v_c) e (a_e) exerceram influência reduzida sobre R_a e R_t , enquanto (f_z) não foi significativo isoladamente, Figura 3.

Figura 3 – Gráfico de efeitos principais para μR_a e μR_t



Fonte: Minitab 2019

3.2 Modelagem de C_{pk} para as Respostas R_a , R_t

A modelagem e otimização do processo consideraram os efeitos das variáveis de ruído para avaliar a robustez e estabilidade das condições de usinagem. No entanto, essas variáveis não foram incluídas diretamente nos modelos de regressão nem na etapa de otimização, conforme Figura 4.

Figura 4 - Resultados de Média, Amplitude, Desvio Padrão e Modelagem do C_{pk} de R_a e R_t

Experimentos	Variáveis de controle				Variáveis de Ruído			Respostas			
	vc	fz	ae	ap	Vb	Q	C	μR_a	μR_t	Cpk (Ra)	Cpk (Rt)
	(m/min)	(mm/dent e)	(mm)	(mm)	(mm)	(l/min)	%	(μm)	(μm)		
1	60	0,1	15	1	0	0	0	0,55	4,31	0,198	1,204
2	60	0,2	15	1	0,3	20	20	0,372	2,91	-0,361	-0,038
3	60	0,1	15	1,5	0	0	0	0,691	3,97	0,845	0,892
4	60	0,2	15	1,5	0,3	20	20	0,801	5,223	1,347	1,086
5	90	0,1	15	1	0	0	0	0,612	4,013	0,562	0,76
6	90	0,2	15	1	0,3	20	20	0,551	3,201	0,271	0,275
7	90	0,1	15	1,5	0	0	0	0,733	4,874	1,293	1,581
8	90	0,2	15	1,5	0,3	20	20	0,866	4,733	1,284	1,303
9	60	0,1	18	1	0	0	0	0,612	4,013	0,681	0,82
10	60	0,2	18	1	0,3	20	20	0,411	2,773	-0,36	-0,14
11	60	0,1	18	1,5	0	0	0	0,333	4,274	-0,719	1,066
12	60	0,2	18	1,5	0,3	20	20	0,816	5,023	1,633	1,573
13	90	0,1	18	1	0	0	0	0,628	4,217	0,717	0,931
14	90	0,2	18	1	0,3	20	20	0,36	2,651	-0,612	-0,283
15	90	0,1	18	1,5	0	0	0	0,749	4,112	1,249	0,904
16	90	0,2	18	1,5	0,3	20	20	0,899	4,882	1,466	1,312
17	75	0,15	16,5	1,25	0,15	10	10	0,647	3,865	0,771	0,76
18	75	0,15	16,5	1,25	0,15	10	10	0,626	3,636	0,678	0,591
19	75	0,15	16,5	1,25	0,15	10	10	0,674	3,907	0,925	0,762
20	75	0,15	16,5	1,25	0,15	10	10	0,645	3,742	0,777	0,479

Fonte: Autor

A ANOVA para C_{pk} (R_a) indicou que o modelo geral é altamente significativo (p-valor de 0,003). Com um R^2 de 99,66% e R^2_{aj} de 97,87%, o modelo demonstrou elevada robustez e capacidade explicativa da variabilidade do C_{pk} (R_a), confirmando que as variáveis explicativas têm um efeito significativo. Para o C_{pk} R_t também foi significativo (p-valor de 0,019), indicando a influência das variáveis. O modelo apresentou R^2_{aj} elevado (93,08%), demonstrando explicabilidade da variabilidade. De acordo com os efeitos principais, (a_p) é o fator mais significativo para o C_{pk} R_t , devido ao maior valor F e menor p-valor, sendo influenciado também pelo (f_z) de acordo com Figura 5.

Figura 5 - Análise de variância para C_{pk} R_a e C_{pk} R_t


Fonte	GL	SQ (Aj.)	QM (Aj.)	Valor F	Valor-P
Modelo	16	9,27062	0,57941	55,53	0,003
Linear	4	4,00388	1,00097	95,93	0,002
fz	1	0,00155	0,00155	0,15	0,726
ap	1	3,33256	3,33256	319,39	0,000
vc	1	0,55009	0,55009	52,72	0,005
ae	1	0,11968	0,11968	11,47	0,043
Interações de 2 fatores	6	3,10701	0,51784	49,63	0,004
fz*ap	1	2,46636	2,46636	236,37	0,001
fz*vc	1	0,44485	0,44485	42,63	0,007
fz*ae	1	0,01934	0,01934	1,85	0,267
ap*vc	1	0,12378	0,12378	11,86	0,041
ap*ae	1	0,05011	0,05011	4,80	0,116
vc*ae	1	0,00257	0,00257	0,25	0,654
Interações de 3 fatores	4	1,96729	0,49182	47,14	0,005
fz*ap*vc	1	0,43104	0,43104	41,31	0,008
fz*ap*ae	1	0,80807	0,80807	77,44	0,003
fz*vc*ae	1	0,29668	0,29668	28,43	0,013
ap*vc*ae	1	0,43149	0,43149	41,35	0,008
Interações de 4 fatores	1	0,07148	0,07148	6,85	0,079
fz*ap*vc*ae	1	0,07148	0,07148	6,85	0,079
Curvatura	1	0,12095	0,12095	11,59	0,042
Erro	3	0,03130	0,01043		
Total	19	9,30192			

Fonte	GL	SQ (Aj.)	QM (Aj.)	Valor F	Valor-P
Modelo	16	5,20095	0,32506	16,97	0,019
Linear	4	3,03633	0,75908	39,63	0,006
fz	1	0,58876	0,58876	30,73	0,012
ap	1	2,39287	2,39287	124,91	0,002
vc	1	0,00639	0,00639	0,33	0,604
ae	1	0,04831	0,04831	2,52	0,210
Interações de 2 fatores	6	1,58662	0,26444	13,80	0,027
fz*ap	1	1,40004	1,40004	73,09	0,003
fz*vc	1	0,00030	0,00030	0,02	0,909
fz*ae	1	0,01891	0,01891	0,99	0,394
ap*vc	1	0,02614	0,02614	1,36	0,327
ap*ae	1	0,04669	0,04669	2,44	0,216
vc*ae	1	0,09455	0,09455	4,94	0,113
Interações de 3 fatores	4	0,35514	0,08878	4,63	0,119
fz*ap*vc	1	0,07196	0,07196	3,76	0,148
fz*ap*ae	1	0,13036	0,13036	6,81	0,080
fz*vc*ae	1	0,02545	0,02545	1,33	0,333
ap*vc*ae	1	0,12738	0,12738	6,65	0,082
Interações de 4 fatores	1	0,11941	0,11941	6,23	0,088
fz*ap*vc*ae	1	0,11941	0,11941	6,23	0,088
Curvatura	1	0,10345	0,10345	5,40	0,103
Erro	3	0,05747	0,01916		
Total	19	5,25842			

Fonte: Minitab 2019

Na análise dos efeitos principais da ANOVA, (a_p) foi o fator mais significativo (p -valor $< 0,001$) para o C_{pk} (R_a), seguida (v_c) (p -valor de 0,005). A (a_e) também foi significativa (p -valor de 0,043), mas com menor influência, enquanto (f_z) não teve influência isolada (p -valor de 0,726). Em relação às interações significativas, destacam-se $f_z \times a_p$ (p -valor = 0,001) e $f_z \times a_p \times a_e$ (p -valor = 0,003). Para C_{pk} de R_t , observa-se que o avanço por dente (a_p) tem a maior influência pois possui o maior valor de F, menor valor P, e demonstrado em Figura 6.

Figura 6 - Gráfico de efeitos principais para o $C_{pk} R_a$ e $C_{pk} R_t$



Fonte: Minitab 2019

4. CONSIDERAÇÕES FINAIS

Ambos os modelos de ANOVA para $C_{pk} (R_a)$ e $C_{pk} (R_t)$ apresentaram significância estatística, evidenciando que as variáveis explicativas possuem um impacto relevante nos índices de capacidade de processo.

Para o $C_{pk} R_a$, o R^2 foi de 99,66%; R^2 ajustado de 97,87% , e para o $C_{pk} R_t$, R^2 foi de 98,91%; R^2 ajustado de 93,08%, demonstrando que ambos possuem uma excelente capacidade de explicação dos dados.

Para as várias e controle, observou-se que: profundidade de corte (ap) maior influência tanto para R_a quanto para R_t ; quanto as interações significativas, avanço por dente (fz) e profundidade de corte (ap).

O próximo estágio, será a: Otimização do $C_{pk} R_a$ e $C_{pk} R_t$ visando encontrar os índices de desempenho do processo, e realização do experimento de confirmação para validar as informações coletadas quanto à robustez do projeto e a melhoria do processo.

AGRADECIMENTOS

Os autores agradecem a Universidade Federal de Itajubá – UNIFEI, Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e a Coordenação de Aperfeiçoamento de Pessoas de Nível Superior (CAPES), pelo incentivo a pesquisa.

REFERÊNCIAS

- ARRUDA, E. C.; ARAUJO, D. B.; OLIVEIRA, R. G. Process optimization in end milling of AISI H13 hardened steel using RPD-RSM approach. **Journal of Manufacturing Processes**, v. 42, p. 50-58, 2019.
- BERTOLINI, M.; SALDANHA, R.; SILVA, T. A comprehensive study on process capability analysis: A review and future directions. **International Journal of Production Research**, v. 60, n. 24, p. 7497-7515, 2022.
- BAZARAA, Mokhtar S.; SHERALI, Hanif D.; SHETTY, Chitharanjan M. **Nonlinear programming: theory and algorithms**. John Wiley & sons, 2006.
- BRITO, F. P.; SANTOS, P. R.; RIBEIRO, J. F. Process control and variability reduction in machining operations. **International Journal of Advanced Manufacturing Technology**, v. 73, n. 5-8, p. 803-815, 2014.
- CAIRO, A.; D'ARCY, J. **Understanding the significance of process capability indices in quality control**. **Quality Engineering**, v. 33, n. 4, p. 412-425, 2021.
- CHAUDHRY, M. M.; WANG, Q.; AHMAD, W. **Robust multi-objective optimization for sustainable design**. **Sustainable Computing: Informatics and Systems**, v. 38, p. 100674, 2023. DOI: 10.1016/j.suscom.2022.100674.
- CHEN, M.; LI, X.; ZHANG, T. Hybrid robust optimization in hard turning processes using neural networks and evolutionary algorithms. **Journal of Manufacturing Science and Engineering**. Associações: Harbin Institute of Technology, China; Technical University of Munich, Alemanha, 2020.
- DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. **Tecnologia da usinagem dos materiais**. 9 ed. São Paulo: ArtLiber, 2014.
- KHAN, M. A.; ALI, M. Optimization of surface roughness in turning of titanium alloy using Taguchi method and ANOVA. **Journal of Manufacturing Processes**, v. 77, p. 170-180, 2022.
- MONTGOMERY, Douglas C. *Design and analysis of experiments*. 8. ed. Hoboken: John Wiley & Sons, 2013. 630 p.
- MONTGOMERY, Douglas C. *Introduction to statistical quality control*. 7. ed. Hoboken: John Wiley & Sons, 2012. 734 p.
- MONTGOMERY, D. C. (2017) **Design and Analysis of Experiments**. John Wiley & Sons, 9th ed., 640 p.

MONTGOMERY, Douglas C. **Introduction to statistical quality control**. John Wiley & sons, 2020.

OLIVEIRA, Carlos Henrique de. *Otimização robusta multivariada no fresamento de topo do aço inoxidável duplex UNS S32205*. 2022. **Tese (Doutorado)** — Universidade Federal de Itajubá (UNIFEI), Itajubá, 2022. Disponível em: <https://repositorio.unifei.edu.br/jspui/handle/123456789/3619> . Acesso em 10/10/2025.

PAIVA, A. P.; MEDEIROS, E. P.; LISBOA, E. A robust optimization approach based on propagation of errors: application to turning process. **International Journal of Production Research**, v. 52, n. 18, p. 5383-5397, 2014.

RANI, R.; KUMAR, V. A hybrid approach using Taguchi and Grey relational analysis for multi-response optimization in machining. **Journal of Cleaner Production**, v. 367, p. 132850, 2022.

RODRIGUES, D. A.; PAIVA, A. P.; LISBOA, E. Multi-objective robust design optimization using RPD-RSM-NBI method in machining processes. **Journal of Manufacturing Systems**, v. 51, p. 199-211, 2019.

TAGUCHI, Genichi. **Introduction to quality engineering: designing quality into products and processes**. 1986.

TIWARI, P. et al. Application of Response Surface Methodology for Robust Parameter Design in Manufacturing Processes. **International Journal of Advanced Manufacturing Technology**, v. 127, n. 7, p. 2103-2116, 2023.