

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
PRODUÇÃO

**OTIMIZAÇÃO ESTOCÁSTICA MULTIOBJETIVO DE
PROCESSOS DE FABRICAÇÃO E RECUPERAÇÃO:
UMA ABORDAGEM PARA QUALIDADE E
SUSTENTABILIDADE**

Simone Carneiro Streitenberger

Itajubá
Fevereiro 2020

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
PRODUÇÃO

Simone Carneiro Streitenberger

**OTIMIZAÇÃO ESTOCÁSTICA MULTIOBJETIVO DE
PROCESSOS DE FABRICAÇÃO E RECUPERAÇÃO:
UMA ABORDAGEM PARA QUALIDADE E
SUSTENTABILIDADE**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção como parte dos requisitos para a obtenção do título de *Mestre em Ciências em Engenharia de Produção*.

Área de concentração: Engenharia de Produção

Orientador: Prof. Dr. Anderson Paulo de Paiva

Itajubá

Fevereiro 2020

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
PRODUÇÃO

Simone Carneiro Streitenberger

**OTIMIZAÇÃO ESTOCÁSTICA MULTIOBJETIVO DE
PROCESSOS DE FABRICAÇÃO E RECUPERAÇÃO:
UMA ABORDAGEM PARA QUALIDADE E
SUSTENTABILIDADE**

Dissertação aprovada por banca examinadora em 17 de Fevereiro de 2020, conferindo à autora o título de Mestre em Ciências em Engenharia de Produção.

Banca Examinadora:

Prof. Dr. Roberto da Costa Quinino
Prof. Dr. José Henrique de Freitas Gomes
Prof. Dr. Anderson Paulo de Paiva (Orientador)

Itajubá
Fevereiro 2020

AGRADECIMENTOS

Agradeço a Deus e à minha família pelo apoio incondicional e por serem minha segurança.

Ao meu orientador, Prof. Dr. Anderson Paiva, pela paciência e generosidade com que me conduziu, sempre me ensinando e me fazendo acreditar que eu sou capaz.

Aos professores do Instituto de Engenharia de Produção e Gestão por terem contribuído tanto para meu crescimento, em especial ao professor Dr. Pedro Paulo Balestrassi pelo incentivo e apoio. Aos membros da banca, professor Dr. Roberto Quinino e professor Dr. José Henrique Gomes, pelas orientações e contribuições acadêmicas.

Aos tantos colegas e amigos que conquistei durante esta trajetória, por todo carinho e suporte que me deram, imprescindíveis para que eu chegasse até aqui. Em especial aos amigos Andreza, Kelly, Clara, Taynara, Fabrício, Alexandre, Afonso, Renata, Eduardo, Max, Vinicius e, ao meu companheiro incansável de estudos e querido amigo, Estevão, por ter estado comigo, literalmente, todos os dias, enfrentando desafios, comemorando conquistas e tornando a caminhada muito mais leve.

A UNIFEI, aos órgãos de fomento à pesquisa FAPEMIG, CNPq e especialmente à CAPES pelo apoio financeiro.

*"Não sabendo que era impossível, foi lá e fez."
(Jean Cocteau)*

RESUMO

A busca por melhorias na qualidade de produtos industriais emerge como constante preocupação quando se trata de processos de fabricação e recuperação. Recobrimento, reciclagem e reuso, por sua vez, são alguns processos de recuperação também em evidência devido ao crescente foco em questões ambientais e de sustentabilidade. Estes processos são compostos por um número de variáveis de entrada que podem ser ajustadas com a finalidade de otimizar determinadas respostas relevantes, trazendo benefícios consideráveis. Entretanto, a complexidade de contemplar diferentes variáveis de saída com objetivos distintos, simultaneamente, faz com que o estudo e a busca por soluções concretas para problemas deste tipo sejam continuamente negligenciados. Técnicas e ferramentas de análise, modelagem e otimização, quando corretamente aplicadas, podem ser extremamente interessantes neste cenário. Este trabalho propõe um método de otimização multiobjetivo de duas fases, para qualidade e sustentabilidade, baseada no uso da análise fatorial, do método de Interseção Normal à Fronteira e da programação estocástica. A aplicação do método foi exemplificada através de um processo de soldagem de revestimento de placas de aço carbono ABNT 1020 utilizando arame tubular de aço inoxidável austenítico ABNT 316L. O primeiro estágio do método focou na otimização das características geométricas do cordão de solda, a partir da obtenção da melhor configuração dos parâmetros de entrada do processo, de maneira a aumentar o nível de qualidade do produto final. Na segunda etapa, tendo a sustentabilidade como foco, sugeriu-se a solução de um problema de otimização estocástica multiobjetivo, elencando o desperdício de material e o custo associado à energia elétrica como objetivos a serem simultaneamente otimizados. Como resultado, verificou-se que o método é capaz de prover resultados consistentes e relevantes quando lida com um grande número de respostas, e ainda permite acoplar informações externas ao processo, como a variação do custo da energia elétrica, produzindo informações importantes e úteis para apoiar a tomada de decisão dentro das indústrias.

Palavras-chave: Otimização multiobjetivo, Análise Fatorial, Método da Interseção Normal à Fronteira, Programação estocástica, Soldagem de revestimento.

ABSTRACT

Searching for improvements in the quality of industrial products emerges as a constant concern when dealing with manufacturing and recovery processes. Recovering, recycling and reusing are some recovery processes that are also in the spotlights because of environmental and sustainability issues. These processes generally involve a number of input variables that can be adjusted willing to optimize determined relevant responses, producing considerable benefits. Nevertheless, the complexity when contemplating distinct output variables with different but simultaneously goals makes this kind of research being continuously neglected. Applying analysis, modeling and optimizing tools in an adequate way may produce interesting results. This study proposes a two-phase optimization method based on the use of factor analysis, the Normal Boundary Intersection method and stochastic programming. The first phase focuses on the process quality characteristics and the second one on its sustainability. A real application was developed in a cladding process of ABNT 1020 carbon steel plate using austenitic ABNT 316L stainless steel cored wire to exemplify this approach. The first stage of the method focused on optimizing the geometric characteristics of the weld bead in order to improve the quality of the final product. In the second stage, which focuses on a sustainability aspect, it was solved a multiobjective stochastic problem aiming the minimization of the waste of material (scrap and rework) jointly with the energy consumption. It was possible to state that the method may provide consistent results when dealing with a large number of responses, and it also allows embodying external relevant information, like the electricity's cost variation, producing important data to support the decision making.

Keywords: *Multiobjective Optimization, Factor Analysis, Normal Boundary Intersection method, Stochastic Programming, Cladding.*

LISTA DE ILUSTRAÇÕES

Figura 1.1 –Teste Qui-Quadrado para o número de variáveis de entrada	4
Figura 2.1 –Fronteira de Pareto para problemas biobjetivo obtida a partir do NBI .	10
Figura 2.2 –Experimento fatorial com efeitos principais	13
Figura 2.3 –Experimento fatorial com efeito interação	13
Figura 2.4 –Experimento fatorial sem efeito de interação	14
Figura 2.5 –Representação do arranjo CCD para 3 fatores	16
Figura 2.6 –Arranjo de mistura para 3 componentes	17
Figura 3.1 –Classificação dos processos de fabricação.	22
Figura 3.2 –Perfil geométrico do cordão de solda.	25
Figura 5.1 –Método - Fase 1: uma abordagem para qualidade	31
Figura 5.2 –Método - Fase 2: uma abordagem para sustentabilidade	32
Figura 6.1 –Gráfico de probabilidade para os resíduos dos modelos das variáveis de resposta	38
Figura 6.2 –Gráfico de correlação para as respostas originais	39
Figura 6.3 –Dendrograma de clusterização das variáveis originais	40
Figura 6.4 –Gráfico de correlação para os fatores extraídos	43
Figura 6.5 –Gráfico de probabilidade para os resíduos dos modelos dos fatores . . .	45
Figura 6.6 –Gráfico 3D dos fatores normalizados <i>versus</i> seus respectivos pesos . . .	46
Figura 6.7 –Gráficos de contorno e superfície para a distância de Mahalanobis . . .	48
Figura 6.8 –Gráficos de contorno e superfície para a entropia	49
Figura 6.9 –Gráfico de contorno para as variáveis originais e fatores extraídos . . .	50
Figura 6.10 –Cordão de solda particionado	51
Figura 6.11 –Fotografias originais dos cordões de solda experimentais	52
Figura 6.12 –Áreas de refugo e retrabalho dos cordões de solda experimentais	52
Figura 6.13 –Gráfico de probabilidade para os resíduos do modelo da média do des- perdício	59
Figura 6.14 –Gráfico de probabilidade para os resíduos do modelo da média do custo da energia elétrica	60
Figura 6.15 –Fronteira de Pareto para o desperdício de material	62

LISTA DE QUADROS

Quadro 4.1 – Descrição das bandeiras tarifárias brasileiras	27
Quadro 6.1 – Variáveis originais e seus sentidos de otimização	35
Quadro 6.2 – Variáveis de resposta, sentidos de otimização e convexidade	39

LISTA DE TABELAS

Tabela 4.1 –Valores (em R\$) da modalidade tarifária horária azul referentes ao mês 03/2019	27
Tabela 6.1 –Parâmetros do processo e níveis de trabalho	33
Tabela 6.2 –SQA e <i>p-value</i> para a análise de curvatura referentes às variáveis de resposta	36
Tabela 6.3 –Valores dos ajustes para os modelos das variáveis de resposta	38
Tabela 6.4 –Matriz de correlação para as respostas originais	40
Tabela 6.5 –Cargas fatoriais rotacionadas e comunalidades	41
Tabela 6.6 – <i>Scores</i> dos fatores	42
Tabela 6.7 –Análise de variância para o fator F1	43
Tabela 6.8 –Análise de variância para o fator F2	44
Tabela 6.9 –Análise de variância para o fator F3	44
Tabela 6.10 –Valores dos ajustes para os modelos dos fatores	44
Tabela 6.11 –Informações utilizadas na definição dos valores alvo dos fatores	45
Tabela 6.12 –Análise de variância para a distância de Mahalanobis (proporções de componentes)	47
Tabela 6.13 –Análise de variância para a entropia (proporções de componentes)	48
Tabela 6.14 –Valores dos ajustes para os modelos da distância de Mahalanobis (<i>M</i>) e entropia (<i>E</i>)	48
Tabela 6.15 –Valores ótimos para as variáveis de resposta originais	49
Tabela 6.16 –Matriz <i>Pay-off</i> para os dados otimizados	50
Tabela 6.17 –Valores ótimos para as variáveis de resposta e alvos individuais	53
Tabela 6.18 –Áreas de retrabalho e refugo calculadas para as faces do corte D dos corpos de prova	53
Tabela 6.19 –Desperdícios das faces direita e esquerda e desperdício médio	54
Tabela 6.20 –Custo da energia para HP (em R\$) a partir do calor imposto	55
Tabela 6.21 –Custo da energia para HFP (em R\$) a partir do calor imposto	57
Tabela 6.22 –Análise de variância para o desperdício de material (proporções de componentes)	58
Tabela 6.23 –Análise de variância para o custo da energia elétrica (proporções de componentes)	59
Tabela 6.24 –Valores ótimos para o problema estocástico	61
Tabela 6.25 –Resultados ótimos para as abordagens de qualidade e sustentabilidade	63
Tabela C.1 –Análise de variância para o calor imposto (CI)	77
Tabela C.2 –Análise de variância para a penetração (P)	78

Tabela C.3 –Análise de variância para a área de penetração (AP)	78
Tabela C.4 –Análise de variância para a diluição (D)	79
Tabela C.5 –Análise de variância para a largura (L)	79
Tabela C.6 –Análise de variância para o reforço (R)	80
Tabela C.7 –Análise de variância para o índice de convexidade (IC)	80
Tabela C.8 –Análise de variância para a área de reforço (AR)	81
Tabela C.9 –Análise de variância para o fator de penetração (FP)	81
Tabela C.10 –Análise de variância para o fator de reforço (FR)	82

LISTA DE ABREVIATURAS E SIGLAS

DoE	<i>Design of Experiments</i> – Planejamento de experimentos
RSM	<i>Response Surface Methodology</i> - Metodologia de Superfície de Respostas
ANOVA	<i>Analysis of Variance</i> - Análise de variância
CCD	<i>Central Composite Design</i> - Arranjo Composto Central
MOP	<i>Multiobjective Optimization Programming</i> – Problema de Otimização Multiobjetivo
NBI	<i>Normal Boundary Intersection</i> - Interseção Normal à Fronteira
ANEEL	Agência Nacional de Energia Elétrica
CEMIG	Companhia Energética de Minas Gerais S.A.
MMSE	<i>Multivariate Mean Square Error</i> - Erro Quadrático Médio Multivariado
PCA	<i>Principal Component Analysis</i> - Análise de Componentes Principais
GL	Graus de liberdade
SQ	Soma de Quadrados
SQA	Soma de Quadrados Ajustada
MQA	Média Quadrática Ajustada
HP	Horário de ponta
HFP	Horário fora de ponta
OLS	<i>Ordinary Least Squares</i> – Mínimos Quadrados Ordinários

SUMÁRIO

Agradecimentos	iv
Epígrafe	v
Resumo	vi
Abstract	vii
Lista de Figuras	vii
Lista de Quadros	viii
Lista de Tabelas	ix
Lista de Abreviaturas e Siglas	xii
1 Introdução	1
1.1 Justificativa e Relevância	3
1.2 Objetivos	4
1.2.1 Objetivo Geral	4
1.2.2 Objetivos Específicos	5
1.3 Método de pesquisa	5
1.4 Delimitações do estudo	6
1.5 Estrutura do Trabalho	6
2 Fundamentação Teórica	8
2.1 Otimização multiobjetivo	8
2.1.1 Método da Interseção Normal à Fronteira	9
2.1.2 Programação estocástica multiobjetivo	11
2.2 Planejamento de Experimentos	12
2.2.1 Arranjo fatorial	12
2.2.2 Metodologia de Superfície de Resposta	14
2.2.3 Arranjo de misturas	17
2.3 Análise de dados multivariados	17
2.3.1 Análise Fatorial	18
2.4 Erro Quadrático Médio Multivariado	20
3 Processos de fabricação	22
3.1 Processos de fabricação	22

3.1.1	Soldagem	22
3.1.1.1	Soldagem de revestimento	23
3.1.1.2	Características e variáveis do processo	24
3.1.1.3	Refugo e retrabalho	25
4	Sistema tarifário brasileiro de energia elétrica	26
5	Abordagem Estocástica Multiobjetivo para qualidade e sustentabilidade	28
6	Estudo de caso	33
6.1	Aplicação do método	35
6.1.1	Fase 1: uma abordagem para qualidade	35
6.1.2	Fase 2: uma abordagem para sustentabilidade	50
7	Conclusão	64
7.1	Sugestões para trabalhos futuros	65
	Referências	66
	APÊNDICE A Artigos investigados no periódico <i>Journal of Cleaner Production</i>	73
	APÊNDICE B Arranjo experimental e respostas coletadas e calculadas	76
	APÊNDICE C Análise de variância (ANOVA) para os modelos das respostas coletadas e calculadas	77
	APÊNDICE D Valores da distância de Mahalanobis e entropia para os 70 subproblemas do NBI	83
	APÊNDICE E Soluções ótimas para os fatores F1, F2 e F3	86

1 INTRODUÇÃO

Processos de fabricação são aqueles que, por meio de máquinas e ferramentas, transformam um material inicial através de alterações químicas ou físicas, agregando valor a ele (GROOVER, 2013). Estes processos são considerados componentes-chave dentro da indústria sendo, desta forma, foco de constantes pesquisas de otimização. Determinados processos de fabricação podem também ser aplicados como processos de recuperação, cujo objetivo esteja relacionado à recuperação de peças desgastadas, ou à reciclagem de determinado componente, dentre outros (WAINER *et al.*, 2013).

Abordagens de recobrimento, revestimento, remanufatura, reuso e reciclagem vêm sendo amplamente pesquisadas e aplicadas ao contexto industrial, principalmente porque técnicas de recuperação focando a sustentabilidade ambiental estão em considerável evidência atualmente. As partes envolvidas em todo o ciclo de produção, dos consumidores à alta gestão, estão, cada vez mais, demandando e exigindo processos mais conscientes e sustentáveis (RUSINKO, 2007). Explorar e optar por estes caminhos pode proporcionar benefícios não somente ambientais, mas também econômicos (ZHANG; LIU, 2017).

De acordo com Flandinet *et al.* (2012), a reutilização de materiais a partir de técnicas de reciclagem vem sendo encorajada por um grande número de países e indústrias a fim de minimizar as perdas. A remanufatura, por exemplo, pode, além de preservar o valor intrínseco de produtos desativados (PENG *et al.*, 2019), eliminar estágios de produção, como o processamento de material, reduzindo significativamente o ciclo de vida dos processos (LIU *et al.*, 2016).

Cabrera *et al.* (2011) destacaram o desenvolvimento de várias tecnologias, como processos microbiológicos, para recuperar espécies metálicas de interesse através da redução ou remoção de metais pesados de meios contaminados, tais como os danos causados pelo resíduo sólido gerado pelo processo de extração de níquel a partir da utilização da tecnologia de carbonato de amônio.

Flandinet *et al.* (2012) explicaram a importância do desenvolvimento de técnicas de reciclagem para as placas de circuitos impresso que já foram utilizadas e estariam para descarte. Embora sejam compostas por metais pesados e substâncias nocivas, metais preciosos são responsáveis por mais de 70% de sua composição, o que torna o assunto interessante não somente sob o aspecto de evitar a poluição ambiental, mas também de auxiliar na reciclagem de componentes valiosos. Seguindo esta mesma linha, Zhan *et al.* (2015) abordaram a recuperação sustentável de gálio e índio, dentre outros metais, a partir de LEDs que estejam no final de seu ciclo de vida, focando na redução de danos aos recursos e à saúde e aumentando a proteção ambiental.

Liu *et al.* (2016) apontaram o processo de revestimento por feixe de laser (*laser cladding*) como uma das técnicas mais efetivas para remanufatura de componentes automotivos, reforçando a ênfase dada às técnicas de reaproveitamento. O processo de revestimento a partir do aço inoxidável, que deposita uma camada de aço inoxidável em superfícies de aço carbono ou aços de baixa liga, também pode ser considerado como outro método interessante (GOMES *et al.*, 2013). Sua base pode ser um material comum, geralmente mais barato que o aço inoxidável puro e que pode, inclusive, estar para descarte, justificando os interesses econômicos e ambientais desta técnica.

No entanto, embora o reuso do aço possa implicar na redução de custos, um mercado amplo relacionado ainda não está completamente difundido, visto que seus benefícios não estão rateados entre os envolvidos na cadeia de suprimento. Desta forma, poderia ser interessante inserir nesta cadeia de suprimentos uma figura especializada em aquisição, recondicionamento e distribuição de elementos de reuso (DUNANT *et al.*, 2018), com a finalidade de explorar e reconhecer os ganhos da incorporação de tais técnicas.

Ainda assim, é possível notar que a remanufatura está se tornando uma atividade relevante à medida que esta consciência social sobre a proteção ambiental e a redução de perdas tem aumentado. Shakourloo (2017) propuseram um novo modelo para otimizar o processo de remanufatura, focado nos lucros e custos do processo, aplicando a programação multiobjetivo. A maior vantagem deste tipo de trabalho é que ele contribui com a sustentabilidade das operações, o que significa utilizar os recursos disponíveis sem comprometer as necessidades das gerações futuras.

A otimização multiobjetivo vem se tornando uma grande aliada na melhoria dos processos de produção industrial, pois, juntamente com a aplicação de técnicas de análise e modelagem, permite encontrar cenários em que a configuração dos parâmetros do processo sejam ótimos, ainda que sujeito a restrições e necessidades específicas. Além disso, a otimização pode ser abordada sob diferentes perspectivas, como qualidade e sustentabilidade, por exemplo, podendo ainda acoplar informações externas ao processo, mas relevantes ao contexto da produção, como o custo de energia ou de materiais, incorporando estocasticidade ao problema.

Considerando a relevância e importância deste tema dentro do contexto industrial, este trabalho, tendo seu foco na otimização de processos de fabricação e recuperação, propõe um método de duas fases baseada no uso da análise fatorial, do método de Interseção Normal à Fronteira e da programação estocástica. Um estudo de caso é apresentado, exemplificando a aplicação do método a um processo de soldagem de revestimento de placas de aço carbono ABNT 1020 utilizando arame tubular de aço inoxidável austenítico ABNT 316L.

1.1 JUSTIFICATIVA E RELEVÂNCIA

A implementação de métodos de otimização multiobjetivo em processos industriais tem crescido consideravelmente. Entretanto, embora largamente difundidas, estas técnicas nem sempre são utilizadas de forma adequada, considerando todos os aspectos relevantes e essenciais dos métodos escolhidos.

Realizando uma pesquisa no periódico internacional *Journal of Cleaner Production*, cujas duas importantes abordagens envolvidas na proposta deste estudo, qualidade e sustentabilidade, são extensamente citadas, encontra-se a aplicação da Metodologia de Superfície de Resposta (RSM - *Response Surface Methodology*) em um número considerável de trabalhos. A RSM é largamente utilizada para identificação das respostas que influenciam o processo. A busca foi executada na base da revista, compreendendo o período de 2015 a 2019, tendo como critério de busca a palavra-chave “*response surface methodology*”. Foram considerados apenas os resultados relacionados a artigos completos, sendo descartadas outras categorias, tais como artigos de revisão. Visando reduzir o número de 259 resultados retornados, aplicou-se um filtro adicional onde o termo de busca exato estivesse apresentado em seu título. Os 26 artigos selecionados podem ser observados no Apêndice A.

Dentre estes, avaliaram-se alguns dos critérios considerados extremamente relevantes a um problema de otimização: i) convexidade das funções; ii) sentido de otimização do problema (maximização ou minimização); iii) número de fatores, ou variáveis de entrada do processo, considerados; iv) número de respostas; v) número de pontos centrais; vi) realização de otimização multiobjetivo; vii) avaliação da correlação entre as repostas consideradas e viii) utilização da restrição de espaço experimental.

Em relação ao número de variáveis de entrada do processo, desenvolveu-se um teste Qui-Quadrado de qualidade de ajuste para avaliar a predominância de algum número específico de fatores, obtendo-se um *p-value* com valor igual a 0,001. Desta forma, determinou-se que problemas com 3 e 4 variáveis de entrada ocorrem mais frequentemente nos artigos investigados, sendo os problemas com 2 ou 5 variáveis menos recorrentes. O gráfico para os valores observados e esperados pode ser observado na Figura 1.1.

O número de variáveis de saída determina se o problema é multiobjetivo ou não. Dentre os 26 artigos, 13 apresentam funções objetivo sendo otimizadas simultaneamente e 14 trabalham com apenas um objetivo a ser otimizado ou os autores optaram por não tratar o problema como multiobjetivo. Sendo assim, executando o mesmo teste Qui-Quadrado anteriormente realizado, conclui-se que ambos os problemas ocorrem com a mesma frequência, visto que se obteve um *p-value* igual a 0,847.

Um ponto crítico dentro de um cenário de otimização é a análise da convexidade da função objetivo em relação ao sentido de otimização proposto para tal. Em 66% dos

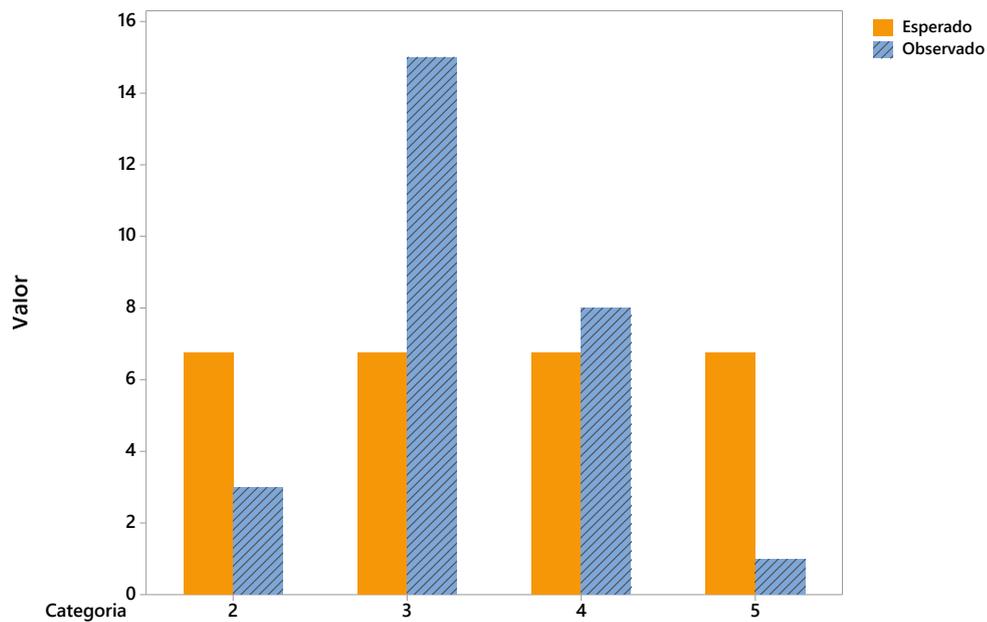


Figura 1.1 – Teste Qui-Quadrado para o número de variáveis de entrada

casos avaliados, a convexidade e o sentido de otimização não eram coincidentes, ou seja, funções convexas foram maximizadas ou funções côncavas foram minimizadas. Este tipo de situação exigiria a aplicação de uma restrição de espaço experimental dentro do algoritmo utilizado para solucionar o problema de otimização, para que fosse possível limitar a região de solução do problema.

Entretanto, dentre os artigos analisados, 8 deles não mencionaram como a solução ótima foi obtida, enquanto que os 18 restantes aplicaram o algoritmo *Desirability*. Porém, é importante salientar que esta abordagem não trabalha com restrição de espaço experimental, o que pode acarretar em soluções fora da região de viabilidade e, portanto, sem garantia de confiabilidade, além de não considerar a correlação entre as respostas. Em relação a esta última questão, apenas um artigo mencionou explicitamente sobre a correlação entre respostas, o que deixa margem para o questionamento sobre a realização desta análise nos demais trabalhos.

Desta forma, este estudo se justifica à medida em que propõe demonstrar a aplicação adequada de um conjunto de técnicas de análise, modelagem e otimização, com a finalidade de garantir a qualidade da resposta ótima dentro de um cenário multiobjetivo.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Baseado na discussão anteriormente apresentada, o principal objetivo deste estudo é propor um método de duas fases para otimização de processos de fabricação e

recuperação, sob abordagens de qualidade e sustentabilidade, utilizando análise fatorial, programação estocástica e o método da Interseção Normal à Fronteira.

1.2.2 Objetivos Específicos

Este trabalho visa propor um método composto por duas etapas. Os objetivos específicos da primeira fase são:

- modelar um problema multiobjetivo envolvendo variáveis relacionadas à qualidade do processo, através da Metodologia de Superfície de Resposta;
- aplicar a análise fatorial para neutralização do efeito de correlação entre as respostas e redução de dimensionalidade do problema;
- otimizar os erros quadráticos médios multivariados dos resultados das otimizações dos fatores, para solução da questão de objetivos conflitantes e
- aplicar o método NBI para a otimização do problema, obtendo as fronteiras ou superfícies de Pareto contendo soluções ótimas.

Em relação à segunda fase, os objetivos específicos são:

- modelar um problema estocástico envolvendo variáveis relacionadas à sustentabilidade do processo e
- utilizar o método NBI para solução do problema, obtendo as fronteiras ou superfícies de Pareto de soluções ótimas.

1.3 MÉTODO DE PESQUISA

Para atingir os objetivos determinados neste trabalho, propõe-se a utilização de técnicas de estatística multivariada (análise fatorial), planejamento de experimentos (Metodologia de Superfície de Resposta) e métodos de otimização (programação estocástica e NBI).

Este estudo pode ser caracterizado como sendo explicativo e quantitativo, visto que investiga a influência de fatores na ocorrência de um determinado fenômeno e trabalha dados experimentais coletados que podem ser quantificados e tratados estatisticamente. Neste aspecto, também apresenta características de modelagem já que desenvolve seu curso através de funções modeladas com o apoio de *softwares* estatísticos. Além disso, devido ao seu interesse prático, exemplificado através da aplicação do método a um processo de soldagem de revestimento, esta pesquisa também pode ser classificada como de natureza aplicada.

1.4 DELIMITAÇÕES DO ESTUDO

Este trabalho busca propor um método que, em um primeiro momento, proporcione a identificação de uma resposta ótima de parâmetros de processos de fabricação e recuperação, considerando variáveis relacionadas à determinada característica de qualidade do produto final, e, em um segundo momento, permita uma configuração ótima destes mesmos parâmetros, porém agora associados a características especificamente atreladas à sustentabilidade do processo.

O estudo visa também exemplificar o método através da sua aplicação em um processo de soldagem de revestimento de chapas de aço carbono ABNT 1020, tendo o arame tubular de aço inoxidável ABNT 316L como metal de adição, sob duas perspectivas principais: i) definir as condições ótimas das variáveis de entrada de maneira a otimizar a geometria do cordão de solda, visando à qualidade do processo como um todo e ii) definir a configuração ótima do processo sujeito à minimização do consumo de energia simultaneamente à minimização do desperdício de material, buscando, assim, um cenário de maior sustentabilidade.

O enfoque, entretanto, não está na execução do processo em si, mas na aplicação de uma combinação de técnicas e métodos sobre os dados coletados no trabalho de dissertação de [Gomes \(2010\)](#). Para tal, as respostas relativas ao processo foram, em sua totalidade, obtidas do trabalho de dissertação de [Gomes \(2010\)](#) que analisou e otimizou o processo de soldagem com arame tubular empregada em uma operação de revestimento de chapas de aço carbono com aço inoxidável utilizando algumas técnicas distintas das abordadas neste trabalho.

1.5 ESTRUTURA DO TRABALHO

Este trabalho está subdividido em 7 capítulos, onde o primeiro apresentou uma breve contextualização dos assuntos abordados na pesquisa, bem como sua justificativa, delimitações e objetivos.

O capítulo 2 apresenta a fundamentação teórica, abordando os principais conceitos trabalhados neste estudo, como: planejamento de experimentos, otimização multiobjetivo, método da Interseção Normal à Fronteira, análise fatorial e Erro Quadrático Médio Multivariado.

O terceiro capítulo apresenta uma contextualização sobre os processos de fabricação e recuperação, além de uma breve descrição do processo de soldagem de revestimento. O quarto capítulo, por sua vez, aborda o sistema de tarifação da energia elétrica no cenário brasileiro.

O quinto e o sexto capítulos apresentam, respectivamente, o método proposto para

a otimização de processos de fabricação ou recuperação, visando aspectos de qualidade e sustentabilidade, e a aplicação deste método a um processo de soldagem de revestimento de placas de aço carbono ABNT 1020 utilizando arame tubular de aço inoxidável austenítico ABNT 316L.

Finalmente, o capítulo 7 apresenta as conclusões deste estudo e sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 OTIMIZAÇÃO MULTIOBJETIVO

Problemas de otimização que recaem sobre aplicações práticas e industriais têm, em sua grande maioria, seu desempenho impactado por múltiplos objetivos. Uma formulação geral para problemas de otimização multiobjetivo (MOP - *Multiobjective Optimization Programming*) é apresentada na Equação (2.1) (KARPAT; ÖZEL, 2005).

$$\begin{aligned} \min_x f(x) &= \{f_1(x), f_2(x), f_3(x), \dots, f_k(x)\} \\ \text{s.a. : } g_j(x) &= b_j, j = 1, 2, \dots, m \\ h_j(x) &\leq b_j, j = 1, 2, \dots, m + p \end{aligned} \tag{2.1}$$

onde $f_i(x)$ representa a i -ésima função objetivo, $g_i(x)$ e $h_i(x)$ denotam, respectivamente, as restrições de igualdade e desigualdade, e o vetor $x = (x_1, x_2, \dots, x_n)$ representa as n variáveis de decisão do processo.

Um dos grandes desafios enfrentados dentro da otimização multiobjetivo está relacionado à importância de cada uma das funções objetivo compreendidas pelo problema, sob determinada condição. Duas abordagens distintas podem ser utilizadas para lidar com esta questão. A primeira delas, conhecida como aglutinação, sugere que a todos os objetivos sejam atribuídos pesos referentes ao seu grau de relevância dentro do processo, e que, posto isto, todos eles sejam agregados em uma única função a ser otimizada. Desta forma, a otimização desta função global garante que as características individuais também sejam otimizadas. A segunda, conhecida como priorização, determina que um objetivo seja escolhido como o mais importante, fazendo com que ele componha exclusivamente a função a ser otimizada, enquanto que as demais funções objetivo sejam tratadas como restrições do problema (PAIVA *et al.*, 2009). Assim, o atendimento de todas as restrições garante que a resposta ótima forneça soluções que atendam a todos os objetivos.

Além disso, usualmente em MOP, os objetivos possuem sentidos de otimização conflitantes. Ou seja, parte das características visa ser minimizada, enquanto que parte objetiva ser maximizada, simultaneamente. Para lidar com a dificuldade em determinar a relação de *trade-off* que produza o melhor cenário possível, a otimização multiobjetivo busca encontrar a denominada Fronteira de Pareto, que contém soluções viáveis em que nenhum objetivo pode ser melhorado sem o sacrifício de, pelo menos, um dos outros objetivos (BOKRANTZ; FREDRIKSSON, 2017). Assim sendo, a Fronteira de Pareto fornece um conjunto de soluções potenciais que devem ser exploradas pelo tomador de decisão,

visto que não é viável melhorar todas as funções objetivo simultaneamente (KARPAT; ÖZEL, 2005).

2.1.1 Método da Interseção Normal à Fronteira

A grande maioria dos casos reais envolvem a otimização de duas ou mais funções cujos objetivos são conflitantes, o que requer estratégias mais sofisticadas para a obtenção de bons resultados. Das e Dennis (2003) propuseram um método para suprir, dentre outras, a incapacidade do método das somas ponderadas de encontrar uma distribuição uniforme das soluções Pareto ótimas (NAVES *et al.*, 2017). Denominado Interseção Normal à Fronteira (NBI - *Normal Boundary Intersection*), o método fornece soluções distintas e equidistantes dentro da Fronteira de Pareto, independentemente da distribuição de pesos ou escalas relativas das funções objetivo envolvidas (MOURA *et al.*, 2018).

De acordo com Brito *et al.* (2014), para um cenário biobjetivo, o problema pode ser matematicamente expresso em termos da Equação (2.2).

$$\begin{aligned} & \min \bar{f}_1(x) \\ & s.t. : \bar{f}_1(x) - \bar{f}_2(x) + 2w - 1 = 0 \\ & \quad g_j(x) \geq 0 \\ & \quad 0 \leq w \leq 1 \end{aligned} \tag{2.2}$$

onde $\bar{f}_1(x)$ e $\bar{f}_2(x)$ são funções objetivo normalizadas de acordo com a Equação (2.3).

$$\bar{f}(x) = \frac{f_i(x) - f_i^U}{f_i^N - f_i^U} \tag{2.3}$$

Os valores de Utopia e Nadir, f_i^U e f_i^N , respectivamente, representam o melhor e o pior valor para a função a ser normalizada. Estes valores são obtidos a partir da matriz denominada *Pay-off* que consiste em um matriz composta pelos valores individuais ótimos de cada função na diagonal principal, representados por $f_i^*(x_i^*)$. Os valores ótimos do vetor \mathbf{x} devem ser aplicados às funções objetivos remanescentes $f_i(x_i^*)$ para completar as linhas da matriz *Pay-off*, como pode ser observado na Equação (2.4).

$$\bar{\Phi} = \begin{bmatrix} f_1^*(x_1^*) & \dots & f_1(x_i^*) & \dots & f_1(x_m^*) \\ \vdots & \ddots & & & \vdots \\ f_i(x_1^*) & \dots & f_i^*(x_i^*) & \dots & f_i(x_m^*) \\ \vdots & & & \ddots & \vdots \\ f_m(x_1^*) & \dots & f_m(x_i^*) & \dots & f_m^*(x_m^*) \end{bmatrix} \tag{2.4}$$

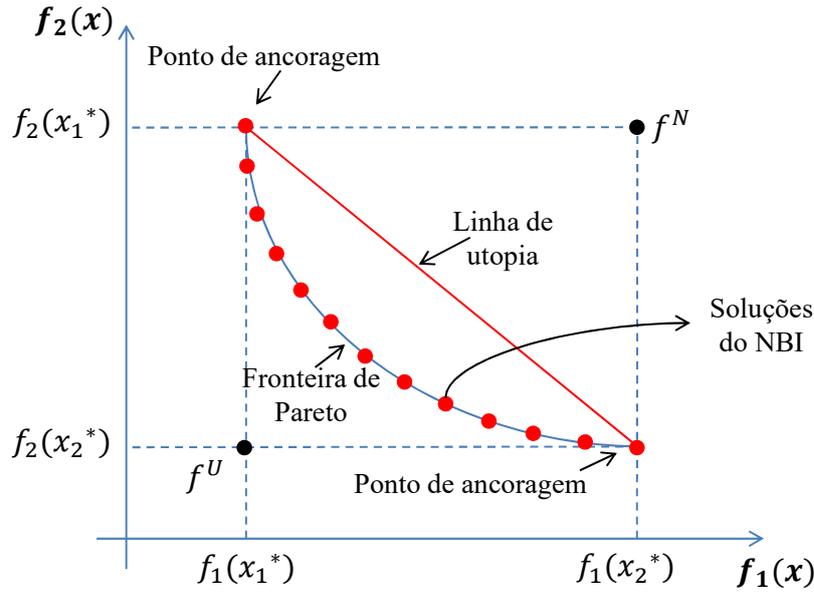


Figura 2.1 – Fronteira de Pareto para problemas biobjetivo obtida a partir do NBI

A representação gráfica para problemas biobjetivo é ilustrada na Figura 2.1.

De maneira similar, em situações cujo propósito seja a otimização de três ou mais funções simultaneamente, o problema pode ser genericamente modelado conforme a Equação (2.5):

$$\begin{aligned}
 & \min_{(\mathbf{x}, t)} \mathbf{D} \\
 & s.t. : \bar{\Phi} \mathbf{w} + D \hat{\mathbf{n}} = \bar{\mathbf{F}}(\mathbf{x}) \\
 & \quad \mathbf{x} \in \Omega \\
 & \quad g_j(\mathbf{x}) \leq 0 \\
 & \quad h_j(\mathbf{x}) \leq 0
 \end{aligned} \tag{2.5}$$

onde $\bar{\Phi}$ representa a matriz *Pay-off* normalizada, $\bar{\mathbf{F}}(\mathbf{x})$ é o vetor das funções objetivo normalizadas, \mathbf{w} é o vetor de pesos e $\hat{\mathbf{n}}$ é o vetor normalizado unitário.

Naves *et al.* (2017) ressaltam que, quando identificada uma relação entre os pesos e as soluções de Pareto, esta relação pode ser modelada e também otimizada, de maneira que torna-se possível identificar as melhores soluções no espaço compreendido pela Fronteira de Pareto.

É válido mencionar que se as funções objetivo são positivamente correlacionadas, isto pode causar instabilidade ou superajuste do modelo e a não representatividade dos coeficientes de regressão (WU, 2005; YUAN *et al.*, 2008; BOX *et al.*, 1973), e o método do NBI provavelmente produzirá resultados não realistas (COSTA *et al.*, 2016). Além disso, na maioria dos processos de fabricação, dois objetivos devem ser atingidos: a distância

em relação ao alvo e sua variância. Entretanto, quando o problema envolve múltiplas respostas e objetivos distintos, ele se torna muito mais complexo. Sendo assim, exemplos de abordagens utilizadas para lidar com estes problemas são a Análise Fatorial e o Erro Quadrático Médio Multivariado, detalhados nas sessões seguintes.

2.1.2 Programação estocástica multiobjetivo

De acordo com [Díaz-García et al. \(2005\)](#), no contexto da RSM e da otimização multiobjetivo, objetiva-se otimizar um modelo de segunda ordem, conforme Equação (2.6).

$$\begin{aligned} \min_x \hat{Y}(\mathbf{x}, \hat{\beta}) \\ \text{s.t. } \|\mathbf{x}\|^2 = x_1^2 + \dots + x_k^2 \leq \xi^2 \end{aligned} \quad (2.6)$$

sendo ξ^2 uma constante conhecida necessária à restrição do espaço experimental. O polinômio a ser otimizado, apresentado na Equação (2.11), agora passa a considerar as incertezas nos coeficientes calculados conforme Equação (2.7), tornando-o estocástico.

$$\hat{Y}(\mathbf{x}, \hat{\beta}) = \hat{\beta}_0 + \sum_{i=1}^k \hat{\beta}_i x_i + \sum_{i=1}^k \hat{\beta}_{ii} x_i^2 + \sum_{i < j}^k \hat{\beta}_{ij} x_i x_j \equiv z'(\mathbf{x}) \hat{\beta} \quad (2.7)$$

onde $z(\mathbf{x})$ contém os termos polinomiais de k preditores em \mathbf{x} , e $\hat{\beta}$ é o vetor dos coeficientes da regressão dos quadrados mínimos. Entretanto, estes coeficientes não são determinísticos, já que assumiram-se $Y_i = z'(\mathbf{x}_i)\beta + \epsilon_i$, onde $\epsilon_i \sim N(0, \sigma^2)$, ϵ_i 's independentes para $i = 1, \dots, n$, e $\hat{\beta} \sim N_p(\beta, \sigma^2(X'X)^{-1})$, com $p = 1 + k + k(k+1)/2$ e $(n-p)\hat{\sigma}^2/\sigma^2 \sim \chi_{n-p}^2$, sendo $\hat{\sigma}^2$ o estimador não enviesado de σ^2 e X a matriz experimental de dimensão $n \times p$ e $\text{rank } p$ ([DÍAZ-GARCÍA et al., 2005](#)).

Sendo assim, em um problema estocástico, as variáveis de resposta, as variáveis de controle e até mesmo alguns parâmetros envolvidos nestes estudos podem ter uma característica aleatória ([DÍAZ-GARCÍA et al., 2005](#)). Alguns problemas com múltiplas respostas que consideram a presença de incerteza podem ser observados em ([YANG et al., 2018](#); [FU et al., 2019](#); [SHABANI](#); [SOWLATI, 2016](#); [REN et al., 2019](#)).

Uma abordagem muito útil relacionada à programação estocástica é o problema dual, onde as funções a serem otimizadas são determinadas pela média e pela variância da variável de resposta. Assim, considerando a presença de coeficientes aleatórios na função objetivo e na restrição, um problema para o qual o objetivo seja minimizar o valor da média mais a variância de uma variável de resposta, sujeito ao valor da média mais o desvio

padrão de uma segunda variável de resposta, pode ser modelado conforme Equação (2.8).

$$\begin{aligned} \min_x F(x) &= w(\mathbf{x}^T\beta) + (1-w)[\mathbf{x}^T(\tilde{\Sigma}_\beta)\mathbf{x}] \\ s.a. : g_1(\mathbf{x}) &= \mathbf{x}^T\gamma + s_i\sqrt{\mathbf{x}^T(\tilde{\Sigma}_\beta)\mathbf{x}} - c \leq 0 \\ g_2(\mathbf{x}) &= \mathbf{x}^T\mathbf{x} \leq \xi^2 \end{aligned} \quad (2.8)$$

onde w representa o peso associado à primeira parte do problema, $\mathbf{x}^T\beta$ e $\mathbf{x}^T(\tilde{\Sigma}_\beta)\mathbf{x}$ representam a média e a variância da primeira variável de resposta, respectivamente, e $\mathbf{x}^T\gamma$ e $\sqrt{\mathbf{x}^T(\tilde{\Sigma}_\beta)\mathbf{x}}$ indicam a média e o desvio padrão da segunda variável de resposta. O valor de s_i está relacionado à probabilidade da restrição $g_1(\mathbf{x})$ ser satisfeita e c é um valor constante definido pelo pesquisador. A restrição $g_2(\mathbf{x})$, por sua vez, corresponde à restrição experimental do problema.

2.2 PLANEJAMENTO DE EXPERIMENTOS

O planejamento de experimentos (DoE – *Design of Experiments*) constitui um conjunto de técnicas que auxiliam na coleta de dados apropriados que possam ser analisados por métodos estatísticos, resultando em conclusões significativas sobre o processo. Para isto, experimentos são planejados de maneira que sejam realizadas alterações intencionais nos parâmetros de entrada do processo, de forma que se possam identificar as possíveis alterações, provocadas por estas ações, nas variáveis de resposta (MYERS; MONTGOMERY, 2002).

Existem diversos tipos de arranjos de experimentos disponíveis e sua escolha deve considerar aspectos como o número de fatores envolvidos no problema, se o efeito de interação entre estes fatores será analisado e se objetiva-se otimizar uma resposta de interesse. Dentre os mais utilizados, podem-se destacar o arranjo fatorial completo, em que os fatores são variados conjuntamente; o arranjo fatorial fracionado, que considera apenas um conjunto de experimentos do fatorial completo para cenários onde existam mais do que 4 fatores; a Metodologia de Superfície de Resposta, em que espera-se otimizar uma resposta que é influenciada por vários fatores; e o arranjo de mistura, um tipo especial de superfície de resposta na qual os fatores são componentes de uma mistura e, conseqüentemente, seus níveis não são independentes (MYERS; MONTGOMERY, 2002).

2.2.1 Arranjo fatorial

Arranjos fatoriais são aplicados a cenários que envolvem dois ou mais fatores, de forma que cada conjunto de experimentos ou réplica contenha todas as combinações possíveis para os níveis dos fatores considerados. Para casos em que haja a níveis para o fator

A, b níveis para o fator B, c níveis para o fator C, e assim por diante, ter-se-á um total de $abc\dots n$ observações para n réplicas do experimento completo (MONTGOMERY, 2013).

Montgomery (2013) define efeito de um fator como sendo a alteração provocada na variável de resposta a partir da alteração no nível da variável de entrada. Este, quando relacionado aos fatores primários, é chamado de efeito principal. A Figura 2.2 apresenta um exemplo de gráfico para um experimento fatorial com efeitos principais significativos.

Quando o efeito de determinada variável depende do nível escolhido de outra variável, ele é classificado como um efeito de interação. É possível observar visualmente sua ocorrência através de gráficos de efeitos de interação. O cruzamento entre as retas, conforme exemplificado na Figura 2.3, aponta a presença de um efeito de interação, enquanto que retas paralelas indicam a inexistência deste efeito, como mostrado na Figura 2.4.

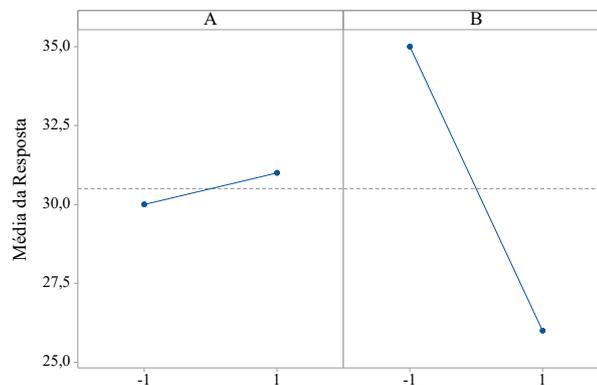


Figura 2.2 – Experimento fatorial com efeitos principais

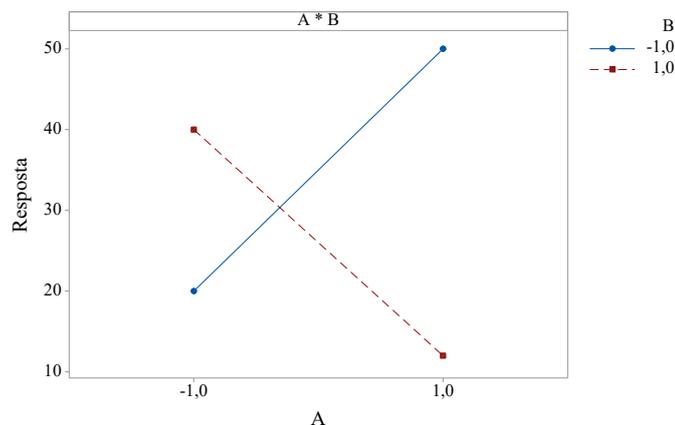


Figura 2.3 – Experimento fatorial com efeito interação

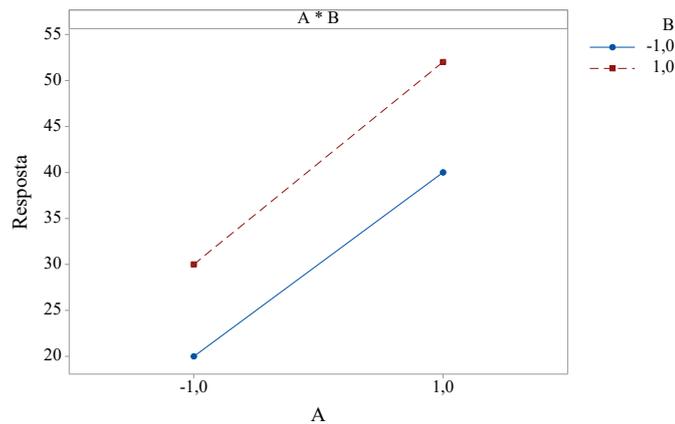


Figura 2.4 – Experimento fatorial sem efeito de interação

2.2.2 Metodologia de Superfície de Resposta

A Metodologia de Superfície de Resposta é um conjunto de técnicas utilizadas para modelar e analisar problemas em diferentes contextos, onde uma resposta de interesse é influenciada por tantas outras variáveis e cujo objetivo seja otimizar esta resposta. Embora sua abrangência seja bastante ampla, como pode ser observado no levantamento realizado no periódico internacional *Journal of Cleaner Production* apresentado no Apêndice A, sua principal aplicação encontra-se no setor industrial, especialmente em cenários onde muitas variáveis de entrada possam influenciar alguma medida de desempenho ou característica de qualidade do produto ou processo (MYERS; MONTGOMERY, 2002).

Lu e Xu (2017) utilizaram esta metodologia visando encontrar as melhores condições para uma nova estratégia de recuperação de ouro não lixiviante a partir de cartões de memória descartados. Costa *et al.* (2016) desenvolveram uma otimização multivariada para um processo de fresagem a seco de AISI 1045, considerado mais sustentável que o processo de fresagem convencional, já que não utiliza fluidos de corte. Klepa *et al.* (2019) elaboraram um estudo cujo objetivo era obter uma matéria prima a partir da mistura de resíduos de construção com óxido de zinco para utilizar como sensor termoluminescente e realizou um experimento para obter um produto com o mínimo de óxido de zinco, porém com o máximo de luminescência, através da RSM. Nasiri e Arsalani (2018) utilizaram a RSM para avaliar a influência de fatores experimentais, tais como concentração inicial de corante, tempo de contato, pH inicial e dosagem de adsorvente na eficiência da remoção de cristais violetas e, então, encontrar a condição ótima desses fatores que maximizasse a função objetivo.

Usualmente, o objetivo do problema está em otimizar apenas uma resposta ou diversas delas simultaneamente. Entretanto, a relação entre as variáveis dependentes e independentes é, geralmente, desconhecida, tornando esta tarefa ainda mais complexa.

Sendo assim, o propósito da RSM está em encontrar funções que sejam capazes de aproximar a relação real entre as variáveis de entrada (x) e cada uma das variáveis de saída (y) em alguma região de interesse, por meio de um polinômio de ordem mais alta, caso haja curvatura significativa no sistema (NAVES *et al.*, 2017). Posteriormente a isto, o objetivo concentra-se em encontrar um conjunto de condições operacionais que, de alguma forma, otimize todas as respostas ou, ao menos, garanta que elas estejam dentro de um intervalo satisfatório (MYERS; MONTGOMERY, 2002).

Desta forma, inicialmente, pode-se desenvolver um arranjo fatorial com pontos centrais, que permite a aproximação desta relação desejada por um modelo de primeira ordem, conforme Equação (2.9).

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_kx_k + \varepsilon \quad (2.9)$$

Para verificar a existência de curvatura quadrática, deve-se calcular a diferença entre a média dos n_f experimentos fatoriais, \bar{y}_f , e a média dos n_c experimentos nos pontos centrais, \bar{y}_c . Se esta diferença for pequena, então os pontos centrais recaem no plano que passa através dos pontos fatoriais ou, pelo menos, próximos a este plano, indicando que não há curvatura quadrática (MONTGOMERY, 2013).

A Soma de Quadrados (SQ) para a curvatura quadrática pura, que pode ser observada na Equação (2.10), deve ser incorporada na análise de variância (ANOVA) e deve-se realizar um teste de hipóteses para a curvatura, onde a hipótese nula H_0 indica que a soma de todos os coeficientes quadráticos é igual a zero, enquanto a hipótese alternativa H_1 indica que esta soma não é igual a zero (MONTGOMERY, 2013). Se for obtido um valor de *p-value* menor que 5%, então existe curvatura na região. Do contrário, o experimentador terá que avaliar outras regiões experimentais onde a curvatura quadrática esteja presente.

$$SQ_{Quadratica\ pura} = \frac{n_f n_c (\bar{y}_f - \bar{y}_c)^2}{n_f + n_c} \quad (2.10)$$

Havendo curvatura no sistema, um polinômio de grau mais alto deve ser utilizado, tal como o modelo de segunda ordem apresentado na Equação (2.11), por exemplo (MONTGOMERY, 2013). Desta forma, complementa-se a matriz fatorial com pontos axiais para se obter um Arranjo Composto Central (CCD), que é o arranjo mais utilizado para estimar superfícies de resposta de segunda ordem (COSTA *et al.*, 2016).

$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i < j} \sum_{i < j} \beta_{ij} x_i x_j + \varepsilon \quad (2.11)$$

Um arranjo CCD para k fatores consiste em um arranjo fatorial 2^k ou um arranjo

fatorial fracionado de resolução V , adicionado de n_c pontos centrais e $2k$ pontos axiais (MYERS; MONTGOMERY, 2002). Via de regra, a literatura recomenda que se trabalhe com 3 a 5 pontos centrais. A Figura 2.5 representa um arranjo do tipo CCD para 3 fatores.

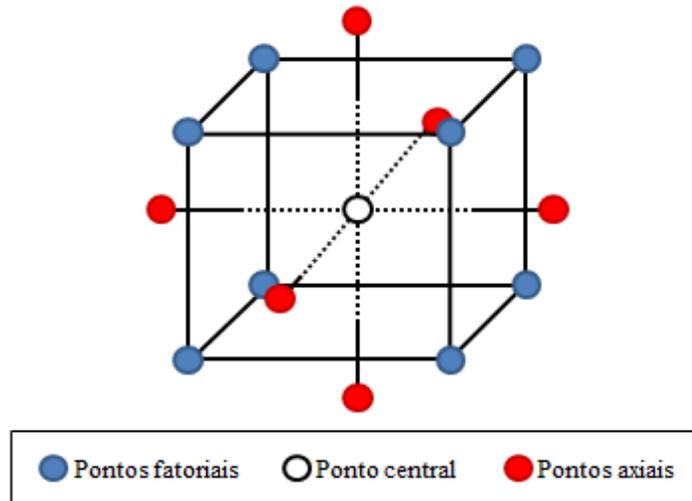


Figura 2.5 – Representação do arranjo CCD para 3 fatores

O método mais frequentemente utilizado para a estimação dos coeficientes (β 's) dos modelos, conhecido como Método dos Mínimos Quadrados, consiste em determinar seus valores de forma que a soma dos quadrados dos erros seja minimizada (MYERS; MONTGOMERY, 2002). Encontrado um modelo, para que se identifique quais dos seus termos possuem efeito estatisticamente significativos, pode-se realizar uma análise de variância. Basta observar quais são os termos cujo p -value são menores que um determinado nível de significância (α), geralmente estabelecido como 5%.

Outra informação relevante fornecida pela ANOVA é dada pelo coeficiente de determinação (R^2), que pode ser interpretado como sendo a proporção de variabilidade nos dados explicada pelo modelo analisado. Quanto maior o valor de R^2 , maior a adequação do modelo ao processo. Além disso, para os casos em que existam muitos fatores envolvidos na modelagem, pode-se avaliar o impacto do aumento ou da diminuição do número de termos no modelo através da observação do valor de R^2 ajustado. Esta estatística, amplamente utilizada, é uma variação da estatística R^2 que reflete o número de fatores presentes no modelo. Da mesma forma, altos valores para R^2 ajustado indicam um bom nível de ajuste (MYERS; MONTGOMERY, 2002).

Montgomery (2013) afirmou, entretanto, que, adicionalmente, deve-se realizar uma análise de resíduos para verificação de sua normalidade, de maneira a ratificar as informações sobre a adequação do modelo obtidas a partir da ANOVA.

Estabelecido o modelo que represente uma função aproximada relacionando as variáveis de saída às variáveis de entrada do processo, é necessário que se aplique um

método de otimização para identificar o valor ótimo para as determinadas respostas de interesse. Este tópico será abordado na próxima seção.

2.2.3 Arranjo de misturas

Arranjos de misturas são aqueles nos quais os fatores representam componentes de uma mistura e que, conseqüentemente, possuem níveis dependentes um do outro. Para uma mistura com n ingredientes, tem-se x_1, x_2, \dots, x_n proporções não negativas que somam uma unidade, conforme Equação (2.12) (MONTGOMERY, 2013).

$$\begin{aligned} 0 \leq x_i \leq 1, i = 1, 2, \dots, n \\ x_1 + x_2 + \dots + x_n = 1 \end{aligned} \quad (2.12)$$

Em uma mistura com 3 componentes, conforme ilustrado na Figura 2.6, seu espaço de solução corresponde a um triângulo onde os vértices representam misturas puras, que contêm 100% de um único componente.

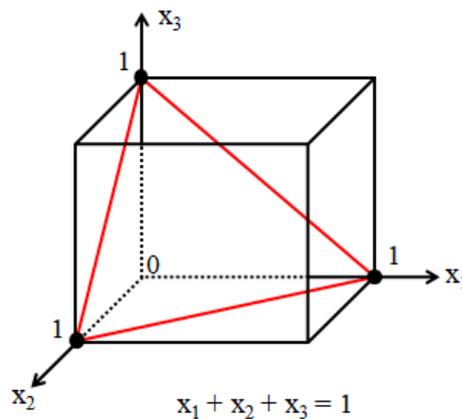


Figura 2.6 – Arranjo de mistura para 3 componentes

Arranjos de misturas são muito utilizados para realizar a distribuição dos pesos entre as funções que se objetiva otimizar quando da aplicação do método NBI na otimização multiobjetivo.

2.3 ANÁLISE DE DADOS MULTIVARIADOS

Estatística multivariada refere-se ao estudo de fenômenos cujas unidades amostrais ou experimentais possuem diversas variáveis de resposta que devem ser analisadas simultaneamente considerando a estrutura de correlação existente entre elas (FERREIRA, 2008).

Hair *et al.* (2009) afirmaram que para uma análise ser considerada multivariada, todas suas variáveis devem ser aleatórias e inter-relacionadas de maneira que seus efeitos não possam ser significativamente interpretados de forma isolada.

Muitas técnicas multivariadas são extensões das análises univariadas ou bivariadas. Técnicas dependentes como, por exemplo, a análise de regressão múltipla, são aplicadas quando uma variável ou conjunto de variáveis é identificado como sendo uma variável dependente a ser explicada por variáveis independentes. Já as técnicas de interdependência são aquelas que envolvem a análise simultânea de todas as variáveis com a finalidade de encontrar uma estrutura para o conjunto de variáveis como um todo. Neste caso, nenhuma variável, ou grupo de variáveis, pode ser definida como dependente ou independente. A análise fatorial é considerada uma técnica multivariada de interdependência (HAIR *et al.*, 2009).

2.3.1 Análise Fatorial

Johnson e Wichern (2007) e Ferreira (2008) mencionaram que o propósito essencial da análise fatorial está em descrever as relações de covariância entre as variáveis de resposta em termos de alguns poucos fatores que reúnam variáveis altamente correlacionadas, mas que possuam correlações baixas com as variáveis de outros grupos.

Um vetor randômico observável \mathbf{X} com p componentes, média μ e matriz de covariância Σ é linearmente dependente de algumas variáveis aleatórias não observáveis F_1, F_2, \dots, F_m , denominadas fatores comuns, e fontes adicionais de variação, chamadas de fatores específicos, $\epsilon_1, \epsilon_2, \dots, \epsilon_p$. Assim, o modelo de análise fatorial em notação matricial pode ser observado na Equação (2.13), onde \mathbf{L} representa a matriz de cargas dos fatores com dimensão $(p \times m)$ (JOHNSON; WICHERN, 2007).

$$\mathbf{X} - \mu = \mathbf{L}\mathbf{F} + \epsilon \quad (2.13)$$

Para realizar a análise fatorial, alguns pressupostos devem ser considerados, conforme Equação (2.14).

$$\begin{aligned} \mathbf{E}(\mathbf{F}) &= \mathbf{0}, \quad \mathbf{Cov}(\mathbf{F}) = \mathbf{E}[\mathbf{F}\mathbf{F}'] = \mathbf{I} \\ \mathbf{E}(\epsilon) &= \mathbf{0}, \quad \mathbf{Cov}(\epsilon) = \mathbf{E}[\epsilon\epsilon'] = \mathbf{\Psi} \end{aligned} \quad (2.14)$$

onde:

$$\mathbf{\Psi} = \begin{bmatrix} \psi_1 & 0 & \dots & 0 \\ 0 & \psi_2 & & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \psi_p \end{bmatrix} \quad (2.15)$$

Desta forma, é possível demonstrar que a matriz de covariância pode também ser expressa pela Equação (2.16), utilizando o modelo de fator ortogonal ($X = \mu + LF + \epsilon$) e considerando os pressupostos acima.

$$\begin{aligned} \mathbf{\Sigma} = \mathbf{Cov}(\mathbf{X}) &= \mathbf{E}(\mathbf{X} - \mu)(\mathbf{X} - \mu)' \\ &= \mathbf{L}\mathbf{E}(\mathbf{F}\mathbf{F}')\mathbf{L}' + \mathbf{E}(\epsilon\mathbf{F}')\mathbf{L}' + \mathbf{L}\mathbf{E}(\mathbf{F}\epsilon') + \mathbf{E}(\epsilon\epsilon') \\ &= \mathbf{L}\mathbf{L}' + \mathbf{\Psi} \end{aligned} \quad (2.16)$$

Por independência, a covariância entre σ e F é igual a zero. Portanto, a covariância entre X e F é igual a L , como demonstrado na Equação (2.17).

$$\begin{aligned} \mathbf{Cov}(\mathbf{X}, \mathbf{F}) &= \mathbf{E}(\mathbf{X} - \mu)\mathbf{F}' = \mathbf{E}(\mathbf{L}\mathbf{F} + \epsilon)\mathbf{F}' = \mathbf{E}(\mathbf{L}\mathbf{F}\mathbf{F}' + \epsilon\mathbf{F}') \\ &= \mathbf{L}\mathbf{E}(\mathbf{F}\mathbf{F}') + \mathbf{E}(\epsilon\mathbf{F}') = \mathbf{L} \end{aligned} \quad (2.17)$$

De onde conclui-se que:

$$\begin{aligned} \text{Var}(X_i) &= l_{i1}^2 + \dots + l_{im}^2 + \psi_i = h_i^2 + \psi_i = \sigma_{ii} \\ \text{Cov}(X_i, X_k) &= l_{i1}l_{k1} + \dots + l_{im}l_{km} \\ \text{Cov}(X_i, F_j) &= l_{ij} \end{aligned} \quad (2.18)$$

Sendo assim, a variância total da variável X_i , denotada por σ_{ii} , pode ser subdividida em duas partes: comunalidade ou variância comum, representada por h_i^2 , que corresponde aos elementos da diagonal principal da matriz $\mathbf{L}\mathbf{L}'$; e a variância específica, representada por ψ_i , relativa à variância de ϵ . As variâncias comum e específica indicam a porção da variância explicada pelos fatores comum e específicos, respectivamente.

Para o desenvolvimento deste trabalho, utilizou-se o método do componente principal para estimar os parâmetros da análise fatorial. De acordo com Johnson e Wichern (2007), este método é baseado na decomposição espectral da matriz de covariância, detalhada na Equação (2.19). Esta técnica utiliza os autovalores (λ_i) e autovetores (e_i) para

decompor a matriz Σ . A matriz com todos os autovetores dispostos em colunas é denotada por \mathbf{P} e a matriz diagonal cujos elementos não-zero são iguais aos autovalores de Σ é identificada por Λ .

$$\Sigma = \mathbf{P}\Lambda\mathbf{P}' = \mathbf{P}\Lambda^{1/2}\Lambda^{1/2}\mathbf{P}' = \mathbf{L}\mathbf{L}' \quad (2.19)$$

Escolhendo m fatores, com mp , para representar o conjunto de dados, obtém-se uma estimativa para a matriz de covariância (S), conforme Equação (2.20), onde $\tilde{\psi}_i = \sigma_{ii} - \sum_{j=1}^m \tilde{l}_{ij}^2$.

$$\mathbf{S} = \tilde{\mathbf{L}}\tilde{\mathbf{L}}' + \tilde{\Psi}$$

$$\mathbf{S} = \begin{bmatrix} \sqrt{\hat{\lambda}_1}\hat{\mathbf{e}}_1 & \sqrt{\hat{\lambda}_2}\hat{\mathbf{e}}_2 & \dots & \sqrt{\hat{\lambda}_m}\hat{\mathbf{e}}_m \end{bmatrix} \begin{bmatrix} \sqrt{\hat{\lambda}_1}\hat{\mathbf{e}}_1' \\ \sqrt{\hat{\lambda}_2}\hat{\mathbf{e}}_2' \\ \vdots \\ \sqrt{\hat{\lambda}_m}\hat{\mathbf{e}}_m' \end{bmatrix} + \begin{bmatrix} \tilde{\psi}_1 & 0 & \dots & 0 \\ 0 & \tilde{\psi}_2 & & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \tilde{\psi}_m \end{bmatrix} \quad (2.20)$$

Não obstante, em casos onde as unidades das variáveis não são mensuráveis, é conveniente trabalhar com variáveis padronizadas, subtraindo o valor médio de cada variável observável e dividindo pelo seu desvio padrão. Sendo assim, torna-se possível utilizar a matriz de correlação estimada (R) ao invés da matriz de covariância Σ .

2.4 ERRO QUADRÁTICO MÉDIO MULTIVARIADO

Paiva *et al.* (2009) propuseram um índice, denominado Erro Quadrático Médio Multivariado (MMSE - *Multivariate Mean Square Error*), capaz de agregar diversas respostas mantendo sua estrutura de variância-covariância e o desvio individual de cada alvo, conforme Equação (2.21).

$$MMSE_i = (PC_i - \zeta_{PC_i})^2 + \lambda_i \quad (2.21)$$

Os autores utilizaram a Análise de Componentes Principais (PCA - *Principal Component Analysis*) para obter a função do MMSE. Entretanto, esta abordagem pode ser modificada para a utilização da análise fatorial que é considerada uma extensão da PCA, já que ambos os métodos aproximam o modelo de covariância, ainda que a aproximação baseada na análise fatorial seja mais elaborada (JOHNSON; WICHERN, 2007). A Equação (2.22) demonstra o cálculo do índice aplicado no trabalho. Para efeitos de simplificação, a variância foi desconsiderada, sem prejuízos para a otimização.

$$\text{Índice} = (\mu - T)^2 \quad (2.22)$$

onde μ é a média do fator obtida a partir da otimização e T é seu respectivo valor de alvo individual, que pode ser obtido a partir da Equação (2.23):

$$T = \sum_{i=1}^n L_i \left(\frac{T_i - \mu_i}{\sigma_i} \right) \quad (2.23)$$

onde n é o número total de variáveis de resposta, μ_i , T_i , σ_i e L_i representam, respectivamente, os valores individuais da média, alvo, desvio padrão e carga do fator cujo alvo deseja-se obter, todos relativos à i -ésima variável de resposta original.

3 PROCESSOS DE FABRICAÇÃO

3.1 PROCESSOS DE FABRICAÇÃO

Processos de fabricação são aqueles que transformam um material inicial por meio de alterações químicas ou físicas visando agregar valor a ele. Eles são subdivididos em duas grandes categorias: operações de processamento e operações de montagem (MARQUES *et al.*, 2017). Operações de processamento são aquelas que modificam o aspecto ou propriedade física de um material de forma a agregar valor ao produto transformado. Operações de montagem, por sua vez, unem dois ou mais componentes, de forma permanente ou semipermanente, para a criação de uma nova entidade. Estes processos são realizados por meio de maquinários e ferramental que se utilizam de energia, proveniente de fontes mecânicas, térmicas, elétricas ou químicas (GROOVER, 2013).

A Figura 3.1 apresenta uma classificação das operações de processamento e de montagem. Dentro desta subdivisão, destacam-se, para este estudo, os processos de união permanente que englobam as técnicas de soldagem.

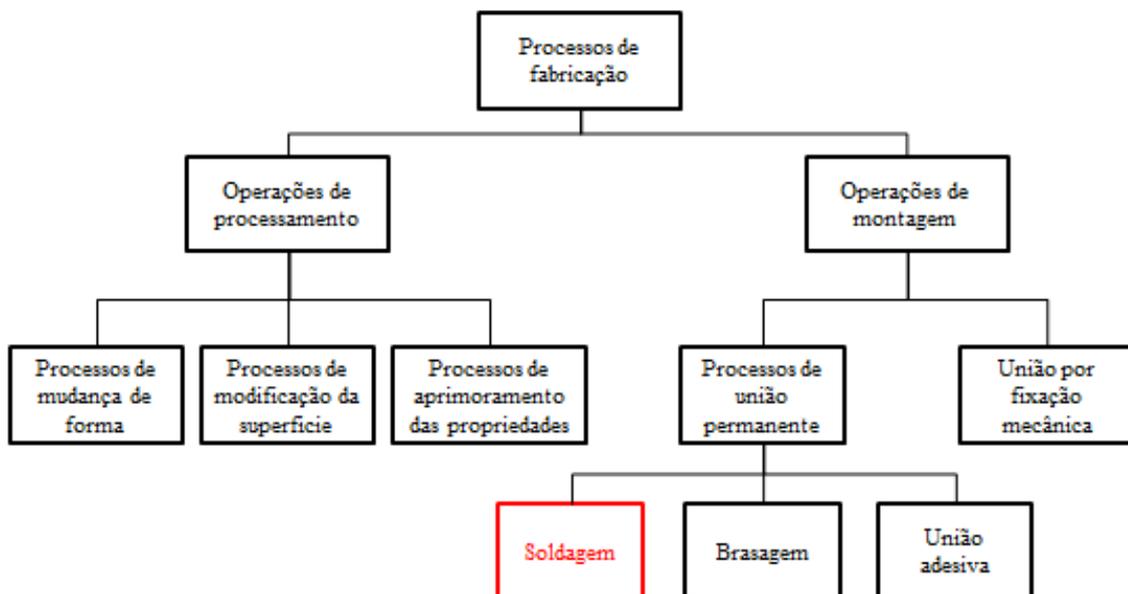


Figura 3.1 – Classificação dos processos de fabricação.

Fonte: adaptado de Groover (2013)

3.1.1 Soldagem

Groover (2013) definiu soldagem como o "processo de união de materiais no qual duas ou mais peças são coalescidas em suas superfícies de contato pela aplicação adequada

de calor e/ou pressão". É considerado o mais importante processo de união permanente de peças metálicas utilizado na indústria, pois permite compor o produto final com segurança, rapidez e economia de material (MARQUES *et al.*, 2017).

O termo soldagem abrange diversos processos utilizados na fabricação e recuperação de peças, equipamentos e estruturas. Embora considerada um processo de união, muitas de suas variações são aplicadas visando à formação de uma estrutura revestida com características específicas ou ainda à recuperação de peças desgastadas, através da deposição de material sobre determinada superfície (MARQUES *et al.*, 2017).

Classificam-se os processos de soldagem em dois grandes grupos: soldagem por fusão e soldagem no estado sólido. Em muitos processos de soldagem por fusão, um metal de adição é utilizado para facilitar a coalescência e prover as características desejadas ao produto final. As categorias de fusão podem ser organizadas de acordo com o tipo de fonte de energia utilizada para fundir as peças, sendo elas: soldagem a arco, soldagem por resistência, soldagem a gás oxicom bustível, soldagem com feixe de elétrons e soldagem a laser (GROOVER, 2013).

Os processos de soldagem a arco, cuja fonte de energia é o arco elétrico, são os de maior importância industrial na atualidade. O arco elétrico, que consiste de uma descarga elétrica, é a fonte de calor mais utilizada na soldagem por fusão devido às suas características como, por exemplo, concentração adequada de energia para a fusão localizada do metal de base e facilidade de controle (MARQUES *et al.*, 2017).

3.1.1.1 Soldagem de revestimento

Revestimento constitui em um processo cujo objetivo está em obter determinadas propriedades ou dimensões a partir da deposição de algum material de adição sobre uma superfície metálica. Esta técnica é empregada para estender o tempo de vida de materiais que não tenham características específicas ou que possam estar em estado de desgaste ou corrosão (PHILLIPS, 1965).

Segundo a norma ASTM (2017), o desgaste é definido como um "dano a uma superfície sólida envolvendo uma perda progressiva de material devido à movimentação relativa entre a superfície e um ou vários materiais". Sendo, portanto, o desgaste um fenômeno superficial, técnicas de recuperação, como a soldagem de revestimento, têm trazido inúmeros benefícios relacionados à redução do custo de fabricação de novas peças e à manutenção, ou mesmo prevenção, de peças desgastadas (WAINER *et al.*, 2013).

A soldagem de revestimento é um tipo de revestimento em que uma camada espessa de determinado metal de solda de interesse, como o aço inoxidável, por exemplo, é depositado sobre uma chapa de aço carbono ou de baixa liga para torná-lo resistente à corrosão ou desgaste (GUPTA; SHARMA, 2011).

Este estudo explora um cenário específico de soldagem de revestimento de uma placa de aço carbono ABNT 1020 utilizando arame tubular de aço inoxidável ABNT 316L realizado por [Gomes \(2010\)](#). Este processo tem se destacado no ambiente industrial, pois permite obter superfícies com suas características desejáveis a partir de materiais de baixo custo.

De forma geral, um processo de soldagem de revestimento ótimo em termos de qualidade é aquele que recobre o máximo da superfície do material base, maximizando o reforço e produzindo uma penetração mínima. Reforços grandes, entretanto, podem significar perda de material. Isto porque após a soldagem, geralmente se faz necessário melhorar a qualidade da superfície através da usinagem. Além disso, uma grande penetração não é requerida, pois o objetivo principal é obter uma superfície que incorpore as características do material que está sendo adicionado.

Sob perspectivas econômicas e ambientais, este processo pode atingir um cenário ainda mais atraente através da redução do desperdício de material de adição e também da minimização do calor imposto, que levará a um menor consumo de energia elétrica e conseqüente redução de custos, considerando que os revestimentos são, geralmente, depositados por processos de soldagem a arco elétrico ou gás oxicomustível ([PHILLIPS, 1965](#)).

3.1.1.2 Características e variáveis do processo

As principais características desejadas no processo de soldagem de revestimento, diferentemente das aplicações convencionais de soldagem que exigem que a penetração do material depositado seja alta de maneira a garantir a resistência da junta soldada, resumem-se a grandes larguras do cordão (L), baixos percentuais de diluição (D), altos reforços (R) e baixas penetrações (P). Isto porque, neste tipo específico de soldagem, como o principal objetivo é obter uma superfície revestida por um material usualmente mais dispendioso, o interessante é que se obtenha a maior área recoberta com um menor número de passes, consumindo a menor quantidade de material possível ([GOMES, 2010](#)). Pode-se estabelecer, então, que a otimização deste processo tem como um de seus focos a geometria do cordão de solda, que pode ser observada na Figura 3.2.

É importante destacar que o controle sobre a diluição é imprescindível para que não haja alteração na composição do material do qual se deseja manter as características. O cálculo da composição híbrida do cordão de solda pode ser obtido da razão entre a base fundida e a área total do cordão de solda depositado ([PHILLIPS, 1965](#)). Assim, segundo [Kannan e Murugan \(2006\)](#) e [Wainer *et al.* \(2013\)](#), a composição final terá características mais próximas do material de deposição, quando da diluição baixa, mantendo suas propriedades de interesse de resistência à corrosão.

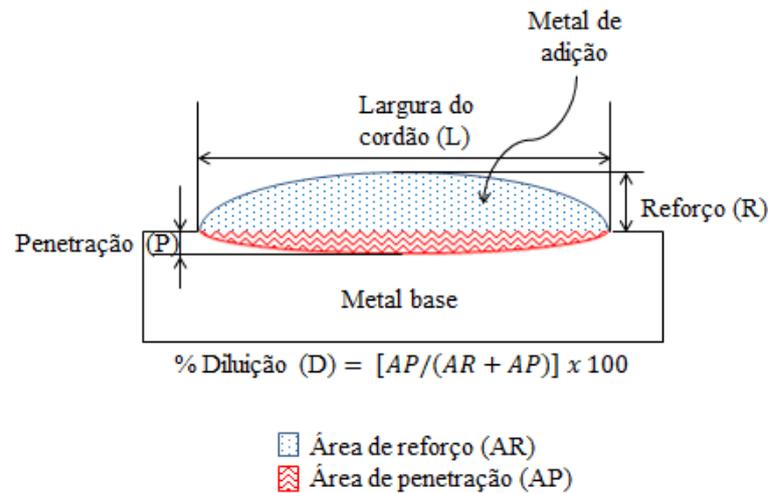


Figura 3.2 – Perfil geométrico do cordão de solda.

Fonte: adaptado de [Gomes \(2010\)](#)

3.1.1.3 Refugo e retrabalho

Segundo [Montgomery \(2013\)](#), o retrabalho pode ser entendido como a realização de atividades voltadas para a eliminação de defeitos identificados no produto, oriundos de seu processo de fabricação. O termo refugo, por sua vez, é utilizado para designar produtos, componentes ou materiais identificados como perdas do processo produtivo, sendo, portanto, descartados.

No processo de soldagem de revestimento, depositar material de adição além do necessário levará a um processo de usinagem indispensável para remover seu excesso. Por outro lado, revestir com uma quantidade insuficiente exigirá um novo processo de soldagem para atingir o padrão encontrado para a geometria ótima do cordão.

Desta forma, o presente estudo classifica como material de refugo (A_{re}) a área de reforço que ultrapassa a área de reforço ótima de um cordão de solda, já que esta quantidade deverá ser descartada por um processo de usinagem. Já a área de retrabalho (A_t) é definida como sendo a diferença entre a área de reforço ótima e a área de reforço obtida, nas regiões em que a primeira excede a segunda. A partir desses valores, é possível obter as áreas totais associadas ao desperdício de material do processo.

4 SISTEMA TARIFÁRIO BRASILEIRO DE ENERGIA ELÉTRICA

A atual estrutura tarifária brasileira de energia, controlada pela Agência Nacional de Energia Elétrica (ANEEL), está vigorando desde 1993 e é composta pelas parcelas de consumo de energia elétrica (kW/h) e/ou de demanda de potência ativa (kW), de acordo com a modalidade de fornecimento (ANEEL, 2012).

O sistema também contempla, desde 2010, um segmento chamado Horo-Sazonal, que diferencia tarifas para os horários de ponta (HP) e fora de ponta (HFP). HP refere-se ao período composto por três horas diárias consecutivas definidas pela distribuidora no intervalo das 18h às 21h, consideradas algumas exceções. HFP, por sua vez, são as horas diárias consecutivas e complementares àquelas definidas no HP. São ainda fixados valores distintos para o período de 7 ciclos de faturamento consecutivos, compreendido entre os meses de maio e novembro, definido como período seco; e de 5 ciclos de faturamento consecutivos, referentes ao meses de dezembro de um ano a abril do ano seguinte, conhecido como período úmido (ANEEL, 2012).

São três as modalidades de fornecimento disponíveis: convencional, horária verde e horária azul. A primeira delas é definida como modalidade tarifária convencional binômia e é aplicada às unidades consumidoras do grupo A, caracterizada por tarifas de consumo de energia elétrica e demanda de potência independentemente das horas de utilização do dia, com demanda contratada mínima de 30kW e máxima de 149kW (ANEEL, 2012).

A modalidade tarifária horária verde, por sua vez, é aplicada às unidades consumidoras do grupo A, caracterizada por tarifas diferenciadas de consumo de energia elétrica, de acordo com as horas de utilização do dia e o período (seco/úmido), assim como de uma única tarifa de demanda de potência, sendo esta demanda contratada mínima de 30kW (ANEEL, 2012).

Já a modalidade tarifária azul é aplicada às unidades consumidoras do grupo A, caracterizada por tarifas diferenciadas de consumo de energia elétrica e de demanda de potência de acordo com as horas de utilização do dia, com demanda contratada mínima de 30kW para um dos postos horários (HP ou HFP) (ANEEL, 2012). Podem optar pela modalidade os clientes com potência instalada entre 30kW e 300kW (este é o valor definido pela CEMIG e pode alterar dependendo da concessionária).

O grupo A é uma das classificações da unidade consumidora de energia elétrica e é composta por receptores de energia em alta tensão igual ou superior a 2,3kV ou por unidades atendidas a partir de um sistema subterrâneo de distribuição em tensão secundária. Geralmente indústrias e estabelecimentos comerciais de médio e grande porte estão incluídos nesta categoria. O outro grupo possível, grupo B, contempla os clientes de

baixa tensão, caracterizados por residências e pequenas instalações industriais e comerciais (ANEEL, 2012).

Uma característica incorporada em 2015 é o Sistema de Bandeiras Tarifárias que determina se haverá ou não acréscimo no valor da energia a ser repassada ao consumidor final, em função das condições de geração de eletricidade. O Quadro 4.1 apresenta uma sucinta descrição sobre as bandeiras existentes (ANEEL).

Quadro 4.1 – Descrição das bandeiras tarifárias brasileiras

Bandeira	Descrição
Verde	Condições favoráveis de geração de energia A tarifa não sofre nenhum acréscimo.
Amarela	Condições de geração menos favoráveis. A tarifa sofre acréscimo de R\$ 0,010 para cada quilowatt-hora (kWh) consumidos.
Vermelha - Patamar 1	Condições mais custosas de geração. A tarifa sofre acréscimo de R\$ 0,030 para cada quilowatt-hora kWh consumido.
Vermelha - Patamar 2	Condições ainda mais custosas de geração. A tarifa sofre acréscimo de R\$ 0,050 para cada quilowatt-hora kWh consumido.

Fonte: ANEEL.

A Tabela 4.1 mostra as tarifas referentes ao Grupo A-Subgrupo A4 (2,3kV a 25kV), considerando a modalidade tarifária horária azul, que serão utilizadas neste estudo. Os dados foram obtidos da concessionária CEMIG no mês 03/2019. Estes valores se alteram mensalmente de acordo com o contexto energético do país em termos de produção e consumo, além de poderem apresentar diferenças para cada concessionária.

Tabela 4.1 – Valores (em R\$) da modalidade tarifária horária azul referentes ao mês 03/2019

	Verde	Amarela	Vermelha	
			Patamar 1	Patamar 2
HP - Seco	0,32282	0,33282	0,35282	0,37282
HP - Úmido	0,32282	0,33282	0,35282	0,37282
HFP - Seco	0,47753	0,48753	0,50753	0,52753
HFP - Úmido	0,47753	0,48753	0,50753	0,52753

Fonte: CEMIG.

5 ABORDAGEM ESTOCÁSTICA MULTIOBJETIVO PARA QUALIDADE E SUSTENTABILIDADE

Conforme mencionado no capítulo introdutório deste trabalho, este estudo objetiva propor um método de otimização de duas fases baseada em análise fatorial, programação estocástica e no método da Interseção Normal à Fronteira, focando, em sua primeira etapa, em características relacionadas à qualidade dos processos de fabricação e recuperação e, em um segundo momento, em aspectos relacionados à sua sustentabilidade. Para tal, os métodos apresentados nas seções anteriores podem ser combinados de maneira a se obter resultados mais acurados em um problema de otimização.

Em processos de manufatura, um dos principais objetivos está na otimização de características de qualidade do produto para se que possa atender à expectativa dos clientes, aumentando sua satisfação. Para isto, faz-se essencial identificar as variáveis de saída do processo diretamente relacionadas à sua qualidade, bem como os respectivos parâmetros de entrada que as influenciam. De posse destas informações, define-se o sentido de otimização (minimização ou maximização) desejado de cada uma das variáveis de interesse.

Aplicando-se os conceitos da RSM ao processo em questão, torna-se possível modelar funções que sejam capazes de aproximar a relação real entre as variáveis de entrada e saída. Sendo assim, o primeiro passo do método proposto está na realização de um planejamento de experimentos para a coleta das respostas a serem trabalhadas durante a otimização. Coletados os dados, faz-se uma análise de influência dos parâmetros de entrada sobre as variáveis de saída e modelam-se as respostas de interesse do problema, para subsequente otimização.

O planejamento de experimentos pode ser realizado a partir da construção de um arranjo fatorial completo com pontos centrais, por exemplo. Coletam-se os dados, analisam-se as respostas e, neste ponto, avalia-se a existência de curvatura na região experimental através da análise de variância. No caso de não existir curvatura, devem ser realizados novos experimentos, considerando outros intervalos de variação dos fatores, até que se encontre uma região adequada com curvatura presente. Os métodos da máxima subida e máxima declividade são frequentemente utilizados para encontrar esta região. Finalmente, pontos axiais são adicionados, permitindo que sejam modeladas funções quadráticas para as variáveis de saída, que serão utilizadas por todas as etapas do método.

Estando o conjunto de respostas completo, é possível obter um modelo quadrático para cada uma das respostas de interesse a partir da análise do arranjo experimental. De posse dos modelos, deve-se avaliar a adequação de cada um deles através da ANOVA e

da análise da normalidade dos resíduos.

Posteriormente, avaliam-se as convexidades das funções para verificar a existência de conflito com seus sentidos de otimização estabelecidos. Para isto, pode-se calcular o gradiente e a hessiana de cada uma delas, de acordo com as Equações (5.1) e (5.2), respectivamente. Avaliam-se, então, os autovalores da matriz hessiana, de forma que, sendo todos positivos, a função é dita estritamente convexa e sendo todos negativos, a função é classificada como estritamente côncava. Seguindo esta mesma regra, mas para os casos em que exista ao menos um autovalor igual a zero, a função é definida como convexa ou côncava, simplesmente. Caso a matriz hessiana apresente autovalores positivos e negativos, a função é caracterizada como sendo de sela.

$$G = \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \\ \vdots \\ \frac{\partial f}{\partial x_n} \end{bmatrix} \quad (5.1)$$

$$H = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix} \quad (5.2)$$

Feito isto, o próximo passo é verificar a existência de correlação entre as respostas, já que esta é uma questão que interfere nos resultados obtidos da otimização do problema. Deve-se desenvolver uma análise de correlação para todas as variáveis de resposta e, caso seja identificada correlação entre elas, recomenda-se executar uma análise fatorial, visto que ela neutraliza este efeito a partir da geração de fatores não correlacionados. É interessante mencionar que a extração de fatores em um problema que possua um considerável número de variáveis de resposta também proporciona uma redução na dimensionalidade do problema.

A definição do número de fatores interessantes ao cenário analisado é subjetiva e deve ser discutida juntamente com o responsável pelo processo. O agrupamento das variáveis originais em *clusters* é um recurso auxiliar para esta definição. Extraídos os fatores, eles devem ser, então, modelados como funções polinomiais das variáveis de entrada (normalmente um polinômio de segunda ordem tende a ser satisfatório). Visto que as funções agrupadas nos fatores podem apresentar sentidos de otimização conflitantes (minimização e maximização), um recurso interessante é considerar o índice baseado no MMSE e deta-

lhado no Capítulo 2 como a função objetivo a ser minimizada, pelos motivos já elencados no capítulo 2.

Neste momento, o método NBI pode ser aplicado para formulação do problema de otimização, de maneira que se encontre um conjunto de soluções ótimas que minimize o índice calculado. É importante ressaltar que a decisão sobre o algoritmo de otimização a ser escolhido deve considerar as necessidades de aplicação de restrições relevantes ao cenário do problema.

Para determinar qual a melhor resposta dentro da fronteira de Pareto produzida pelo método NBI, pode-se aplicar algum critério que auxilie nesta identificação. Este método propõe obter o valor da distância de Mahalanobis, que indica a dispersão dos dados em relação ao ponto de ótimo, e o valor de entropia associado ao vetor de pesos do NBI, que indica qual porção do problema exerceu maior influência na identificação da solução ótima, para cada uma destas soluções. A formulação da distância de Mahalanobis e da entropia podem ser observadas nas Equações (5.3) e (5.4), respectivamente:

$$M = \sqrt{(\mathbf{x} - \mathbf{T})^T \Sigma^{-1} (\mathbf{x} - \mathbf{T})} \quad (5.3)$$

onde \mathbf{x} é o vetor com os valores das soluções Pareto-ótimas obtidas na otimização, Σ é a matriz de covariância a ele associada e \mathbf{T} é o vetor de valores alvo e

$$E = - \sum_{i=1}^n w_i \ln(w_i) \quad (5.4)$$

onde w_i representa o i -ésimo valor de peso considerado em cada subproblema do NBI.

Considerando que o cenário ideal seria aquele em que fosse obtido o maior valor de entropia e o menor valor da distância de Mahalanobis, torna-se intuitivo trabalhar com a razão entre ambos (E/M). Desta forma, o conjunto de pesos associados ao maior valor da razão E/M é identificado e aplicado ao NBI de maneira que seja possível encontrar a solução ótima para as respostas originais, indicando o final da fase 1 do método. A Figura 5.1 apresenta uma síntese desta primeira fase do método proposto neste trabalho.

Executar o processo produtivo com a configuração ótima das variáveis de entrada obtida nesta primeira etapa, embora produza os resultados interessantes em termos de qualidade, pode não ser o mais sustentável quando consideram-se algumas questões relevantes como, por exemplo, consumo de energia e desperdício de material. Assim, este estudo também engloba uma segunda perspectiva de otimização, utilizando a programação estocástica multiobjetivo. A segunda fase do método proposto está sumarizada na Figura 5.2.

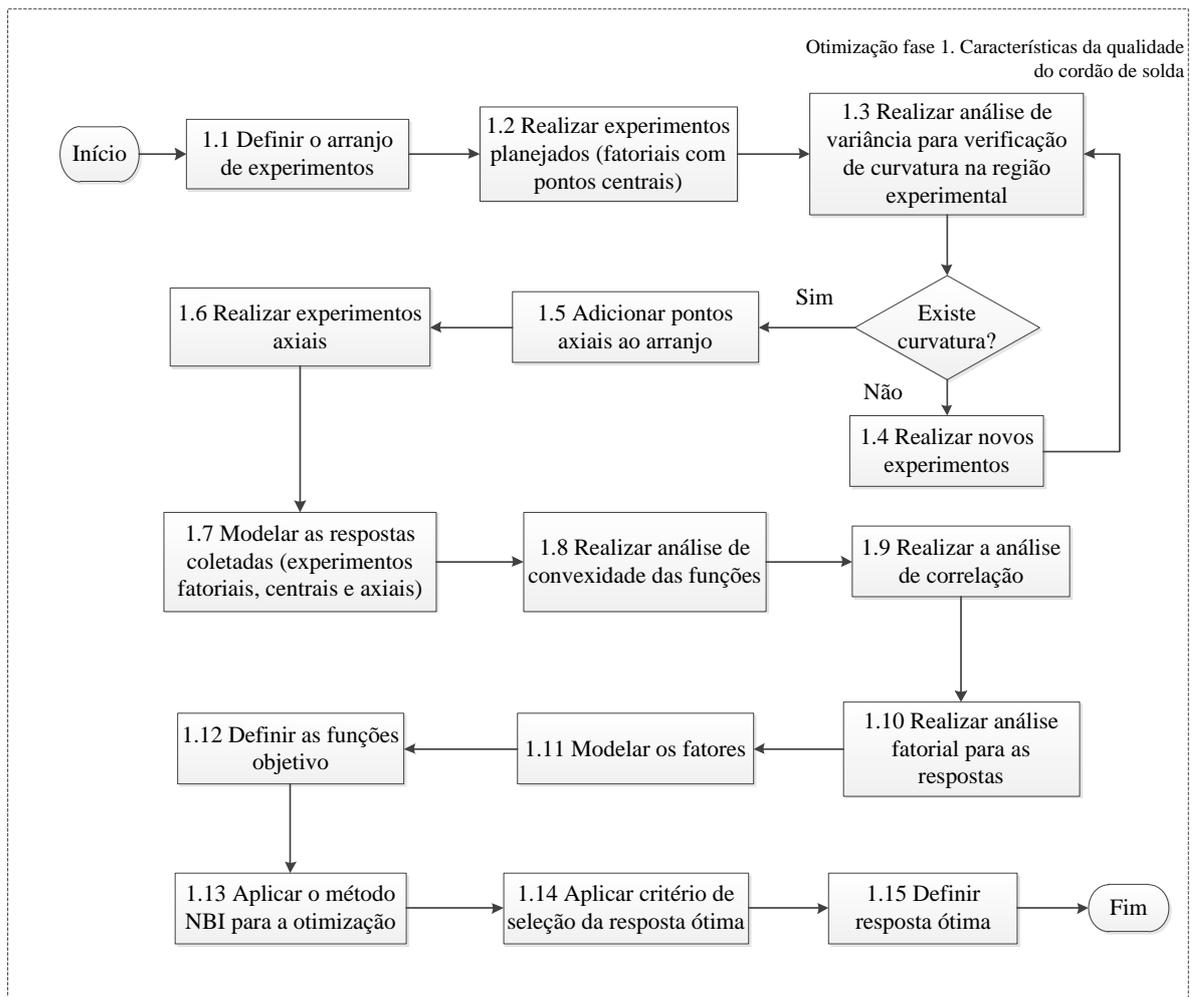


Figura 5.1 – Método - Fase 1: uma abordagem para qualidade

Assim como realizado na primeira etapa do método, o passo inicial da segunda abordagem está em identificar as respostas de interesse do processo, porém agora sob a ótica da sustentabilidade. Neste ponto, é válido mencionar que pode-se associar a algumas características, como à energia, por exemplo, o seu custo. Isto traz um caráter estocástico para o problema, pois permite incorporar a variação dos valores praticados pelo mercado de energia, o que enriquece a análise e agrega uma questão bastante relevante ao contexto das indústrias, que é a redução dos custos de produção.

Coletadas as respostas relacionadas às variáveis de saída elencadas, suas respectivas funções de média e variância devem ser modeladas em termos das variáveis de entrada do processo. A adequação dos modelos deve também ser validada através da ANOVA e da análise de resíduos.

De posse destas informações, formula-se o problema estocástico e, para sua solução,

aplica-se o método NBI, que produzirá a fronteira de Pareto. Conforme anteriormente mencionado, devem-se considerar as necessidades de aplicação de restrições relevantes ao cenário do problema durante a escolha do algoritmo de otimização a ser utilizado.

Para determinação do melhor ponto da superfície construída, utiliza-se um critério auxiliar, como a distância de Mahalanobis, por exemplo. Neste caso, a solução ótima para as respostas originais estará associada ao menor valor da distância de Mahalanobis calculado, indicando a maior proximidade da solução em relação aos valores alvo desejados. Esta etapa sinaliza o fim da segunda fase do método.

A aplicação do método de forma adequada proporciona informações concretas e confiáveis que podem dar suporte a ajustes nos processos, de acordo com os interesses da indústria e necessidades dos clientes.

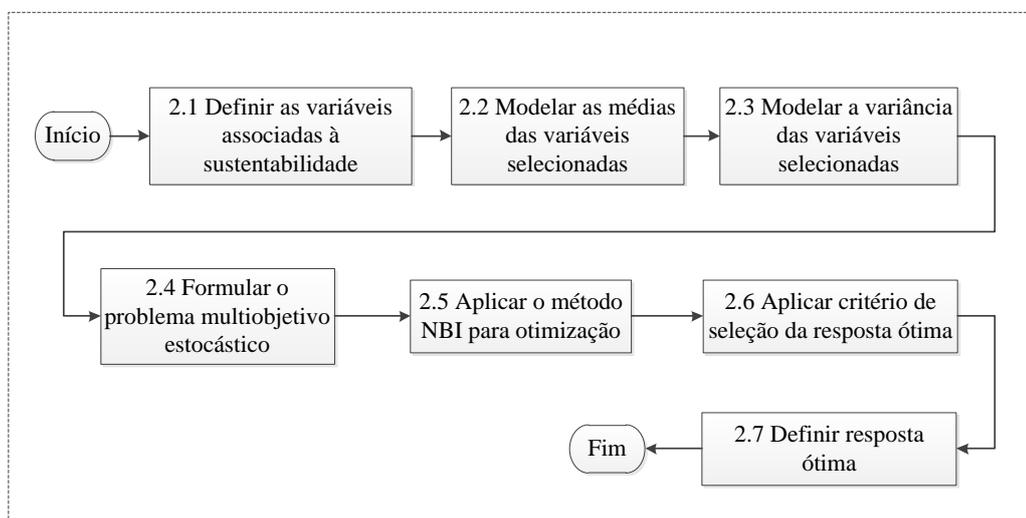


Figura 5.2 – Método - Fase 2: uma abordagem para sustentabilidade

6 ESTUDO DE CASO

Os dados explorados nesta pesquisa originaram-se do trabalho de dissertação de [Gomes \(2010\)](#), cujo objetivo foi otimizar o processo de soldagem com arame tubular para as operações de revestimento de chapas de aço ABNT 1020 com aço inoxidável ABNT 316L, em termos da geometria do cordão de solda, da produtividade do processo e da qualidade superficial dos revestimentos. Para tal, implementaram-se técnicas de experimentação, como o DoE, a fim de garantir coleta e análise adequadas dos dados. Aplicou-se a MSR para conhecimento do fenômeno estudado e, na sequência, empregou-se o Erro Quadrático Médio Multivariado para a otimização do problema, visto que o método contempla a correlação entre múltiplas respostas, através da técnica de Análise de Componentes Principais (PCA).

Os parâmetros de processo definidos no trabalho de [Gomes \(2010\)](#) foram: velocidade de alimentação do arame, tensão, velocidade de soldagem e distância bico de contato peça. Os níveis de trabalho para cada parâmetro foram definidos após a realização de alguns testes e podem ser observados na Tabela 6.1.

Tabela 6.1 – Parâmetros do processo e níveis de trabalho

Parâmetro	Unidade	Níveis de trabalho				
		-2	-1	0	1	2
Velocidade de alimentação do arame (V_a)	m/min	5,5	7,0	8,5	10,0	11,5
Tensão (T)	V	24,5	27,0	29,5	32,0	34,5
Velocidade de soldagem (V_s)	cm/min	20,0	30,0	40,0	50,0	60,0
Distância bico de contato peça (N)	mm	10,0	15,0	20,0	25,0	30,0

Fonte: [Gomes \(2010\)](#)

Para cada objetivo inicial imposto, (i) geometria do cordão de solda, (ii) produtividade do processo e (iii) qualidade superficial dos revestimentos, definiram-se as seguintes respostas de interesse: (i) largura do cordão (L), penetração (P), reforço (R) e diluição (D); (ii) taxa de deposição (TD) e rendimento do processo (η); e (iii) formação de escória (E) e aspecto superficial (S).

Adotou-se o arranjo composto central (CCD) para definição da matriz experimental. Detalhes sobre a composição do arranjo experimental e o registro das respostas de interesse consideradas no trabalho de referência podem ser obtidos na dissertação de [Gomes \(2010\)](#).

Para a aplicação do método proposto neste estudo, consideraram-se as respostas associadas às variáveis P, AP, D, L, R e AR coletadas por [Gomes \(2010\)](#). É importante destacar que as respostas referentes às demais variáveis (CI, IC, FP e FR), embora não

registradas no trabalho de [Gomes \(2010\)](#), foram calculadas com base em informações coletadas durante os experimentos executados que puderam ser acessadas para incorporação nesta pesquisa. A matriz experimental apresentando as informações das 10 variáveis de resposta originais referentes aos 31 experimentos realizados pode ser observada no Apêndice B.

A primeira abordagem para otimização do processo de soldagem de revestimento envolve a determinação dos valores ótimos relacionados à qualidade do processo, no que diz respeito às características geométricas do cordão de solda. Como mencionado no Capítulo 3, um processo de soldagem de revestimento ótimo em termos de qualidade é, basicamente, aquele que reveste a maior superfície possível do material base, maximizando o reforço e produzindo uma penetração mínima suficiente. Entretanto, é válido ressaltar que um reforço muito grande pode representar perda de material, já que, após a soldagem, é geralmente necessário melhorar a qualidade da superfície através da usinagem. A abordagem multiobjetivo lida com esta questão a partir do momento que não permite ao reforço ser indiscriminadamente maximizado, visto que as outras variáveis de resposta estão, simultaneamente, buscando seus valores ótimos.

A qualidade do produto final e as propriedades do revestimento são fortemente influenciadas pelo percentual de diluição. Isto porque como o produto final é resultado de um processo de união de materiais cujas composições químicas são distintas, a mistura destes elementos presentes nos diferentes aços pode comprometer as propriedades finais de anti-corrosão ([GOMES, 2010](#)). Sendo a diluição uma relação entre a área de penetração e a área total da seção transversal do cordão de solda, minimizar a penetração favorece níveis de diluição que atendam ao objetivo de se obter uma superfície que incorpore as características do material adicionado.

O Quadro 6.1 sumariza as variáveis de processo consideradas neste estudo e seus respectivos sentidos de otimização. O índice de convexidade, que constitui a relação entre o reforço e a largura do cordão (R/L), o fator de penetração, determinado pela relação entre a largura do cordão e a penetração (L/P) e o fator de reforço, definido como a relação entre a largura do cordão e o reforço (L/R), são adimensionais enquanto que a diluição [$AP/(AP + AR)$] é um valor percentual.

A segunda abordagem para a otimização deste processo de soldagem de revestimento envolve a realização da otimização multiobjetivo com enfoque na sustentabilidade do processo. Para tal, consideraram-se dois aspectos: o custo da energia elétrica e o desperdício de material, este último associado a refugo e retrabalho. Isto justifica a presença da variável de calor imposto nas respostas de interesse elencadas para esta pesquisa, pois, através dela, torna-se possível contemplar a energia demandada pelo processo.

Quadro 6.1 – Variáveis originais e seus sentidos de otimização

Variáveis de resposta	Sigla	Sentido de otimização
Calor imposto (J/cm)	CI	Minimização
Penetração (mm)	P	Minimização
Área de penetração (mm^2)	AP	Minimização
Diluição (%)	D	Minimização
Largura do cordão de solda (mm)	L	Maximização
Reforço (mm)	R	Maximização
Índice de convexidade	IC	Minimização
Área de reforço (mm^2)	AR	Maximização
Fator de penetração	FP	Maximização
Fator de reforço	FR	Maximização

6.1 APLICAÇÃO DO MÉTODO

6.1.1 Fase 1: uma abordagem para qualidade

Estabelecidas as respostas de interesse, é possível iniciar a aplicação da fase 1 do método proposto no Capítulo 4. Como os dados trabalhados neste estudo de caso foram obtidos do trabalho de [Gomes \(2010\)](#), conforme elucidado anteriormente, as etapas de definição do arranjo experimental (1.1) e realização dos experimentos (1.2, 1.4, 1.5 e 1.6) não serão reexecutadas. A etapa 1.3 será detalhada para demonstrar sua execução, embora não seja necessário validar a existência de curvatura sobre a região experimental do arranjo elaborado, visto que o trabalho base já garante esta informação.

Etapa 1.1 - Definir o arranjo de experimentos

O estudo de [Gomes \(2010\)](#) definiu a matriz experimental a partir de um arranjo composto central (CCD) com 4 fatores e 2 níveis ($2^k = 2^4 = 16$), 8 pontos axiais ($2k = 2 * 4 = 8$), 7 pontos centrais e 1 réplica, totalizando 31 experimentos.

Etapa 1.2 - Realizar experimentos planejados (fatoriais com pontos centrais)

Das informações detalhadas no Apêndice B, os experimentos de 1 a 16 representam os pontos fatoriais e os experimentos de 25 a 31 estão associados aos pontos centrais.

Etapa 1.3 - Realizar análise de variância para verificação de curvatura na região experimental

A partir das respostas coletadas nos experimentos fatoriais e centrais, modelaram-se funções aproximadas para cada uma das respostas com a finalidade de avaliar a presença de curvatura. Para tal, observaram-se os *p-value* para a curvatura apresentados nas análises de variância, conforme Apêndice C. Com exceção dos modelos para a penetração, área de penetração, largura e fator de reforço, os demais apresentaram *p-value* inferior a 5%, indicando a presença de curvatura para nos modelos nelas baseados, conforme sumarizado

na Tabela 6.2.

Tabela 6.2 – SQA e p -value para a análise de curvatura referentes às variáveis de resposta

	CI	P	AP	D	L	R	IC	AR	FP	FR
SQA	0,025	0,068	0,089	0,003	0,227	0,055	0,000	30,297	4,042	0,013
p -value	0,000	0,077	0,502	0,000	0,054	0,010	0,044	0,000	0,008	0,434

Etapa 1.4 - Realizar novos experimentos

Não foi necessária a realização desta etapa, pois a presença de curvatura na maioria dos modelos garante um cenário aceitável para prosseguir com a aplicação do método. Além disso, o trabalho garantiu que o arranjo era adequado para continuidade das análises.

Etapa 1.5 - Adicionar pontos axiais ao arranjo e Etapa 1.6 - Realizar experimentos axiais

Adicionar pontos axiais ao arranjo permite a incorporação de termos quadráticos ao modelo. Dos dados coletados e apresentados no apêndice B, os experimentos 17 a 24 referem-se aos pontos axiais acrescentados ao arranjo original.

Etapa 1.7 - Modelar as respostas coletadas (experimentos fatoriais, centrais e axiais)

Realizando a análise do arranjo apresentado no apêndice B através do *software* estatístico *Minitab*[®] foi possível estimar as funções aproximadas para cada uma das respostas partindo de um modelo quadrático completo com a aplicação do método de eliminação *backward*. Contemplando as respostas coletadas referentes aos experimentos fatoriais, centrais e axiais, as Equações (6.1) a (6.10) representam, agora, os modelos finais para cada uma das variáveis e que foram considerados ao longo das próximas etapas.

$$\begin{aligned} \hat{C}I = & 0,788 + 0,086Va + 0,089T - 0,243Vs - 0,080N + 0,070Vs^2 - 0,027VaVs \\ & - 0,026TVs + 0,029VsN \end{aligned} \quad (6.1)$$

$$\begin{aligned} \hat{P} = & 1,632 + 0,122Va + 0,122T + 0,093Vs - 0,241N - 0,117Vs^2 + 0,076VaVs \\ & - 0,100VaN \end{aligned} \quad (6.2)$$

$$\begin{aligned} \hat{A}P = & 8,299 + 1,295Va + 1,056T - 0,553Vs - 1,776N - 0,227Vs^2 + 0,259N^2 \\ & + 0,524VaT - 0,505VaN - 0,291TN \end{aligned} \quad (6.3)$$

$$\begin{aligned} \hat{D} = & 0,310 - 0,003Va + 0,025T + 0,037Vs - 0,043N - 0,007T^2 - 0,012Vs^2 \\ & + 0,008VaT - 0,008VsN \end{aligned} \quad (6.4)$$

$$\begin{aligned}\hat{L} = & 10,640 + 0,797Va + 0,656T - 1,451Vs - 0,629N + 0,270Vs^2 + 0,266VaT \\ & - 0,114VaVs - 0,102TVs\end{aligned}\quad (6.5)$$

$$\begin{aligned}\hat{R} = & 2,592 + 0,203Va - 0,116T - 0,262Vs + 0,126N + 0,030T^2 + 0,057Vs^2 \\ & + 0,032N^2 - 0,047VaT\end{aligned}\quad (6.6)$$

$$\begin{aligned}\hat{C} = & 0,243 + 0,001Va - 0,026T + 0,009Vs + 0,027N + 0,005T^2 + 0,005N^2 \\ & - 0,009VaT\end{aligned}\quad (6.7)$$

$$\hat{AR} = 19,079 + 3,375Va - 5,538Vs + 1,570Vs^2 - 0,941VaVs\quad (6.8)$$

$$\begin{aligned}\hat{FP} = & 6,534 + 0,151Va - 1,738Vs + 0,731N + 1,057Vs^2 - 0,486VaVs + 0,549VaN \\ & (6.9)\end{aligned}$$

$$\hat{FR} = 4,103 - 0,005Va + 0,407T - 0,147Vs - 0,421N - 0,051N^2 + 0,141VaT\quad (6.10)$$

A partir das informações de R^2 e $R_{ajustado}^2$ extraídas da ANOVA, realizada com o apoio do *software* Minitab® e apresentadas na Tabela 6.3, percebe-se que todos os modelos possuem nível de ajuste superior a 85%. A Figura 6.1 apresenta também a análise dos resíduos dos modelos que corrobora com as conclusões obtidas a partir da ANOVA, visto que todos os *p-values* apresentaram valor superior a 5%, indicando normalidade dos resíduos para todos os casos.

Etapa 1.8 - Realizar análise das convexidades das funções

Definidos os modelos para cada uma das variáveis de resposta e confirmados seus ajustes, é essencial avaliar a convexidade das funções para garantir que a posterior otimização seja realizada de maneira correta. As convexidades das funções foram identificadas através do cálculo do gradiente e da hessiana, conforme Equações (5.1) e (5.2). O Quadro 6.2 apresenta todas as variáveis de resposta consideradas, seus respectivos sentidos de otimização e convexidades e uma coluna indicando se estes dois últimos são coincidentes ou conflitantes. Analisando este quadro, identificou-se a necessidade de aplicação de uma restrição de espaço experimental, visto que existem indicadores de conflito no sentido de

Tabela 6.3 – Valores dos ajustes para os modelos das variáveis de resposta

Variável de resposta	R^2 (%)	$R^2_{ajustado}$ (%)
CI	97,97	97,23
P	88,64	85,18
AP	97,85	96,93
D	95,55	93,93
L	98,75	98,30
R	95,29	93,58
IC	95,79	94,51
AR	97,58	97,21
FP	88,34	85,42
FR	94,76	93,46

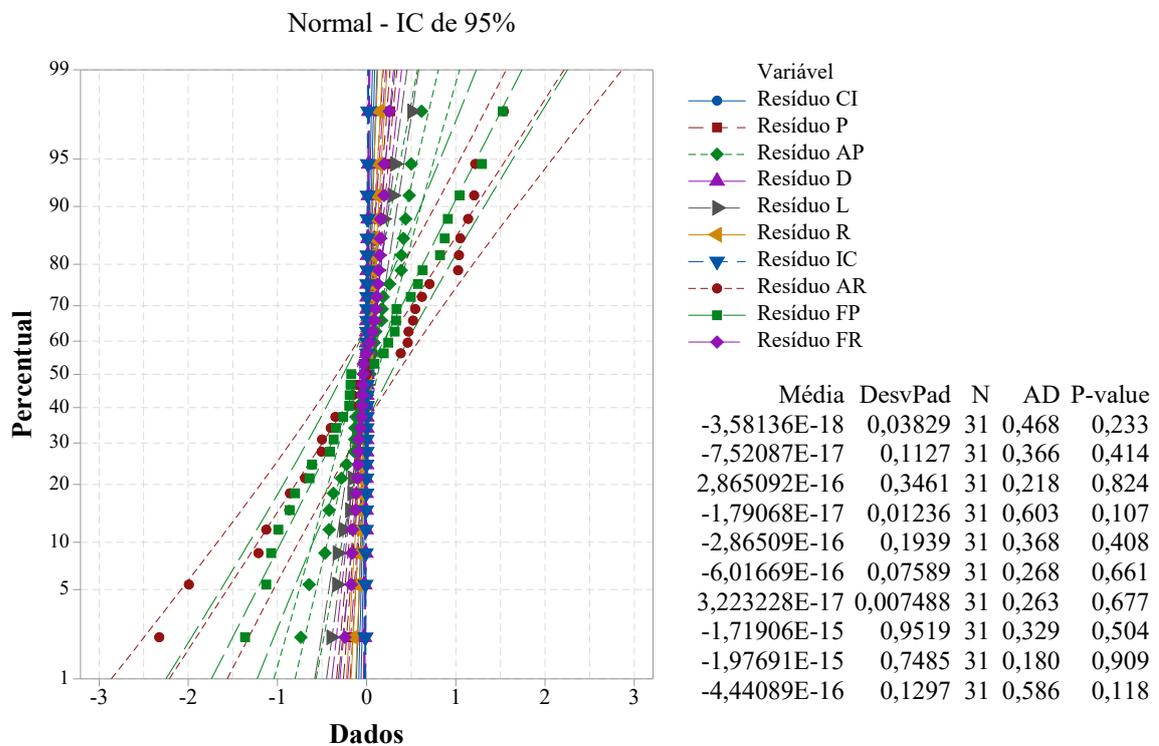


Figura 6.1 – Gráfico de probabilidade para os resíduos dos modelos das variáveis de resposta

otimização e convexidade das funções. Esta é uma informação que deverá ser considerada na determinação do algoritmo a ser aplicado na otimização do problema.

Etapa 1.9 - Realizar a análise de correlação

Considerando os valores coletados para as 10 variáveis de respostas originais, apresentados no Apêndice B, o próximo passo foi a realização de uma análise de correlação entre elas. A análise foi feita utilizando-se os softwares *RStudio*[®] e *Minitab*[®] e o resultado pode ser observado na Figura 6.2 e na tabela 6.4 que apresenta, em destaque, os valores

Quadro 6.2 – Variáveis de resposta, sentidos de otimização e convexidade

Variável de resposta	Sentido de otimização	Convexidade	Indicador
CI	Minimização	Sela	Conflitante
P	Minimização	Sela	Conflitante
AP	Minimização	Sela	Conflitante
D	Minimização	Sela	Conflitante
L	Maximização	Sela	Conflitante
R	Maximização	Sela	Conflitante
IC	Minimização	Sela	Conflitante
AR	Maximização	Sela	Conflitante
FP	Maximização	Sela	Conflitante
FR	Maximização	Sela	Conflitante

de *p-value* associados.

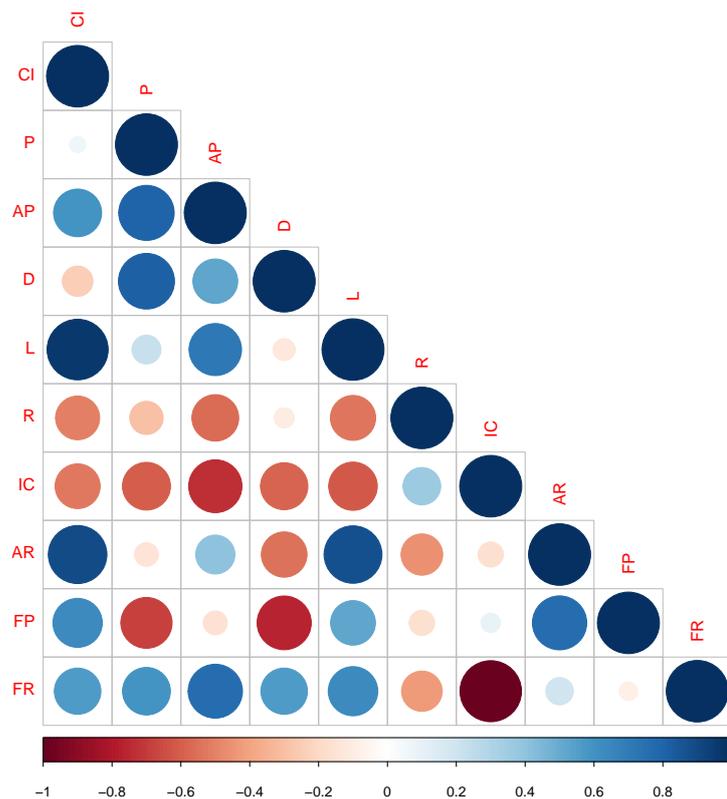


Figura 6.2 – Gráfico de correlação para as respostas originais

Etapa 1.10 - Realizar análise fatorial para as respostas

Constatada a existência de correlação entre os pares de variáveis, realizou-se uma análise fatorial, com o apoio do *software* estatístico *Minitab*[®] para obtenção de fatores não correlacionados. Para definição do número de fatores a serem extraídos, executou-se o agrupamento das variáveis originais em *clusters*, por meio do *software Minitab*[®]. Con-

Tabela 6.4 – Matriz de correlação para as respostas originais

	CI	P	AP	D	L	R	IC	FR	FP
P	0.070 0.708								
AP	0.600 0.000	0.800 0.000							
D	-0.243 0.188	0.818 0.000	0.523 0.003						
L	0.969 0.000	0.220 0.234	0.715 0.000	-0.127 0.496					
R	0.562 0.001	-0.387 0.032	0.038 0.841	-0.773 0.000	0.522 0.003				
IC	-0.529 0.002	-0.601 0.000	-0.738 0.000	-0.584 0.001	-0.615 0.000	0.335 0.065			
AR	0.891 0.000	-0.149 0.425	0.400 0.026	-0.542 0.002	0.872 0.000	0.854 0.000	-0.167 0.369		
FP	0.635 0.000	-0.683 0.000	-0.150 0.420	-0.762 0.000	0.524 0.002	0.742 0.000	0.099 0.595	0.769 0.000	
FR	0.564 0.001	0.597 0.000	0.767 0.000	0.564 0.001	0.639 0.000	-0.316 0.084	-0.984 0.000	0.198 0.286	-0.089 0.632

siderando o método de agrupamento Ward, também conhecido como método da mínima variância, a correlação como medida de distância e determinando o nível de similaridade dentro do *cluster* de aproximadamente 80%, obteve-se o dendrograma apresentado na Figura 6.3.

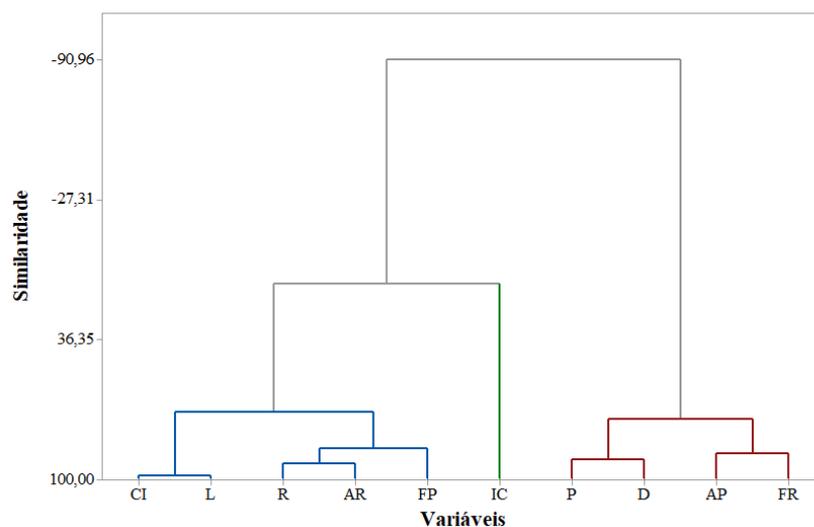


Figura 6.3 – Dendrograma de clusterização das variáveis originais

Desta forma, a partir da clusterização das variáveis originais, determinou-se a extração de 3 fatores. Para tal, utilizou-se também o *software* estatístico *Minitab*[®] considerando o método de extração por correlação e tipo de rotação Varimax.

A análise fatorial, portanto, considera diferentes variáveis reunidas em um mesmo fator. Na Tabela 6.5 é possível observar as cargas fatoriais rotacionadas, que representam a covariância entre as variáveis consideradas e o fator F_j , e as comunalidades, que indicam o quanto desta variável é explicada pelo determinado fator ao qual ela pertence. É possível notar que aproximadamente 98% da variância pode ser explicada após a realização da análise fatorial.

Tabela 6.5 – Cargas fatoriais rotacionadas e comunalidades

Variável	Fator 1	Fator 2	Fator 3	Comunalidade
CI	0,847	-0,507	0,001	0,974
P	-0,126	-0,341	0,925	0,988
AP	0,395	-0,527	0,739	0,979
D	-0,557	-0,461	0,651	0,947
L	0,829	-0,534	0,151	0,995
R	0,904	0,385	-0,154	0,989
IC	-0,073	0,941	-0,305	0,984
AR	0,986	-0,122	-0,072	0,993
FP	0,727	-0,056	-0,654	0,959
FR	0,106	-0,938	0,315	0,99
Variância	4,2205	3,0797	2,4976	9,7978
%Var	0,986	0,308	0,25	0,98

Os fatores possuem *scores* não correlacionados e são capazes de representar as variáveis que os compõem. Os *scores* obtidos nesta etapa do estudo, ou seja, os valores assumidos pelos três fatores em cada um dos 31 experimentos estão apresentados na Tabela 6.6. A Figura 6.4 apresenta a análise realizada sobre os fatores, comprovando que eles não estão correlacionados.

As variáveis são distribuídas dentro dos fatores de acordo com suas maiores cargas fatoriais. Sendo assim, o fator $F1$ reuniu cinco variáveis (AR, R, CI, L e FP), o fator $F2$, por sua vez, resumiu-se apenas à variável IC e o fator $F3$ reuniu as quatro variáveis restantes (FR, P, AP, e D).

Etapa 1.11 - Modelar os fatores

A partir da definição da composição dos 3 fatores, realizou-se a modelagem de cada um deles, partindo de um modelo quadrático completo com a aplicação do método de eliminação *backward*, através do *software* estatístico *Minitab*®. As funções obtidas estão apresentadas nas Equações (6.11), (6.12) e (6.13).

$$\hat{F}1 = -0,2080 + 0,6130Va - 0,8810Vs + 0,0367N + 0,1972Vs^2 + 0,0715N^2 - 0,0971VaVs \quad (6.11)$$

Tabela 6.6 – Scores dos fatores

#	Va	T	Vs	N	Scores F1	Scores F2	Scores F3
1	7,0	27,0	30,0	15,0	-0,007	-0,614	-0,805
2	10,0	27,0	30,0	15,0	1,366	0,154	0,617
3	7,0	32,0	30,0	15,0	0,117	-1,771	-0,226
4	10,0	32,0	30,0	15,0	1,605	-1,738	1,164
5	7,0	27,0	50,0	15,0	-1,430	-0,579	-0,109
6	10,0	27,0	50,0	15,0	-0,166	1,002	1,504
7	7,0	32,0	50,0	15,0	-1,506	-1,535	-0,675
8	10,0	32,0	50,0	15,0	-0,216	-0,698	1,889
9	7,0	27,0	30,0	25,0	0,182	0,694	-0,750
10	10,0	27,0	30,0	25,0	1,774	1,719	-0,727
11	7,0	32,0	30,0	25,0	0,373	-0,029	-0,785
12	10,0	32,0	30,0	25,0	1,532	-0,548	-1,271
13	7,0	27,0	50,0	25,0	-0,934	1,374	-0,945
14	10,0	27,0	50,0	25,0	-0,281	1,788	-0,381
15	7,0	32,0	50,0	25,0	-1,166	0,475	-0,654
16	10,0	32,0	50,0	25,0	-0,315	-0,133	0,093
17	5,5	29,5	40,0	20,0	-1,404	-0,608	-1,004
18	11,5	29,5	40,0	20,0	1,117	0,971	2,227
19	8,5	24,5	40,0	20,0	0,257	1,851	-0,251
20	8,5	34,5	40,0	20,0	-0,238	-1,087	0,570
21	8,5	29,5	20,0	20,0	2,632	-1,173	-2,132
22	8,5	29,5	60,0	20,0	-1,461	0,106	-0,291
23	8,5	29,5	40,0	10,0	0,213	-0,264	2,170
24	8,5	29,5	40,0	30,0	-0,047	1,615	-0,233
25	8,5	29,5	40,0	20,0	-0,237	-0,111	0,326
26	8,5	29,5	40,0	20,0	-0,212	-0,173	0,399
27	8,5	29,5	40,0	20,0	-0,150	0,063	0,276
28	8,5	29,5	40,0	20,0	-0,414	-0,228	0,529
29	8,5	29,5	40,0	20,0	-0,277	-0,125	-0,209
30	8,5	29,5	40,0	20,0	-0,307	-0,114	-0,110
31	8,5	29,5	40,0	20,0	-0,403	-0,284	-0,208

$$\hat{F}2 = -0,0916 + 0,2787Va - 0,7247T + 0,2660Vs + 0,6198N + 0,0913T^2 - 0,1376Vs^2 + 0,1647N^2 - 0,2529VaT - 0,1817VaN \quad (6.12)$$

$$\hat{F}3 = 0,175 + 0,5958Va + 0,2994Vs - 0,5661N - 0,3854Vs^2 + 0,1595N^2 + 0,1963VaVs - 0,3839VaN \quad (6.13)$$

As Tabelas 6.7, 6.8 e 6.9 exibem as análises de variância e a Tabela 6.10 os valores de ajuste para os modelos dos 3 fatores. A Figura 6.5 apresenta os *p-values* referentes à normalidade dos resíduos a eles associados, confirmando a adequação dos modelos, visto que apresentaram valor superior a 5%.

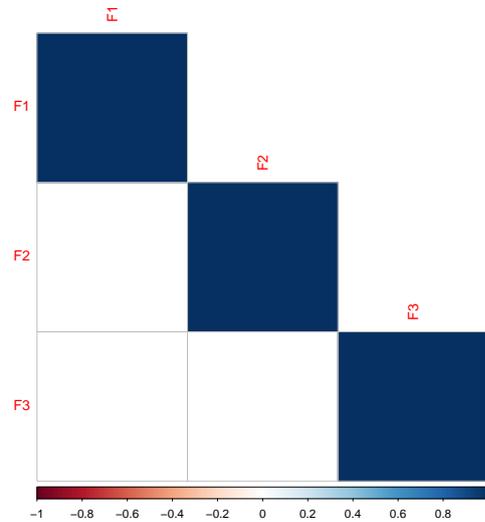


Figura 6.4 – Gráfico de correlação para os fatores extraídos

Tabela 6.7 – Análise de variância para o fator F1

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	6	29,048	4,841	122,05	0,000
Linear	3	27,676	9,225	232,57	0,000
<i>Va</i>	1	9,018	9,018	227,33	0,000
<i>Vs</i>	1	18,626	18,626	469,56	0,000
<i>N</i>	1	0,032	0,032	0,81	0,376
Quadrado	2	1,221	0,611	15,39	0,000
<i>Vs*Vs</i>	1	1,135	1,135	28,61	0,000
<i>N*N</i>	1	0,149	0,149	3,76	0,064
Interação com 2 fatores	1	0,151	0,151	3,80	0,063
<i>Va*Vs</i>	1	0,151	0,151	3,80	0,063
Erro	24	0,952	0,040		
Falta de ajuste	18	0,895	0,050	5,25	0,024
Erro Puro	6	0,057	0,010	*	*
Total	30	30,000			

Etapa 1.12 - Definir as funções objetivo

Conforme mencionado no capítulo introdutório, como a análise fatorial considera diferentes variáveis agrupadas em um mesmo fator, em alguns casos, elas podem apresentar sentidos de otimização conflitantes. Neste caso, por exemplo, é possível notar que dentro do fator 1 tem-se como objetivo a minimização da variável CI enquanto se deseja maximizar a variável L.

Para endereçar esta questão, trabalhou-se com o índice baseado no MMSE como função objetivo, conforme definido nas Equações (2.22) e (2.23), pelas razões anterior-

Tabela 6.8 – Análise de variância para o fator F2

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	9	28,643	3,183	49,24	0,000
Linear	4	25,369	6,347	98,19	0,000
<i>Va</i>	1	1,865	1,865	28,85	0,000
<i>T</i>	1	12,606	12,606	195,04	0,000
<i>Vs</i>	1	1,698	1,698	26,27	0,000
<i>N</i>	1	9,218	9,218	142,62	0,376
Quadrado	3	1,704	0,570	8,79	0,001
<i>T*T</i>	1	0,241	0,241	3,73	0,067
<i>Vs*Vs</i>	1	0,548	0,548	8,47	0,008
<i>N*N</i>	1	0,784	0,784	12,13	0,002
Interação com 2 fatores	2	1,552	0,776	12,01	0,000
<i>Va*T</i>	1	1,024	1,024	15,84	0,001
<i>Va*N</i>	1	0,528	0,528	8,18	0,009
Erro	21	1,357	0,065		
Falta de ajuste	15	1,285	0,086	7,06	0,012
Erro Puro	6	0,073	0,012	*	*
Total	30	30,000			

Tabela 6.9 – Análise de variância para o fator F3

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	7	26,773	3,8246	27,26	0,000
Linear	3	18,362	6,121	43,62	0,000
<i>Va</i>	1	8,520	8,520	60,72	0,000
<i>Vs</i>	1	2,152	2,152	15,33	0,001
<i>N</i>	1	7,690	7,690	54,80	0,000
Quadrado	2	5,437	2,718	19,37	0,000
<i>Vs*Vs</i>	1	4,337	337	30,91	0,000
<i>N*N</i>	1	0,743	0,743	5,29	0,031
Interação com 2 fatores	2	2,974	1,487	10,60	0,001
<i>Va*Vs</i>	1	0,616	0,616	4,39	0,047
<i>Va*N</i>	1	2,358	2,358	16,80	0,000
Erro	23	3,227	0,140		
Falta de ajuste	17	2,651	0,156	1,62	0,285
Erro Puro	6	0,577	0,096	*	*
Total	30	30,000			

Tabela 6.10 – Valores dos ajustes para os modelos dos fatores

Fator	<i>R</i> (%)	$R_{ajustado}^2$ (%)
<i>F1</i>	96,83	96,03
<i>F2</i>	95,48	93,54
<i>F3</i>	89,24	85,97

mente detalhadas. Os valores das médias, alvos individuais e desvios padrão para cada uma das respostas que foram utilizados para definir os valores alvo dos fatores podem ser

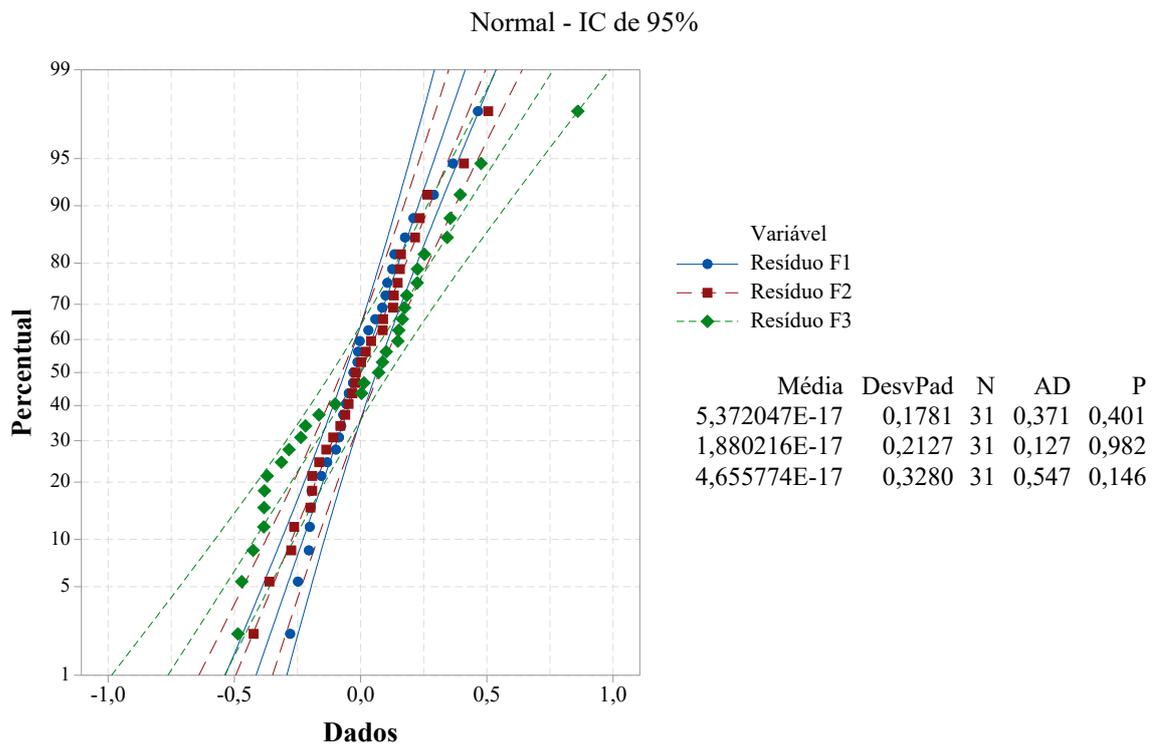


Figura 6.5 – Gráfico de probabilidade para os resíduos dos modelos dos fatores

observados na Tabela 6.11. Ainda para este cálculo dos alvos dos fatores, consideraram-se as cargas fatoriais apresentadas na Tabela 6.5.

Tabela 6.11 – Informações utilizadas na definição dos valores alvo dos fatores

Variável de resposta	Média	Alvo individual	Desvio Padrão
CI	0,843	0,268	0,437
P	1,541	0,334	0,832
AP	8,324	2,361	4,685
D	0,295	0,059	0,166
L	10,849	1,735	15,525
R	2,685	0,350	3,522
CI	0,251	0,037	0,180
AR	20,294	6,119	38,587
FP	7,352	2,192	14,584
FR	4,064	0,567	5,303

Os valores alvo obtidos para cada fator, que compuseram as respectivas funções objetivo baseadas no MMSE, foram $F1_{alvo} = 9,72287$, $F2_{alvo} = -1,63963$ e $F3_{alvo} = -5,58537$.

Etapa 1.13 - Aplicar o método NBI para otimização

O método NBI foi aplicado na etapa de otimização, de forma a obter soluções ótimas equidistantes na superfície de Pareto. Considerou-se um conjunto de 70 combinações

de pesos (w_1 , w_2 e w_3) variando de 0,00001 a 0,99998, gerados através de um arranjo de mistura *simplex lattice* com 3 componentes, grau de *lattice* igual a 10 e aumentado com pontos centrais e axiais. A faixa de variação de pesos foi estabelecida de maneira a garantir que nenhuma função fosse ignorada (peso igual a zero) ou considerada com peso total (peso igual a um) durante a otimização.

O valor do índice baseado no MMSE para os 3 fatores foram considerados como as respostas a serem minimizadas, já que o objetivo era obter um valor de erro o mais próximo possível de zero. A matriz *Pay-off* gerada por meio da minimização individual de cada função objetivo é apresentada na matriz (6.14), onde os valores destacados representam o valor de utopia de cada função.

$$Pay-off_{fatores} = \begin{bmatrix} \mathbf{49,259} & 80,434 & 55,813 \\ 0,766 & \mathbf{0,000} & 0,646 \\ 16,982 & 40,067 & \mathbf{12,180} \end{bmatrix} \quad (6.14)$$

Cada combinação de pesos pode ser considerada como um subproblema do método NBI. O gráfico 3D dos fatores normalizados e seus respectivos pesos são exibidos na Figura 6.6.

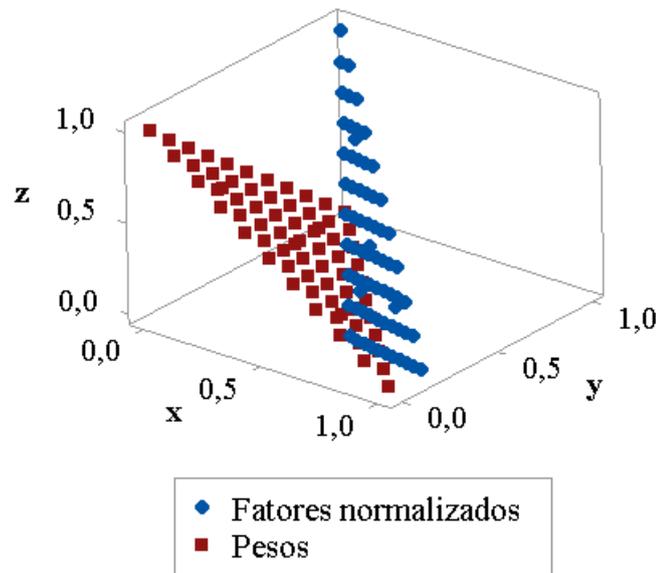


Figura 6.6 – Gráfico 3D dos fatores normalizados *versus* seus respectivos pesos

A otimização foi realizada utilizando-se o algoritmo Gradiente Reduzido Generalizado (GRG) não linear, por meio do suplemento *Solver* do *software Microsoft Excel*[®]. As soluções ótimas obtidas para cada fator podem ser observados no Apêndice E.

Etapa 1.14 - Aplicar critério de seleção da resposta ótima

Visando determinar o melhor ponto da superfície de Pareto, calcularam-se a distância de Mahalanobis (M) e a entropia (E) para cada um dos 70 subproblemas do NBI, de acordo com as Equações (5.3) e (5.4). Estas informações podem ser observadas no Apêndice D.

Considerando estas duas métricas, o objetivo estaria em encontrar o valor mínimo para M e valor máximo para E , simultaneamente, conforme mencionado no Capítulo 4. É válido reafirmar que o máximo valor de entropia é desejado para garantir que todas as respostas estejam sendo consideradas no problema, visto que este conceito está relacionado à dispersão dos dados de entrada. Por outro lado, o menor valor da distância de Mahalanobis é almejado, pois ele indica que as respostas estão o mais próximo possível de seus respectivos valores alvo.

Para demonstrar que os sentidos desejados para ambos os critérios estavam adequados, tanto a distância de Mahalanobis quanto a entropia foram modeladas em função dos pesos do NBI, como pode ser observado nas Equações (6.15) e (6.16).

$$\hat{M} = 5,627w_1 + 7,272w_2 + 6,057w_3 - 15,266w_1w_2 - 14,883w_1w_3 - 16,860w_2w_3 \quad (6.15)$$

$$\hat{E} = 0,001(w_1 + w_2 + w_3) + 3,241w_1w_2 + 3,241w_1w_3 + 3,241w_2w_3 \quad (6.16)$$

onde w_1 , w_2 e w_3 representam os pesos aplicados aos fatores F1, F2 e F3, respectivamente, em determinado subproblema do NBI.

As análises de variância para ambos modelos estão apresentadas nas Tabelas 6.12 e 6.13, onde GL, SQ, SQA e QMA referem-se, respectivamente, aos graus de liberdade, soma de quadrados, soma de quadrados ajustada e média quadrática ajustada.

Tabela 6.12 – Análise de variância para a distância de Mahalanobis (proporções de componentes)

Fonte de variação	GL	SQ	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Regressão	5	121,748	121,748	24,350	40,79	0,000
Linear	2	7,393	5,403	2,701	4,520	0,015
Quadrática	3	114,355	114,355	38,118	63,850	0,000
$w_1 * w_2$	1	25,522	47,257	47,257	79,160	0,000
$w_1 * w_3$	1	31,195	44,916	44,916	75,230	0,000
$w_2 * w_3$	1	57,639	57,639	57,639	96,550	0,000
Erro residual	64	38,209	38,209	0,597		
Total	69	159,956				

Os valores dos ajustes dos modelos foram satisfatórios, conforme apresentado na Tabela 6.14.

Tabela 6.13 – Análise de variância para a entropia (proporções de componentes)

Fonte de variação	GL	SQ	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Regressão	5	4,869	4,869	0,974	294,070	0,000
Linear	2	0,000	0,000	0,000	0,000	0,000
Quadrática	3	4,869	4,869	1,623	490,11	0,000
$w_1 * w_2$	1	1,185	2,130	2,130	643,140	0,000
$w_1 * w_3$	1	1,555	2,130	2,130	643,140	0,000
$w_2 * w_3$	1	2,130	2,130	2,130	643,140	0,000
Erro residual	64	0,212	0,212	0,003		
Total	69	5,081				

Tabela 6.14 – Valores dos ajustes para os modelos da distância de Mahalanobis (M) e entropia (E)

Função	R (%)	$R_{ajustado}^2$ (%)
M	76,11	74,25
E	95,82	95,50

Desta forma, é possível observar através dos gráficos de contorno e superfície para a distância de Mahalanobis e a entropia, respectivamente, apresentados nas Figuras 6.7 e 6.8, que as convexidades coincidem com os sentidos de otimização em ambos os casos.

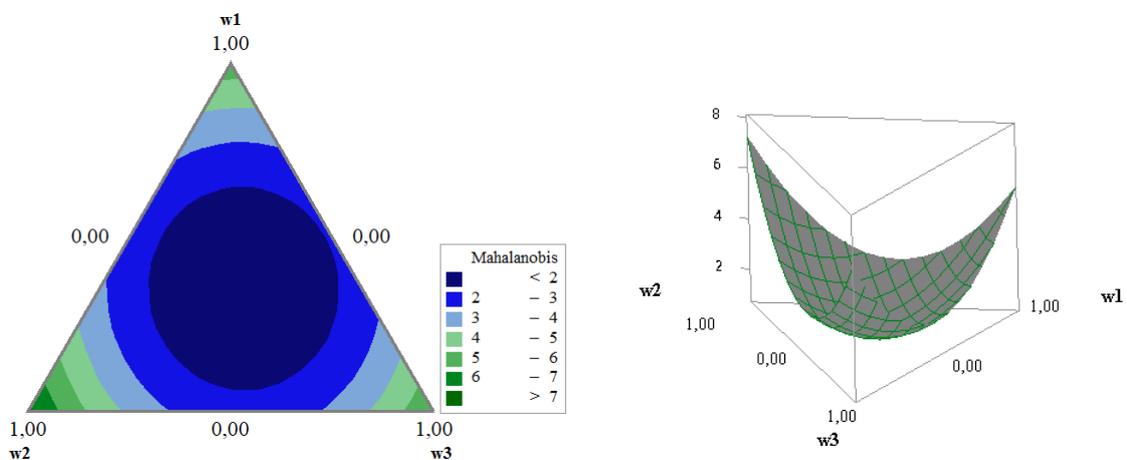


Figura 6.7 – Gráficos de contorno e superfície para a distância de Mahalanobis

Etapa 1.15 - Definir resposta ótima

Calculou-se a razão entre a entropia e a distância de Mahalanobis (E/M) para as 70 combinações de pesos. A razão atingiu seu máximo valor $E/M = 0,8272$ quando $w_1=0,30$, $w_2=0,30$ e $w_3=0,40$, conforme pode ser observado no Apêndice D, indicando esta combinação de pesos como o melhor ponto na superfície de Pareto previamente construída. A este subproblema estão associados os valores codificados dos parâmetros de entrada: $Va = -0,355$, $T = -1,255$, $Vs = 0,615$ e $N = 1,386$. Desta forma, concluiu-se que os valores decodificados $Va = 8,96\text{m/min}$, $T = 29,38\text{V}$, $Vs = 24,21\text{cm/min}$ e $N = 17,90\text{mm}$ determinam a configuração ótima para os parâmetros de entrada capazes

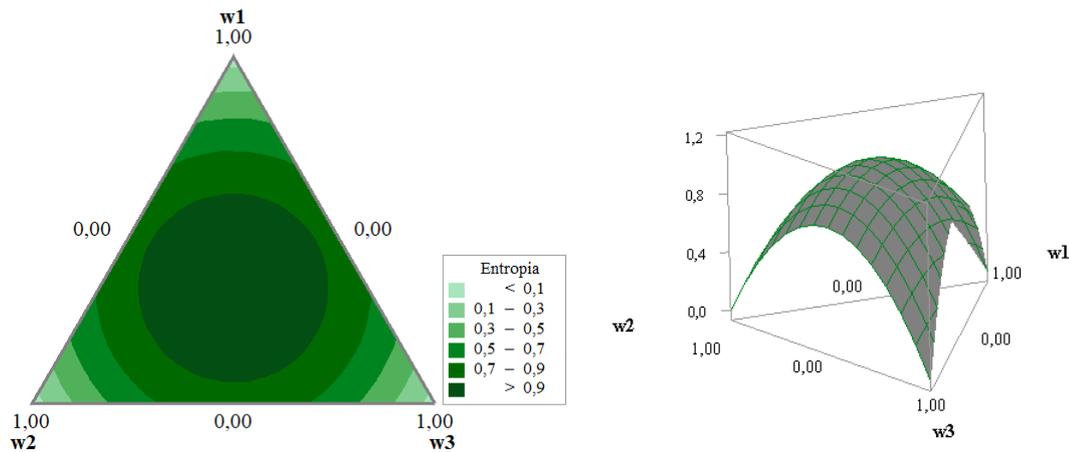


Figura 6.8 – Gráficos de contorno e superfície para a entropia

de produzir o cordão de solda com a melhor geometria possível no contexto do problema analisado.

Aplicando esta configuração aos modelos das 10 variáveis de resposta originais indicados nas Equações de (6.1) até (6.10), obtiveram-se seus respectivos valores ótimos, que podem ser observados na Tabela 6.15, juntamente de seus valores de alvo individuais.

Tabela 6.15 – Valores ótimos para as variáveis de resposta originais

Variável de resposta	Valor ótimo	Alvo individual
CI	1,4300	0,4371
P	1,2901	0,8320
AP	9,7068	4,6846
D	0,2310	0,1664
L	14,1002	15,5248
R	3,1701	3,5221
IC	0,2205	0,1797
AR	33,1815	38,5868
FP	11,8559	14,5843
FR	4,4722	5,3035

A Tabela 6.16 apresenta a matriz *Pay-off* relacionada à configuração de todas as respostas de interesse quando considerados os melhores resultados individuais, identificados na diagonal principal, dentre os 70 subproblemas otimizados no NBI.

A Figura 6.9 demonstra que a solução ótima está dentro da região de solução viável do problema, que foi obtida considerando tanto as variáveis de resposta originais, quanto os fatores extraídos. Desta forma, é fácil perceber, a partir das Tabelas 6.15 e 6.16 e da Figura 6.9, a complexidade de um problema multiobjetivo com muitas variáveis e a relação de *trade-off* presente na otimização do problema.

Tabela 6.16 – Matriz *Pay-off* para os dados otimizados

CI	1.282	1.463	1.463	1.475	1.566	1.569	1.305	1.566	1.475	1.305
P	1.833	0.900	0.900	0.911	1.051	1.035	1.945	1.051	0.911	1.945
AP	12.239	7.728	7.728	7.879	9.557	9.308	13.190	9.557	7.879	13.190
D	0.321	0.180	0.180	0.177	0.200	0.193	0.339	0.200	0.177	0.339
L	13.587	14.168	14.168	14.188	14.972	14.842	13.749	14.972	14.188	13.749
R	2.728	3.373	3.373	3.388	3.432	3.435	2.647	3.432	3.388	2.647
IC	0.194	0.238	0.238	0.238	0.229	0.230	0.186	0.229	0.238	0.186
AR	25.958	35.605	35.605	36.038	38.559	38.374	24.851	38.559	36.038	24.851
FP	8.161	14.201	14.201	14.208	14.070	14.122	7.696	14.070	14.208	7.696
FR	4.962	4.194	4.194	4.200	4.346	4.322	5.168	4.346	4.200	5.168

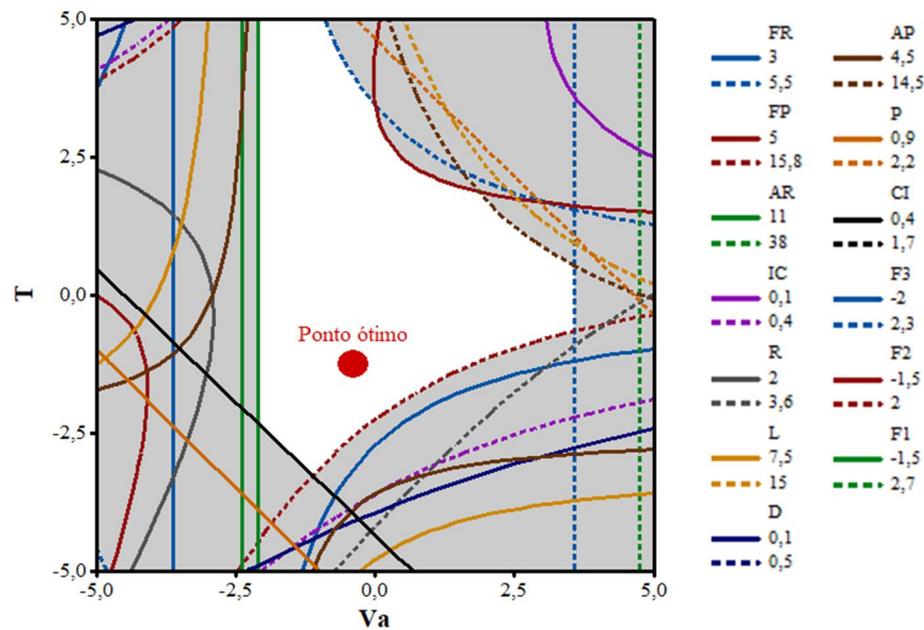


Figura 6.9 – Gráfico de contorno para as variáveis originais e fatores extraídos

6.1.2 Fase 2: uma abordagem para sustentabilidade

Etapa 2.1 - Definir as variáveis associadas à sustentabilidade

As variáveis de calor imposto e área de reforço foram selecionadas como as duas respostas mais relevantes, visto que estão relacionados ao consumo de energia e ao desperdício de material, respectivamente.

Assim, sendo a proposta da segunda fase do método a aplicação de uma otimização estocástica multiobjetivo, modelou-se o problema de forma a minimizar a soma da média e variância relacionadas ao desperdício de material (aço inoxidável), sujeito a um valor limite de custo da energia elétrica. Os coeficientes das funções objetivo e das restrições não foram considerados constantes, já que eles são suscetíveis a variação e, portanto, a um determinado intervalo de confiança, dando ao problema um caráter estocástico.

Conforme detalhado no Capítulo 3, para extração da informação de desperdício

de material associado às áreas de refugo e retrabalho, foi necessário comparar as áreas de reforço obtidas com execução de cada um dos 31 experimentos com a área de reforço de um cordão de solda configurado com a geometria ótima, em termos de qualidade.

Para este estudo de caso, consideraram-se como geometria ótima e, consequentemente área de reforço ótima, aquelas produzidas a partir da configuração ótima dos parâmetros de entrada obtida no estudo de Gomes (2010). Tomou-se esta decisão de trabalhar sobre os dados otimizados de Gomes (2010) e não sobre os valores ótimos identificados na fase 1 deste estudo de caso porque, devido à limitação de recursos, os experimentos não puderam ser replicados e confirmados. Além disso, todos os corpos de prova do estudo de Gomes (2010) encontravam-se em perfeito estado de conservação e disponíveis para manipulação, o que permitiu realizar os trabalhos necessários e coletar as fotografias de suas faces, essenciais para análise.

Entretanto, é importante ressaltar que utilizar os dados em questão como referência em nada impacta a aplicação da fase 2 para efeitos de exemplificação do método proposto. As áreas de reforço dos cordões de solda produzidos nos 31 experimentos desenvolvidos e apresentados no Apêndice B foram conflitadas com a área de reforço do experimento de confirmação (geometria ótima) para verificar possíveis áreas de retrabalho e refugo.

Assim, os 32 corpos de prova, oriundos dos experimentos do CCD e do experimento de confirmação realizado a partir da configuração ótima obtida por Gomes (2010), foram particionados em 5 porções, conforme Figura 6.10. Fotografaram-se os perfis das áreas de reforço das faces direita e esquerda dos cortes D de cada um deles. Antes da obtenção das imagens, ambas as faces foram lixadas e, posteriormente, sofreram um ataque com nital 4%, para que fosse possível obter maior nitidez da área de reforço nos corpos de prova.

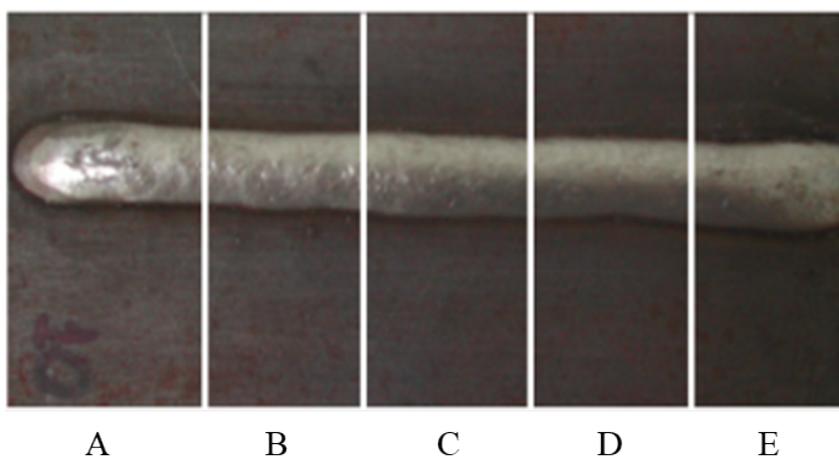


Figura 6.10 – Cordão de solda particionado

Para que fosse possível calcular as áreas relevantes ao problema estocástico, as fotografias originais das faces dos cordões de solda, exemplificadas na Figura 6.11, foram

convertidas em imagens através das quais fosse possível medir as áreas de refugo e área de retrabalho.

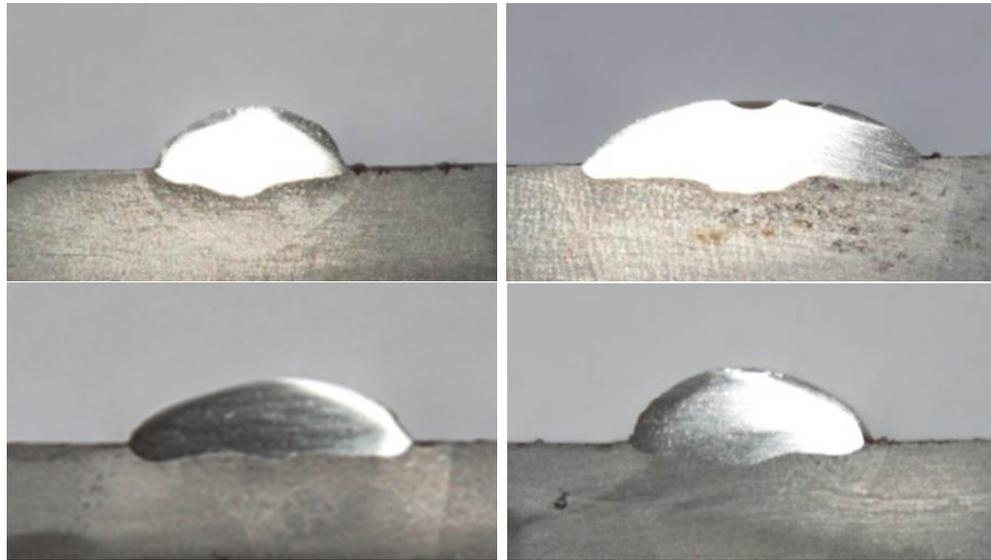


Figura 6.11 – Fotografias originais dos cordões de solda experimentais

A Figura 6.12 mostra os mesmos cordões de solda apresentados na Figura 6.11 transformados em imagens. As áreas em azul e vermelho representam as áreas de refugo e retrabalho, respectivamente, quando comparadas à geometria do cordão de solda ótimo (experimento de confirmação). Estas figuras foram obtidas utilizando recursos de computação gráfica onde as fotografias reais foram convertidas em imagens, de forma que fosse possível contabilizar o número de pixels, realizar a conversão em escala adequada e calcular as medidas reais dos cordões.

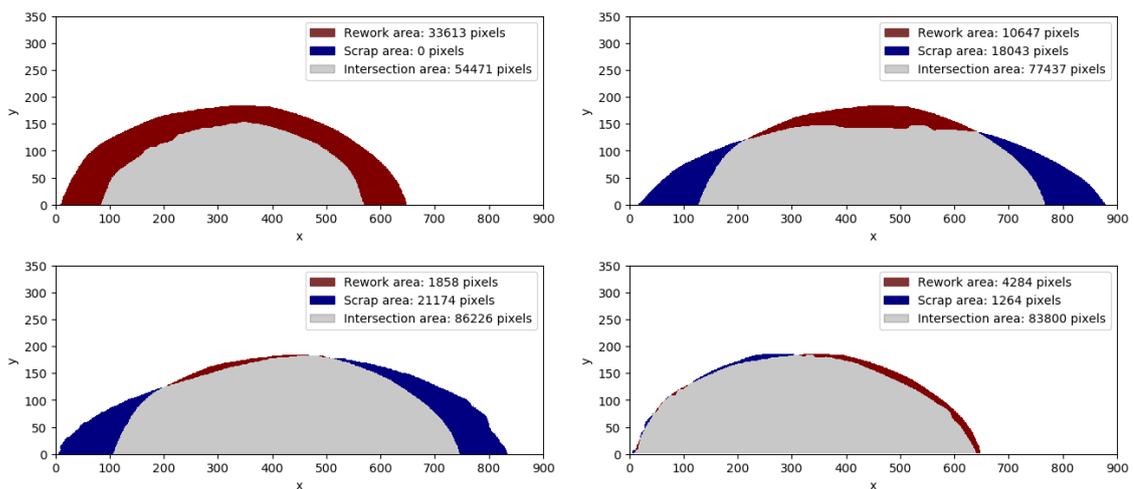


Figura 6.12 – Áreas de refugo e retrabalho dos cordões de solda experimentais

A configuração ótima encontrada por Gomes (2010) foi aquela em que $Va = 10,3\text{m/min}$, $T = 27,0\text{V}$, $Vs = 50,3\text{cm/min}$ e $N = 23,4\text{mm}$. Aplicados seus respectivos valores codificados ($Va = 1,208$, $T = -1,011$, $Vs = 1,033$ e $N = 0,671$) ao modelos

apresentados nas Equações (6.1) até (6.10), obtiveram-se as respostas ótimas para as 10 variáveis de saída, conforme apresentado na Tabela 6.17. Para efeitos informativos, incluíram-se nesta tabela as informações dos valores referentes à geometria ótima e ao alvos individuais, gerados na fase 1 do método.

Tabela 6.17 – Valores ótimos para as variáveis de resposta e alvos individuais

Variável de resposta	Valor ótimo (GOMES, 2010)	Valor ótimo Fase 1	Alvo individual Fase 1
CI	0,586	1,4300	0,4371
P	1,480	1,2901	0,8320
AP	6,056	9,7068	4,6846
D	0,256	0,2310	0,1664
L	8,947	14,1002	15,5248
R	2,931	3,1701	3,5221
IC	0,316	0,2205	0,1797
AR	17,936	33,1815	38,5868
FP	6,377	11,8559	14,5843
FR	3,057	4,4722	5,3035

A Tabela 6.18 apresenta os valores das áreas de refugio e retrabalho para as faces direita (FD) e esquerda (FE) do corte D dos corpos de prova, calculados a partir das imagens exemplificadas na Figura 6.12.

Tabela 6.18 – Áreas de retrabalho e refugio calculadas para as faces do corte D dos corpos de prova

#	Retrabalho		Refugio	
	FD	FE	FD	FE
1	9,083	8,401	0,000	0,000
2	0,215	3,787	2,631	0,728
3	9,109	9,594	0,241	0,098
4	3,353	6,153	5,683	1,641
5	14,548	25,777	0,000	0,000
6	10,268	11,777	0,000	0,000
7	14,679	18,387	0,000	0,000
8	9,648	13,356	0,000	0,000
9	11,013	8,843	0,000	0,000
10	1,187	1,580	0,350	0,126
11	7,438	7,817	0,000	0,000
12	2,393	1,879	2,201	1,107
13	15,820	15,928	0,000	0,000
14	11,113	9,623	0,000	0,000
15	14,715	17,050	0,000	0,000

Continuação da Tabela 6.18

#	Retrabalho		Refugo	
	FD	FE	FD	FE
16	10,307	14,695	0,000	0,000
17	14,655	16,484	0,000	0,000
18	5,487	6,601	0,183	0,014
19	9,915	12,569	0,000	0,000
20	13,298	13,286	0,000	0,000
21	0,514	1,078	5,859	4,130
22	16,238	22,710	0,000	0,000
23	9,585	10,448	0,007	0,000
24	5,669	12,270	0,000	0,000
25	7,450	11,717	0,000	0,000
26	10,239	9,940	0,000	0,000
27	9,820	12,166	0,000	0,000
28	10,061	12,681	0,000	0,000
29	11,871	16,087	0,000	0,000
30	9,864	11,429	0,000	0,000
31	8,599	14,221	0,000	0,000

A partir destas informações, contabilizou-se o total de desperdício para cada uma das faces, somando-se os valores referentes à área de retrabalho e à área de refugo. E então, o valor do desperdício médio para cada um dos experimentos foi obtido a partir da média simples dos desperdícios das duas faces, conforme apresentado na Tabela 6.19.

Tabela 6.19 – Desperdícios das faces direita e esquerda e desperdício médio

#	Desperdício		Desperdício médio
	FD	FE	
1	9,083	8,401	8,742
2	2,846	4,515	3,681
3	9,350	9,692	9,521
4	9,036	7,794	8,415
5	14,548	25,777	20,163
6	10,268	11,777	11,023
7	14,679	18,387	16,533
8	9,648	13,356	11,502
9	11,013	8,843	9,928
10	1,537	1,706	1,622

Continuação da Tabela 6.19

#	Desperdício		Desperdício médio
	FD	FE	
11	7,438	7,817	7,628
12	4,594	2,986	3,790
13	15,820	15,928	15,874
14	11,113	9,623	10,368
15	14,715	17,050	15,883
16	10,307	14,695	12,501
17	14,655	16,484	15,570
18	5,670	6,615	6,143
19	9,915	12,569	11,242
20	13,298	13,286	13,292
21	6,373	5,208	5,791
22	16,238	22,710	19,474
23	9,592	10,448	10,020
24	5,669	12,270	8,970
25	7,450	11,717	9,584
26	10,239	9,940	10,090
27	9,820	12,166	10,993
28	10,061	12,681	11,371
29	11,871	16,087	13,979
30	9,864	11,429	10,647
31	8,599	14,221	11,410

O outro aspecto relacionado à segunda abordagem do método refere-se ao custo da energia elétrica demandada pelo processo de soldagem. As Tabelas 6.20 e 6.21 apresentam os custos da energia elétrica calculados a partir do calor imposto referente a cada um dos experimentos realizados, considerando todos os cenários de tarifação apurados para o mês de 03/2019 dentro do sistema de brasileiro de energia apresentados na Tabela 4.1.

Tabela 6.20 – Custo da energia para HP (em R\$) a partir do calor imposto

		HP			
		Verde	Amarelo	Vermelha	
				Patamar 1	Patamar 2
#	CI	Custo	Custo	Custo	Custo
1	0,9288	0,300	0,309	0,328	0,346

Continuação da Tabela 6.20

		HP			
		Verde	Amarelo	Vermelha	
				Patamar 1	Patamar 2
		0,32282	0,33282	0,35282	0,37282
#	CI	Custo	Custo	Custo	Custo
2	1,1556	0,373	0,385	0,408	0,431
3	1,1584	0,374	0,386	0,409	0,432
4	1,4912	0,481	0,496	0,526	0,556
5	0,5605	0,181	0,187	0,198	0,209
6	0,6642	0,214	0,221	0,234	0,248
7	0,6758	0,218	0,225	0,238	0,252
8	0,8371	0,270	0,279	0,295	0,312
9	0,7722	0,249	0,257	0,272	0,288
10	0,9666	0,312	0,322	0,341	0,360
11	0,9728	0,314	0,324	0,343	0,363
12	1,1456	0,370	0,381	0,404	0,427
13	0,4633	0,150	0,154	0,163	0,173
14	0,5735	0,185	0,191	0,202	0,214
15	0,5798	0,187	0,193	0,205	0,216
16	0,7027	0,227	0,234	0,248	0,262
17	0,6239	0,201	0,208	0,220	0,233
18	0,9425	0,304	0,314	0,333	0,351
19	0,6431	0,208	0,214	0,227	0,240
20	0,9729	0,314	0,324	0,343	0,363
21	1,6549	0,534	0,551	0,584	0,617
22	0,5074	0,164	0,169	0,179	0,189
23	0,9868	0,319	0,328	0,348	0,368
24	0,6726	0,217	0,224	0,237	0,251
25	0,7965	0,257	0,265	0,281	0,297
26	0,8009	0,259	0,267	0,283	0,299
27	0,7921	0,256	0,264	0,279	0,295
28	0,7788	0,251	0,259	0,275	0,290
29	0,7744	0,250	0,258	0,273	0,289
30	0,7611	0,246	0,253	0,269	0,284
31	0,7700	0,249	0,256	0,272	0,287

Tabela 6.21 – Custo da energia para HFP (em R\$) a partir do calor imposto

		HFP			
		Verde	Amarelo	Vermelha	
				Patamar 1	Patamar 2
		0,47753	0,48753	0,50753	0,52753
#	CI	Custo	Custo	Custo	Custo
1	0,9288	0,444	0,453	0,471	0,490
2	1,1556	0,552	0,563	0,587	0,610
3	1,1584	0,553	0,565	0,588	0,611
4	1,4912	0,712	0,727	0,757	0,787
5	0,5605	0,268	0,273	0,284	0,296
6	0,6642	0,317	0,324	0,337	0,350
7	0,6758	0,323	0,329	0,343	0,357
8	0,8371	0,400	0,408	0,425	0,442
9	0,7722	0,369	0,376	0,392	0,407
10	0,9666	0,462	0,471	0,491	0,510
11	0,9728	0,465	0,474	0,494	0,513
12	1,1456	0,547	0,559	0,581	0,604
13	0,4633	0,221	0,226	0,235	0,244
14	0,5735	0,274	0,280	0,291	0,303
15	0,5798	0,277	0,283	0,294	0,306
16	0,7027	0,336	0,343	0,357	0,371
17	0,6239	0,298	0,304	0,317	0,329
18	0,9425	0,450	0,459	0,478	0,497
19	0,6431	0,307	0,314	0,326	0,339
20	0,9729	0,465	0,474	0,494	0,513
21	1,6549	0,790	0,807	0,840	0,873
22	0,5074	0,242	0,247	0,258	0,268
23	0,9868	0,471	0,481	0,501	0,521
24	0,6726	0,321	0,328	0,341	0,355
25	0,7965	0,380	0,388	0,404	0,420
26	0,8009	0,382	0,390	0,406	0,422
27	0,7921	0,378	0,386	0,402	0,418
28	0,7788	0,372	0,380	0,395	0,411
29	0,7744	0,370	0,378	0,393	0,409
30	0,7611	0,363	0,371	0,386	0,402
31	0,7700	0,368	0,375	0,391	0,406

Para a determinação do custo médio da energia elétrica, calculou-se a média simples dos oito valores de custo possíveis (quatro para HFP e quatro para HP) apresentados nas Tabelas 6.20 e 6.21.

Etapa 2.2 - Modelar as médias das variáveis selecionadas

A partir das respostas estabelecidas para cada uma das variáveis selecionadas, construíram-se os modelos para as médias do desperdício de material e do custo da energia elétrica, apresentados nas Equações (6.17) e (6.18).

$$\text{Desperdício} = 11,273 - 2,509Va + 0,353T + 3,662Vs - 0,587N - 0,571N^2 + 0,916VaT \quad (6.17)$$

$$\begin{aligned} \text{Custo} = & 0,33319 + 0,03632Va + 0,03766T - 0,10266Vs - 0,03388N + 0,02975Vs^2 \\ & - 0,01133VaVs - 0,01085TVs + 0,01211VsN \end{aligned} \quad (6.18)$$

As funções foram obtidas através do *software* estatístico *Minitab*[®], partindo de um modelo quadrático completo com a aplicação do método de eliminação *backward*, e apresentaram valores de ajuste iguais a $R^2 = 92,20\%$ e $R_{ajustado}^2 = 90,25\%$ e $R^2 = 97,97\%$ e $R_{ajustado}^2 = 97,23\%$, respectivamente. As Tabelas 6.22 e 6.23 apresentam a análise de variância para ambos modelos. As respectivas análises de resíduos indicaram normalidade dos dados, confirmando sua adequação, conforme Figuras 6.13 e 6.14.

Tabela 6.22 – Análise de variância para o desperdício de material (proporções de componentes)

Fonte de variação	GL	SQA	QMA	F-value	p-value
Modelo	6	507,244	84,541	47,30	0,000
Linear	4	484,220	121,055	67,73	0,000
<i>Va</i>	1	151,122	151,122	84,55	0,000
<i>T</i>	1	2,991	2,991	1,67	0,208
<i>Vs</i>	1	321,839	321,839	180,07	0,000
<i>N</i>	1	8,268	8,268	4,63	0,042
Quadrado	1	9,595	9,595	5,37	0,029
<i>N*N</i>	1	9,595	9,595	5,37	0,029
Interação com 2 Fatores	1	13,429	13,429	7,51	0,011
<i>Va*T</i>	1	13,429	13,429	7,51	0,011
Erro	24	42,895	1,787		
Falta de ajuste	18	30,919	1,718	0,86	0,631
Erro puro	6	11,976	1,996	*	*
Total	30	550,139			

Etapa 2.3 - Modelar a variância das variáveis selecionadas

Tabela 6.23 – Análise de variância para o custo da energia elétrica (proporções de componentes)

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	8	0,378504	0,047313	132,54	0,000
Linear	4	0,346181	0,86545	242,44	0,000
<i>V_a</i>	1	0,031653	0,031653	88,67	0,000
<i>T</i>	1	0,034036	0,034036	95,34	0,000
<i>V_s</i>	1	0,252950	0,252950	708,59	0,000
<i>N</i>	1	0,027541	0,027541	77,15	0,000
Quadrado	1	0,026039	0,026039	72,94	0,000
<i>V_s*V_s</i>	1	0,026039	0,026039	72,94	0,000
Interação com 2 Fatores	3	0,00685	0,002095	5,87	0,004
<i>V_a*V_s</i>	1	0,002052	0,002052	5,75	0,025
<i>T*V_s</i>	1	0,001885	0,001885	5,28	0,031
<i>V_s*N</i>	1	0,002347	0,002347	6,58	0,018
Erro	22	0,007854	0,000357		
Falta de ajuste	16	0,007618	0,000476	12,13	0,003
Erro puro	6	0,000236	0,000039	*	*
Total	30	0,386358			

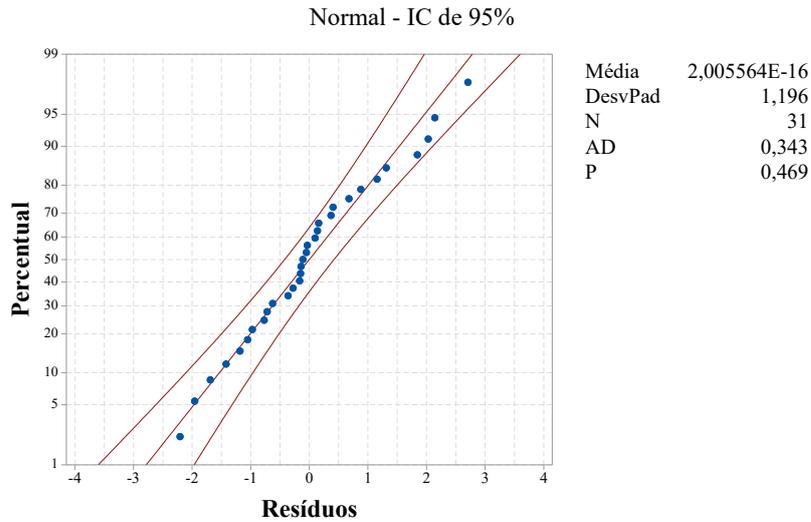


Figura 6.13 – Gráfico de probabilidade para os resíduos do modelo da média do desperdício

Para calcular a variância de cada uma das configurações associadas aos parâmetros de entrada do modelo utilizou-se a Equação (6.19):

$$Var[f(x)] = \sigma^2 \mathbf{Z}^T(x) (\mathbf{X}^T \mathbf{X}) \mathbf{Z}(x) \quad (6.19)$$

onde σ^2 é o termo relativo ao erro quadrático multivariado, ou seja, a variação associada à realização do experimento em questão determinada pelo operador, a matriz

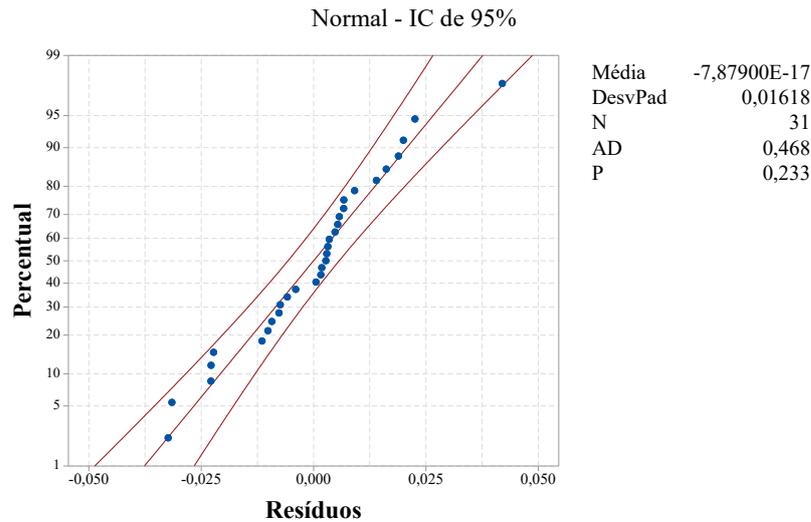


Figura 6.14 – Gráfico de probabilidade para os resíduos do modelo da média do custo da energia elétrica

\mathbf{X} refere-se à matriz do arranjo experimental e o vetor $\mathbf{Z}(x)$ corresponde à Equação (6.20):

$$\mathbf{Z}^T(x) = [1 \ x_1 \ x_2 \ \dots \ x_n \ x_1^2 \ x_2^2 \ \dots \ x_n^2 \ \dots \ x_1 \ x_2 \ x_2 \ x_3 \ \dots \ x_{n-1} \ x_n] \quad (6.20)$$

Etapa 2.4 - Formular o problema multiobjetivo estocástico

Para formulação do problema estocástico, partiu-se do problema dual, conforme definido na Equação (2.8), que estabelece que a função objetivo seja composta pela média ($f_1(x)$) e variância ($f_2(x)$) de uma variável de resposta, neste caso desperdício de material, sujeito ao valor da média mais o desvio padrão de uma segunda variável de resposta, aqui estabelecida como sendo o custo da energia elétrica.

O valor de s_i estabelecido foi de 1,96, representando a probabilidade de 97,5% e o valor de c considerado foi de 0,380, obtido a partir da média dos valores médios calculados para os custos associados aos 31 experimentos.

Etapa 2.5 - Aplicar método NBI para otimização

Para a otimização do problema construído, considerou-se a formulação para cenários biobjetivo do método NBI descrita na Equação (2.2). Para tal, escalonaram-se as funções $f_1(x)$ e $f_2(x)$, a partir da matriz *Pay-off* que pode ser observada na Equação (6.21).

$$Pay-off_{estocástica} = \begin{bmatrix} \mathbf{1,833} & 11,273 \\ 0,429 & \mathbf{0,094} \end{bmatrix} \quad (6.21)$$

Considerou-se um conjunto de 21 pesos (w), variando de 0 a 1 em incrementos de 0,05, para a realização da otimização. A Tabela 6.24 apresenta os resultados ótimos, a distância de Mahalanobis calculada segundo a Equação (5.3) e o custo da energia elétrica obtido em cada um dos 21 subproblemas. A otimização foi realizada utilizando-se o algoritmo Gradiente Reduzido Generalizado (GRG) não linear, por meio do suplemento *Solver* do *software Microsoft Excel*[®].

Tabela 6.24 – Valores ótimos para o problema estocástico

#	w	Desperdício		Distância de Mahalanobis	Custo da energia elétrica
		Média	Variância		
1	0,00	11,273	0,094	2,898	0,342
2	0,05	10,322	0,094	2,037	0,340
3	0,10	9,533	0,099	1,480	0,355
4	0,15	8,829	0,108	1,141	0,371
5	0,20	8,192	0,119	1,008	0,380
6	0,25	7,648	0,133	1,039	0,380
7	0,30	7,182	0,150	1,122	0,380
8	0,35	6,772	0,169	1,163	0,380
9	0,40	6,404	0,189	1,153	0,380
10	0,45	6,071	0,211	1,098	0,380
11	0,50	5,765	0,233	1,009	0,380
12	0,55	5,482	0,257	0,901	0,380
13	0,60	5,218	0,281	0,795	0,380
14	0,65	4,970	0,306	0,721	0,380
15	0,70	4,737	0,331	0,718	0,380
16	0,75	4,515	0,356	0,809	0,380
17	0,80	4,305	0,382	0,986	0,380
18	0,85	4,105	0,409	1,223	0,380
19	0,90	3,913	0,435	1,501	0,380
20	0,95	3,728	0,462	1,809	0,380
21	1,00	3,551	0,490	2,139	0,380

Etapa 2.6 - Aplicar critério de seleção da resposta ótima

Para auxiliar na seleção da resposta ótima, dentre as soluções geradas a partir da otimização do problema, considerou-se a distância de Mahalanobis. Seu cálculo foi realizado com o apoio do *software* estatístico *Minitab*[®], utilizando as respostas relativas à média e à variância do desperdício e a matriz de covariância associada. Os valores obtidos também podem ser observados na Tabela 6.24.

Etapa 2.7 - Definir resposta ótima

A partir da identificação do menor valor para a distância de Mahalanobis calculada, neste caso 0,718 (em destaque na Tabela 6.24), foi possível definir o melhor ponto da fronteira de Pareto exibida na Figura 6.15. Associados a este ponto, estão os valores de 4,737 para a média do desperdício de material e 0,331 para a sua variância associada. É importante ressaltar que, como o custo da energia elétrica foi estabelecido como restrição no problema, todos os pontos da fronteira respeitam o valor limite definido. Para o modelo proposto, caso fosse desejável obter um menor custo limite referente à energia elétrica, este valor deveria ser alterado na restrição $g_1(x)$.

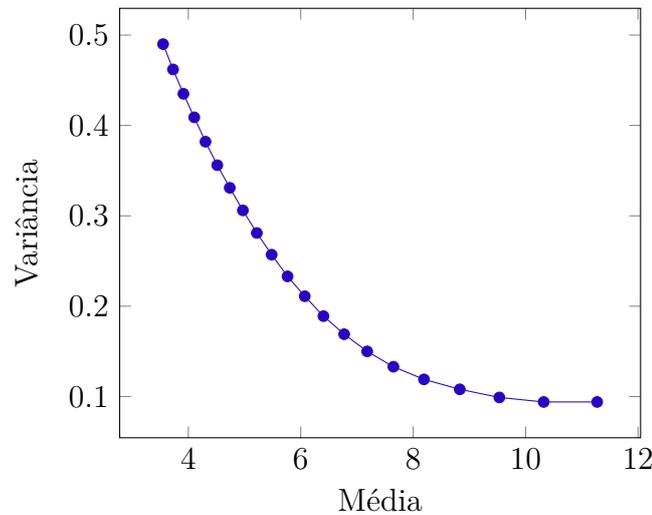


Figura 6.15 – Fronteira de Pareto para o desperdício de material

Avaliando o subproblema 15, definido como o melhor ponto da fronteira de Pareto, obtêm-se os valores codificados dos parâmetros de entrada $Va = 0,967$, $T = -0,600$, $Vs = -0,649$ e $N = 1,081$. Seus valores decodificados $Va = 9,95\text{m/min}$, $T = 28,00\text{V}$, $Vs = 33,51\text{cm/min}$ e $N = 25,41\text{mm}$ determinam, então, a configuração ótima para os parâmetros de entrada considerando uma abordagem estocástica para o custo da energia elétrica e o desperdício de material.

Aplicando esta configuração aos modelos das 10 variáveis de resposta originais indicados nas Equações (6.1) até (6.10), obtiveram-se seus valores ótimos. A Tabela 6.25 apresenta os resultados ótimos segundo as duas abordagens do método, qualidade e sustentabilidade, bem como os valores de alvo individual relacionados a cada variável de saída.

Tabela 6.25 – Resultados ótimos para as abordagens de qualidade e sustentabilidade

Variável de resposta	Valor ótimo		Alvo individual	Sentido de otimização
	Qualidade	Sustentabilidade		
CI	1,4300	0,9054	0,4371	Minimização
P	1,2901	1,1547	0,8320	Minimização
AP	9,7068	6,9210	4,6846	Minimização
D	0,2310	0,2160	0,1664	Minimização
L	14,1002	11,2695	15,5248	Maximização
R	3,1701	3,2635	3,5221	Maximização
IC	0,2205	0,2963	0,1797	Minimização
AR	33,1815	27,1925	38,5868	Maximização
FP	11,8559	9,9239	14,5843	Maximização
FR	4,4722	3,3537	5,3035	Maximização

Observando a Tabela 6.25 e revisitando os sentidos de otimização das variáveis de resposta, percebe-se uma redução de 36,69% no calor imposto em relação à resposta ótima identificada na fase 1, o que é bastante interessante, visto que seu objetivo era ser minimizado. Por outro lado, é possível observar que, embora a área de reforço esteja associada ao objetivo de maximização, seu valor também sofreu redução em relação à abordagem de qualidade, distanciando ainda mais do seu valor de alvo individual. Esta relação de *trade-off* também pode ser observada nas variáveis de resposta largura do cordão, índice de convexidade, fator de penetração e fator de reforço.

Desta forma, é válido ressaltar que a abordagem de sustentabilidade cumpre com seu objetivo, oferecendo ganhos em termos de custo do processo relacionado ao consumo de energia elétrica, ao mesmo tempo em que apresenta redução no material desperdiçado. Entretanto, para que isto aconteça, a configuração ótima do cordão de solda, produzida na abordagem de qualidade, será comprometida.

7 CONCLUSÃO

Problemas relacionados aos processos de fabricação e recuperação são classificados como multiobjetivo e envolvem um grande número de variáveis de resposta de interesse que apresentam, por muitas vezes, objetivos conflitantes (minimização e maximização). Este trabalho realizou um estudo sobre um processo de soldagem de revestimento de chapas de aço carbono ABNT 1020 utilizando arame tubular de aço inoxidável austenístico ABNT 316L, para exemplificar o método proposto de otimização de duas fases sob perspectivas distintas: qualidade e sustentabilidade.

A primeira abordagem focou na otimização dos parâmetros de entrada do processo de maneira a produzir um cordão de solda com a melhor geometria possível, enquanto a segunda buscou otimizar aspectos relacionados à sustentabilidade do processo, neste caso o custo da energia elétrica e o desperdício de material, considerando a estocasticidade de ambos.

O estudo envolveu a combinação de técnicas de planejamento de experimentos, otimização multiobjetivo estocástica e análise multivariada para entendimento do processo e obtenção de soluções otimizadas.

A partir das respostas obtidas e detalhadas ao longo do capítulo anterior, podem-se sintetizar as seguintes conclusões para este trabalho:

- todas as funções matemáticas obtidas para as variáveis de saída do processo apresentaram ajustes superiores a 85% com indicação de normalidade dos resíduos, o que as caracteriza como modelos de alta confiabilidade;
- a análise fatorial produziu o efeito esperado de neutralização das correlações existentes entre as variáveis de interesse que podem afetar de forma não desejada os resultados da otimização do processo;
- a utilização dos erros quadráticos médios multivariados como funções objetivos do problema de otimização é uma estratégia bem sucedida quando os objetivos são conflitantes;
- incorporar ao problema de otimização informações externas ao processo, como o custo da energia elétrica, permite agregar resultados extremamente relevantes ao contexto da empresa;
- é possível modelar e otimizar o problema considerando um cenário estocástico, o que possibilita englobar características não determinísticas influentes ao processo;

- a aplicação do método NBI para solucionar o problema de otimização multiobjetivo produz uma série de soluções na fronteira ou superfície de Pareto que podem ser escolhidas a partir de um critério que seja mais interessante à empresa. No estudo de caso, estabeleceram-se a distância de Mahalanobis e a entropia, mas o método permite a seleção de diferentes critérios;
- as diferentes abordagens produzem soluções que podem ser conjuntamente analisadas, servindo como apoio à tomada de decisão para possíveis ajustes dos processos de produção.

Conclui-se, então, que os resultados obtidos confirmaram que métodos de otimização quando aplicados de forma adequada são capazes de contemplar múltiplas respostas de interesse do processo simultaneamente - ainda que envolvam cenários dinâmicos, como é o caso do custo da energia elétrica - e podem ser ferramentas extremamente úteis para apoiar a tomada de decisão dentro das indústrias.

7.1 SUGESTÕES PARA TRABALHOS FUTUROS

Visando a incorporação da estocasticidade ao problema de otimização multiobjetivo relacionado ao processo de soldagem de revestimento, incluiu-se apenas o custo da energia elétrica na aplicação da segunda etapa do método. Um possível estudo a ser realizado constitui na elaboração de um modelo que contemple não apenas o custo da energia elétrica, mas também o custo do material associado ao desperdício, por exemplo.

Desta forma, os resultados poderiam trazer impacto e interesse ainda maiores às indústrias, corroborando com a proposta de que a aplicação correta do método pode proporcionar ganhos de qualidade e sustentabilidade ambiental e financeira de proporções consideráveis.

Além disso, outra possibilidade seria explorar diferentes processos de fabricação ou recuperação envolvendo um grandes número de variáveis de resposta demonstrando a aplicabilidade do método em cenários diferentes e até mesmo mais complexos.

REFERÊNCIAS

- ANEEL. *Bandeiras Tarifárias*. Disponível em: <http://www.aneel.gov.br/tarifas-consumidores/-/asset_publisher/e2INtBH4EC4e/content/bandeira-tarifaria/654800>. Citado na página 27.
- ANEEL. *Resolução Normativa Nº 482, de 17 de abril de 2012*. 2012. Disponível em: <<http://www2.aneel.gov.br/cedoc/ren2012482.pdf>>. Citado 2 vezes nas páginas 26 e 27.
- ASTM. *ASTM G40-17, Standard Terminology Relating to Wear and Erosion*. West Conshohocken: ASTM International, 2017. Citado na página 23.
- BAGHEL, R.; UPADHYAYA, S.; CHAURASIA, S.; SINGH, K.; KALLA, S. Optimization of process variables by the application of response surface methodology for naphthol blue black dye removal in vacuum membrane distillation. *Journal of Cleaner Production*, Elsevier, v. 199, p. 900–915, 10 2018. ISSN 0959-6526. Citado na página 74.
- BAHRAMI, H.; ESLAMI, A.; NABIZADEH, R.; MOHSENI-BANDPI, A.; ASADI, A.; SILLANPÄÄ, M. Degradation of trichloroethylene by sonophotolytic-activated persulfate processes: Optimization using response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 198, p. 1210–1218, 10 2018. ISSN 0959-6526. Citado na página 74.
- BOKRANTZ, R.; FREDRIKSSON, A. Necessary and sufficient conditions for Pareto efficiency in robust multiobjective optimization. *European Journal of Operational Research*, North-Holland, v. 262, n. 2, p. 682–692, 10 2017. ISSN 0377-2217. Citado na página 8.
- BOX, G. E.; HUNTER, W. G.; MACGREGOR, J. F.; ERJAVEC, J. Some Problems Associated with the Analysis of Multiresponse Data. *Technometrics*, 1973. ISSN 15372723. Citado na página 10.
- BRITO, T.; PAIVA, A.; FERREIRA, J.; GOMES, J.; BALESTRASSI, P. A normal boundary intersection approach to multiresponse robust optimization of the surface roughness in end milling process with combined arrays. *Precision Engineering*, Elsevier, v. 38, n. 3, p. 628–638, 7 2014. ISSN 0141-6359. Citado na página 9.
- CABRERA, G.; GÓMEZ, J.; HERNÁNDEZ, I.; COTO, O.; CANTERO, D. Different strategies for recovering metals from CARON process residue. *Journal of Hazardous Materials*, Elsevier, v. 189, n. 3, p. 836–842, 5 2011. ISSN 0304-3894. Citado na página 1.
- CAO, L.; CHEN, H.; TSANG, D. C.; LUO, G.; HAO, S.; ZHANG, S.; CHEN, J. Optimizing xylose production from pinewood sawdust through dilute-phosphoric-acid hydrolysis by response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 178, p. 572–579, 3 2018. ISSN 0959-6526. Citado na página 74.
- CEMIG. *Valores de Tarifas e Serviços*. Disponível em: <https://www.cemig.com.br/pt-br/atendimento/Paginas/valores_de_tarifa_e_servicos.aspx>. Citado 2 vezes nas páginas 26 e 27.

CHAROEN, K.; PRAPAINAINAR, C.; SUREEYATANAPAS, P.; SUWANNAPHISIT, T.; WONGAMORNPITAK, K.; HOLMES, S. M.; PRAPAINAINAR, P. Application of response surface methodology to optimize direct alcohol fuel cell power density for greener energy production. *Journal of Cleaner Production*, Elsevier, v. 142, p. 1309–1320, 1 2017. ISSN 0959-6526. Citado na página 73.

CHOUDHURY, P.; MONDAL, P.; MAJUMDAR, S.; SAHA, S.; SAHOO, G. C. Preparation of ceramic ultrafiltration membrane using green synthesized CuO nanoparticles for chromium (VI) removal and optimization by response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 203, p. 511–520, 12 2018. ISSN 0959-6526. Citado na página 74.

COSTA, D. M. D.; BRITO, T. G.; PAIVA, A. P. de; LEME, R. C.; BALESTRASSI, P. P. A normal boundary intersection with multivariate mean square error approach for dry end milling process optimization of the AISI 1045 steel. *Journal of Cleaner Production*, Elsevier, v. 135, p. 1658–1672, 11 2016. ISSN 0959-6526. Citado 3 vezes nas páginas 10, 14 e 15.

DAS, I.; DENNIS, J. E. Normal-Boundary Intersection: A New Method for Generating the Pareto Surface in Nonlinear Multicriteria Optimization Problems. *SIAM Journal on Optimization*, 2003. ISSN 1052-6234. Citado na página 9.

DÍAZ-GARCÍA, J. A.; RAMOS-QUIROGA, R.; CABRERA-VICENCIO, E. Stochastic programming methods in the response surface methodology. *Computational Statistics & Data Analysis*, North-Holland, v. 49, n. 3, p. 837–848, 6 2005. ISSN 0167-9473. Citado na página 11.

DUNANT, C. F.; DREWNIOK, M. P.; SANSOM, M.; CORBEY, S.; CULLEN, J. M.; ALLWOOD, J. M. Options to make steel reuse profitable: An analysis of cost and risk distribution across the UK construction value chain. *Journal of Cleaner Production*, Elsevier, v. 183, p. 102–111, 5 2018. ISSN 0959-6526. Citado na página 2.

FERREIRA, D. F. *Estatística Multivariada*. 1. ed. Lavras: Editora UFLA, 2008. 662 p. Citado 2 vezes nas páginas 17 e 18.

FLANDINET, L.; TEDJAR, F.; GHETTA, V.; FOULETIER, J. Metals recovering from waste printed circuit boards (WPCBs) using molten salts. *Journal of hazardous materials*, v. 213-214, p. 485–90, 4 2012. ISSN 1873-3336. Citado na página 1.

FU, Y.; TIAN, G.; FATHOLLAHI-FARD, A. M.; AHMADI, A.; ZHANG, C. Stochastic multi-objective modelling and optimization of an energy-conscious distributed permutation flow shop scheduling problem with the total tardiness constraint. *Journal of Cleaner Production*, Elsevier, v. 226, p. 515–525, 7 2019. ISSN 0959-6526. Citado na página 11.

GASEMLOO, S.; KHOSRAVI, M.; SOHRABI, M. R.; DASTMALCHI, S.; GHARBANI, P. Response surface methodology (RSM) modeling to improve removal of Cr (VI) ions from tannery wastewater using sulfated carboxymethyl cellulose nanofilter. *Journal of Cleaner Production*, Elsevier, v. 208, p. 736–742, 1 2019. ISSN 0959-6526. Citado na página 75.

GOMES, J. *Análise e otimização da soldagem de revestimento de chapas de aço ABNT 1020 com utilização de arame tubular inoxidável austenítico*. Itajubá: [s.n.], 2010. 120 p. Citado 9 vezes nas páginas 6, 24, 25, 33, 34, 35, 51, 52 e 53.

GOMES, J.; PAIVA, A.; COSTA, S.; BALESTRASSI, P.; PAIVA, E. Weighted Multivariate Mean Square Error for processes optimization: A case study on flux-cored arc welding for stainless steel claddings. *European Journal of Operational Research*, North-Holland, v. 226, n. 3, p. 522–535, 5 2013. ISSN 0377-2217. Citado na página 2.

GOPAL, K.; SATHIYAGNANAM, A. P.; KUMAR, B. R.; SARAVANAN, S.; RANA, D.; SETHURAMASAMYRAJA, B. Prediction of emissions and performance of a diesel engine fueled with n-octanol/diesel blends using response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 184, p. 423–439, 5 2018. ISSN 0959-6526. Citado na página 74.

GROOVER, M. P. *Fundamentals of modern manufacturing : materials, processes, and systems*. [S.l.]: John Wiley & Sons, Inc, 2013. 1101 p. ISBN 9781118231463. Citado 3 vezes nas páginas 1, 22 e 23.

GUPTA, D.; SHARMA, A. Development and microstructural characterization of microwave cladding on austenitic stainless steel. *Surface and Coatings Technology*, Elsevier, v. 205, n. 21-22, p. 5147–5155, 8 2011. ISSN 0257-8972. Citado na página 23.

HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E. *Multivariate Data Analysis*. 7. ed. [S.l.]: Prentice Hall, 2009. 785 p. Citado na página 18.

JOHNSON, R. A.; WICHERN, D. W. *Applied multivariate statistical analysis*. 6th. ed. [S.l.]: Prentice Hall, 2007. Citado 3 vezes nas páginas 18, 19 e 20.

KAKOI, B.; KALULI, J. W.; NDIBA, P.; THIONG'O, G. Optimization of Maerua Decumbent bio-coagulant in paint industry wastewater treatment with response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 164, p. 1124–1134, 10 2017. ISSN 0959-6526. Citado na página 73.

KANNAN, T.; MURUGAN, N. Effect of flux cored arc welding process parameters on duplex stainless steel clad quality. *Journal of Materials Processing Technology*, Elsevier, v. 176, n. 1-3, p. 230–239, 6 2006. ISSN 0924-0136. Citado na página 24.

KARPAT, Y.; ÖZEL, T. Hard turning optimization using neural network modeling and swarm intelligence. *Transactions of the North American Manufacturing Research Institute of SME*, v. 33, p. 179–186, 2005. Citado 2 vezes nas páginas 8 e 9.

KHALID, A. A. H.; YAAKOB, Z.; ABDULLAH, S. R. S.; TAKRIFF, M. S. Analysis of the elemental composition and uptake mechanism of *Chlorella sorokiniana* for nutrient removal in agricultural wastewater under optimized response surface methodology (RSM) conditions. *Journal of Cleaner Production*, Elsevier, v. 210, p. 673–686, 2 2019. ISSN 0959-6526. Citado na página 75.

KLEPA, R. B.; MEDEIROS, M. F.; FRANCO, M. A. C.; TAMBERG, E. T.; FARIAS, T. M. d. B.; FILHO, J. A. P.; BERSANETI, F. T.; SANTANA, J. C. C. Reuse of construction waste to produce thermoluminescent sensor for use in highway traffic control. *Journal of Cleaner Production*, Elsevier, v. 209, p. 250–258, 2 2019. ISSN 0959-6526. Citado na página 14.

- LIU, Z.; JIANG, Q.; LI, T.; DONG, S.; YAN, S.; ZHANG, H.; XU, B. Environmental benefits of remanufacturing: A case study of cylinder heads remanufactured through laser cladding. *Journal of Cleaner Production*, Elsevier, v. 133, p. 1027–1033, 10 2016. ISSN 0959-6526. Citado 2 vezes nas páginas 1 e 2.
- LU, Y.; XU, Z. Recycling non-leaching gold from gold-plated memory cards: Parameters optimization, experimental verification, and mechanism analysis. *Journal of Cleaner Production*, Elsevier, v. 162, p. 1518–1526, 9 2017. ISSN 0959-6526. Citado na página 14.
- Markandeya; DHIMAN, N.; SHUKLA, S.; KISKU, G. Statistical optimization of process parameters for removal of dyes from wastewater on chitosan cenospheres nanocomposite using response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 149, p. 597–606, 4 2017. ISSN 0959-6526. Citado na página 73.
- MARQUES, P. V.; MODENESI, P. J.; BRACARENSE, A. Q. *Soldagem: fundamentos e tecnologia*. 4. ed. Rio de Janeiro: Elsevier, 2017. 370 p. ISBN 9788535271096. Citado 2 vezes nas páginas 22 e 23.
- MOHAMMED, B. S.; KHED, V. C.; NURUDDIN, M. F. Rubbercrete mixture optimization using response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 171, p. 1605–1621, 1 2018. ISSN 0959-6526. Citado na página 74.
- MOHAMMED, I. Y.; ABAKR, Y. A.; HUI, J. N. X.; ALABA, P. A.; MORRIS, K. I.; IBRAHIM, M. D. Recovery of clean energy precursors from Bambara groundnut waste via pyrolysis: Kinetics, products distribution and optimisation using response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 164, p. 1430–1445, 10 2017. ISSN 0959-6526. Citado na página 73.
- MOHAMMED, I. Y.; ABAKR, Y. A.; YUSUP, S.; KAZI, F. K. Valorization of Napier grass via intermediate pyrolysis: Optimization using response surface methodology and pyrolysis products characterization. *Journal of Cleaner Production*, Elsevier, v. 142, p. 1848–1866, 1 2017. ISSN 0959-6526. Citado na página 73.
- MONTGOMERY, D. C. *Design and Analysis of Experiments*. 8th. ed. [S.l.]: John Wiley & Sons, Inc., 2013. Citado 5 vezes nas páginas 13, 15, 16, 17 e 25.
- MORERO, B.; GROPELLI, E. S.; CAMPANELLA, E. A. Evaluation of biogas upgrading technologies using a response surface methodology for process simulation. *Journal of Cleaner Production*, Elsevier, v. 141, p. 978–988, 1 2017. ISSN 0959-6526. Citado na página 73.
- MOURA, D.; BARCELOS, V.; SAMANAMUD, G. R. L.; FRANÇA, A. B.; LOFRANO, R.; LOURES, C. C. A.; NAVES, L. L. R.; AMARAL, M. S.; NAVES, F. L. Normal boundary intersection applied as multivariate and multiobjective optimization in the treatment of amoxicillin synthetic solution. *Environmental monitoring and assessment*, v. 190, n. 3, p. 140, 2 2018. ISSN 1573-2959. Citado na página 9.
- MYERS, R. H.; MONTGOMERY, D. *Response Surface Methodology: process and product optimization using designed experiments*. 2. ed. [S.l.]: John Wiley & Sons, Inc., 2002. 798 p. Citado 4 vezes nas páginas 12, 14, 15 e 16.

- NASIRI, R.; ARSALANI, N. Synthesis and application of 3D graphene nanocomposite for the removal of cationic dyes from aqueous solutions: Response surface methodology design. *Journal of Cleaner Production*, Elsevier, v. 190, p. 63–71, 7 2018. ISSN 0959-6526. Citado 2 vezes nas páginas 14 e 74.
- NAVES, F. L.; PAULA, T. I. de; BALESTRASSI, P. P.; BRAGA, W. L. M.; SAWHNEY, R. S.; PAIVA, A. P. de. Multivariate Normal Boundary Intersection based on rotated factor scores: A multiobjective optimization method for methyl orange treatment. *Journal of Cleaner Production*, Elsevier, v. 143, p. 413–439, 2 2017. ISSN 0959-6526. Citado 3 vezes nas páginas 9, 10 e 15.
- OSAMA, M.; WALVEKAR, R.; KHALID, M.; RASHEED, A. K.; WONG, W. Y.; GUPTA, T. C. S. M. Physical properties optimization of POME-groundnut-naphthenic based graphene nanolubricant using response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 193, p. 277–289, 8 2018. ISSN 0959-6526. Citado na página 74.
- PAIVA, A. P.; PAIVA, E. J.; R., F. J.; BALESTRASSI, P. P.; COSTA, S. C. A multivariate mean square error optimization of AISI 52100 hardened steel turning. *International Journal of Advanced Manufacturing Technology*, v. 43, p. 631–643, 2009. Citado 2 vezes nas páginas 8 e 20.
- PENG, S.; LI, T.; LI, M.; GUO, Y.; SHI, J.; TAN, G. Z.; ZHANG, H. An integrated decision model of restoring technologies selection for engine remanufacturing practice. *Journal of Cleaner Production*, Elsevier, v. 206, p. 598–610, 1 2019. ISSN 0959-6526. Citado na página 1.
- PHILLIPS, A. L. *Welding Handbook: Special Welding Processes and Cutting*. [S.l.]: London: American Welding Society, 1965. Citado 2 vezes nas páginas 23 e 24.
- POULADI, B.; FANAELI, M. A.; BAGHMISHEH, G. Optimization of oxidative desulfurization of gas condensate via response surface methodology approach. *Journal of Cleaner Production*, Elsevier, v. 209, p. 965–977, 2 2019. ISSN 0959-6526. Citado na página 75.
- RANIC, M.; NIKOLIC, M.; PAVLOVIC, M.; BUNTIC, A.; SILER-MARINKOVIC, S.; DIMITRIJEVIC-BRANKOVIC, S. Optimization of microwave-assisted extraction of natural antioxidants from spent espresso coffee grounds by response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 80, p. 69–79, 10 2014. ISSN 0959-6526. Citado na página 73.
- REN, C.; LI, Z.; ZHANG, H. Integrated multi-objective stochastic fuzzy programming and AHP method for agricultural water and land optimization allocation under multiple uncertainties. *Journal of Cleaner Production*, Elsevier, v. 210, p. 12–24, 2 2019. ISSN 0959-6526. Citado na página 11.
- RUSINKO, C. A. Green manufacturing: An evaluation of environmentally sustainable manufacturing practices and their impact on competitive outcomes. *IEEE Transactions on Engineering Management*, v. 54, n. 3, p. 445–454, 2007. ISSN 00189391. Citado na página 1.
- SARIKAYA, M.; GÜLLÜ, A. Taguchi design and response surface methodology based analysis of machining parameters in CNC turning under MQL. *Journal of Cleaner Production*, Elsevier, v. 65, p. 604–616, 2 2014. ISSN 0959-6526. Citado na página 73.

- SHABANI, N.; SOWLATI, T. A hybrid multi-stage stochastic programming-robust optimization model for maximizing the supply chain of a forest-based biomass power plant considering uncertainties. *Journal of Cleaner Production*, Elsevier, v. 112, p. 3285–3293, 1 2016. ISSN 0959-6526. Citado na página 11.
- SHAKOURLUO, A. A multi-objective stochastic goal programming model for more efficient remanufacturing process. *International Journal of Advanced Manufacturing Technology*, v. 91, p. 1007–1021, 2017. ISSN 14333015. Citado na página 2.
- ŞİMŞEK, B.; UYGUNOĞLU, T.; KORUCU, H.; KOCAKERİM, M. M. Analysis of the effects of dioctyl terephthalate obtained from polyethylene terephthalate wastes on concrete mortar: A response surface methodology based desirability function approach application. *Journal of Cleaner Production*, Elsevier, v. 170, p. 437–445, 1 2018. ISSN 0959-6526. Citado na página 74.
- SULAIMAN, N. S.; HASHIM, R.; AMINI, M. H. M.; DANISH, M.; SULAIMAN, O. Optimization of activated carbon preparation from cassava stem using response surface methodology on surface area and yield. *Journal of Cleaner Production*, Elsevier, v. 198, p. 1422–1430, 10 2018. ISSN 0959-6526. Citado na página 74.
- TYAGI, M.; RANA, A.; KUMARI, S.; JAGADEVAN, S. Adsorptive removal of cyanide from coke oven wastewater onto zero-valent iron: Optimization through response surface methodology, isotherm and kinetic studies. *Journal of Cleaner Production*, Elsevier, v. 178, p. 398–407, 3 2018. ISSN 0959-6526. Citado na página 74.
- UDDIN, M. K.; BAIG, U. Synthesis of Co₃O₄ nanoparticles and their performance towards methyl orange dye removal: Characterisation, adsorption and response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 211, p. 1141–1153, 2 2019. ISSN 0959-6526. Citado na página 75.
- VENKATAKRISHNAN, B.; SANDHYA, K.; ABINANDAN, S.; VEDARAMAN, N.; VELAPPAN, K. Fixation of carbon dioxide and optimization of liming process waste produced in tanneries using response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 209, p. 855–861, 2 2019. ISSN 0959-6526. Citado na página 75.
- WAINER, E.; BRANDI, S. D.; MELLO, F. D. H. d. *Soldagem: processos de metalurgia*. São Paulo: Blucher, 2013. 494 p. ISBN 9788521202387. Citado 3 vezes nas páginas 1, 23 e 24.
- WANG, C.; WANG, H.; LIU, Y.; HUANG, L. Optimization of surface treatment for flotation separation of polyvinyl chloride and polyethylene terephthalate waste plastics using response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 139, p. 866–872, 12 2016. ISSN 0959-6526. Citado na página 73.
- WU, F. C. Optimization of correlated multiple quality characteristics using desirability function. *Quality Engineering* WU, F. C. *Optimization of correlated multiple quality characteristics using desirability function*. *Quality Engineering*, 2005., v. 17, n. 1, p. 119–126, 2005. ISSN 08982112. Citado na página 10.
- YANG, Z.; LIU, P.; CHENG, L.; WANG, H.; MING, B.; GONG, W. Deriving operating rules for a large-scale hydro-photovoltaic power system using implicit stochastic optimization. *Journal of Cleaner Production*, Elsevier, v. 195, p. 562–572, 9 2018. ISSN 0959-6526. Citado na página 11.

YUAN, J.; WANG, K.; YU, T.; FANG, M. Reliable multi-objective optimization of high-speed WEDM process based on Gaussian process regression. *International Journal of Machine Tools and Manufacture*, Pergamon, v. 48, n. 1, p. 47–60, 1 2008. ISSN 0890-6955. Citado na página 10.

ZBAIR, M.; AHSAINI, H. A.; ANFAR, Z. Porous carbon by microwave assisted pyrolysis: An effective and low-cost adsorbent for sulfamethoxazole adsorption and optimization using response surface methodology. *Journal of Cleaner Production*, v. 202, p. 571–581, 2018. ISSN 09596526. Citado na página 75.

ZHAN, L.; XIA, F.; YE, Q.; XIANG, X.; XIE, B. Novel recycle technology for recovering rare metals (Ga, In) from waste light-emitting diodes. *Journal of Hazardous Materials*, Elsevier, v. 299, p. 388–394, 12 2015. ISSN 0304-3894. Citado na página 1.

ZHANG, P.; LIU, Z. On sustainable manufacturing of Cr-Ni alloy coatings by laser cladding and high-efficiency turning process chain and consequent corrosion resistance. *Journal of Cleaner Production*, Elsevier, v. 161, p. 676–687, 9 2017. ISSN 0959-6526. Citado na página 1.

APÊNDICE A – ARTIGOS INVESTIGADOS NO PERIÓDICO
JOURNAL OF CLEANER PRODUCTION

Autores	Artigo
Ranic <i>et al.</i> (2014)	Optimization of microwave-assisted extraction of natural antioxidants from spent espresso coffee grounds by response surface methodology
Sarıkaya e Güllü (2014)	Taguchi design and response surface methodology based analysis of machining parameters in CNC turning under MQL
Wang <i>et al.</i> (2016)	Optimization of surface treatment for flotation separation of polyvinyl chloride and polyethylene terephthalate waste plastics using response surface methodology
Charoen <i>et al.</i> (2017)	Application of response surface methodology to optimize direct alcohol fuel cell power density for greener energy production
Kakoi <i>et al.</i> (2017)	Optimization of Maerua Decumbent bio-coagulant in paint industry wastewater treatment with response surface methodology
Markandeya <i>et al.</i> (2017)	Statistical optimization of process parameters for removal of dyes from wastewater on chitosan cenospheres nanocomposite using response surface methodology
Mohammed <i>et al.</i> (2017a)	Recovery of clean energy precursors from Bambara groundnut waste via pyrolysis: Kinetics, products distribution and optimisation using response surface methodology
Mohammed <i>et al.</i> (2017b)	Valorization of Napier grass via intermediate pyrolysis: Optimization using response surface methodology and pyrolysis products characterization
Morero <i>et al.</i> (2017)	Evaluation of biogas upgrading technologies using a response surface methodology for process simulation

Continuação da tabela A.1

Autores	Artigo
<i>Baghel et al. (2018)</i>	Optimization of process variables by the application of response surface methodology for naphthol blue black dye removal in vacuum membrane distillation
<i>Bahrami et al. (2018)</i>	Degradation of trichloroethylene by sonophotolytic-activated persulfate processes: Optimization using response surface methodology
<i>Cao et al. (2018)</i>	Optimizing xylose production from pinewood sawdust through dilute-phosphoric-acid hydrolysis by response surface methodology
<i>Choudhury et al. (2018)</i>	Preparation of ceramic ultrafiltration membrane using green synthesized CuO nanoparticles for chromium (VI) removal and optimization by response surface methodology
<i>Gopal et al. (2018)</i>	Prediction of emissions and performance of a diesel engine fueled with n-octanol/diesel blends using response surface methodology
<i>Mohammed et al. (2018)</i>	Rubbercrete mixture optimization using response surface methodology
<i>Nasiri e Arsalani (2018)</i>	Synthesis and application of 3D graphene nanocomposite for the removal of cationic dyes from aqueous solutions: Response surface methodology design
<i>Osama et al. (2018)</i>	Physical properties optimization of POME-groundnut-naphthenic based graphene nanolubricant using response surface methodology
<i>Şimşek et al. (2018)</i>	Analysis of the effects of dioctyl terephthalate obtained from polyethylene terephthalate wastes on concrete mortar: A response surface methodology based desirability function approach application
<i>Sulaiman et al. (2018)</i>	Optimization of activated carbon preparation from cassava stem using response surface methodology on surface area and yield
<i>Tyagi et al. (2018)</i>	Adsorptive removal of cyanide from coke oven wastewater onto zero-valent iron: Optimization through response surface methodology, isotherm and kinetic studies

Continuação da tabela A.1

Autores	Artigo
<i>Zbair et al. (2018)</i>	Porous carbon by microwave assisted pyrolysis: An effective and low-cost adsorbent for sulfamethoxazole adsorption and optimization using response surface methodology
<i>Gasemloo et al. (2019)</i>	Response surface methodology (RSM) modeling to improve removal of Cr (VI) ions from tannery wastewater using sulfated carboxymethyl cellulose nanofilter
<i>Khalid et al. (2019)</i>	Analysis of the elemental composition and uptake mechanism of <i>Chlorella sorokiniana</i> for nutrient removal in agricultural wastewater under optimized response surface methodology (RSM) conditions
<i>Pouladi et al. (2019)</i>	Optimization of oxidative desulfurization of gas condensate via response surface methodology approach
<i>Uddin e Baig (2019)</i>	Synthesis of Co ₃ O ₄ nanoparticles and their performance towards methyl orange dye removal: Characterisation, adsorption and response surface methodology
<i>Venkatakrishnan et al. (2019)</i>	Fixation of carbon dioxide and optimization of liming process waste produced in tanneries using response surface methodology

APÊNDICE B – ARRANJO EXPERIMENTAL E RESPOSTAS COLETADAS E CALCULADAS

#	Parâmetros				Variáveis de resposta									
	Va	T	Vs	N	CI	P	AP	D	L	R	IC	AR	FP	FR
1	7,0	27,0	30,0	15,0	0,929	1,375	7,615	0,264	11,187	2,628	0,235	21,179	8,137	4,257
2	10,0	27,0	30,0	15,0	1,156	1,661	9,941	0,258	12,991	3,116	0,240	28,508	7,822	4,170
3	7,0	32,0	30,0	15,0	1,158	1,689	9,939	0,315	12,698	2,496	0,197	21,702	7,518	5,087
4	10,0	32,0	30,0	15,0	1,491	1,977	14,412	0,313	15,047	2,778	0,185	31,718	7,612	5,416
5	7,0	27,0	50,0	15,0	0,561	1,647	7,428	0,362	9,215	2,165	0,235	13,059	5,595	4,256
6	10,0	27,0	50,0	15,0	0,664	1,936	9,419	0,337	9,961	2,667	0,268	18,568	5,145	3,735
7	7,0	32,0	50,0	15,0	0,675	1,538	7,838	0,371	9,748	2,065	0,212	13,297	6,339	4,721
8	10,0	32,0	50,0	15,0	0,837	2,181	12,997	0,411	11,511	2,425	0,211	18,593	5,279	4,747
9	7,0	27,0	30,0	25,0	0,772	1,250	6,155	0,225	10,325	2,870	0,278	21,362	8,257	3,598
10	10,0	27,0	30,0	25,0	0,967	0,999	6,783	0,183	11,428	3,594	0,315	30,151	11,436	3,180
11	7,0	32,0	30,0	25,0	0,973	1,321	6,948	0,237	11,267	2,848	0,253	22,388	8,526	3,956
12	10,0	32,0	30,0	25,0	1,146	1,100	8,715	0,220	13,337	3,179	0,238	31,205	12,119	4,195
13	7,0	27,0	50,0	25,0	0,463	1,111	4,597	0,250	7,992	2,554	0,320	13,813	7,190	3,129
14	10,0	27,0	50,0	25,0	0,574	1,225	5,370	0,233	8,625	2,797	0,324	17,541	7,038	3,084
15	7,0	32,0	50,0	25,0	0,580	1,370	5,331	0,288	8,476	2,363	0,279	13,221	6,188	3,587
16	10,0	32,0	50,0	25,0	0,703	1,637	8,032	0,302	10,840	2,598	0,240	18,577	6,622	4,172
17	5,5	29,5	40,0	20,0	0,624	1,382	5,874	0,316	9,067	2,207	0,243	12,786	6,560	4,109
18	11,5	29,5	40,0	20,0	0,942	2,139	11,501	0,309	12,212	3,056	0,250	25,860	5,709	3,997
19	8,5	24,5	40,0	20,0	0,643	1,205	6,055	0,228	9,424	3,026	0,321	20,615	7,824	3,114
20	8,5	34,5	40,0	20,0	0,973	1,864	10,271	0,356	11,690	2,458	0,210	18,575	6,270	4,756
21	8,5	29,5	20,0	20,0	1,655	0,948	8,558	0,186	14,934	3,454	0,231	37,638	15,760	4,324
22	8,5	29,5	60,0	20,0	0,507	1,433	6,670	0,358	8,482	2,250	0,265	11,955	5,920	3,770
23	8,5	29,5	40,0	10,0	0,987	2,178	13,299	0,404	11,733	2,610	0,223	19,547	5,386	4,495
24	8,5	29,5	40,0	30,0	0,673	1,283	5,819	0,242	9,221	2,891	0,314	18,216	7,190	3,189
25	8,5	29,5	40,0	20,0	0,797	1,708	8,399	0,311	10,823	2,596	0,240	18,673	6,336	4,169
26	8,5	29,5	40,0	20,0	0,800	1,723	8,735	0,317	10,926	2,592	0,237	18,921	6,341	4,215
27	8,5	29,5	40,0	20,0	0,792	1,623	8,482	0,309	10,744	2,655	0,247	18,970	6,620	4,047
28	8,5	29,5	40,0	20,0	0,779	1,801	8,774	0,328	10,612	2,495	0,235	17,951	5,891	4,253
29	8,5	29,5	40,0	20,0	0,774	1,485	7,876	0,300	10,636	2,621	0,246	18,466	7,160	4,058
30	8,5	29,5	40,0	20,0	0,761	1,490	8,204	0,311	10,586	2,612	0,247	18,208	7,106	4,053
31	8,5	29,5	40,0	20,0	0,770	1,504	8,014	0,310	10,571	2,557	0,242	17,862	7,028	4,134

APÊNDICE C – ANÁLISE DE VARIÂNCIA (ANOVA) PARA OS MODELOS DAS RESPOSTAS COLETADAS E CALCULADAS

Tabela C.1 – Análise de variância para o calor imposto (CI)

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	10	1,192	0,119	46,01	0,000
Linear	4	1,149	0,287	110,86	0,000
<i>V_a</i>	1	0,127	0,127	48,96	0,000
<i>T</i>	1	0,137	0,137	52,75	0,000
<i>V_s</i>	1	0,781	0,781	301,27	0,000
<i>N</i>	1	0,105	0,105	40,46	0,000
Interação com 2 fatores	6	0,043	0,007	2,77	0,063
<i>V_a*T</i>	1	0,002	0,002	0,58	0,462
<i>V_a*V_s</i>	1	0,011	0,011	4,43	0,057
<i>V_a*N</i>	1	0,003	0,003	1,21	0,292
<i>T*V_s</i>	1	0,011	0,011	4,07	0,067
<i>T*N</i>	1	0,003	0,003	1,25	0,285
<i>V_s*N</i>	1	0,013	0,013	5,07	0,044
Erro	12	0,031	0,003		
Curvatura	1	0,025	0,025	41,54	0,000
Falta de ajuste	5	0,005	0,001	4,72	0,043
Erro Puro	6	0,001	0,000		
Total	22	1,223			

Tabela C.2 – Análise de variância para a penetração (P)

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	10	1,652	0,165	7,51	0,001
Linear	4	1,382	0,345	15,72	0,000
<i>Va</i>	1	0,125	0,125	5,69	0,034
<i>T</i>	1	0,162	0,162	7,35	0,019
<i>Vs</i>	1	0,101	0,101	4,60	0,053
<i>N</i>	1	0,994	0,994	45,22	0,000
Interação com 2 fatores	6	0,270	0,045	2,05	0,137
<i>Va*T</i>	1	0,018	0,018	0,83	0,381
<i>Va*Vs</i>	1	0,092	0,092	4,17	0,064
<i>Va*N</i>	1	0,160	0,160	7,25	0,020
<i>T*Vs</i>	1	0,000	0,000	0,00	0,996
<i>T*N</i>	1	0,000	0,000	0,02	0,900
<i>Vs*N</i>	1	0,000	0,000	0,01	0,906
Erro	12	0,264	0,022		
Curvatura	1	0,068	0,068	3,82	0,077
Falta de ajuste	5	0,096	0,019	1,15	0,426
Erro Puro	6	0,100	0,017		
Total	22	1,916			

Tabela C.3 – Análise de variância para a área de penetração (AP)

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	10	106,164	10,616	60,44	0,000
Linear	4	95,855	23,964	136,42	0,000
<i>Va</i>	1	24,547	24,547	139,74	0,503
<i>T</i>	1	17,860	17,860	101,67	0,001
<i>Vs</i>	1	5,634	5,634	32,07	0,000
<i>N</i>	1	47,814	47,814	272,20	0,000
Interação com 2 fatores	6	10,309	1,718	9,78	0,000
<i>Va*T</i>	1	4,392	4,392	25,00	0,000
<i>Va*Vs</i>	1	0,127	0,127	0,72	0,411
<i>Va*N</i>	1	4,709	4,709	23,22	0,000
<i>T*Vs</i>	1	0,285	0,285	1,62	0,227
<i>T*N</i>	1	1,358	1,358	7,73	0,017
<i>Vs*N</i>	1	0,068	0,068	0,39	0,545
Erro	12	2,108	0,176		
Curvatura	1	0,089	0,089	0,48	0,502
Falta de ajuste	5	1,313	0,263	2,23	0,179
Erro Puro	6	0,706	0,118		
Total	22	108,272			

Tabela C.4 – Análise de variância para a diluição (D)

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	10	0,059	0,059	14,42	0,000
Linear	4	0,056	0,014	34,38	0,000
<i>Va</i>	1	0,000	0,000	0,48	0,503
<i>T</i>	1	0,007	0,007	18,16	0,001
<i>Vs</i>	1	0,018	0,018	44,69	0,000
<i>N</i>	1	0,030	0,030	74,19	0,000
Interação com 2 fatores	6	0,003	0,000	1,11	0,410
<i>Va</i> * <i>T</i>	1	0,001	0,001	2,33	0,153
<i>Va</i> * <i>Vs</i>	1	0,000	0,000	0,97	0,344
<i>Va</i> * <i>N</i>	1	0,001	0,001	0,69	0,423
<i>T</i> * <i>Vs</i>	1	0,000	0,000	0,20	0,662
<i>T</i> * <i>N</i>	1	0,000	0,000	0,16	0,700
<i>Vs</i> * <i>N</i>	1	0,001	0,001	2,34	0,152
Erro	12	0,005	0,000		
Curvatura	1	0,003	0,003	27,03	0,000
Falta de ajuste	5	0,001	0,000	2,55	0,143
Erro Puro	6	0,000	0,000		
Total	22	0,063			

Tabela C.5 – Análise de variância para a largura (L)

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	10	56,080	5,608	88,18	0,000
Linear	4	54,484	13,621	214,17	0,000
<i>Va</i>	1	10,291	10,291	161,81	0,000
<i>T</i>	1	7,843	7,843	123,31	0,000
<i>Vs</i>	1	30,012	30,012	471,89	0,000
<i>N</i>	1	6,339	6,339	99,67	0,000
Interação com 2 fatores	6	1,595	0,266	4,18	0,017
<i>Va</i> * <i>T</i>	1	1,134	1,134	17,83	0,001
<i>Va</i> * <i>Vs</i>	1	0,207	0,207	3,25	0,097
<i>Va</i> * <i>N</i>	1	0,015	0,015	0,24	0,634
<i>T</i> * <i>Vs</i>	1	0,167	0,167	2,63	0,131
<i>T</i> * <i>N</i>	1	0,000	0,000	0,01	0,921
<i>Vs</i> * <i>N</i>	1	0,071	0,071	1,11	0,312
Erro	12	0,763	0,063		
Curvatura	1	0,227	0,227	4,65	0,054
Falta de ajuste	5	0,427	0,085	4,68	0,044
Erro Puro	6	0,110	0,018		
Total	22	56,842			

Tabela C.6 – Análise de variância para o reforço (R)

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	10	2,178	0,218	22,00	0,000
Linear	4	2,111	0,528	53,31	0,000
<i>Va</i>	1	0,626	0,626	63,21	0,000
<i>T</i>	1	0,168	0,168	16,93	0,001
<i>Vs</i>	1	0,939	0,939	94,81	0,000
<i>N</i>	1	0,380	0,380	38,31	0,000
Interação com 2 fatores	6	0,067	0,011	1,12	0,405
<i>Va*T</i>	1	0,035	0,035	3,52	0,085
<i>Va*Vs</i>	1	0,015	0,015	1,49	0,246
<i>Va*N</i>	1	0,000	0,000	0,06	0,809
<i>T*Vs</i>	1	0,002	0,002	0,19	0,670
<i>T*N</i>	1	0,000	0,000	0,00	0,969
<i>Vs*N</i>	1	0,015	0,015	1,47	0,249
Erro	12	0,119	0,010		
Curvatura	1	0,055	0,055	9,61	0,010
Falta de ajuste	5	0,048	0,010	3,63	0,074
Erro Puro	6	0,016	0,003		
Total	22	2,297			

Tabela C.7 – Análise de variância para o índice de convexidade (IC)

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	10	0,027	0,027	22,57	0,000
Linear	4	0,025	0,006	52,98	0,000
<i>Va</i>	1	0,000	0,000	0,08	0,782
<i>T</i>	1	0,010	0,010	85,27	0,000
<i>Vs</i>	1	0,001	0,001	11,64	0,005
<i>N</i>	1	0,014	0,014	114,92	0,000
Interação com 2 fatores	6	0,002	0,000	2,29	0,104
<i>Va*T</i>	1	0,001	0,001	11,25	0,006
<i>Va*Vs</i>	1	0,000	0,000	0,17	0,686
<i>Va*N</i>	1	0,000	0,000	0,72	0,412
<i>T*Vs</i>	1	0,000	0,000	0,06	0,808
<i>T*N</i>	1	0,000	0,000	1,49	0,245
<i>Vs*N</i>	1	0,000	0,000	0,05	0,829
Erro	12	0,001	0,000		
Curvatura	1	0,000	0,000	5,19	0,044
Falta de ajuste	5	0,001	0,000	6,88	0,018
Erro Puro	6	0,000	0,000		
Total	22	0,028			

Tabela C.8 – Análise de variância para a área de reforço (AR)

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	10	623,891	62,389	22,44	0,000
Linear	4	606,401	151,600	54,53	0,000
<i>Va</i>	1	187,973	187,973	67,62	0,000
<i>T</i>	1	2,657	2,657	0,96	0,348
<i>Vs</i>	1	415,604	415,604	149,50	0,000
<i>N</i>	1	0,167	0,167	0,06	0,810
Interação com 2 fatores	6	17,489	2,915	1,05	0,442
<i>Va*T</i>	1	1,066	1,066	0,38	0,547
<i>Va*Vs</i>	1	14,173	14,173	5,10	0,043
<i>Va*N</i>	1	0,133	0,133	0,05	0,830
<i>T*Vs</i>	1	1,631	1,631	0,59	0,459
<i>T*N</i>	1	0,136	0,136	0,05	0,829
<i>Vs*N</i>	1	0,349	0,349	0,13	0,729
Erro	12	33,359	2,780		
Curvatura	1	30,297	30,297	108,82	0,000
Falta de ajuste	5	1,868	0,374	1,88	0,232
Erro Puro	6	1,194	0,199		
Total	22	657,250			

Tabela C.9 – Análise de variância para o fator de penetração (FP)

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	10	54,236	5,423	7,77	0,001
Linear	4	44,242	11,060	15,85	0,000
<i>Va</i>	1	1,770	1,770	2,54	0,137
<i>T</i>	1	0,011	0,011	0,02	0,902
<i>Vs</i>	1	30,333	30,333	43,45	0,000
<i>N</i>	1	12,128	12,128	17,37	0,001
Interação com 2 fatores	6	9,994	1,666	2,39	0,094
<i>Va*T</i>	1	0,040	0,040	0,06	0,815
<i>Va*Vs</i>	1	3,782	3,782	5,42	0,038
<i>Va*N</i>	1	4,824	4,824	6,91	0,022
<i>T*Vs</i>	1	0,028	0,028	0,04	0,846
<i>T*N</i>	1	0,017	0,017	0,02	0,880
<i>Vs*N</i>	1	1,304	1,304	1,87	0,917
Erro	12	8,377	0,698		
Curvatura	1	4,041	4,041	10,26	0,008
Falta de ajuste	5	2,952	0,591	2,56	0,141
Erro Puro	6	1,382	0,230		
Total	22	62,619			

Tabela C.10 – Análise de variância para o fator de reforço (FR)

Fonte de variação	GL	SQA	QMA	<i>F-value</i>	<i>p-value</i>
Modelo	10	6,886	0,689	35,41	0,000
Linear	4	6,493	1,623	83,48	0,000
<i>V_a</i>	1	0,001	0,001	0,04	0,850
<i>T</i>	1	2,619	2,619	134,68	0,000
<i>V_s</i>	1	0,368	0,368	18,93	0,001
<i>N</i>	1	3,505	3,505	180,27	0,000
Interação com 2 fatores	6	0,392	0,065	3,37	0,035
<i>V_a*T</i>	1	0,316	0,316	16,27	0,002
<i>V_a*V_s</i>	1	0,000	0,000	0,00	0,976
<i>V_a*N</i>	1	0,024	0,024	1,21	0,293
<i>T*V_s</i>	1	0,011	0,011	0,59	0,458
<i>T*N</i>	1	0,025	0,025	1,29	0,279
<i>V_s*N</i>	1	0,016	0,016	0,85	0,375
Erro	12	0,233	0,019		
Curvatura	1	0,013	0,013	0,66	0,434
Falta de ajuste	5	0,178	0,036	5,11	0,036
Erro Puro	6	0,042	0,007		
Total	22	7,120			

APÊNDICE D – VALORES DA DISTÂNCIA DE MAHALANOBIS
E ENTROPIA PARA OS 70 SUBPROBLEMAS
DO NBI

Combinação	M	E	E/M
1	7,45023	0,00003	0,000004
2	4,41124	0,32510	0,073698
3	3,83522	0,32510	0,084767
4	3,00726	0,50042	0,166403
5	2,81215	0,63903	0,227241
6	2,87955	0,50042	0,173783
7	2,48756	0,61088	0,245573
8	1,83120	0,80182	0,437865
9	2,01459	0,80182	0,398007
10	2,63457	0,61088	0,231870
11	2,49882	0,67303	0,269338
12	1,73392	0,89795	0,517872
13	1,38622	0,95027	0,685514
14	1,84642	0,89795	0,486317
15	2,73344	0,67303	0,246220
16	2,55194	0,69316	0,271621
17	1,88610	0,94335	0,500158
18	1,45213	1,02965	0,709066
19	1,35347	1,02965	0,760750
20	1,83805	0,94335	0,513235
21	2,81392	0,69316	0,246333
22	2,59273	0,67303	0,259582
23	1,93409	0,94335	0,487748
24	1,62744	1,05492	0,648208
25	1,36973	1,08890	0,794977
26	1,33695	1,05492	0,789051
27	1,74201	0,94335	0,541528
28	2,78886	0,67303	0,241327
29	4,30049	0,61088	0,142049
30	1,97747	0,89795	0,454088
31	1,62056	1,02965	0,635369

Continuação da tabela D.1

Combinação	M	E	E/M
32	1,48169	1,08890	0,734903
33	1,31635	1,08890	0,827210
34	1,25393	1,02965	0,821144
35	1,72345	0,89795	0,521018
36	2,84081	0,61088	0,215037
37	3,98026	0,50042	0,125725
38	5,65893	0,80182	0,141691
39	1,77592	0,95027	0,535088
40	1,58637	1,02965	0,649061
41	1,51086	1,05492	0,698223
42	1,39970	1,02965	0,735624
43	1,34927	0,95027	0,704284
44	1,95598	0,80182	0,409934
45	3,28696	0,50042	0,152243
46	4,27121	0,32510	0,076114
47	3,92229	0,63903	0,162924
48	5,47343	0,80182	0,146493
49	2,03435	0,89795	0,441392
50	1,89676	0,94335	0,497347
51	1,86892	0,94335	0,504756
52	1,86545	0,89795	0,481357
53	1,94635	0,80182	0,411961
54	2,92864	0,63903	0,218202
55	4,20990	0,32510	0,077223
56	8,11407	0,00003	0,000004
57	3,77550	0,32510	0,086108
58	3,17174	0,50042	0,157774
59	3,73027	0,61088	0,163763
60	2,65731	0,67303	0,253274
61	2,56282	0,69316	0,270468
62	2,62398	0,67303	0,256491
63	2,75647	0,61088	0,221616
64	3,03813	0,50042	0,164712
65	4,43527	0,32510	0,073299
66	7,91703	0,00003	0,000004
67	1,38431	1,09861	0,793617
68	1,63832	0,86756	0,529545

Continuação da tabela D.1

Combinação	M	E	E/M
69	4,95725	0,86756	0,175009
70	1,57294	0,86756	0,551557

APÊNDICE E – SOLUÇÕES ÓTIMAS PARA OS FATORES F1, F2 E F3

Combinação	w_1	w_2	w_3	F1	F2	F3
1	0,999998	0,000001	0,000001	49,259	0,766	16,982
2	0,899998	0,100001	0,000001	52,376	0,690	19,290
3	0,899998	0,000001	0,100001	49,914	0,754	16,501
4	0,799999	0,200000	0,000001	55,494	0,613	21,599
5	0,799999	0,100001	0,100001	53,032	0,678	18,810
6	0,799999	0,000001	0,200000	50,570	0,742	16,021
7	0,699999	0,300000	0,000001	58,611	0,536	23,907
8	0,699999	0,200000	0,100001	56,149	0,601	21,119
9	0,699999	0,100001	0,200000	53,687	0,666	18,330
10	0,699999	0,000001	0,300000	51,225	0,730	15,541
11	0,599999	0,400000	0,000001	61,729	0,460	26,216
12	0,599999	0,300000	0,100001	59,267	0,524	23,427
13	0,599999	0,200000	0,200000	56,805	0,589	20,638
14	0,599999	0,100001	0,300000	54,342	0,654	17,850
15	0,599999	0,000001	0,400000	51,880	0,718	15,061
16	0,500000	0,500000	0,000001	64,846	0,383	28,524
17	0,500000	0,400000	0,100001	62,384	0,448	25,736
18	0,500000	0,300000	0,200000	59,922	0,512	22,947
19	0,500000	0,200000	0,300000	57,460	0,577	20,158
20	0,500000	0,100001	0,400000	54,998	0,642	17,370
21	0,500000	0,000001	0,500000	52,536	0,706	14,581
22	0,400000	0,599999	0,000001	67,964	0,307	30,833
23	0,400000	0,500000	0,100001	65,502	0,371	28,044
24	0,400000	0,400000	0,200000	63,040	0,436	25,256
25	0,400000	0,300000	0,300000	60,577	0,500	22,467
26	0,400000	0,200000	0,400000	58,115	0,565	19,678
27	0,400000	0,100001	0,500000	55,653	0,629	16,889
28	0,400000	0,000001	0,599999	53,191	0,694	14,101
29	0,300000	0,699999	0,000001	71,081	0,230	33,142
30	0,300000	0,599999	0,100001	68,619	0,294	30,353
31	0,300000	0,500000	0,200000	66,157	0,359	27,564
32	0,300000	0,400000	0,300000	63,695	0,424	24,775
33	0,300000	0,300000	0,400000	61,233	0,488	21,987

Continuação da tabela E.1

Combinação	w_1	w_2	w_3	F1	F2	F3
34	0,300000	0,200000	0,500000	58,771	0,553	19,198
35	0,300000	0,100001	0,599999	56,309	0,617	16,409
36	0,300000	0,000001	0,699999	53,847	0,682	13,621
37	0,200000	0,799999	0,000001	74,199	0,153	35,450
38	0,200000	0,699999	0,100001	71,737	0,218	32,661
39	0,200000	0,599999	0,200000	69,275	0,282	29,873
40	0,200000	0,500000	0,300000	66,813	0,347	27,084
41	0,200000	0,400000	0,400000	64,350	0,412	24,295
42	0,200000	0,300000	0,500000	61,888	0,476	21,507
43	0,200000	0,200000	0,599999	59,426	0,541	18,718
44	0,200000	0,100001	0,699999	56,964	0,605	15,929
45	0,200000	0,000001	0,799999	54,502	0,670	13,140
46	0,100001	0,899998	0,000001	77,316	0,077	37,759
47	0,100001	0,799999	0,100001	74,854	0,141	34,970
48	0,100001	0,699999	0,200000	72,392	0,206	32,181
49	0,100001	0,599999	0,300000	69,930	0,270	29,393
50	0,100001	0,500000	0,400000	67,468	0,335	26,604
51	0,100001	0,400000	0,500000	65,006	0,400	23,815
52	0,100001	0,300000	0,599999	62,544	0,464	21,026
53	0,100001	0,200000	0,699999	60,082	0,529	18,238
54	0,100001	0,100001	0,799999	57,620	0,593	15,449
55	0,100001	0,000001	0,899998	55,157	0,658	12,660
56	0,000001	0,999998	0,000001	80,434	0,000	40,067
57	0,000001	0,899998	0,100001	77,972	0,065	37,279
58	0,000001	0,799999	0,200000	75,510	0,129	34,490
59	0,000001	0,699999	0,300000	73,048	0,194	31,701
60	0,000001	0,599999	0,400000	70,585	0,258	28,912
61	0,000001	0,500000	0,500000	68,123	0,323	26,124
62	0,000001	0,400000	0,599999	65,661	0,388	23,335
63	0,000001	0,300000	0,699999	63,199	0,452	20,546
64	0,000001	0,200000	0,799999	60,737	0,517	17,758
65	0,000001	0,100001	0,899998	58,275	0,581	14,969
66	0,000001	0,000001	0,999998	55,813	0,646	12,180
67	0,333333	0,333333	0,333333	61,835	0,471	23,076
68	0,666666	0,166667	0,166667	55,547	0,619	20,029
69	0,166667	0,666666	0,166667	71,134	0,235	31,572
70	0,166667	0,166667	0,666666	58,824	0,558	17,628