

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA DE PRODUÇÃO

**Avaliação da influência de parâmetros do Algoritmo
Genético na otimização de um problema
multiobjetivo utilizando-se Arranjo de Misturas**

Taynara Incerti de Paula

Itajubá, Julho de 2015

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA DE PRODUÇÃO

Taynara Incerti de Paula

**Avaliação da influência de parâmetros do Algoritmo
Genético na otimização de um problema
multiobjetivo utilizando-se Arranjo de Misturas**

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

Área de Concentração: Modelagem, Otimização e Controle

Orientador: Prof. Dr. Anderson Paulo de Paiva

Itajubá, Julho de 2015

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA DE PRODUÇÃO

Taynara Incerti de Paula

**Avaliação da influência de parâmetros do Algoritmo
Genético na otimização de um problema
multiobjetivo utilizando-se Arranjo de Misturas**

Dissertação aprovada por banca examinadora em 16 de julho de 2015, conferindo ao autor o título de **Mestre em Ciências em Engenharia de Produção**.

Banca Examinadora:

Prof. Dr. Rogério Santana Peruchi (UFG)

Prof. Dr. Paulo Henrique da Silva Campos (UNIFEI)

Prof. Dr. José Henrique de Freitas Gomes (UNIFEI)

Prof. Dr. Anderson Paulo de Paiva (Orientador)

Itajubá, Julho de 2015

Este trabalho é dedicado àqueles que não estarão presentes na comemoração de mais uma conquista, José Rogério de Paula e Belmira Incerti de Carvalho.

AGRADECIMENTOS

À minha família, pelo apoio em mais uma jornada. Agradeço especialmente à minha mãe, Palmira Maria de Carvalho, minha tia, Edna Maria de Carvalho e meu irmão, Diego Incerti de Paula.

Ao Prof. Dr. Anderson Paulo de Paiva, não só pela orientação e importantes contribuições a este trabalho e para a minha formação, mas também pela amizade, paciência e incentivo.

Aos professores do Instituto de Engenharia de Produção e Gestão da UNIFEI pela contribuição na minha formação, em especial aos professores Rogério Santana Peruchi, Pedro Paulo Balestrassi e José Henrique de Freitas Gomes pelas orientações e contribuições acadêmicas.

A todos os amigos da pós-graduação, em especial aos queridos amigos Patrícia, Elisa, Julio, David, Kívia, Camila, Harlenn e Diogo, por todo o apoio e por terem tornado este último ano muito mais divertido.

A todos os colegas do GEPE de Qualidade, em especial aos companheiros de trabalhos e estudos Danielle, Tarcísio, Gustavo, Paulinho, Pedro, Edielson e Adriano, por toda amizade e paciência.

A FAPEMIG, CAPES e CNPq, pelo apoio financeiro.

RESUMO

A complexidade dos problemas de otimização multiobjetivo tem levado diversos pesquisadores a desenvolver e aperfeiçoar métodos e algoritmos capazes de solucionar estes problemas de maneira adequada e eficiente. Alguns métodos aplicáveis à otimização multiobjetivo, como o Método do Critério Global, realizam a aglutinação das diferentes respostas através da atribuição de pesos, que priorizam as funções mais importantes. Uma maneira de solucionar um problema multiobjetivo é utilizar o Método do Critério Global para definir o problema e depois empregar o Algoritmo Genético como o algoritmo de busca da solução ótima para este problema. Um obstáculo geralmente encontrado na utilização do Algoritmo Genético é a necessidade de configuração de diferentes parâmetros responsáveis pelo funcionamento do algoritmo, devido à dificuldade em determinar os melhores valores para estes, já que não existe um consenso sobre quais seriam os valores mais adequados. Uma configuração inadequada desses parâmetros pode influenciar no desempenho do algoritmo, levando-o a localizar soluções insatisfatórias. Este trabalho aborda a complexidade de problemas de otimização multiobjetivo, em relação à determinação dos pesos aplicados às funções objetivo e a interação que pode haver entre estes pesos e os parâmetros do algoritmo utilizado na solução deste problema. Foi proposto um procedimento experimental que aplica o planejamento de experimentos, através de um arranjo de misturas combinado com variáveis de processo, na avaliação da influência dos parâmetros do algoritmo genético na solução do problema e da interação destes com os pesos atribuídos às funções objetivo, além de possibilitar a determinação dos pesos e parâmetros ótimos para a solução do problema em questão. O procedimento proposto foi aplicado na otimização do processo de soldagem com arame tubular empregada em uma operação de revestimento de chapas de aço carbono com aço inoxidável e os parâmetros do algoritmo genético avaliados foram o tamanho da população, a taxa de *crossover* e o tipo de mutação. O método provou ser eficiente, permitindo a detecção de interações significativas entre os parâmetros analisados e os pesos das funções objetivo, além de permitir a análise da influência dos parâmetros na solução do problema e de ter determinado os pesos e parâmetros ótimos para a utilização na otimização do processo de soldagem. Como resultados, destaca-se a grande influência do tipo de mutação no resultado da otimização e a grande interação entre os parâmetros taxa de *crossover* e tamanho da população.

Palavras-chave: Algoritmo Genético, Otimização Multiobjetivo, Planejamento de Experimentos, Método do Critério Global.

ABSTRACT

The complexity of multiobjective optimization problems has led many researchers to develop and refine methods and algorithms that can solve these problems in an appropriate and efficient way. Several multiobjective optimization techniques, such as the Global Criterion Method, perform the scalarization of different responses by multiplying weighting factors to each response, in order to prioritize the most important ones. An approach that can be used for solving a multiobjective problem is the use of the Global Criteria Method to define the optimization problem and then the application of the Genetic Algorithm as the search technique, in order to find the optimal solution. When dealing with Genetic Algorithms, there is an obstacle that is the tuning of several parameters that are responsible for the genetic operations. The difficulty in determining the best values for these parameters can be explained by the fact that there is no consensus in the literature of which would be the most appropriate values for setting them up. An inadequate setup of these parameters can have an effect on the performance of the algorithm, leading it to find unsatisfactory solutions. This study addresses the complexity of multiobjective optimization problems in relation to the determination of weights applied to objective functions and interactions which may exist between the weights and the parameters of the algorithm used to solve this problem. The experimental procedure proposed in this study applies the design of experiments methodology, through a mixture design with process variables, in order to assess the effect of the parameters in the solution of the problem and the interaction of these with the weights assigned to the objective functions, and also to enable the definition of the optimal weights and parameters for solving the optimization problem. The proposed procedure was applied to the optimization of flux cored arc welding used in a stainless steel cladding operation and the parameters that were analyzed were the population size, the crossover rate and the mutation type. The method proved to be efficient, allowing the detection of significant interactions between the algorithm parameters and the weights for the objective functions and also the analysis of parameters effect on the problem solution. The procedure also proved to be efficient for the definition of the optimal weights and parameters for the optimization of the welding process. As a result, it can be highlighted the great influence of the type of mutation on the result of the optimization and the interaction between the crossover rate and population size parameters.

Keywords: Genetic Algorithms, Multiobjective Optimization, Design of Experiments, Global Criterion Method.

LISTA DE FIGURAS

Figura 2.1 - Fronteira de Pareto para um problema biobjetivo	8
Figura 2.2 - Esquema geral de um modelo ou processo.....	12
Figura 2.3 - Arranjo fatorial completo para 3 fatores em 2 níveis	15
Figura 2.4 - Arranjo fatorial de meia fração para 3 fatores em 2 níveis.....	16
Figura 2.5 - Configuração de um arranjo de Misturas.....	17
Figura 2.6 - Configurações de arranjos de mistura <i>simplex lattice</i>	18
Figura 2.7 - Diagrama de um experimento envolvendo três variáveis (fatores) de processo e três componentes para a mistura.	21
Figura 2.8 - Técnicas de Busca.....	23
Figura 2.9 - Etapas do algoritmo genético.....	25
Figura 2.10 - Codificação de um cromossomo no Algoritmo Genético.....	26
Figura 2.11 - Exemplo de operação de <i>crossover</i>	28
Figura 2.12 - Exemplo de operação de mutação	29
Figura 2.13 - Cruzamento de um ponto.....	33
Figura 2.14 - Cruzamento de dois pontos.....	33
Figura 2.15 - Cruzamento difuso.....	34
Figura 3.1 - Resumo do procedimento experimental aplicado.....	40
Figura 3.2 - Perfil geométrico desejado do cordão de solda na soldagem de revestimento	43
Figura 3.3 - Geometria dos cordões após a preparação dos corpos de prova.....	43
Figura 3.4 - Distribuição dos experimentos no sistema triangular de coordenadas do arranjo <i>simplex lattice</i>	48
Figura 3.5 - Gráfico de cubo para definição de testes dos parâmetros do algoritmo genético.....	49
Figura 3.6 - Representação gráfica do arranjo de misturas definido.....	49
Figura 3.7 - Curva de poder de teste para determinação do número de réplicas do arranjo experimental.....	50
Figura 3.8 - Tela do <i>Matlab</i> [®] <i>Optimization Toolbox</i>	51
Figura 4.1 - Teste de normalidade dos resíduos para EPG com dez réplicas.....	53
Figura 4.2 - Transformação de Box-Cox.....	54
Figura 4.3 - Teste de normalidade para dados transformados de EPG com dez réplicas.....	54
Figura 4.4 - Dendograma da análise de <i>Cluster</i> para as réplicas do arranjo experimental	55
Figura 4.5 - Teste de normalidade dos resíduos para EPG com três réplicas.....	56

Figura 4.6 - Testes de normalidade para dados transformados de EPG com três réplicas	56
Figura 4.7 - Relação entre EPG e $EPG_{\text{Box-Cox}}$	57
Figura 4.8 - Gráficos de efeitos principais dos parâmetros do algoritmo genético	59
Figura 4.9 - Gráficos de resposta dos componentes	59
Figura 4.10 - Gráficos de contorno para a função $EPG_{\text{Box-Cox}}$ para $w_4 = 0$	60
Figura 4.11 - Gráficos de contorno para a função $EPG_{\text{Box-Cox}}$ para $w_1 = 0$	60
Figura 4.12 - Gráficos de superfície de resposta para a função $EPG_{\text{Box-Cox}}$	61
Figura 4.13 - Resultados da otimização da função $EPG_{\text{Box-Cox}}$	62
Figura 4.14 - Curva de poder de teste para determinação do número de réplicas do experimento de confirmação	63
Figura 4.15 - Teste <i>One-Sample T</i> e <i>Boxplot</i> para os dados dos experimentos de confirmação	64

LISTA DE QUADROS

Quadro 2.1 - Definições relacionadas à otimização de processos	6
Quadro 2.2 - Características e aplicações dos Arranjos experimentais	14
Quadro 2.3 - Exemplos de aplicações do Algoritmo Genético para solução de problemas multiobjetivo	24
Quadro 2.4 - Terminologia utilizada para os Algoritmos Genéticos	25
Quadro 2.5 - Tipos de seleção utilizados em diferentes estudos	31
Quadro 2.6 - Tipos de <i>crossover</i> utilizados em diferentes estudos	33

LISTA DE TABELAS

Tabela 2.1 - Tamanhos de população utilizados em diferentes estudos	30
Tabela 2.2 - Taxas de <i>crossover</i> utilizadas em diferentes estudos	34
Tabela 2.3 - Taxas de mutação utilizadas em diferentes estudos	36
Tabela 2.4 - Números de gerações utilizados em diferentes estudos	37
Tabela 3.1 - Parâmetros de soldagem e níveis de trabalho.....	42
Tabela 3.2 - Coeficientes estimados para os modelos quadráticos completos	44
Tabela 3.3 - Resultados das otimizações individuais	46
Tabela 3.4 - Parâmetros do Algoritmo Genético e níveis de teste	46
Tabela 3.5 - Fragmento do arranjo de misturas <i>simplex lattice</i> definido	47
Tabela 3.6 - Parâmetros fixos utilizados para o Algoritmo Genético	51
Tabela 4.1 - Análise de Variância para os modelos com dez réplicas.....	53
Tabela 4.2 - Análise de Variância para os modelos com três réplicas	56
Tabela 4.3 - Configurações do <i>desirability</i>	62
Tabela 4.4 - Resultados dos experimentos de confirmação.....	63
Tabela 4.5 - Resultados ótimos.....	65
Tabela 4.6 - Comparação entre os resultados ótimos e os ótimos individuais das respostas ...	65
Tabela 4.7 - Estrutura de correlação das respostas otimizadas.....	66

LISTA DE ABREVIATURAS E SIGLAS

ANOVA	<i>Analysis of Variance</i> – Análise de Variância
DOE	<i>Design of Experiments</i> – Planejamento de Experimentos
EPG	Erro Percentual Global
FFD	<i>Full Factorial Design</i> – Arranjo Fatorial Completo
GA	<i>Genetic Algorithm</i> – Algoritmo Genético
GRG	Gradiente Reduzido Generalizado
MCG	Método do Critério Global
MOP	<i>Multiobjective Optimization Problem</i> – Problema de Otimização Multiobjetivo
OLS	<i>Ordinary Least Squares</i> – Mínimos Quadrados Ordinários
WS	<i>Weighted Sums</i> – Somas Ponderadas

SUMÁRIO

1 INTRODUÇÃO.....	1
1.1 Justificativa.....	3
1.2 Objetivos.....	3
1.3 Contribuições.....	4
1.4 Delimitações da pesquisa.....	4
1.5 Metodologia.....	4
1.6 Estrutura da dissertação	5
2 FUNDAMENTAÇÃO TEÓRICA	6
2.1 Otimização Multiobjetivo.....	6
2.1.1 Definições.....	6
2.1.2 Métodos de Aglutinação	8
2.1.3 Método do Critério Global	9
2.1.4 Erro Percentual Global	10
2.2 Planejamento de Experimentos	11
2.2.1 Definições.....	11
2.2.2 Arranjos Fatoriais	14
2.2.3 Arranjo de Misturas	16
2.2.4 Arranjo de misturas combinado com variáveis de processo.....	21
2.3 Algoritmo Genético	22
2.3.1 Definições.....	22
2.3.2 Estrutura dos Algoritmos Genéticos.....	24
2.3.3 Operadores Genéticos.....	27
2.3.4 Parâmetros do Algoritmo Genético	29
2.3.5 Configuração dos Parâmetros do Algoritmo Genético.....	38
3 PROCEDIMENTO EXPERIMENTAL	40
3.1. Procedimento proposto	40
3.2. Modelagem das respostas do processo de soldagem.....	41
3.3. Definição do problema de otimização	45
3.4. Definição do arranjo de misturas.....	46
3.5. Otimização pelo Algoritmo Genético.....	50
4 RESULTADOS E DISCUSSÕES.....	53
4.1 Modelagem do Erro Percentual Global	53

4.2	Análise da Influência dos Parâmetros	57
4.3	Otimização da Função EPG.....	62
4.3.1	Confirmação	62
4.3.2	Avaliação dos pesos e parâmetros ótimos	64
5	CONCLUSÕES	67
5.1	Sugestões para trabalhos futuros	68
	REFERÊNCIAS BIBLIOGRÁFICAS	69
	APÊNDICES	76
	ANEXOS	112

1 INTRODUÇÃO

Otimização, segundo a definição de Rao (2009), é o processo responsável por encontrar as condições que proporcionam o valor máximo ou mínimo de uma função. Para Deb (2001), a busca por soluções ótimas para um problema se deve principalmente à necessidade de se minimizar custos e melhorar qualidade, entre outros fatores.

O problema de otimização multiobjetivo é aquele que, como o próprio nome já diz, trata de diversos objetivos ao mesmo tempo. Em outras palavras, este tipo de problema relaciona diferentes características que devem ser otimizadas em conjunto. Contudo, a tarefa de otimizar diferentes objetivos simultaneamente apresenta, na maioria das vezes, um grau de complexidade mais elevado (GOMES, 2013).

Uma grande variedade de problemas de engenharia, entre outras áreas, envolvem problemas de otimização multiobjetivo. A complexidade deste tipo de problema tem levado vários pesquisadores a desenvolver métodos e algoritmos que tornem possível a solução destes, de maneira adequada e eficiente.

Segundo Paiva (2012), o processo de otimização multiobjetivo contempla três etapas: a primeira é a modelagem das funções objetivo e das restrições, seguida pela determinação da estratégia de combinação entre os múltiplos objetivos e finalizando com a aplicação de um algoritmo capaz de determinar o ponto de ótimo que atenda ao sistema como um todo. O primeiro desafio está na determinação do método mais adequado para a execução de cada uma destas etapas.

É possível combinar as diferentes funções objetivo em apenas uma função a ser otimizada, através de métodos de aglutinação. O método do Critério Global é um método de aglutinação, que combina as funções objetivo escalonadas através da atribuição de pesos a cada uma delas, em uma única função que passa a ser o objetivo o problema (RAO e FREIHEIT, 1991). Segundo Gomes (2013), pouco se é discutido sobre como deve ser feita a atribuição de pesos às funções. O autor ainda afirma que muitas vezes este processo acaba sendo baseado na experiência e no julgamento do tomador de decisão, podendo conduzir a resultados satisfatórios, porém, em alguns casos, não ao melhor resultado.

Com o problema de otimização devidamente definido, deve-se aplicar um algoritmo de otimização que será responsável por encontrar a solução ótima para o problema. Um

algoritmo de solução de problemas de otimização amplamente utilizado é o Algoritmo Genético. Esta técnica tem sido empregada em diversas áreas da engenharia e também de outras ciências, pois é bastante adequada para a solução de problemas mais complexos (HEREDIA-LANGNER *et al.*, 2002).

O Algoritmo Genético segue um procedimento dividido em diferentes operações, que são controladas por parâmetros (ORTIZ *et al.*, 2004). É abordado na literatura o fato de que a escolha correta destes parâmetros pode influenciar no desempenho do algoritmo, porém muitos pesquisadores encontram dificuldades em determinar os melhores valores para os parâmetros, já que não existe um consenso sobre quais seriam os valores mais adequados. Com isso, se a modelagem e a definição do problema de otimização forem feitas corretamente, mas o algoritmo utilizado não for corretamente configurado, a qualidade da solução encontrada para o problema pode ser afetada.

A fim de contornar os problemas de configuração dos parâmetros do algoritmo genético, diferentes pesquisas têm sido realizadas para a identificação e otimização de parâmetros. Dentre as soluções encontradas estão a utilização de técnicas adaptativas, de meta-heurísticas e também a utilização de planejamento de experimentos.

A metodologia de planejamento de experimentos combina técnicas matemáticas e estatísticas para o desenvolvimento de arranjos experimentais eficientes, balanceados e econômicos e se tornou uma grande aliada dos pesquisadores na otimização de problemas multiobjetivo, pois utilizando arranjos experimentais é possível modelar as funções objetivo e até determinar os pesos para as funções (MONTGOMERY, 2009).

Dadas as discussões anteriores, esta pesquisa explora a suposição de que, se a complexidade do problema de otimização multiobjetivo pode aumentar dependendo da distribuição de pesos atribuída às funções objetivo originais, então os parâmetros do algoritmo utilizado para a solução do problema devem ser adequados para a tarefa mais complexa. Sendo assim, este trabalho é baseado nos seguintes pressupostos:

1^a) Existe interação entre os pesos definidos para as funções objetivo e os parâmetros do algoritmo genético?

2^a) Se existe interação, como isso afeta a solução do problema de otimização?

1.1 Justificativa

Como discutido anteriormente, a otimização de um problema multiobjetivo envolvendo a utilização de diferentes métodos e técnicas estatísticas não são tão triviais. No caso da utilização de métodos de aglutinação e algoritmos genéticos, definir os pesos das funções e a configuração adequada dos parâmetros do algoritmo pode ser considerado um obstáculo extra para a solução correta do problema.

O objeto de estudo desta pesquisa é o algoritmo genético e o modo com que a configuração dos parâmetros que controlam as etapas seguidas pelo algoritmo influenciam na qualidade das soluções finais encontradas. O levantamento feito na seção 2.3.4 deste trabalho mostra que existem divergências na literatura sobre os valores ideais de utilização destes parâmetros e que muitos pesquisadores encontram dificuldade em determiná-los.

Esta discussão sobre a configuração dos parâmetros levou alguns pesquisadores a buscar estratégias para contornar este problema. A seção 2.3.5 apresenta algumas pesquisas relativas a este tema. Através deste levantamento percebeu-se que as técnicas utilizadas por estes pesquisadores, com exceção das técnicas adaptativas, não levam em consideração a necessidade que pode haver de se ter configurações diferentes dos parâmetros para diferentes configurações de pesos das funções.

Com esta lacuna a ser preenchida dentro das pesquisas em algoritmo genético, este trabalho pretende propor um procedimento experimental capaz de analisar a influência dos parâmetros deste algoritmo na solução de problemas multiobjetivo com ponderação de respostas.

1.2 Objetivos

Com base na discussão apresentada na seção anterior, o objetivo geral deste trabalho é propor um procedimento experimental capaz de permitir a avaliação da influência dos parâmetros do algoritmo genético nos resultados obtidos na otimização de um problema multiobjetivo que utiliza a ponderação das respostas originais.

Como objetivos específicos, este trabalho visa:

- Propor um procedimento experimental para a otimização simultânea de pesos atribuídos às funções no método do critério global e dos parâmetros do algoritmo genético, através da utilização de um arranjo de misturas;
- Aplicar o procedimento proposto à otimização de um processo de soldagem;

- Avaliar se existe interação entre os parâmetros do algoritmo genético e os pesos atribuídos para as respostas;
- Avaliar a influência dos parâmetros do algoritmo genético nos resultados obtidos na otimização do processo de soldagem.

1.3 Contribuições

Considerando-se as questões levantadas sobre os problemas de configuração dos parâmetros do algoritmo genético para problemas de otimização multiobjetivo com ponderação de funções, este trabalho apresenta como contribuição a proposição de um procedimento experimental para otimização simultânea de pesos atribuídos às funções em um método de otimização de aglutinação (Método do Critério Global) e dos parâmetros utilizados para a configuração do algoritmo genético, através da utilização de um arranjo experimental de misturas combinado com variáveis de processo.

1.4 Delimitações da pesquisa

Os resultados apresentados nesta pesquisa não poderão ser generalizados, pois estão sujeitos a algumas limitações, como definido a seguir:

- **Limitação do processo de aplicação:** espera-se que o procedimento experimental proposto possa ser aplicado em diferentes processos. Todavia, este trabalho está limitado à aplicação apenas ao processo de soldagem com arame tubular empregado para operações de revestimento de chapas de aço carbono utilizando o aço inoxidável, tal como apresentado em Gomes (2013).
- **Limitação do número de parâmetros:** outra delimitação desta pesquisa foi o número de parâmetros do algoritmo que foram analisados. Como comentado anteriormente, o Algoritmo Genético está sujeito à configuração de vários parâmetros. Entretanto, o teste de todos os parâmetros tornaria este estudo muito exaustivo. Portanto, somente três parâmetros serão escolhidos para avaliação e para demonstração da utilidade e eficácia da metodologia proposta.

1.5 Metodologia

Para atingir os objetivos determinados neste trabalho, propõe-se a utilização de planejamento de experimentos, empregando-se um arranjo de misturas combinado com variáveis de processo. Com a utilização deste arranjo experimental, será possível determinar a

distribuição dos pesos utilizados para a aglutinação das funções objetivo através do Método do Critério Global e da configuração dos parâmetros do Algoritmo Genético, que será utilizado para encontrar a solução do problema multiobjetivo.

A utilização conjunta destas técnicas deixa clara a classificação desta pesquisa como sendo explicativa, quantitativa e experimental. A pesquisa pode ser classificada como explicativa, pois investiga a influência de fatores na ocorrência de um determinado fenômeno. A classificação de método experimental é justificada pelo uso de experimentos para a coleta dos dados que serão determinantes para a resposta das questões de pesquisa. Por fim, a classificação de abordagem quantitativa se deve ao fato de que todos os dados experimentais coletados serão quantificados e tratados estatisticamente.

O procedimento experimental proposto por este trabalho, que consiste em um conjunto de testes relativos a diferentes configurações de parâmetros do algoritmo genético e de diferentes combinações de pesos para as funções objetivo, será aplicado a um processo de soldagem, o que também permite a classificação desta pesquisa como sendo de natureza aplicada, devido ao seu interesse prático, determinado pela aplicação da pesquisa a casos reais.

1.6 Estrutura da dissertação

Este primeiro capítulo foi escrito com o intuito de apresentar o tema desta dissertação, assim como os objetivos e as delimitações desta pesquisa. Na continuação do presente trabalho, têm-se a seguinte estrutura:

O Capítulo 2 apresenta a fundamentação teórica, abordando os temas mais importantes para a condução da pesquisa. São apresentados os conceitos fundamentais de otimização multiobjetivo, da metodologia de planejamento de experimentos e dos algoritmos genéticos.

O Capítulo 3 apresenta o procedimento experimental proposto e a sua aplicação em um processo de soldagem com arame tubular empregado para operações de revestimento de chapas de aço carbono utilizando o aço inoxidável.

O Capítulo 4 apresenta os resultados e discussões, com a avaliação da influência dos parâmetros do algoritmo e a otimização de pesos e parâmetros.

O Capítulo 5 apresenta as conclusões da pesquisa e sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Otimização Multiobjetivo

Otimização é o ato de obter o melhor resultado para um sistema ou processo, sob determinadas circunstâncias (RAO, 2009). Problemas de otimização são muito comuns em diversas áreas da engenharia, onde muitas vezes é preciso maximizar lucro, produtividade, qualidade ou minimizar perdas e gastos, entre outras características. Esta pesquisa aborda os problemas de otimização multiobjetivo e os conceitos relacionados a este tema são apresentados nas próximas seções.

2.1.1 Definições

Os autores Collete e Siarry (2005) afirmam que a otimização multiobjetivo é um campo crescente da pesquisa operacional. Segundo Ryu *et al.* (2009) os problemas de otimização multiobjetivo podem ser encontrados em diversas situações, desde o projeto de um produto até a gestão de portfólios.

Um problema de otimização multiobjetivo (MOP – *Multiobjective Optimization Problem*) é aquele em que se deseja a otimização simultânea de múltiplas características, que são situações comuns à maioria dos processos industriais. Algumas definições relacionadas à otimização de processos são apresentadas no Quadro 2.1.

Quadro 2.1- Definições relacionadas à otimização de processos

Termo	Definição
Variáveis de decisão	Conjunto de parâmetros controláveis, também chamados de variáveis de controle, geralmente representadas por x .
Função objetivo / Respostas	Características que serão otimizadas. As respostas dependem das variáveis de decisão.
Sentido de otimização	Finalidade da otimização (maximização, minimização ou <i>target</i>)
Restrições	Limites ou funções que restringem as variáveis de decisão. Podem ser de igualdade ($h(x) = 0$) ou desigualdade ($g(x) \leq 0$).

Fonte: próprio autor

Segundo Baril *et al.* (2011), a finalidade da solução de um problema de otimização multiobjetivo é a determinação de um vetor de variáveis de decisão $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$ que

otimiza o vetor de funções objetivo $F(\mathbf{x}) = \{f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_m(\mathbf{x})\}$, dentro de uma região de solução viável. O problema multiobjetivo pode ser formulado da seguinte maneira:

$$\begin{aligned} & \text{Minimizar } F(\mathbf{x}) = \{f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_m(\mathbf{x})\} \\ & \text{Sujeito a : } h_i(\mathbf{x}) = 0, \quad i = 1, 2, \dots, p \\ & \quad \quad \quad g_j(\mathbf{x}) \leq 0, \quad j = 1, 2, \dots, q \\ & \quad \quad \quad \mathbf{x}^{\min} \leq \mathbf{x} \leq \mathbf{x}^{\max} \end{aligned} \tag{2.1}$$

Onde $h_i(\mathbf{x})$ são restrições de igualdade, $g_j(\mathbf{x})$ são restrições de desigualdade e \mathbf{x}^{\min} e \mathbf{x}^{\max} são, respectivamente, os limites mínimo e máximo para o vetor das variáveis de decisão (GOMES, 2013).

O principal objetivo da otimização multiobjetivo é encontrar um conjunto de soluções que minimize todas as funções simultaneamente, porém é comum em um MOP o fato de as funções objetivo apresentarem conflito entre os sentidos de otimização.

2.1.1.1 Otimalidade de Pareto

A otimização de um MOP leva a um conjunto de soluções denominadas Pareto-ótimas. Segundo Rao (2009), o conceito de solução Pareto-ótima é de grande relevância para esses tipos de problema. Considera-se uma solução viável \mathbf{x}^* como Pareto-ótima quando não existe nenhum outro vetor de solução \mathbf{x} tal que $f_i(\mathbf{x}) \leq f_i(\mathbf{x}^*)$, para $i = 1, 2, \dots, m$, com $f_j(\mathbf{x}) < f_j(\mathbf{x}^*)$, em pelo menos um objetivo j .

Gomes (2013) explica o conceito de solução Pareto-ótima com outras palavras. Para o autor, um vetor \mathbf{x}^* é dito Pareto-ótimo se não existe outra solução \mathbf{y} que irá provocar a redução em alguma função objetivo sem causar um aumento simultâneo em pelo menos um dos outros objetivos.

2.1.1.2 Fronteira de Pareto

Em contraste com a otimização de apenas um objetivo, a solução de um MOP é mais um conceito do que uma definição (MARLER e ARORA, 2004). Como não há uma solução global para este tipo de problema, a tarefa essencial dos métodos de otimização multiobjetivo é identificar não somente um ponto de ótimo, mas um conjunto de soluções Pareto-ótimas que, juntas, delimitam a fronteira de eficiência do problema, conhecida como fronteira de Pareto (KULTUREL-KONAK *et al.*, 2006).

Uma Fronteira de Pareto é um conjunto de soluções em que uma melhora em um objetivo só pode existir se, em pelo menos um dos demais objetivos houver uma piora.

Portanto, cada ponto desta fronteira representa uma solução da função objetivo. Para qualquer par de soluções dado como vetores de valores da função objetivo global, uma melhoria em um de seus componentes envolverá piora nos demais. A Figura 2.1 ilustra uma fronteira de Pareto construída para um problema biobjetivo. Nesta figura, os pontos A_1 e A_2 correspondem aos pontos de ancoragem da fronteira, ou seja, os pontos que representam as otimizações individuais de cada função objetivo (GOMES, 2013).




Figura 2.1 - Fronteira de Pareto para um problema biobjetivo
Fonte: GOMES (2013); adaptado de VAHIDINASAB e JADID (2010)

Um problema multiobjetivo será considerado convexo se o conjunto viável X e as funções objetivo individuais forem convexas. É sabido que o conjunto de soluções viáveis de um problema multiobjetivo convexo é, também, convexo e que a Fronteira de Pareto resultará em uma curva convexa. Quando o conjunto viável X não é convexo, ou pelo menos uma das funções for não convexa, o problema será considerado não convexo. Conjuntos de soluções viáveis convexas para problemas multiobjetivo não convexas podem ocorrer, porém, são situações de difícil detecção analiticamente. Em geral, para problemas multiobjetivo não convexas, a curva de Pareto pode ser não convexa e desconectada (DAS e DENNIS, 1998).

2.1.2 Métodos de Aglutinação

Existem diversas técnicas na literatura que abordam maneiras de se tratar problemas multiobjetivo (MYERS *et al.*, 2009). Basicamente, essas estratégias são divididas em dois grupos: os métodos de priorização das funções objetivo (onde elege-se a função objetivo mais importante para ser otimizada e as demais são tratadas no problema como restrições) e os

métodos de aglutinação (onde combina-se as funções objetivo individuais em uma única função, que se torna o objetivo global do problema) (GOMES, 2013).

Existem vários métodos de aglutinação disponíveis na literatura. A técnica de aglutinação mais comumente utilizada na prática é a combinação de diferentes objetivos em uma soma convexa ponderada (LOGIST *et al.*, 2010). Esta técnica é comumente conhecida como método das Somas Ponderadas (WS – *Weighted Sum*). Segundo Das e Dennis (1997) no método de somas ponderadas n pesos (w_i) são escolhidos de maneira que $w_i \geq 0, i = 1, \dots, n$ e $\sum_{i=1}^n w_i = 1$ e o seguinte problema é resolvido:

$$\begin{aligned} \text{Minimizar } F(\mathbf{x}) &= \left[\sum_{i=1}^p w_i f_i(\mathbf{x}) \right] \\ \text{Sujeito a: } g_i(\mathbf{x}) &\leq 0 \end{aligned} \quad (2.2)$$

O método de somas ponderadas, apesar de ser muito utilizado, apresenta algumas desvantagens, como a dificuldade de se encontrar pontos nas regiões não convexas e a dificuldade em se determinar os pesos para as funções de modo a garantir que a solução final seja aceitável (JAIMES *et al.*, 2011).

Alguns outros métodos de aglutinação, como o Método do Critério Global, utilizam também de somas ponderadas em suas funções, como forma de priorizar as funções objetivo mais importantes. Este método será utilizado neste trabalho e a próxima seção explica mais detalhadamente os conceitos do método.

2.1.3 Método do Critério Global

O Método do Critério Global (MCG) é uma técnica de programação de múltiplos objetivos que também utiliza a estratégia de “aglutinação”, considerando alvo e o escalonamento das funções objetivo individuais. Segundo Gomes (2013), a estratégia de aglutinação fica clara quando os desvios relativos das funções objetivo são combinados para compor a função global $F(x)$. Além disso, o escalonamento dos mesmos desvios pelos alvos faz com que respostas de unidades e magnitudes diferentes possam ser tratadas num mesmo problema, fazendo do MCG uma técnica eficiente e aplicável a diferentes tipos de processos.

Rao (2009) define o MCG como um método onde a solução ótima é encontrada através da minimização de um critério global pré-selecionado, $F(x)$, definido como a soma da p -ésima potência dos desvios relativos das funções objetivo individuais em relação às soluções ideais (alvos). Então, a solução ótima pode ser encontrada segundo a Equação (2.3).

$$\begin{aligned} \text{Minimizar } F(\mathbf{x}) &= \sum_{i=1}^p \left\{ \frac{f_i(\mathbf{x}^*) - f_i(\mathbf{x})}{f_i(\mathbf{x}^*)} \right\}^p \\ \text{Sujeito a: } g_j(\mathbf{x}) &\leq 0, \quad j=1,2,\dots,m \end{aligned} \quad (2.3)$$

onde: p é uma constante (geralmente o valor usado para p é 2) e \mathbf{x}^* é a solução ótima para a i -ésima função objetivo e $g_j(\mathbf{x})$ é a restrição do problema.

Algumas variações deste método podem ser encontradas na literatura. A Equação (2.3) definida por Rao (2009) pode ser reescrita, levando em consideração a importância de cada um dos objetivos. Para tratar os vários objetivos de maneira diferente é possível aplicar pesos às funções, como mostrado na Equação (2.4).

$$\begin{aligned} \text{Minimizar } F(\mathbf{x}) &= \sum_{i=1}^p w_i \left\{ \frac{f_i(\mathbf{x}^*) - f_i(\mathbf{x})}{f_i(\mathbf{x}^*)} \right\}^2 \\ \text{Sujeito a: } g_j(\mathbf{x}) &\leq 0, \quad j=1,2,\dots,m \end{aligned} \quad (2.4)$$

Porém, segundo Marler e Arora (2004) a abordagem mais robusta de escalonamento de funções, independente das escalas originais das mesmas, é dada pela Equação (2.5).

$$F(\mathbf{x}) = \frac{f_i(\mathbf{x}^*) - f_i(\mathbf{x})}{f_i(\mathbf{x}^{\max}) - f_i(\mathbf{x}^*)} \quad (2.5)$$

Na Equação (2.6), $f_i(x^*)$ é o valor alvo estabelecido em função da otimização individual de cada função objetivo e $f_i(x)^{\max}$ é o valor que mais se distancia de $f_i(x^*)$ e também leva em consideração os pesos das funções objetivo. Segundo Rao e Freiheit (1991), esta equação normaliza os objetivos para que nenhuma função seja favorecida pela sua magnitude. Sendo assim, podemos reescrever a função para o MCG, baseado nesta forma de escalonamento, como dado pela Equação (2.6).

$$\begin{aligned} \text{Minimizar } F(\mathbf{x}) &= \sum_{i=1}^p w_i \left\{ \frac{f_i(\mathbf{x}^*) - f_i(\mathbf{x})}{f_i(\mathbf{x}^{\max}) - f_i(\mathbf{x}^*)} \right\}^2 \\ \text{Sujeito a: } g_j(\mathbf{x}) &\leq 0, \quad j=1,2,\dots,m \end{aligned} \quad (2.6)$$

2.1.4 Erro Percentual Global

O Erro Percentual Global das respostas Pareto-ótimas, definido por Gomes (2013), indica o desvio das respostas ótimas da função MCG em relação aos ótimos individuais de

cada uma das respostas, permitindo uma avaliação da qualidade da solução encontrada na otimização. O EPG pode ser calculado através da expressão:

$$EPG = \sum_{i=1}^m \left| \frac{y_i^*}{T_i} - 1 \right| \quad (2.7)$$

onde: EPG – Erro percentual global das respostas Pareto-ótimas em relação aos alvos

y_i^* – Valores das respostas Pareto-ótimas

T_i – Alvos definidos (resultados das otimizações individuais)

m – Número de objetivos

Uma vez que a função erro percentual global pode ser modelada e analisada através de um modelo de misturas, a identificação dos pesos ótimos é obtida resolvendo-se um problema de otimização não-linear cujo objetivo é a minimização desta função e os pesos são as variáveis de decisão. Os pesos ótimos ficam então caracterizados como a combinação de valores que fazem o erro percentual global ser o menor possível (GOMES, 2013).

2.2 Planejamento de Experimentos

No geral, experimentos são utilizados para estudar o desempenho de processos. Montgomery (2009) define experimento como sendo um teste ou uma série de testes nas quais propositalmente mudanças são feitas nas variáveis de entrada de um processo ou sistema, para que se possa observar e identificar as razões das mudanças que poderão ser observadas nas respostas (saídas). Ainda segundo o autor, a experimentação tem um papel muito importante na comercialização de tecnologias e na fabricação de produtos.

Segundo Kleijnen *et al.* (2005), o planejamento de experimentos (*DOE - Design of Experiments*) tem uma rica história com muito desenvolvimento teórico e aplicações práticas em diversos campos de pesquisa como na agricultura, em ensaios clínicos, em projeto de produtos e diversas outras áreas. As próximas seções apresentam os principais conceitos relativos a esta metodologia.

2.2.1 Definições

O planejamento de experimentos é definido como uma metodologia de planejamento experimental que combina técnicas matemáticas e estatísticas para o desenvolvimento de arranjos experimentais eficientes, balanceados e econômicos, a partir dos quais, o experimentador pode inferir com elevado nível de confiança (MYERS *et al.*, 2009).

Matematicamente, o DOE combina as técnicas de ANOVA, Testes *2-sample t* e Análise de Regressão, para criar equações não-lineares (superfícies de resposta) que tentam representar fenômenos de interesse, sem modelos mecanicistas, em uma restrita região de interesse (MONTGOMERY, 2009). Quando usado de maneira concatenada com os métodos de otimização, o DOE permite a criação de funções objetivo e restrições para diversos processos industriais, o que justifica sua grande utilização em diversos processos, tais como: usinagem, soldagem, conformação, fabricação, metrologia, desenvolvimento de produtos, metamodelagem, etc.

A metodologia de planejamento de experimentos é geralmente utilizada para a avaliação de processos e sistemas. A Figura 2.2 apresenta o esquema de um processo/sistema genérico.

O processo é uma combinação de operações, máquinas, ferramentas, métodos, pessoas e outros recursos que transformam as entradas (geralmente materiais) em saídas, que geralmente possuem uma ou mais respostas observáveis (MONTGOMERY, 2009). As variáveis que interferem nas respostas são chamadas de fatores. Os fatores podem ser controláveis (aqueles que podem ser controlados de acordo com a necessidade do processo ou do experimentador) ou incontroláveis (também chamados de ruídos).

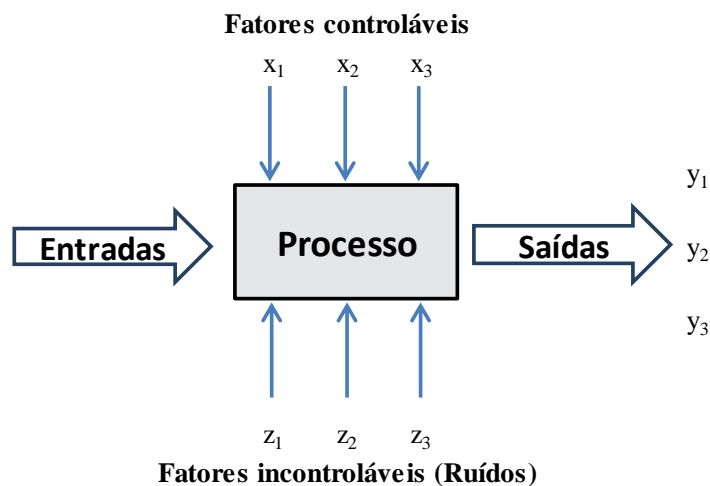


Figura 2.2 - Esquema geral de um modelo ou processo
Fonte: adaptado de MONTGOMERY (2009)

O DOE pode ser utilizado quando se deseja determinar quais fatores mais influenciam as respostas, definir o ajuste dos fatores de modo que os valores desejados para as respostas sejam atingidos ou para que se possa minimizar a variação destas respostas. Pode-se ainda utilizar o DOE para definir como os ruídos interferem nas respostas.

As técnicas do Projeto e Análise de Experimentos têm encontrado uma ampla aplicação em diversas áreas de conhecimento, se mostrando como um conjunto de

ferramentas importantes para o desenvolvimento de produtos e processos (GOMES, 2010). Segundo Montgomery (2009), a aplicação das técnicas de planejamento experimental podem resultar em:

- Melhorias no rendimento dos processos;
- Redução de variabilidade e aumento no nível de conformidade;
- Redução do tempo de desenvolvimento;
- Redução de custos.

Montgomery (2009) também propõe sete etapas para a execução do planejamento e análise de experimentos. São elas:

1. Definição do problema;
2. Escolha dos fatores e definição dos níveis de trabalho;
3. Seleção das variáveis de resposta;
4. Escolha do projeto experimental;
5. Execução dos experimentos;
6. Análise estatística dos dados;
7. Conclusões e recomendações.

De acordo com esta sequência de etapas, após a definição do problema, dos parâmetros e das respostas, o próximo passo é a definição do projeto experimental, também chamado de arranjo experimental. Com relação aos tipos de arranjos experimentais, os mais utilizados são os fatoriais (completos ou fracionados), os arranjos de Taguchi, as superfícies de resposta e os arranjos de misturas.

O Quadro 2.2 apresenta as características principais de alguns dos tipos de arranjos mais comuns, como vantagens e desvantagens da utilização dos mesmos e suas principais aplicações. O arranjo de misturas não aparece neste quadro, pois os conceitos relacionados a este arranjo estão descritos na seção 2.2.3. Uma explicação um pouco mais detalhada também será dada sobre os arranjos fatoriais, na seção 2.2.2.

Existem diversos softwares estatísticos para auxiliar os experimentadores na criação e análise do arranjo escolhido. O experimentador pode entrar com as informações definidas, como o número de fatores e níveis, e esses programas vão apresentar uma seleção de arranjos possíveis. Esses programas geralmente fornecem uma planilha com a ordem dos experimentos, para guiar o experimentador na condução dos mesmos (MONTGOMERY, 2009).

Quadro 2.2 - Características e aplicações dos Arranjos experimentais

Projeto experimental	Vantagens	Desvantagens	Aplicações
Fatorial Completo 2^k	Permite a varredura completa da região de estudo, pois utiliza todos os fatores e respectivos níveis.	Não identifica variação intermediária, pois só trabalha em dois níveis e necessita de um alto número de experimentos para problemas com muitas variáveis.	Processos onde já se tem um prévio domínio e onde a realização dos experimentos não demanda maior tempo ou custo.
Fatorial Fracionado $2^{(k-p)}$	Permite uma pré-análise do processo com um número reduzido de experimentos	Não promove a varredura completa da região experimental	Processos onde se deseja um pré-conhecimento e onde a literatura é limitada, ou corridas que demandam maior tempo ou custo.
Taguchi	Permite a análise de um processo com muitas variáveis de entrada com um número extremamente reduzido de experimentos.	Fornecer uma ideia do processo, porém pode apresentar modelos matemáticos não confiáveis.	Processos onde há pouco ou quase nenhum conhecimento prévio de comportamento, com alta dispersão ou que os experimentos demandem alto custo ou tempo.
Metodologia de Superfície de Resposta	Permite a verificação de variações intermediárias do processo	Pode apresentar erros na extrapolação dos pontos ótimos, já que são realizadas poucas corridas nestes níveis.	Otimização de processos, principalmente bem conhecidos e com baixa dispersão.

Fonte: GOMES (2010); adaptado de NILO JUNIOR (2003)

Segundo Paiva (2006), um bom planejamento de experimentos pode incluir a utilização de réplicas, de aleatorização e blocagem, que devem ser definidas durante a criação do arranjo. Com a utilização das réplicas, é possível criar uma variação para a variável de resposta que pode ser utilizada na avaliação da significância estatística do incremento experimental. A aleatorização dos experimentos garante um aumento da validade dos mesmos, pois aumenta a chance dos efeitos desconhecidos serem distribuídos através dos níveis dos fatores. A blocagem deve ser utilizada nos casos em que não é possível manter a homogeneidade das condições experimentais, pois através da utilização desta técnica é possível avaliar se a falta de homogeneidade interfere nos resultados. Esta técnica divide os experimentos em blocos, onde se presume que cada bloco é mais uniforme do que o todo.

2.2.2 Arranjos Fatoriais

Arranjos fatoriais são amplamente utilizados em experimentos que envolvem diversos fatores onde é necessária a investigação dos efeitos conjuntos desses fatores em uma resposta (MYERS *et al.*, 2009).

O arranjo experimental mais comum é o fatorial completo (FFD - *Full Factorial Design*), que são combinações experimentais de fatores, planejadas de maneira que cada fator (variável independente) seja experimentado um número igual de vezes em cada um dos seus níveis. Deste modo, arranjos FFD são balanceados e ortogonais (a soma dos sinais dos contrastes é nula) (MONTGOMERY, 2009). Este tipo de arranjo cobre todo o espaço experimental e são fáceis de serem conduzidos, pois apresentam um padrão bem estabelecido.

O número de experimentos calculado para um FFD é igual ao número de níveis experimentais elevado ao número de fatores. No caso típico de fatoriais em dois níveis, o número de experimentos (N), para se avaliar os k fatores, é dado por $N = 2^k$ (PAIVA, 2006). A Figura 2.3 - apresenta a distribuição de experimentos de um arranjo fatorial completo para 3 fatores e dois níveis.

Dependendo do número de fatores a serem analisados, o arranjo pode se tornar muito extenso ou até mesmo tornar a experimentação inviável. Nestes casos, pode-se utilizar um arranjo fatorial fracionado, onde o número de experimentos, para fatoriais em dois níveis, é dado por $N = 2^{k-p}$, onde p é a fração utilizada. Por exemplo, se $p=1$ serão realizados metade dos experimentos, se $p=2$, serão realizados apenas um quarto dos experimentos previstos no fatorial completo. Para Montgomery (2009), realizar apenas uma parte dos experimentos pode reduzir significativamente os custos e o tempo de duração dos ensaios, sem comprometer a precisão dos resultados após a análise.

Exemplificando a aplicação do arranjo fatorial fracionado, a Figura 2.4 apresenta um arranjo fatorial fracionado ($N = 2^{3-1}$), onde os experimentos definidos estão destacados.

Exp.	x1	x2	x3
1	-1	-1	-1
2	+1	-1	-1
3	-1	+1	-1
4	+1	+1	-1
5	-1	-1	+1
6	+1	-1	+1
7	-1	+1	+1
8	+1	+1	+1




Figura 2.3 - Arranjo fatorial completo para 3 fatores em 2 níveis
Fonte: próprio autor

depende das proporções dos elementos integrantes da mistura e da quantidade utilizada dessa mistura. Por exemplo, o rendimento de uma plantação de café depende da quantidade de adubo utilizada e das proporções de certos elementos (tais como Nitrogênio, Fósforo e Potássio) presentes no composto. No terceiro tipo, o desempenho da variável está intimamente relacionado com as proporções dos elementos da mistura, associada aos níveis das variáveis de processo envolvidas. Neste tipo, as propriedades dos elementos ou da mistura podem ser influenciadas pelas variáveis de processo. Um exemplo deste tipo de experimento é o caso onde o sabor de um bolo depende das proporções dos ingredientes da mistura e também de variáveis de processo, como tempo e temperatura de preparo. Neste caso, as variáveis de processo seriam representadas por um fatorial completo ou fracionário (CORNELL, 2011).

O sistema triangular de coordenadas permite que os relacionamentos entre os componentes de uma mistura de três elementos sejam visualizados. Em uma mistura, os componentes se restringem mutuamente, uma vez que a sua soma deve ser igual à unidade. Este sistema, portanto, permite que os valores mínimos e máximos dos três elementos da mistura (x_1 , x_2 e x_3) sejam mostrados. A Figura 2.5 mostra a disposição geral deste sistema de coordenadas, onde os componentes são representados em função da sua proporção em relação ao total, e esse total é igual a 100%. Cada vértice do triângulo representa o que se denomina “Mistura Pura”.




Figura 2.5 - Configuração de um arranjo de Misturas
Fonte: próprio autor

Os principais arranjos de misturas são: *simplex-lattice*, *simplex-centroid*, e *extreme-vertices*. Cada qual, de acordo com suas peculiaridades, é adequado a uma situação experimental. O *simplex-lattice design* foi proposto pela primeira vez por Scheffé (1958) e é o arranjo que será utilizado neste trabalho. A principal característica deste tipo de arranjo para mistura é que os pontos são distribuídos uniformemente por toda a região compreendida pelo

simplex. Um *simplex-lattice* para q componentes está associado a um polinômio de grau m , e pode ser denotado como um *simplex-lattice design* $\{q, m\}$. As proporções para cada um dos q componentes assumem os possíveis $(m+1)$ valores igualmente espaçados entre 0 e 1, tal que: $x_i = 0, 1/m; 2/m; \dots; 1$ (CORNELL, 2011). Todas as possíveis combinações das proporções totalizam 1 e definem os pontos a serem usados no arranjo.

Este tipo de arranjo é restrito por fronteiras, isto é, todos os pontos do arranjo estão nas faces da região *simplex*. Para se pesquisar o comportamento da mistura no interior da região *simplex*, pode-se incrementar o arranjo com pontos interiores (GOMES, 2013). A Figura 2.6 representa a configuração dos pontos do arranjo, de acordo com o grau do polinômio, também chamado de grau *lattice*.

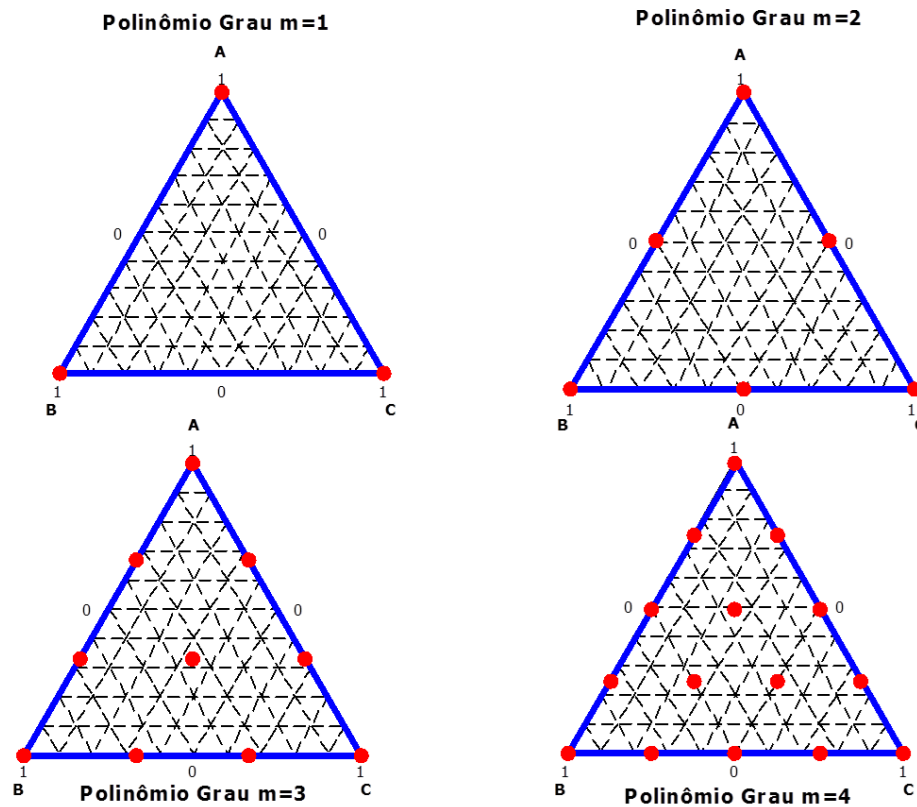


Figura 2.6 - Configurações de arranjos de mistura *simplex lattice*
Fonte: próprio autor

Quanto aos modelos matemáticos utilizados para a representação das respostas, verifica-se que os modelos de misturas apresentam algumas diferenças em relação aos polinômios empregados na Metodologia de Superfície de Resposta. A base do modelamento de experimentos de mistura também é a regressão múltipla, entretanto a grande diferença se deve à existência da restrição $\sum_{i=1}^k x_i = 1$ (GOMES, 2013).

Por exemplo, considerando-se o modelo linear geral, tal que $E(y) = \beta_0 + \sum \beta_i x_i$ e a restrição aos pesos, tal que $\sum_{i=1}^q x_i = 1$, então têm-se que:

$$E(y) = \sum_{i=1}^q x_i \left(\beta_0 + \sum_{i=1}^q \beta_i x_i \right) = \sum_{i=1}^q x_i \left(\beta_0 + \beta_i \sum_{i=1}^q x_i \right) \quad (2.8)$$

$$E(y) = \sum_{i=1}^q x_i \left(\beta_0 + \beta_i \underbrace{\sum_{i=1}^q x_i}_1 \right) \quad (2.9)$$

$$E(y) = \sum_{i=1}^q x_i (\beta_0 + \beta_i) \quad (2.10)$$

Logo, o valor da constante é somado a todos os termos da parte linear dos modelos de mistura. Consideremos, agora, um polinômio de segunda ordem. Se:

$$\sum_{i=1}^q x_i = 1 \Rightarrow x_i = \left(1 - \sum_{\substack{j=1 \\ j \neq i}}^q x_j \right) \Rightarrow x_i^2 = x_i \left(1 - \sum_{\substack{j=1 \\ j \neq i}}^q x_j \right) \quad (2.11)$$

Então:

$$E(y) = \beta_0 \left(\sum_{i=1}^q x_i \right) + \sum_{i=1}^q \beta_i x_i + \sum_{i=1}^q \beta_{ii} \left[x_i \left(1 - \sum_{\substack{j=1 \\ j \neq i}}^q x_j \right) \right] + \sum_{i < j}^q \beta_{ij} x_i x_j \quad (2.12)$$

$$E(y) = \sum_{i=1}^q (\beta_0 + \beta_i + \beta_{ii}) x_i - \sum_{i=1}^q \beta_{ii} x_i \sum_{\substack{j=1 \\ j \neq i}}^q x_j + \sum_{i < j}^q \beta_{ij} x_i x_j \quad (2.13)$$

$$E(y) = \sum_{i=1}^q \beta_i^* x_i + \sum_{i < j}^q \beta_{ij}^* x_i x_j \begin{cases} \beta_i^* = \beta_0 + \beta_i + \beta_{ii} \\ \beta_{ij}^* = \beta_{ij} - \beta_{ii} - \beta_{jj} \end{cases} \quad (2.14)$$

Este fato justifica a ausência dos termos independentes nos modelos para este tipo de arranjo. Dependendo do comportamento da resposta analisada, o modelo pode ser linear, quadrático, cúbico ou quártico (CORNELL, 2011). As Equações (2.15) a (2.20) representam as formas canônicas para cada um destes modelos:

a) Modelo Linear:

$$E(y) = \sum \beta_i x_i \quad (2.15)$$

b) Modelo Quadrático:

$$E(y) = \sum \beta_i x_i + \sum \sum_{i < j} x_i x_j \quad (2.16)$$

c) Modelo Cúbico Especial:

$$E(y) = \sum \beta_i x_i + \sum \sum_{i < j} x_i x_j + \sum \sum_{i < j < k} x_i x_j x_k \quad (2.17)$$

d) Modelo Cúbico Completo:

$$E(y) = \sum \beta_i x_i + \sum \sum_{i < j} x_i x_j + \sum \sum_{i < j} \delta_{ij} x_i x_j (x_i - x_j) + \sum \sum_{i < j < k} x_i x_j x_k \quad (2.18)$$

e) Modelo Quártico Especial:

$$E(y) = \sum \beta_i x_i + \sum \sum_{i < j} x_i x_j + \sum \sum_{i < j} \sum_{i < j < k} x_i^2 x_j x_k + \sum \sum_{i < j < k} x_i x_j^2 x_k \quad (2.19)$$

$$+ \sum \sum_{i < j < k} x_i x_j x_k^2 + \sum \sum_{i < j < k} x_i x_j x_k x_l$$

e) Modelo Quártico Completo:

$$E(y) = \sum \beta_i x_i + \sum \sum_{i < j} x_i x_j + \sum \sum_{i < j} \gamma_{ij} x_i x_j (x_i - x_j) + \sum \sum_{i < j} \delta_{ij} x_i x_j (x_i - x_j)^2 \quad (2.20)$$

$$+ \sum \sum_{i < j < k} x_i^2 x_j x_k + \sum \sum_{i < j < k} x_i x_j^2 x_k + \sum \sum_{i < j < k} x_i x_j x_k^2 + \sum \sum_{i < j < k} x_i x_j x_k x_l$$

A estimação dos coeficientes definidos para esses modelos pode ser realizada utilizando o método dos Mínimos Quadrados Ordinários (*Ordinary Least Squares – OLS*). Com a aplicação deste método é possível a construção de uma função aproximada que relaciona a resposta de interesse com as variáveis do processo (GOMES, 2013).

Após a construção do modelo, deve-se avaliar se o mesmo apresenta significância estatística. Esta verificação pode ser feita através de um procedimento de ANOVA (Análise de Variância), que permite avaliar o ajuste do modelo e também verificar quais são os termos significativos deste modelo. O ajuste é representado através do coeficiente de determinação (R^2), que representa o percentual de variação na resposta que é explicada pelo modelo matemático. Associado a este coeficiente, encontra-se o R^2 ajustado ($R^2(adj.)$), que considera o fato de que R^2 tende a superestimar a quantidade atual de variação nos dados (GOMES, 2013). Deve-se também analisar a normalidade dos resíduos, onde os resíduos devem apresentar distribuição normal, e o resultado do teste de falta de ajuste (*lack-of-fit*), onde o *p-value* para a falta de ajuste tem que ser alto.

2.2.4 Arranjo de misturas combinado com variáveis de processo

Como mencionado anteriormente, existem algumas variações do experimento de misturas original. Em alguns problemas de mistura, existem variáveis de processo em adição a mistura de componentes (MYERS *et al.*, 2009). Adicionar variáveis de processo a um arranjo de misturas pode aumentar muito o escopo do experimento, fornecendo respostas sobre o que é afetado quando se faz alterações em uma ou mais variáveis do processo, se o valor da resposta é afetado, se as propriedades da mistura mudam e até mesmo se essas variáveis podem alterar ou não a mistura ótima (CORNELL, 2011).

Para Myers *et al.* (2009), esse tipo de arranjo é considerado uma classe separada de experimentos pelo fato de que a mistura de componentes é interdependente, já que é restrita à soma das proporções ser igual a uma unidade, enquanto as variáveis de processo podem ser variadas independentemente.

O tipo mais comum de arranjo de mistura combinado com variáveis de processo é um arranjo comum de mistura configurado em cada ponto de um arranjo fatorial nos níveis das variáveis de processo, como exemplificado na Figura 2.7. O modelo mais completo de um arranjo combinado pode ser expresso como o produto dos termos no modelo de componentes de mistura e os termos do modelo de variáveis de processo (CORNELL, 2011).




Figura 2.7- Diagrama de um experimento envolvendo três variáveis (fatores) de processo e três componentes para a mistura.

Fonte: Cornell (2011)

Por exemplo, supondo um arranjo para três componentes de mistura combinado com um fatorial completo para duas variáveis de processo (2^2), o arranjo combinado terá 28 experimentos com diferentes combinações de pesos e variáveis de processo. Se deseja-se

obter um modelo quadrático que se ajuste simultaneamente às variáveis de processo e às proporções da mistura, o modelo pode ser escrito como apresentado na Equação (2.21) (MYERS *et al.*, 2009).

$$E(y) = \sum_{i=1}^3 \beta_i x_i + \sum_{i<j=2}^2 \sum_{i=1}^3 \beta_{ij} x_i x_j + \sum_{k=1}^2 \left[\sum_{i=1}^3 \alpha_{ik} x_i + \sum_{i<j=2}^3 \alpha_{ijk} x_i x_j \right] z_k + \left[\sum_{i=1}^3 \delta_{i12} x_i + \sum_{i<j=2}^3 \delta_{ij12} x_i x_j \right] z_1 z_2 \quad (2.21)$$

Na Equação (2.21), x representa os componentes do arranjo de misturas e z representa as variáveis de processo. Nota-se que os seis primeiros termos deste modelo são independentes das variáveis de processo. Pode-se verificar também que os termos que envolvem somente as variáveis de processo não estão incluídos, pois a restrição da mistura de componentes restringe a inclusão destes no modelo.

Se o número de componentes e variáveis for relativamente grande, o número de experimentos planejados pode ser muito grande. Myers *et al.* (2009) afirmam que muitos autores sugerem a utilização de fatoriais fracionados, apesar de não existir um consenso sobre as melhores escolhas para esse tipo de arranjo.

A análise do arranjo de misturas com variáveis de processo envolve a modelagem de uma função que será dependente tanto dos componentes da mistura, quanto dos fatores. A verificação do ajuste do modelo é feita de maneira semelhante à empregada para os arranjos de mistura comuns.

2.3 Algoritmo Genético

2.3.1 Definições

Os algoritmos de otimização são geralmente divididos em duas grandes categorias: os métodos convencionais baseados em gradientes e os métodos livres de gradientes (MAGNIER e HAGHIGHAT, 2010). A Figura 2.8 apresenta algumas técnicas de busca utilizadas na solução de problemas de otimização.

Computação Evolucionária é uma família de técnicas de busca estocásticas fundamentada na teoria da evolução de Darwin (DIANATI *et al.*, 2002). Dentro do domínio dos procedimentos de busca encontra-se o Algoritmo Genético (*GA – Genetic Algorithm*). Este algoritmo foi inicialmente proposto por Holland (1975) e aprimorado por Goldberg

(1989). Baseado na sobrevivência dos mais aptos e na reprodução dos mesmos, este método busca novas soluções a cada etapa ou geração (ÁLVAREZ *et al.*, 2009).

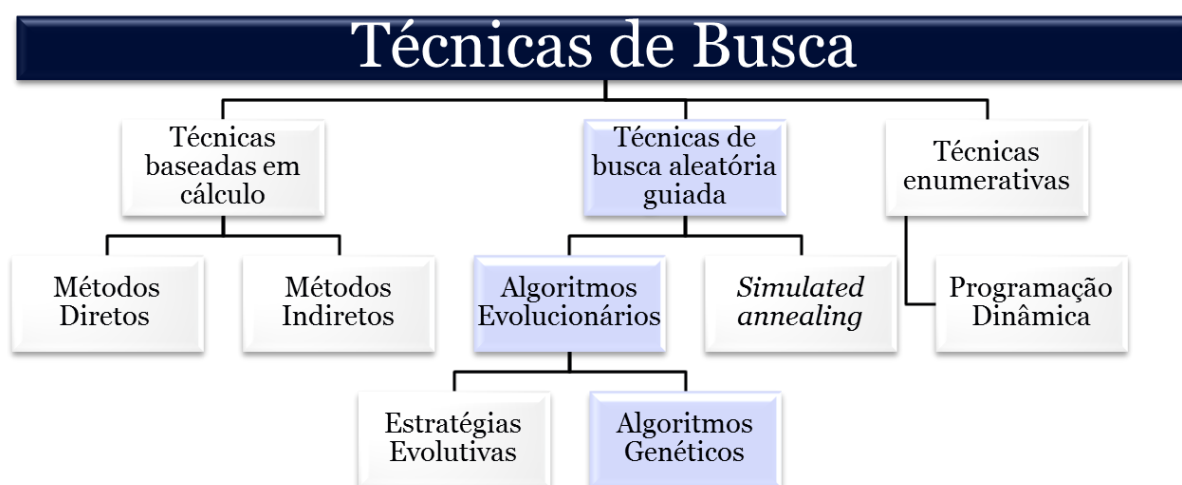


Figura 2.8 - Técnicas de Busca
Fonte: Adaptado de DIANATI *et al.* (2002)

A principal premissa desses algoritmos é a ideia de que combinando diferentes fragmentos de informações importantes para o problema, novas e melhores soluções podem ser encontradas (HEREDIA-LANGNER *et al.*, 2002).

O GA utiliza informações históricas de soluções avaliadas anteriormente na seleção de novos pontos onde é esperado um melhor desempenho (ORTIZ *et al.*, 2004). A diferença apresentada por este tipo de algoritmo é que, ao contrário dos algoritmos de otimização convencionais, a busca é iniciada a partir de um conjunto de pontos ao invés de um ponto apenas.

Cabe ressaltar que, apesar de determinar o conjunto de pontos a ser percorrido de forma aleatória, os algoritmos genéticos não podem ser chamados de buscas aleatórias não direcionadas, pois exploram informações históricas para encontrar novos pontos de busca onde são esperados bons desempenhos (CARVALHO *et al.*, 2003; PINHO, 2008).

Algoritmos Genéticos são bastante adequados para a solução de problemas complexos. Segundo Heredia-Langner *et al.* (2002), estes algoritmos exigem muito pouco da função objetivo (em relação à sua estrutura) e prosperam em ambientes multimodais e até mesmo descontínuos. Além disso, com a codificação adequada, eles podem manipular variáveis inteiras e contínuas ao mesmo tempo e ainda lidar com restrições lineares e não lineares trivialmente.

Pelo fato de apresentarem muitas vantagens em relação aos algoritmos tradicionais e serem mais eficientes na solução de problemas mais complexos, os Algoritmos Genéticos têm

sido utilizados em diversos trabalhos de otimização de problemas multiobjetivo. Alguns exemplos da aplicação deste algoritmo podem ser encontrados em pesquisas de diversas áreas como apresentado no Quadro 2.3.

Quadro 2.3 - Exemplos de aplicações do Algoritmo Genético para solução de problemas multiobjetivo

Áreas de pesquisa	Referências
Bioquímica	MALARD <i>et al.</i> , 2005; MAITI <i>et al.</i> , 2011
Ciência da Computação	HANNE e NICKEL, 2005; CHANG <i>et al.</i> , 2008
Engenharia Ambiental	BOIX <i>et al.</i> , 2012; LOUGHLIN <i>et al.</i> , 2000; CIENIAWSKI <i>et al.</i> , 1995
Engenharia Civil	COELLO e CHRISTIANSEN, 2000; ALMEIDA e AWRUCH, 2009; WANG <i>et al.</i> , 2005; MAGNIER e HAGHIGHAT, 2010
Engenharia de Materiais	GANGULY <i>et al.</i> , 2007
Engenharia Mecânica	DEB <i>et al.</i> , 2014
Manufatura	HEREDIA-LANGNER <i>et al.</i> , 2002; LI <i>et al.</i> , 2014; SANTOS <i>et al.</i> , 2014; CUS e BALIC, 2003; SARDIÑAS <i>et al.</i> , 2013
Química	KASAT e GUPTA, 2003; RAJESH <i>et al.</i> , 2001; ZHANG <i>et al.</i> , 2003; MONTAZER-RAHMATI e BINAEE, 2010
Robótica	ABU-DAKKA <i>et al.</i> , 2014

Fonte: próprio autor

2.3.2 Estrutura dos Algoritmos Genéticos

Para entender como o algoritmo funciona é primeiramente necessário que se apresente os termos envolvidos nas etapas seguidas pelo algoritmo. A terminologia comumente utilizada para o GA, baseada na teoria da evolução natural e na genética, define o vetor de soluções $\mathbf{x} \in \mathbf{X}$ como sendo o *cromossomo* ou indivíduo. Os cromossomos, por sua vez, são constituídos de unidades discretas, os *genes*. Cada gene é responsável por controlar uma ou mais características do cromossomo (KONAK *et al.*, 2006).

Na implementação original do GA por Holland (1975), os genes eram representados através de código binário. Neste caso, o gene é representado por um único *bit* do cordão binário. Este cordão também é chamado de *string*. Apesar da representação binária ainda ser muito utilizada, também é possível codificar os genes utilizando-se valores reais (ALAJMI e WRIGHT, 2014). O Quadro 2.4 apresenta resumidamente os conceitos utilizados para este tipo de algoritmo, especialmente na codificação binária.

Normalmente, um cromossomo corresponde a uma única solução \mathbf{x} no espaço de solução. Isto requer um mecanismo de mapeamento entre o espaço de solução e os cromossomos. Esse mapeamento é chamado de codificação. O GA trabalha na codificação de um problema, não no problema em si (KONAK *et al.*, 2006).

Quadro 2.4- Terminologia utilizada para os Algoritmos Genéticos

Termo	Definição
Cromossomo / Indivíduo	Vetor de possíveis soluções
Gene	Cada uma das possíveis soluções que formam o cromossomo
String	Cordão binário
<i>Bit</i>	Cada valor que forma um <i>string</i>
Fenótipo	Conjunto das variáveis de controle
Genótipo	Conjunto de genes
Pais	Indivíduos que serão utilizados para reprodução
Filhos	Indivíduos gerados a partir dos pais

Fonte: próprio autor

Uma *população* é um grupo de soluções (cromossomos) existente em cada etapa do algoritmo. Cada vez que uma nova população de indivíduos é criada, este procedimento é chamado de *geração*.

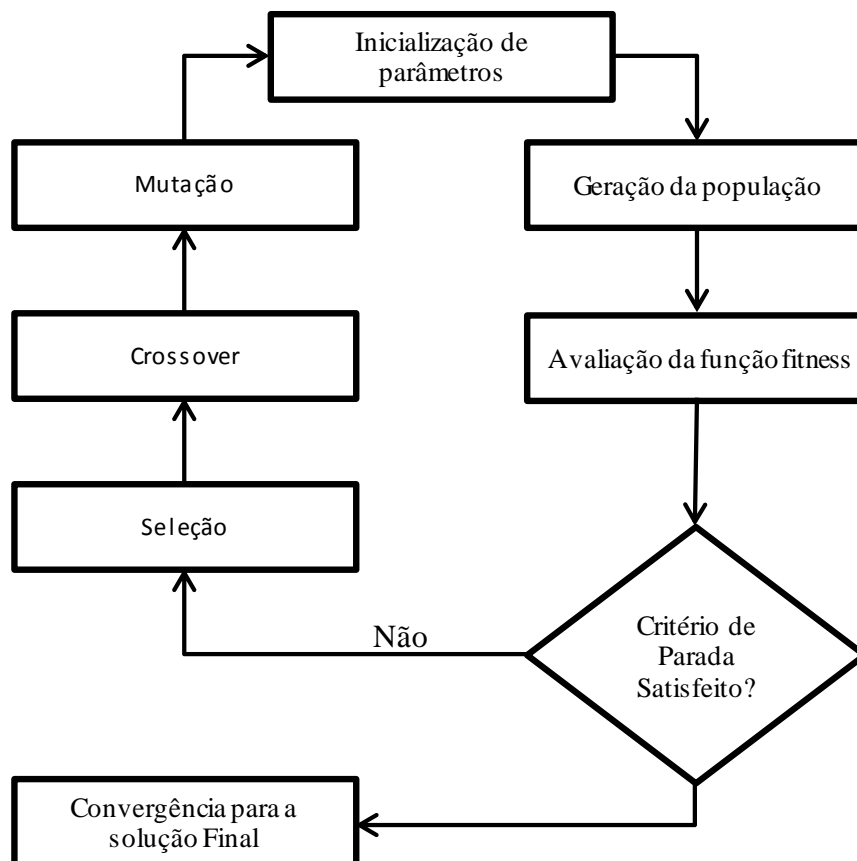


Figura 2.9- Etapas do algoritmo genético
 Fonte: adaptado de ZAIN *et al.* (2010)

Não existe apenas um GA, mas sim uma variedade de algoritmos genéticos, cada um adaptado para diferentes aplicações (SALOMON, 1996). No entanto, existe um GA genérico, chamado de GA canônico. O procedimento para identificação do ponto de ótimo em um GA canônico ocorre em diferentes etapas, como mostrado na Figura 2.9.

O passo inicial na implementação do algoritmo genético é a codificação das soluções potenciais, que determina a forma na qual as variáveis serão manipuladas (MARLER e ARORA, 2004). O método mais usado para a codificação consiste em representar cada solução em um cordão binário (0,1), que forma o cromossomo, como exemplificado na Figura 2.10. Deve-se especificar muito bem a codificação desse cromossomo, para que este represente de forma correta elementos do espaço de busca do problema (PINHO, 2008).

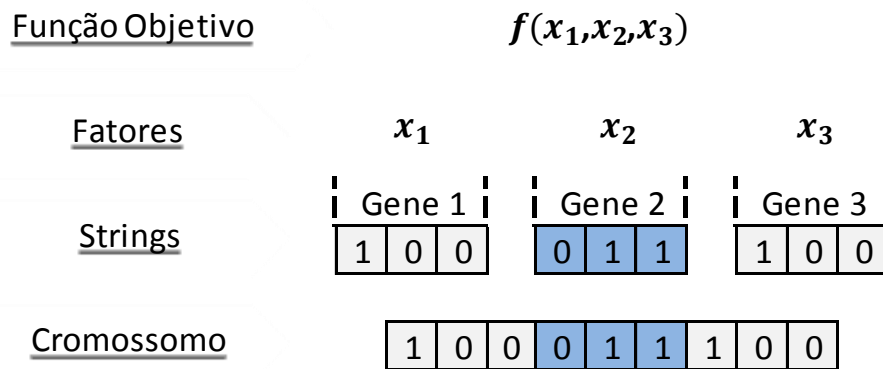


Figura 2.10 - Codificação de um cromossomo no Algoritmo Genético
Fonte: Adaptado de BUSACCA *et al.*(2001)

Após a codificação do processo, o algoritmo segue selecionando potenciais soluções para o problema a ser resolvido. Cada solução (cromossomo) é composta de todas as variáveis, com valores atribuídos dentro dos limites superiores e inferiores determinados para o problema (ALAJMI e WRIGHT, 2014). Como mencionado anteriormente, uma coleção de cromossomos é chamada de população. A população normalmente é aleatoriamente inicializada, porém processos heurísticos também podem ser utilizados.

A população é avaliada durante o processo de evolução do algoritmo. É conferida uma classificação para cada indivíduo, que reflete o grau de adaptação deste em relação ao ambiente (OLIVEIRA *et al.*, 2010). Segundo Fleming e Purhouse (2002), este tipo de algoritmo requer um valor escalar que represente o desempenho de cada solução. Esta avaliação é então baseada em uma função de aptidão, conhecida por *fitness*, que é obtida através de uma função a ser otimizada ao avaliar o cromossomo (indivíduo), geralmente a

função objetivo do problema de otimização. Logo, a aptidão é um valor obtido com a aplicação desta função, que pode ser conhecido através da quantificação da aptidão do indivíduo (PINHO, 2008). Segundo Marler e Arora (2004), a função *fitness* é uma indicação de quão desejável é um indivíduo, em termos de sobrevivência para a próxima geração.

A etapa de seleção é responsável por determinar quais indivíduos serão escolhidos para a etapa de reprodução. A probabilidade de uma dada solução ser escolhida para a próxima etapa é proporcional ao grau de aptidão desta solução. A seleção se baseia no princípio da “sobrevivência do mais apto”, onde as soluções boas são selecionadas para a reprodução e as soluções ruins são eliminadas (SRINIVAS e PATNAIK, 1994).

Se o melhor resultado não é obtido nesta primeira avaliação, o algoritmo segue para a etapa de seleção, onde são determinados quais cromossomos serão utilizados como *pais* na próxima geração. A próxima etapa é a recombinação, onde acontece a combinação dos genes dos “pais” selecionados para a criação de novos indivíduos (*filhos*), que deverão herdar as características positivas de seus pais e possivelmente levar a soluções ótimas. O algoritmo segue então para a etapa de mutação, onde são feitas pequenas alterações aleatórias nos genes dos cromossomos, com o intuito de diversificar a população (ORTIZ *et al.*, 2004; GOMES, 2013).

As etapas de seleção, recombinação e mutação são repetidas até que um dos seguintes critérios de convergência seja satisfeito: o número de gerações alcança o valor pré-estabelecido, o tempo de processamento atinge o valor previsto, o *fitness* do indivíduo mais fraco atinge um mínimo pré-estabelecido ou o *fitness* do indivíduo mais forte atinge um valor desejado (GOMES, 2013). Nestas condições, chega-se ao ponto de ótimo.

O algoritmo genético, assim como outros Algoritmos Evolutivos, pode fornecer várias soluções diferentes para o mesmo problema, porém essas soluções são igualmente boas (FLEMING e PURSHOUSE, 2002). Isso acontece pelo fato de que a população inicial é gerada aleatoriamente, e isso leva o algoritmo a explorar diferentes regiões de busca.

2.3.3 Operadores Genéticos

A evolução do algoritmo é realizada através da utilização de um conjunto de operadores genéticos estocásticos, que manipulam o código genético (FLEMING e PURSHOUSE, 2002). Os operadores genéticos são responsáveis pelo controle da evolução das gerações das soluções dos problemas. Os três principais operadores são reprodução, *crossover* e mutação (CALDAS e NORFORD, 2002).

2.3.3.1 Seleção /Reprodução

Os indivíduos devem ser selecionados para aplicação das próximas operações genéticas (FLEMING e PURSHOUSE, 2002). Para que isso ocorra, o operador de seleção age estabelecendo um grau mínimo de desempenho da função objetivo em cada geração. Esta operação é responsável por selecionar os pais que aumentam a probabilidade de gerar novos indivíduos mais aptos.

Segundo Ortiz *et al.* (2004), a população de filhos criada a cada nova geração do GA é avaliada e classificada para que os pontos no espaço de busca que apresentem o melhor desempenho sejam selecionados para a utilização nas próximas gerações.

2.3.3.2 Recombinação

Recombinação se refere à troca de genes entre cromossomos pais para a criação de novos indivíduos, chamados de filhos. É esperado que os filhos herdem as características positivas de seus pais. O operador de recombinação mais comum e mais importante é o *crossover* (cruzamento) (ORTIZ *et al.*, 2004).

O *crossover* consiste em escolher dois cromossomos dentre os selecionados na etapa anterior e efetuar uma troca aleatória de porções de informação genética entre eles para a geração de um novo cromossomo. Esse cromossomo filho terá então características dos dois pais. A Figura 2.11 exemplifica este processo.




Figura 2.11 - Exemplo de operação de *crossover*
Fonte: próprio autor

Esta operação não é aplicável a todos os cromossomos da população selecionada. A escolha dos indivíduos que passarão pelo cruzamento será definida pelo tipo de *crossover* e a taxa de *crossover* utilizados pelo algoritmo.

2.3.3.3 Mutaç o

A opera o de muta o   respons vel por aplicar pequenas mudan as aleat rias a um ou v rios genes de um cromossomo, a fim de promover varia o e diversidade na popula o. A muta o amplia o espa o de busca, o que aumenta a explora o da superf cie de resposta (ORTIZ *et al.*, 2004).

Segundo Fleming e Purhouse (2002), o papel da muta o   prover a oportunidade de recupera o de alguma caracter stica gen tica boa que possa ter sido perdida durante as etapas de sele o e recombina o. N n ez-Letamendia (2007) afirma que apesar de o operador ser considerado um operador secund rio por alguns autores, a opera o de muta o   a  nica opera o que introduz informa o gen tica n o representada na popula o inicial, fator essencial para que o algoritmo n o fique preso a um  timo local.

O procedimento de muta o na codifica o bin ria consiste na altera o de um *bit* de 0 para 1 (e vice-versa), como exemplificado na Figura 2.12. Existem diferentes tipos de muta o, que s o respons veis por determinar quais *bits* sofrer o muta o.




Figura 2.12 - Exemplo de opera o de muta o
Fonte: pr prio autor

2.3.4 Par metros do Algoritmo Gen tico

O funcionamento do GA demanda a configura o de um n mero de par metros relativamente grande (COSTA *et al.*, 2005). Al m de serem muitos os par metros, a configura o deles denota a escolha de diferentes op oes de fun oes e m todos a serem utilizados (par metros qualitativos), al m de taxas e probabilidades que ser o aplicadas ao algoritmo (par metros quantitativos) (EIBEN e SMIT, 2012).

Nas pr ximas se oes, ser o listados os principais par metros citados na literatura, assim como algumas op oes geralmente utilizadas na configura o dos mesmos.

2.3.4.1 Tamanho da Popula o

O Algoritmo Gen tico permite a busca por solu oes  timas atrav s da avalia o de diferentes cromossomos que fazem parte da popula o. Portanto, o tamanho da popula o  

um fator determinante na qualidade da solução e na eficiência do algoritmo, já que este parâmetro especifica quantos cromossomos formarão uma geração.

Na literatura há várias divergências sobre o tamanho de população ideal. A Tabela 2.1 apresenta um levantamento dos tamanhos de população utilizados em diferentes pesquisas, deixando clara a divergência de valores empregados nos estudos. A coluna de valores testados se refere aos níveis testados pelos pesquisadores para decisão dos melhores valores para utilização. A coluna de valores definidos se refere aos valores que foram definidos a partir de testes, através de levantamento da literatura ou através da experiência dos pesquisadores.

Tabela 2.1 - Tamanhos de população utilizados em diferentes estudos

Estudo	Tamanho da População	
	Valores testados	Valores definidos
Alrashdan <i>et al.</i> (2014)	-	20
Anagun e Ozcelik (2005)	60 - 100	-
Angelova e Pencheva (2011)	-	20
Candan e Yazgan (2014)	50 - 150	150
Costa <i>et al.</i> (2005)	43 - 58	-
Grefenstette (1986)	10 - 160	-
Gomes <i>et al.</i> (2012)	-	150
Hosseini <i>et al.</i> (2014)	-	50
Kozenzy (2015)	-	200
Kumar (2006)	-	20
Loughlin <i>et al.</i> (2000)	20 - 100	100
Montazer-Rakmati e Binaee (2010)	-	60
Oliveira <i>et al.</i> (2010)	50 - 500	500
Ortiz <i>et al.</i> (2004)	20 - 50	20
Pinho (2008)	50 - 200	-
Sankar <i>et al.</i> (2003)	-	20
Zain <i>et al.</i> (2010)	-	100

Fonte: próprio autor

Quanto maior o tamanho da população, maior é a chance de se obter soluções satisfatórias, porém uma população muito grande pode aumentar o número de avaliações e aumentar o tempo de busca do algoritmo (CANDAN e YAZGAN, 2014). Ao mesmo tempo, se o tamanho da população é muito pequeno, não serão obtidas informações suficientes sobre o espaço de busca, o que pode levar o algoritmo a encontrar um ponto de ótimo local, e não o ótimo global (ORTIZ *et al.*, 2004).

Goldberg (1989) propôs que o tamanho da população em problemas usando cromossomos binários de comprimento l , deve ser uma função exponencial de l , de acordo com a Equação (2.22), onde k representa o número de bits do cromossomo.

$$N = 1,65 \times 2^{0,21k} \quad (2.22)$$

Segundo Liepins e Hilliard (1989), a equação proposta por Goldberg (1989) gera tamanhos de população ou impraticavelmente pequenos ou impossivelmente grandes. Ainda segundo os autores, o mais comum é a utilização de tamanhos de população entre 50 e 200, ou ainda em alguns casos, na faixa de 400.

Para Mayer *et al.* (2001), trabalhar com um tamanho de população que seja duas vezes a dimensionalidade do problema é um número eficiente e seguro. A dimensionalidade é o número de fatores do problema estudado (ORTIZ *et al.*, 2004).

2.3.4.2 Tipo de Seleção

O método de seleção escolhido para um GA define quais cromossomos serão selecionados para a próxima geração. Diferentes métodos são listados na literatura, como seleção por classificação, seleção uniforme estocástica, seleção por torneio, o método da roleta, entre outros.

A escolha do método de seleção também não é unificada. O Quadro 2.5 apresenta exemplos de estudos com aplicações dos diferentes tipos de seleção.

Quadro 2.5 - Tipos de seleção utilizados em diferentes estudos	
Estudo	Tipo de seleção
Alrashdan <i>et al.</i> (2014)	Classificação
Angelova e Pencheva (2011)	Roleta
Candan e Yazgan (2014)	Roleta / Torneio
(CHAUDHURI <i>et al.</i> , 2014)	Roleta
Gopalakrishnan e Kosanovic (2015)	Roleta / Torneio / Estocástica Uniforme
Hosseini <i>et al.</i> (2014)	Torneio
Kozenzy (2015)	Estocástica Uniforme
Kumar (2006)	Classificação
Mayer <i>et al.</i> (2001)	Torneio
Ortiz <i>et al.</i> (2004)	Classificação / Torneio
Sankar <i>et al.</i> (2003)	Classificação

Fonte: próprio autor

No método de seleção por classificação, as soluções são classificadas de acordo com os valores de aptidão em ordem decrescente. Por exemplo, o cromossomo mais apto fica em primeiro lugar, o segundo mais apto recebe o segundo lugar e assim por diante, até que o número de pais desejado seja atingido. Segundo Álvarez *et al.* (2009), existem duas versões desse tipo de seleção. Uma delas inclui na classificação os cromossomos da geração atual e da anterior. A outra utiliza somente a geração atual.

O método de seleção uniforme estocástica estabelece uma linha seccionada onde cada seção dessa linha corresponde a um cromossomo pai e é atribuída proporcionalmente aos valores de *fitness* de cada um desses cromossomos. O algoritmo parte de um ponto escolhido aleatoriamente e move-se ao longo desta linha em tamanhos de passo iguais. Os cromossomos selecionados são aqueles que correspondem às seções onde o algoritmo chega após cada passo.

A seleção por torneio escolhe aleatoriamente um determinado número de indivíduos (estipulado anteriormente). Os indivíduos escolhidos são avaliados e então são selecionados alguns dos que apresentam melhor avaliação para serem utilizados na geração da nova população. Esse processo é repetido até que todo o número de cromossomos determinado pelo tamanho da população seja atendido (ORTIZ *et al.*, 2004).

O método da roleta foi proposta por Holland (1975) e ainda tem sido muito utilizado. Como o próprio nome diz, este tipo de seleção simula uma roleta onde a área de cada segmento é proporcional à aptidão do indivíduo relacionado a este segmento. Na sequência, o algoritmo utiliza um número aleatório para selecionar uma das seções. A probabilidade de um cromossomo ser selecionado é então proporcional à área da roleta ocupada por ele.

2.3.4.3 Tipo de *Crossover*

Como mencionado anteriormente, a operação de *crossover* envolve a escolha de dois indivíduos da população para a troca de informações genéticas entre eles, para a formação de novos indivíduos. O tipo de *crossover* escolhido na configuração do algoritmo determina como ocorrerá a troca da informação genética. Os tipos de *crossover* mais utilizados são o de um ponto, de dois pontos e o cruzamento difuso.

Não há definição sobre qual o melhor tipo de cruzamento para um determinado GA. O Quadro 2.6 apresenta alguns trabalhos que utilizam os diferentes tipos de *crossover* apresentados anteriormente.

No cruzamento de um ponto, é escolhido um ponto aleatório dos cromossomos, onde eles serão divididos. A primeira parte de um cromossomo será combinada com a segunda

parte do segundo cromossomo para gerar um filho (COSTA *et al.*, 2005), como exemplificado na Figura 2.13.

Quadro 2.6 - Tipos de *crossover* utilizados em diferentes estudos

Estudo	Tipo de <i>crossover</i>
Angelova e Pencheva (2011)	Dois Pontos
Gopalakrishnan e Kosanovic (2015)	Um ponto / Dois pontos / Difuso
Hosseini <i>et al.</i> (2014)	Dois pontos
Kozeny (2015)	Um ponto
Kumar (2006)	Um ponto
Sankar <i>et al.</i> (2003)	Um ponto

Fonte: próprio autor




Figura 2.13 - Cruzamento de um ponto
Fonte: próprio autor

O cruzamento de dois pontos segue o mesmo princípio do cruzamento de um ponto, porém utiliza-se de dois pontos de corte do cromossomo, como exemplificado na Figura 2.14.




Figura 2.14 - Cruzamento de dois pontos
Fonte: próprio autor

No cruzamento difuso (*scattered crossover*) primeiramente é criado um vetor binário e então os *bits* dos cromossomos são selecionados de acordo com este cordão binário. A Figura 2.15 apresenta um exemplo deste tipo de *crossover*. Nos pontos onde o valor dos *bits* do cordão binário criado é 1, os *bits* selecionados são do Pai 1. Onde o valor dos bits do cordão é 0, os *bits* selecionados são os do Pai 2. Os *bits* selecionados serão combinados para formar o filho (GOPALAKRISHNAN e KOSANOVIC, 2015).




Figura 2.15 - Cruzamento difuso
Fonte: próprio autor

2.3.4.4 Taxa de *Crossover*

A taxa de *crossover* se refere à porcentagem da população de pais que irão sofrer a operação de *crossover*. Como é uma probabilidade, corresponde a um valor entre 0 e 1.

Segundo Ortiz *et al.* (2004), enquanto uma taxa de *crossover* alta pode causar o descarte de boas soluções, uma taxa muito baixa pode dar muita atenção aos cromossomos pais e então estagnar a busca. De acordo com Grefenstette (1986), quanto maior a taxa de *crossover*, mais rapidamente novas estruturas são introduzidas na população.

Existe também uma divergência de opiniões entre pesquisadores sobre quais os melhores valores para a taxa de cruzamento. A Tabela 2.2 apresenta o levantamento das taxas de cruzamento testadas e utilizadas em alguns estudos.

Tabela 2.2 - Taxas de *crossover* utilizadas em diferentes estudos

Estudo	Taxa de <i>Crossover</i>	
	Valores testados	Valores definidos
Alrashdan <i>et al.</i> (2014)	-	0,6
Anagun e Ozcelik (2005)	0,3 - 0,9	-
Candan e Yazgan (2014)	0,1 - 0,9	0,9
Costa <i>et al.</i> (2005)	0,68 - 0,92	-
Grefenstette (1986)	0,25 - 1	-
Hosseini <i>et al.</i> (2014)	-	0,9
Kozeny (2015)	-	0,8
Montazer-Rakmati e Binaee (2010)	-	0,8
Oliveira <i>et al.</i> (2010)	0,5 - 0,8	0,8
Ortiz <i>et al.</i> (2004)	0,5 - 0,85	0,85
Pinho (2008)	0,1 - 0,8	0,8
Sankar <i>et al.</i> (2003)	0,4 - 0,9	0,6
Zain <i>et al.</i> (2010)	-	0,8

Fonte: próprio autor

2.3.4.5 Tipo de Mutação

Assim como nas operações de seleção e recombinação, muitos métodos de mutação podem ser encontrados na literatura. Os mais comuns são a mutação uniforme, a Gaussiana e a *Adaptive Feasible*.

A mutação uniforme seleciona, aleatoriamente, um ou mais genes do cromossomo pai e os substitui por um número aleatório, seguindo uma distribuição uniforme, dentro do espaço de solução (ORTIZ *et al.*, 2004).

A mutação Gaussiana adiciona um número aleatório a cada gene de um indivíduo seguindo uma distribuição Gaussiana, geralmente centrada em 0 e com um desvio padrão σ_i (onde i indica um gene específico do cromossomo). Com a adição de um número a cada gene, os novos cromossomos são localizados em alguma região vizinha à região de busca de seus pais. Assim, este tipo de mutação garante que o espaço de busca não seja limitado ao mesmo definido pela população dos cromossomos pais (HEREDIA-LANGNER *et al.*, 2002).

A mutação *Adaptive Feasible* gera direções de busca aleatórias, respeitando a última geração bem sucedida ou não, onde a região de busca é limitada pelas restrições do problema. Um comprimento de passo é escolhido ao longo de cada direção para que as restrições sejam satisfeitas. Segundo Pais *et al.* (2010), este processo de mutação inicia com a geração aleatória de um vetor de direção de mutação e um comprimento de passo inicial. Em seguida, um novo indivíduo é gerado, e se o mesmo estiver localizado em uma região inviável, o comprimento de passo é reajustado e o procedimento é repetido até que o novo indivíduo seja localizado na região viável.

A escolha do tipo de mutação depende muito do tipo de problema utilizado. A mutação *Adaptive Feasible* é indicada para solução de problemas restritos, enquanto a mutação Gaussiana é contraindicada na solução de problemas com restrições lineares.

Alguns estudos testaram diferentes funções de mutação para avaliação da mais adequada. Ortiz *et al.* (2004) testou as mutações Uniforme e Gaussiana em um problema irrestrito e chegou à conclusão de que a função Gaussiana era a mais adequada para a aplicação. Gopalakrishnan e Kosanovic (2015) também testaram a eficiência de cada uma dessas funções. Já o estudo de Hosseini *et al.* (2014) utilizou a função *Adaptive Feasible*.

2.3.4.6 Taxa de Mutação

A taxa de mutação se refere à porcentagem da população de pais que irão sofrer a operação de mutação. Assim como a taxa de *crossover*, este parâmetro é uma probabilidade e corresponde a um valor entre 0 e 1.

Segundo Pinho (2008), pode-se observar que para uma taxa de mutação muito baixa, pode acontecer que a busca fique estagnada em um ótimo local. Em contrapartida, com uma taxa muito alta, a busca torna-se essencialmente aleatória.

A

Tabela 2.3 apresenta diferentes valores testados e definidos em alguns trabalhos. Esta tabela deixa clara a grande diferença entre os valores geralmente utilizados, que vão desde 0,001 a 1,0.

Tabela 2.3 - Taxas de mutação utilizadas em diferentes estudos

Estudo	Taxa de Mutação	
	Valores testados	Valores definidos
Alrashdan <i>et al.</i> (2014)	-	0,2
Anagun e Ozcelik (2005)	0,001 - 0,01	-
Candan e Yazgan (2014)	0,5 - 0,15	0,15
Costa <i>et al.</i> (2005)	0,0425 - 0,0575	-
Gomes <i>et al.</i> (2012)	-	0,1
Kozenzy (2015)	-	0,15
Kumar (2006)	-	0,3
Loughlin <i>et al.</i> (2000)	0,0001 - 0,01	0,001
Montazer-Rakmati e Binaee (2010)	-	0,01
Oliveira <i>et al.</i> (2010)	0,05 - 0,3	0,3
Ortiz <i>et al.</i> (2004)	0,1 - 0,4	0,4
Pinho (2008)	0,01 - 0,1	0,1
Sankar <i>et al.</i> (2003)	0,001 - 0,01	0,005
Zain <i>et al.</i> (2010)	-	1,0

Fonte: próprio autor

2.3.4.7 Número de Gerações

Em muitos casos, se critérios de parada não são estabelecidos, o algoritmo pode ficar procurando o ponto ótimo por muito tempo. O número de gerações é um parâmetro utilizado como um critério de parada do algoritmo. Se o algoritmo atingir o número de gerações máximo determinado, sem chegar a um ponto de ótimo, o algoritmo deve cessar a busca.

Como no caso dos outros parâmetros, não existe um consenso sobre um número de gerações ideal para uma corrida do GA. Neste caso, porém, percebe-se ainda a utilização de valores muito distintos em diferentes estudos. Alguns pesquisadores utilizam números bem pequenos, entre 20 e 30 gerações, enquanto outros utilizam até mais de 1000 gerações. A Tabela 2.4 exemplifica a utilização deste parâmetro em alguns estudos.

Tabela 2.4 - Números de gerações utilizados em diferentes estudos

Estudo	Numero de Gerações	
	Valores testados	Valores definidos
Alrashdan <i>et al.</i> (2014)		10000
Angelova e Pencheva (2011)		20
Costa <i>et al.</i> (2005)	43 - 58	-
Hosseini <i>et al.</i> (2014)		1000
Montazer-Rakmati e Binaee (2010)		10000
Oliveira <i>et al.</i> (2010)	20 - 200	25
Pinho (2008)	50 - 100	-
Sankar <i>et al.</i> (2003)	-	100

Fonte: próprio autor

2.3.4.8 Outros parâmetros

Como mencionado anteriormente, existem inúmeros parâmetros para a configuração do Algoritmo Genético. Nas seções anteriores foram citados os mais comuns na literatura, porém existem muitos outros, que variam com o software utilizado para realizar a otimização ou com a programação do algoritmo. Abaixo estão listados mais alguns parâmetros que podem ser configurados no *Matlab*[®] *Optimization Toolbox*, que foi o software utilizado neste estudo:

- Tipo de população: especifica o tipo de entrada para a função *fitness*;
- Função de criação: especifica a função que cria a população inicial;
- População inicial: permite a especificação da população inicial para o algoritmo. Se a população inicial não é especificada, a função de criação será utilizada para a geração da população inicial;
- Classificação inicial: permite a classificação da população inicial determinada. Se essa classificação não for especificada, o algoritmo utilizará a função *fitness* para a classificação;
- Faixa inicial: especifica os limites mínimo e máximo para as entradas dos vetores da população inicial;
- Função de escala: especifica a função que realiza o dimensionamento da função *fitness*;
- Contagem de elite: especifica a quantos indivíduos é garantida a sobrevivência para a próxima geração;
- Direção de migração: determina como ocorrerá a migração de cromossomos de uma subpopulação para outra;

- Taxa de migração: como a taxa de crossover, é uma probabilidade e comanda qual a porcentagem de indivíduos sofrerão a migração;
- Intervalo de migração: controla o intervalo de gerações nas quais haverá migração;
- Função híbrida: permite a especificação de outra função de minimização que é executada após o término da evolução do algoritmo genético.

2.3.5 Configuração dos Parâmetros do Algoritmo Genético

Como mencionado na seção anterior, os Algoritmos Genéticos exigem a configuração de vários parâmetros para garantir um bom desempenho na solução de problemas de otimização.

Para contornar os problemas em relação à configuração dos parâmetros do algoritmo, algumas técnicas adaptativas foram desenvolvidas (SRINIVAS e PATNAIK, 1994; LIM *et al.*, 2015). Nestas técnicas, os parâmetros do algoritmo são ajustados no decorrer das etapas do mesmo. Contudo, utilizando essas técnicas, o problema deixa de ser a configuração dos parâmetros e passa a ser um problema de controle desses parâmetros durante as iterações do algoritmo (EIBEN e SMIT, 2012).

Para aqueles que preferem utilizar as técnicas convencionais, a escolha dos parâmetros adequados ainda é um desafio. Dados da literatura divergem sobre os melhores valores para a configuração desses parâmetros, até porque eles podem variar de acordo com os problemas a serem resolvidos. Com isso, algumas pesquisas têm sido feitas, utilizando diferentes métodos, para a identificação da melhor configuração de parâmetros para cada problema.

Um procedimento bastante utilizado pelos pesquisadores é o teste de diferentes combinações de parâmetros, definidas por eles mesmos, até encontrar a que oferece um melhor resultado. O estudo realizado por Alajmi e Wright (2014), por exemplo, avaliou a sensibilidade do GA a diferentes parâmetros utilizando testes de hipóteses na comparação de resultados encontrados para diferentes combinações dos parâmetros, decididas aleatoriamente. Mayer *et al.* (2001) utilizou uma estratégia parecida para a otimização de modelos de sistemas agrícolas, onde os parâmetros foram testados em combinações definidas pelos próprios pesquisadores.

Outro procedimento possível é a utilização de um Algoritmo Genético específico, chamado Meta-GA, para a otimização dos parâmetros de outro GA. Neste caso, a população do Meta-GA consiste de um grupo de GAs, onde cada um deles utilizará uma configuração de

parâmetros diferente. O meta-GA então será capaz de identificar qual é a melhor configuração (NÚÑEZ-LETAMENDIA, 2007). O estudo realizado por Grefenstette (1986) utilizou um meta-GA para otimizar os parâmetros aplicados na otimização de diferentes funções matemáticas. Nuñez-Letamendia (2007) utilizou o Meta-GA para avaliar a influência de alguns parâmetros na solução de problemas de sistemas de negociação do mercado financeiro. O mesmo procedimento foi utilizado por Fernandes-Prieto *et al.* (2011) para a otimização dos parâmetros para a utilização em testes de redes computacionais.

Planejamento de experimentos também tem sido utilizado por alguns pesquisadores para a otimização dos parâmetros do GA. Ortiz *et al.* utilizaram (2004) um arranjo fatorial fracionado para propor um Algoritmo Genético robusto que utiliza os parâmetros otimizados e a função *desirability*. O estudo realizado por Costa *et al.* (2005) também utilizou um arranjo fatorial fracionado para encontrar o melhor *setup* de parâmetros que seriam aplicados na otimização de um processo de cristalização em modo batelada. Costa *et al.* (2007) utilizaram arranjos fatoriais para avaliar a influência dos parâmetros em diversos estudos de caso. Pinho (2008) utilizou um arranjo fatorial completo para analisar o efeito do comportamento dos parâmetros do GA no tempo de convergência e na qualidade das respostas do algoritmo. Um pouco mais sofisticado, um arranjo do tipo Taguchi foi utilizado por Candan e Yazgan (2014) para determinar quais os melhores parâmetros do GA para um problema de programação de um Sistema Flexível de Manufatura (FMS).

Os estudos que utilizaram DOE, como mencionado anteriormente, analisaram, além dos efeitos dos parâmetros, o efeito das interações existentes entre eles. Foram encontradas interações significativas em todas as pesquisas, porém nenhum desses estudos avaliou a possível interação entre os parâmetros e os pesos das funções objetivo, pois nenhum dos problemas de otimização utilizados envolvia a ponderação de funções objetivo.

3 PROCEDIMENTO EXPERIMENTAL

3.1. Procedimento proposto

A complexidade do problema de otimização multiobjetivo pode aumentar dependendo da distribuição de pesos atribuída às funções objetivo originais. Logo, pressupõe-se que os parâmetros do algoritmo utilizado para a solução deste problema de otimização devam ser adequados para uma tarefa mais complexa. Este trabalho tem como proposta mostrar que pode haver interação entre os pesos das funções objetivo e os parâmetros utilizados no algoritmo de solução do problema, através da utilização de um arranjo de misturas combinado com variáveis de processo, bem como interações entre os próprios parâmetros do GA.

Visando avaliar a influência dos parâmetros utilizados pelo Algoritmo Genético na solução de um problema multiobjetivo e determinar quais dos parâmetros testados oferece os melhores resultados para este problema em específico, um procedimento experimental foi desenvolvido. Neste caso, os parâmetros do algoritmo serão considerados como variáveis de processo e serão avaliados em um arranjo experimental de misturas combinado com variáveis de processo, onde as proporções da mistura serão os pesos das funções objetivo. Para isso, a estratégia utilizada neste trabalho foi desenvolvida de acordo com o seguinte procedimento, dividido em cinco passos:

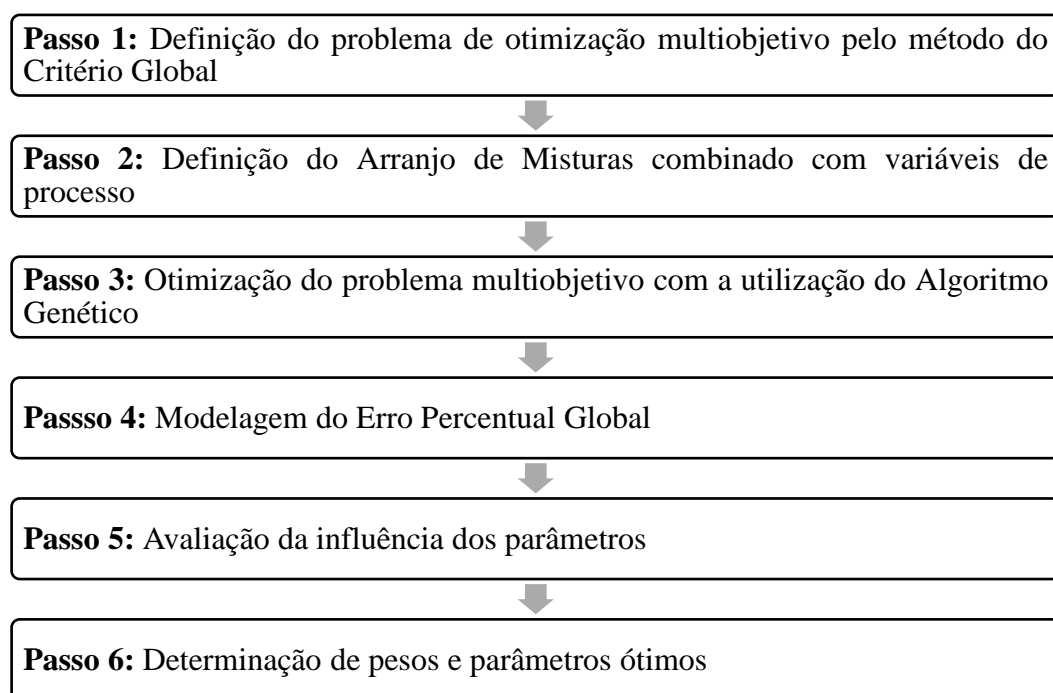


Figura 3.1 - Resumo do procedimento experimental aplicado

No **passo 1**, deve-se definir o processo a ser otimizado, assim como as respostas que serão avaliadas e as variáveis de controle do processo. Neste trabalho, o processo escolhido já possui as suas respostas modeladas. No caso de processos onde as respostas ainda não foram modeladas, a modelagem pode ser feita através de algum procedimento experimental, como discutido na seção 2.2. As respostas modeladas são então otimizadas individualmente para estabelecer os valores de máximo e mínimo individuais. Com estes valores é então possível definir a função do Método do Critério Global, que caracterizará o MOP do estudo, junto com as restrições necessárias para o problema.

No **passo 2**, o arranjo de misturas é definido para que os pesos das funções objetivo e as configurações de teste dos parâmetros do algoritmo sejam determinados.

No **passo 3**, é realizada a otimização da função definida no passo 1, utilizando o Algoritmo Genético e alterando-se os pesos das funções e os parâmetros do algoritmo, como estabelecido no arranjo de misturas do passo 2, para um determinado número de réplicas do arranjo. Os resultados das otimizações de cada experimento serão utilizados para o cálculo do EPG.

No **passo 4**, a função Erro Percentual Global (EPG) é modelada, de maneira semelhante à modelagem das funções objetivo. Análises estatísticas são aplicadas para determinação do ajuste do modelo obtido.

Por fim, no **passo 5**, é realizada a otimização final, onde são determinados os pesos ótimos das funções objetivo e a configuração adequada dos parâmetros para este problema multiobjetivo. Deve-se também avaliar as interações entre os pesos e os parâmetros testados e ainda o efeito dos parâmetros do GA sobre a função EPG.

As próximas seções deste capítulo apresentam a aplicação do procedimento experimental proposto em um processo de soldagem.

3.2. Modelagem das respostas do processo de soldagem

O procedimento proposto neste trabalho será aplicado ao processo de soldagem com arame tubular no revestimento de chapas de aço carbono ABNT 1020 utilizando o aço inoxidável austenítico ABNT 316L, realizado por Gomes (2013). O trabalho em questão realizou o planejamento de experimentos, a coleta de dados e a modelagem das funções objetivo deste processo de soldagem de revestimento, através da metodologia de superfície de resposta.

Os parâmetros de soldagem selecionados como variáveis de entrada foram velocidade de alimentação do arame (Va), tensão (T), velocidade de soldagem (Vs) e distância bico de contato peça (N). Os níveis dos parâmetros foram fixados, como mostra a Tabela 3.1.

Tabela 3.1 - Parâmetros de soldagem e níveis de trabalho

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

Fonte: Gomes (2013)

A velocidade de alimentação do arame (Va) é responsável por controlar o fluxo de corrente do processo e variações inesperadas ou o controle inadequado deste parâmetro pode gerar instabilidades no processo. A tensão (T) determina o comprimento do arco que controla o perfil do cordão, afetando características como a profundidade de penetração. A velocidade de soldagem (Vs) é a relação entre o caminho percorrido pelo arco ao longo da peça e o tempo gasto para percorrê-lo e a distância bico de contato peça (N) define a distância entre o último ponto de contato elétrico e a peça de trabalho e afeta a corrente de soldagem necessária para fundir o arame a uma dada velocidade de alimentação, influenciando diretamente na estabilidade do arco (GOMES, 2013).

As respostas analisadas para este processo incluíram a largura do cordão (W), penetração (P), reforço (R) e diluição (D), que representam as características geométricas do cordão de revestimento. Também foram analisadas mais quatro respostas relacionadas à produtividade do processo e qualidade superficial, porém essas respostas não serão consideradas neste trabalho.

No processo de soldagem de revestimento, o perfil geométrico desejado se resume a grandes larguras do cordão (W), altos reforços (R) e penetrações (P) e percentuais de diluição (D) baixos. Segundo Gomes (2013), a obtenção deste perfil geométrico característico resulta em economias significativas de materiais e tempo. Portanto, um dos maiores desafios deste tipo de processo consiste no ajuste adequado dos parâmetros de entrada para que o material depositado adquira a geometria desejada. A Figura 3.2 apresenta o perfil geométrico desejado do cordão de solda para este processo.

O sequenciamento dos experimentos realizado por Gomes (2013) foi definido por um arranjo composto central (CCD), criado para quatro parâmetros em dois níveis ($2^k = 2^4 = 16$),

oito pontos axiais ($2k = 8$) e sete pontos centrais ($cp = 7$), o que resultou em 31 experimentos. Para o arranjo CCD, adotou-se uma distância codificada α de 2,0. O arranjo experimental utilizado completo pode ser visualizado em anexo neste trabalho.

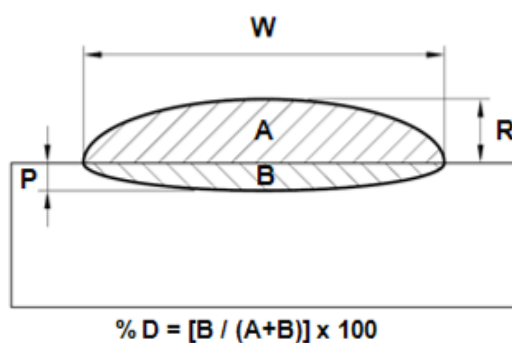


Figura 3.2 – Perfil geométrico desejado do cordão de solda na soldagem de revestimento
Fonte: adaptado de GOMES (2013)

Com a matriz experimental definida, os experimentos foram então realizados. Os cordões de aço inoxidável foram simplesmente depositados sobre as chapas de aço carbono, levando em consideração o ajuste dos parâmetros definidos pelo arranjo experimental (GOMES, 2013). As dimensões do cordão foram preparadas e mensuradas, obtendo-se a largura, penetração, reforço, área de penetração e área total da solda. O percentual de diluição foi então calculado dividindo-se a área de penetração pela área total. A Figura 3.3 apresenta exemplos dos cordões de solda preparados para as medições. Os resultados obtidos nas medições para cada experimento também podem ser visualizados em anexo neste trabalho.




Figura 3.3 - Geometria dos cordões após a preparação dos corpos de prova
Fonte: GOMES (2013)

As funções objetivo para a otimização das características dos revestimentos do processo de soldagem foram determinadas por Gomes (2013), levando em consideração o

modelo de superfície de resposta de segunda ordem, que quando escrito como função dos quatro parâmetros de soldagem relacionados neste estudo, chega-se ao seguinte polinômio:

$$y = \beta_0 + \beta_1 Va + \beta_2 T + \beta_3 Vs + \beta_4 N + \beta_{11} Va^2 + \beta_{22} T^2 + \beta_{33} Vs^2 + \beta_{44} N^2 + \beta_{12} VaT + \beta_{13} VaVs + \beta_{14} VaN + \beta_{23} TVs + \beta_{24} TN + \beta_{34} VsN \quad (3.1)$$

A estimação dos coeficientes β_i , β_{ii} e β_{ij} foi realizada através do software estatístico *Minitab*®, utilizando o método dos Mínimos Quadrados Ordinários (OLS). Após estes cálculos, os coeficientes indicados na Tabela 3.2 foram obtidos. Estes coeficientes representam os modelos quadráticos completos desenvolvidos para as respostas.

Tabela 3.2 - Coeficientes estimados para os modelos quadráticos completos

Coeficiente	Respostas			
	W	P	R	D
β_0	10,700	1,619	2,590	31,219
β_1	0,797	0,122	0,192	-0,282
β_2	0,656	0,122	-0,105	2,493
β_3	-1,451	0,093	-0,223	3,679
β_4	-0,629	-0,241	0,116	-4,250
β_{11}	-0,003	0,027	0,007	-0,230
β_{22}	-0,024	-0,030	0,035	-0,742
β_{33}	0,264	-0,116	0,020	-1,249
β_{44}	-0,044	0,019	0,037	0,031
β_{12}	0,266	0,034	-0,031	0,771
β_{13}	-0,114	0,076	-0,015	0,497
β_{14}	-0,031	-0,100	-0,022	-0,418
β_{23}	-0,102	0,000	-0,005	0,226
β_{24}	-0,006	0,005	0,015	-0,199
β_{34}	0,067	0,005	-0,014	-0,771

Fonte: Gomes (2013)

A adequação dos modelos foi verificada através da Análise de Variância (ANOVA), feita também pelo software *Minitab*®. Os modelos encontrados foram adequados, pois apresentaram *p-values* inferiores a 5% de significância e os valores de $R^2(adj.)$ foram superiores a 80%. Os modelos para a largura do cordão e a diluição apresentaram falta de ajuste (*Lack-of-fit* < 0,05). No entanto, foi possível corrigir estes dados através do procedimento de redução dos modelos, onde estes foram reduzidos através da remoção dos termos não significativos. O critério adotado para esta remoção foi o aumento do valor de $R^2(adj.)$ e a redução da variância *S* dos modelos. Assim, os modelos finais apresentaram os formatos descritos pelas Equações (3.2) a (3.5).

$$W = 10,640 + 0,797Va + 0,656T - 1,451Vs - 0,629N + 0,270Vs^2 + 0,266VaT - 0,114VaVs - 0,102TVs + 0,067VsN \quad (3.2)$$

$$P = 1,639 + 0,122Va + 0,122T + 0,093Vs - 0,241N + 0,025Va^2 - 0,032T^2 - 0,118Vs^2 + 0,034VaT + 0,076VaVs - 0,100VaN \quad (3.3)$$

$$R = 2,597 + 0,191Va - 0,104T - 0,223Vs + 0,115N + 0,034T^2 + 0,019Vs^2 + 0,036N^2 - 0,030VaT - 0,023VaN \quad (3.4)$$

$$D = 31,034 - 0,282Va + 2,493T + 3,679Vs - 4,251N - 0,723T^2 - 1,229Vs^2 + 0,769VaT + 0,497VaVs - 0,418VaN - 0,771VsN \quad (3.5)$$

3.3. Definição do problema de otimização

Nesta seção inicia-se a aplicação do procedimento experimental proposto neste trabalho. Com as respostas do processo definidas e modeladas, pode-se então definir o problema de otimização, com a aplicação do Método do Critério Global.

Após a modelagem das equações para W , P , R e D , os valores para os pontos de ótimo, $f_i(x^*)$, e os pontos de máximo, $f_i(x)^{\max}$, para as quatro respostas foram estabelecidos através da otimização individual restrita de cada uma delas. As respostas largura do cordão (W) e reforço (R) foram maximizadas enquanto as respostas penetração (P) e diluição (D) foram minimizadas. Os valores encontrados nas otimizações individuais estão apresentados na Tabela 3.3.

Tendo o Método do Critério Global como técnica de programação matemática, de acordo com a Equação (2.6), o problema de otimização definido e os resultados das otimizações individuais, pode-se escrever o problema de otimização como:

$$\begin{aligned} \text{Min } G = w_1 \cdot \left(\frac{15,576 - W}{-3,125} \right)^2 + w_2 \cdot \left(\frac{0,828 - P}{0,584} \right)^2 \\ + w_3 \cdot \left(\frac{3,342 - R}{-0,287} \right)^2 + w_4 \cdot \left(\frac{16,275 - D}{7,796} \right)^2 \quad (3.6) \\ \text{s. a.: } Va^2 + T^2 + Vs^2 + N^2 \leq 4,0 \end{aligned}$$

onde: G – Critério global

W, P, R, D – Funções objetivo definidas nas Equações (3.2) a (3.5).

w_1, w_2, w_3, w_4 – Pesos atribuídos a cada uma das funções

A restrição apresentada na Equação (3.6) se refere à restrição esférica para o arranjo CCD, $\mathbf{x}^T \mathbf{x} \leq \alpha^2$, onde $\mathbf{x}^T \mathbf{x}$ é a soma dos quadrados das funções objetivo e $\alpha = 2,0$.

Tabela 3.3 - Resultados das otimizações individuais

i	$f_i(x^*)$	$f_i(x^{max})$	Delta
W	15,576	12,451	-3,125
P	0,828	1,411	0,584
R	3,342	3,055	-0,287
D	16,275	24,071	7,796

3.4. Definição do arranjo de misturas

Definido o problema de otimização, o próximo passo é a definição do arranjo de misturas com variáveis de processo. O arranjo de misturas determinará quais os pesos serão atribuídos para as funções em cada experimento e qual a configuração do algoritmo genético que deverá ser utilizada.

Os parâmetros do algoritmo genético escolhidos para análise como variáveis de processo para este trabalho foram o tamanho da população, a taxa de *crossover* e o tipo de mutação. Esses parâmetros serão representados por T_p , T_c e T_m , respectivamente, como apresentado na **Erro! Fonte de referência não encontrada.** A Tabela 3.4 apresenta os níveis definidos para o teste dos parâmetros.

Tabela 3.4 - Parâmetros do Algoritmo Genético e níveis de teste

Parâmetros	Notação	Níveis de teste	
		-1	+1
Tamanho da População	T_p	20	100
Taxa de <i>crossover</i>	T_c	0,15	0,85
Tipo de mutação	T_m	Gaussiana	<i>Adaptive Feasible</i>

Os parâmetros foram escolhidos com base no levantamento de parâmetros utilizados por pesquisadores apresentado na fundamentação teórica deste trabalho e em testes preliminares. A análise de todos os parâmetros tornaria este estudo muito exaustivo, o que levou à escolha de apenas três parâmetros considerados mais relevantes. O tamanho da população foi escolhido, pois, como afirmado por Lobo *et al.* (2007), este parâmetro é considerado o “candidato mais óbvio” em uma pesquisa de *setup* de parâmetros. A escolha da taxa de *crossover* pode ser justificada pelo fato de que a operação de *crossover* é considerada a principal operação genética, e que a taxa de *crossover* é o principal controle desta operação. Para que não fossem testados somente parâmetros quantitativos, optou-se pela escolha do tipo de mutação como parâmetro qualitativo.

Foi criado um arranjo de misturas *simplex lattice* de grau 4, para quatro componentes que representam os pesos de cada uma das respostas originais (w_1, w_2, w_3, w_4) e três variáveis de

processo (tamanho da população, taxa de *crossover* e tipo de mutação), onde o arranjo escolhido foi o fracionado (2^{k-1}). As proporções mínimas e máximas para cada componente foram definidas em 0 e 1.

Com as configurações definidas, criou-se o arranjo no *Minitab*[®], que resultou em 140 experimentos, com 35 combinações de peso para cada configuração do algoritmo genético. A Tabela 3.5 apresenta uma amostra dos experimentos determinados no arranjo, definido no cenário de $T_p = 20, T_c = 0,15$ e $T_m = Adaptive Feasible$. O arranjo completo está apresentado no Apêndice A.

Tabela 3.5 - Fragmento do arranjo de misturas *simplex lattice* definido

Teste	w₁	w₂	w₃	w₄	Tp	Tc	Tm
1	1,00	0,00	0,00	0,00	-1	-1	1
2	0,75	0,25	0,00	0,00	-1	-1	1
3	0,75	0,00	0,25	0,00	-1	-1	1
4	0,75	0,00	0,00	0,25	-1	-1	1
5	0,50	0,50	0,00	0,00	-1	-1	1
6	0,50	0,25	0,25	0,00	-1	-1	1
7	0,50	0,25	0,00	0,25	-1	-1	1
8	0,50	0,00	0,50	0,00	-1	-1	1
9	0,50	0,00	0,25	0,25	-1	-1	1
10	0,50	0,00	0,00	0,50	-1	-1	1
11	0,25	0,75	0,00	0,00	-1	-1	1
12	0,25	0,50	0,25	0,00	-1	-1	1
13	0,25	0,50	0,00	0,25	-1	-1	1
14	0,25	0,25	0,50	0,00	-1	-1	1
15	0,25	0,25	0,25	0,25	-1	-1	1
16	0,25	0,25	0,00	0,50	-1	-1	1
17	0,25	0,00	0,75	0,00	-1	-1	1
18	0,25	0,00	0,50	0,25	-1	-1	1
19	0,25	0,00	0,25	0,50	-1	-1	1
20	0,25	0,00	0,00	0,75	-1	-1	1
21	0,00	1,00	0,00	0,00	-1	-1	1
22	0,00	0,75	0,25	0,00	-1	-1	1
23	0,00	0,75	0,00	0,25	-1	-1	1
24	0,00	0,50	0,50	0,00	-1	-1	1
25	0,00	0,50	0,25	0,25	-1	-1	1
26	0,00	0,50	0,00	0,50	-1	-1	1
27	0,00	0,25	0,75	0,00	-1	-1	1
28	0,00	0,25	0,50	0,25	-1	-1	1
29	0,00	0,25	0,25	0,50	-1	-1	1
30	0,00	0,25	0,00	0,75	-1	-1	1
31	0,00	0,00	1,00	0,00	-1	-1	1
32	0,00	0,00	0,75	0,25	-1	-1	1
33	0,00	0,00	0,50	0,50	-1	-1	1
34	0,00	0,00	0,25	0,75	-1	-1	1
35	0,00	0,00	0,00	1,00	-1	-1	1

A Figura 3.4 permite a visualização da distribuição de alguns experimentos (os relacionados na Tabela 3.5) no sistema triangular de coordenadas que representa o arranjo *simplex lattice* definido.




Figura 3.4 - Distribuição dos experimentos no sistema triangular de coordenadas do arranjo *simplex lattice*

Também é possível representar a distribuição dos níveis dos parâmetros do GA em um gráfico de cubo, como é apresentado na Figura 3.5. Os vértices do cubo representam cada combinação possível dos parâmetros e os pontos vermelhos indicam as combinações que serão testadas neste trabalho. Serão testadas apenas as quatro combinações definidas pelo arranjo fatorial fracionado.

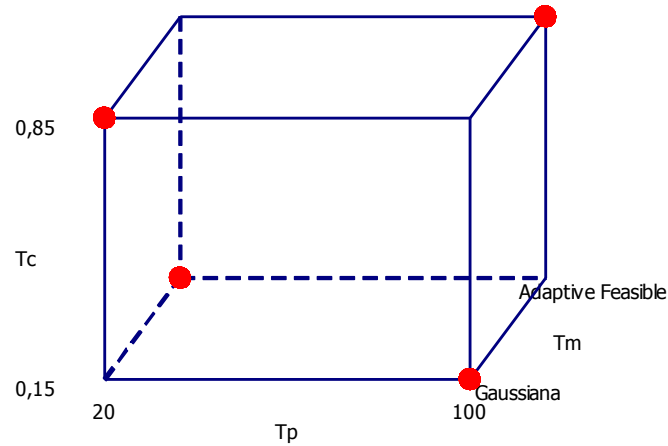


Figura 3.5 - Gráfico de cubo para definição de testes dos parâmetros do algoritmo genético

A Figura 3.6 representa uma parte do arranjo de misturas definido, sendo uma combinação da Figura 3.5 com alguns gráficos do sistema de coordenadas triangulares. É possível verificar através desta figura as configurações que não serão testadas (os triângulos que não apresentam os pontos vermelhos que representam os experimentos) já que um arranjo fatorial fracionado foi escolhido para o teste dos parâmetros. Um gráfico como esse só pode ser montado para 3 respostas, portanto a Figura 3.6 apresenta somente as combinações de peso onde w_4 é mantido zerado.




Figura 3.6 - Representação gráfica do arranjo de misturas definido

Levando em consideração o fato de que o algoritmo genético encontra diferentes soluções para o mesmo problema, devido à sua inicialização aleatória, é necessário que se tenha réplicas do arranjo para que se possa avaliar a variabilidade experimental. O cálculo do número de réplicas foi feito para o arranjo fatorial de dois níveis, com base no deslocamento do centroide dos arranjos de mistura quando há diferentes combinações de variáveis de processo. As curvas de poder de teste construídas para um desvio padrão amostral de 0,02 e nível de significância de 5% estão apresentadas na Figura 3.7.

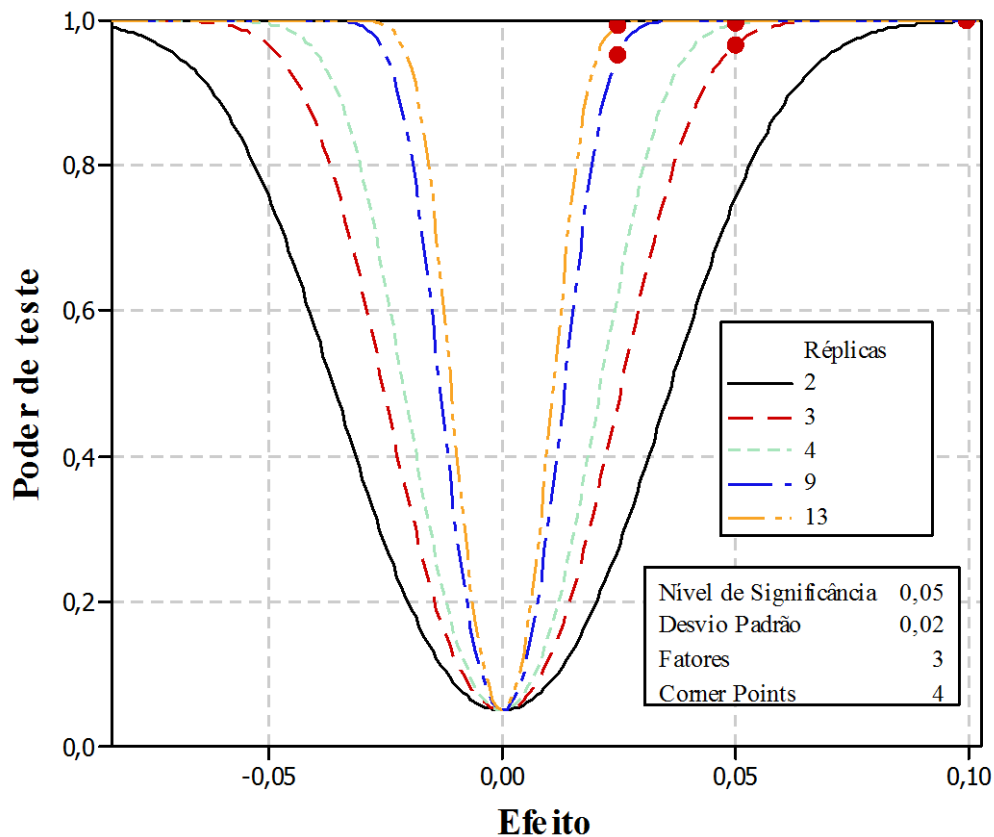


Figura 3.7 - Curva de poder de teste para determinação do número de réplicas do arranjo experimental

A curva de poder de teste gerada sugere diferentes números de réplicas, dependendo do poder de teste e do efeito desejados. Optou-se então por replicar o arranjo dez vezes, o que gerou 1400 experimentos no total.

3.5. Otimização pelo Algoritmo Genético

O problema de otimização definido foi programado e executado no *Matlab*[®]. Utilizou-se o Algoritmo Genético do *Optimization Toolbox*, pacote de otimização disponível no *Matlab*[®], por ser de fácil programação e simplificar a configuração dos parâmetros do

algoritmo. A Figura 3.8 apresenta a tela do *software*, exemplificando a aplicação da otimização da função programada e a configuração dos parâmetros.

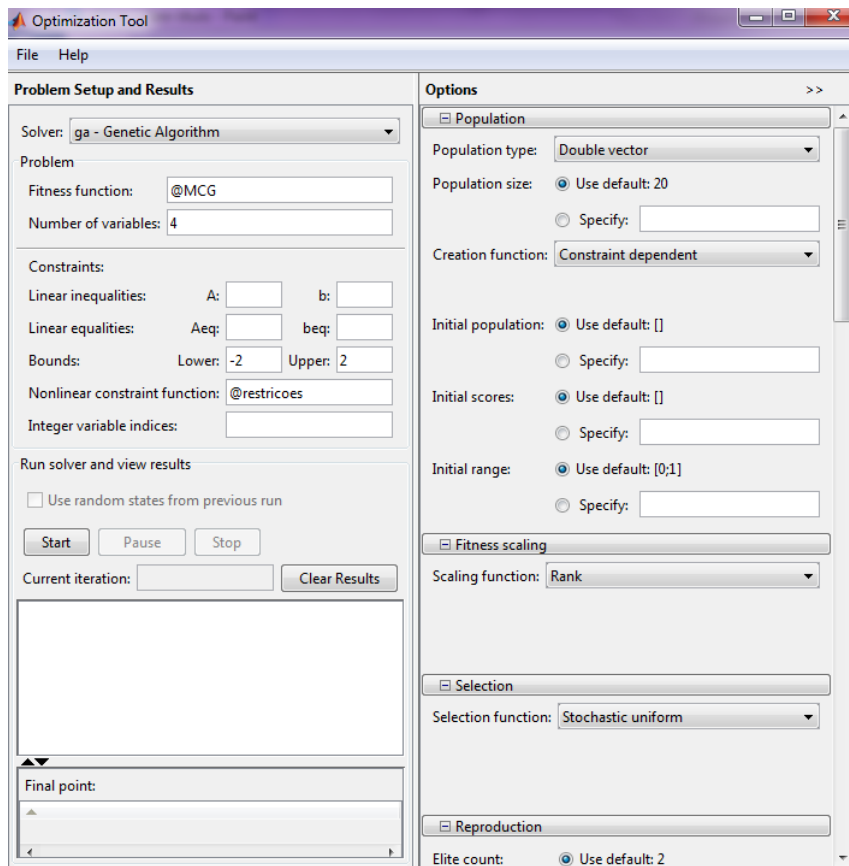


Figura 3.8- Tela do *Matlab*[®] *Optimization Toolbox*

Tabela 3.6 - Parâmetros fixos utilizados para o Algoritmo Genético

Parâmetros	Valores/Funções
Tipo de População	Vetor Duplo (<i>Double Vector</i>)
Função de Criação	Dependente da restrição (<i>Constraint Dependent</i>)
Função de escala	Classificação (<i>Rank</i>)
Tipo de seleção	Uniforme estocástica (<i>Stochastic Uniform</i>)
Tipo de <i>crossover</i>	Difuso (<i>Scattered</i>)
Direção de Migração	Para frente (<i>Forward</i>)
Função Híbrida	Nenhuma

As configurações dos parâmetros utilizados para o Algoritmo Genético, mantidas fixas em todos os experimentos, estão especificadas na Tabela 3.6, com exceção dos parâmetros para os quais foram utilizadas as configurações padrão (*default*) do *Optimization Toolbox*.

O problema foi otimizado de acordo com as 140 configurações de pesos e parâmetros determinados pelo arranjo de misturas, em 10 réplicas. Os resultados encontrados em cada uma das otimizações foram utilizados para o cálculo do Erro Percentual Global, segundo a

Equação (2.7). Os resultados das otimizações, assim como os resultados calculados para o EPG para cada experimento estão apresentados no Apêndice A.

A partir dos resultados encontrados para o EPG para os 1400 experimentos, é possível realizar a modelagem da função EPG, que é o quarto passo do procedimento experimental proposto. Os próximos passos do procedimento aplicado ao processo de soldagem estão apresentados no Capítulo 4 deste trabalho.

4 RESULTADOS E DISCUSSÕES

4.1 Modelagem do Erro Percentual Global

Assim, com o arranjo de misturas criado e os resultados calculados para o EPG de cada um dos experimentos em suas dez réplicas, foi possível a modelagem da função EPG, através do *Minitab*®. Para a análise do DOE, o modelo utilizado foi o modelo quártico completo de primeira ordem e o método de ajuste utilizado foi o *backward elimination*, onde parte-se do modelo completo e elimina-se todos os termos não significativos.

Os resultados da análise de variância para a modelagem da função EPG utilizando as 10 réplicas estão listados na Tabela 4.1. Apesar de o modelo não ter apresentado falta de ajuste (*Lack-of-fit*) e um $R^2(adj.)$ de 84,80%, os resíduos não apresentaram distribuição normal, pois o *p-value* do teste de normalidade (apresentado na Figura 4.1) foi menor que 0,05.

Tabela 4.1 - Análise de Variância para os modelos com dez réplicas

Resposta	DF	Adj. SS	Adj. MS	F	p-value	Lack-of-fit	$R^2(adj.)$
EPG	36	64,0384	1,7788	217,89	0,000	0,977	84,80
EPG _{Box-Cox}	24	950,895	39,621	157,71	0,000	0,968	72,89

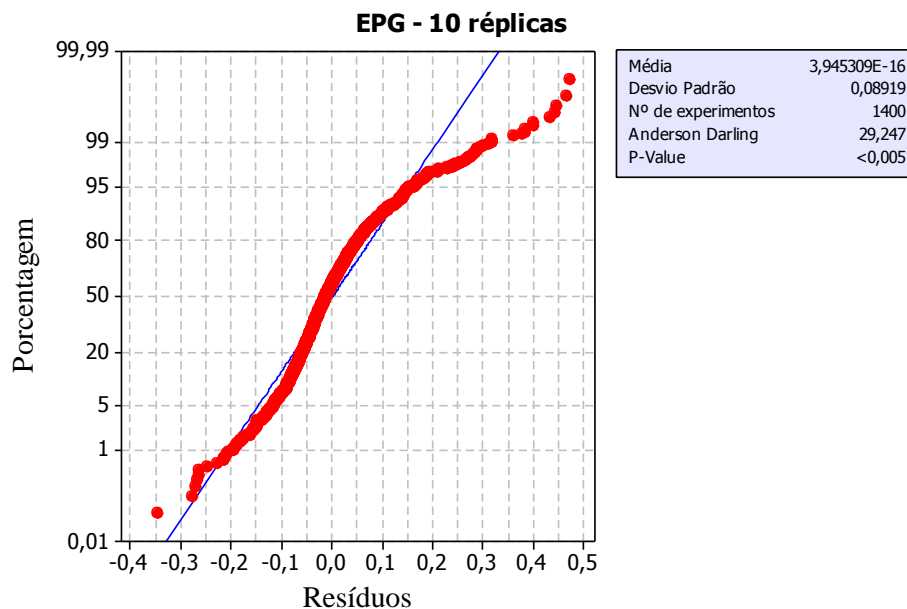


Figura 4.1 - Teste de normalidade dos resíduos para EPG com dez réplicas

A não-normalidade dos resíduos indica que o modelo pode não ser o mais adequado. Uma alternativa, neste caso, é utilizar uma função de transformação de dados para se obter a normalidade. Então, aplicou-se a transformação de Box-Cox, disponível no *Minitab*®, em

todos os resultados obtidos para EPG e analisou-se novamente o arranjo. Os dados da transformação de Box-Cox estão apresentados na Figura 4.2. Os resultados da Análise de Variância obtida para o novo modelo também estão apresentados na Tabela 4.1.

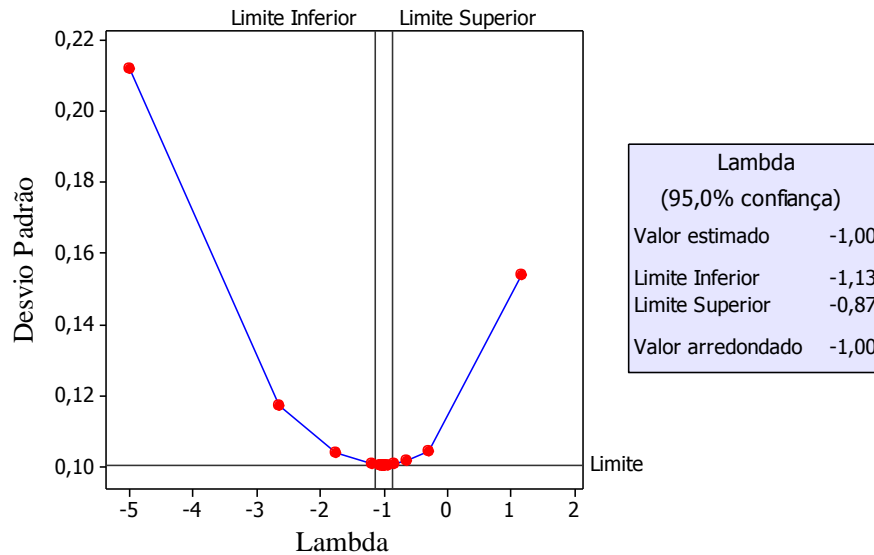


Figura 4.2 - Transformação de Box-Cox

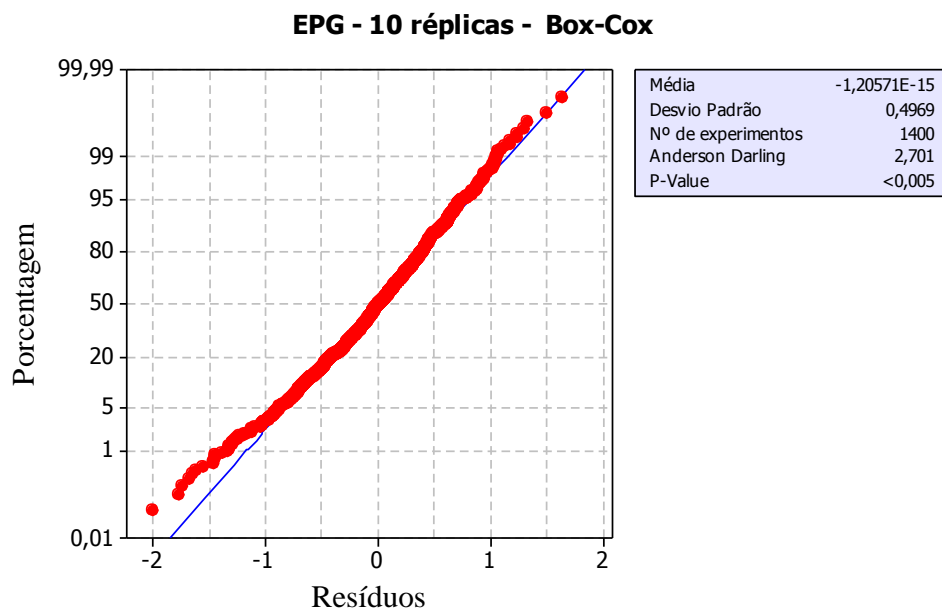


Figura 4.3 - Teste de normalidade para dados transformados de EPG com dez réplicas

Através da análise do modelo para os dados transformados, percebeu-se que o comportamento dos resíduos melhorou em relação ao primeiro modelo, mas não foi suficiente para que os mesmos se aproximassem de uma distribuição normal. Além disso, o ajuste do modelo foi menor, apresentando um $R^2(adj.)$ de apenas 72,89%.

Uma explicação para a falta de ajuste pode ser o fato de algumas réplicas serem muito diferentes, o que faz com que alguns resíduos sejam muito grandes, podendo causar a falta de ajuste do modelo e a não normalidade dos resíduos. Isto pode acontecer quando se replica o arranjo visto que a inicialização do algoritmo genético é randômica.

Quando existem réplicas muito diferentes, pode-se aplicar algum método que agrupe as réplicas mais similares. Então, para contornar os problemas encontrados devido às réplicas, foi realizada uma Análise de *Cluster*, que agrupa os conjuntos de réplicas que apresentam maior grau de similaridade. O resultado da Análise de *Cluster* realizada, onde foram utilizados o método de ligação *Ward* e a medida de distância por correlação, pode ser verificado através da Figura 4.4.




Figura 4.4 - Dendrograma da análise de *Cluster* para as réplicas do arranjo experimental

Através da análise da Figura 4.4 pode-se notar que as réplicas 2, 6 e 10 possuem um grau de similaridade maior que 95%. De acordo com a curva de poder de teste da Figura 3.7, três réplicas também são capazes de garantir um alto poder de teste (maior que 0,9) e de detectar um efeito da ordem de 0,05. Portanto, decidiu-se utilizar na modelagem da função EPG somente as réplicas de número 2, 6 e 10, por serem mais similares.

O arranjo foi analisado novamente, para as três réplicas escolhidas, tanto para EPG quanto para os dados transformados de EPG (Mesma transformação de Box-Cox, especificada na Figura 4.2). Os dados da análise de variância para os dois modelos estão apresentados na Tabela 4.2 e os gráficos das análises de normalidade dos resíduos estão apresentados nas Figuras 4.5 e 4.6.

Tabela 4.2 - Análise de Variância para os modelos com três réplicas

Resposta	DF	Adj. SS	Adj. MS	F	p-value	Lack-of-fit	R ² (adj.)
EPG	46	18,6621	0,40570	166,62	0,000	0,998	94,79
EPG _{Box-Cox}	32	333,819	10,4318	100,28	0,000	0,983	88,35

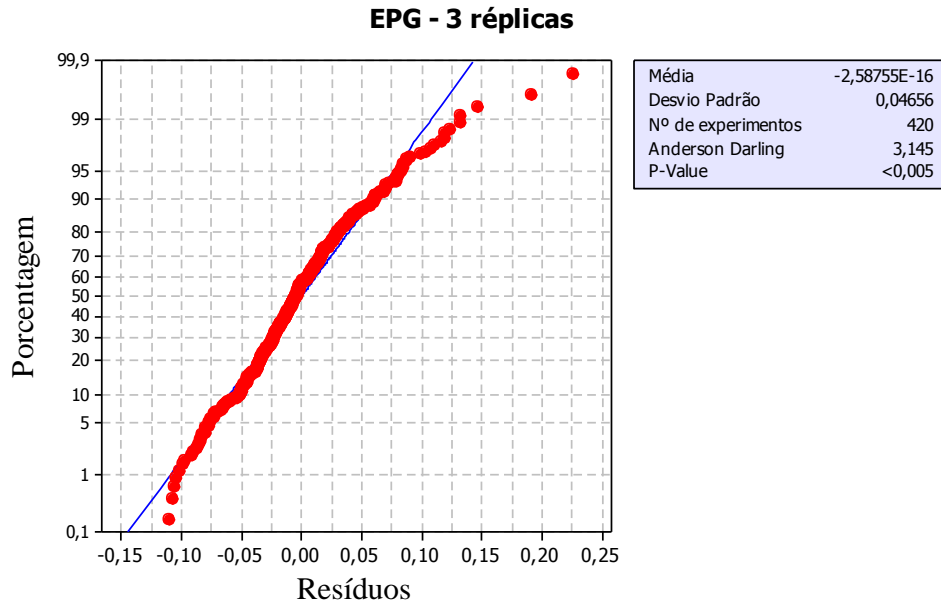


Figura 4.5 - Teste de normalidade dos resíduos para EPG com três réplicas

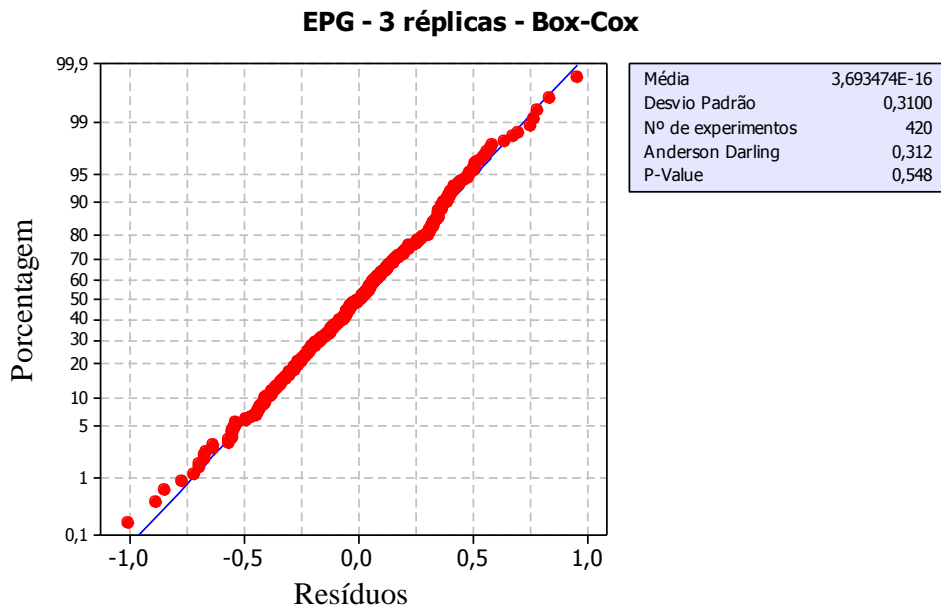


Figura 4.6 - Testes de normalidade para dados transformados de EPG com três réplicas

Novamente o modelo para a função EPG apresentou bom ajuste, sem *lack-of-fit* e um $R^2(\text{adj.})$ de 94,79%, porém os resíduos não se adequam à distribuição normal. Entretanto, com a transformação dos dados, os resíduos se apresentaram normais ($p\text{-value} > 0,05$) e o modelo

apresentou um $R^2(adj.)$ de 88,35%, além de não apresentar falta de ajuste. Isto indica que este modelo é adequado para a representação dos dados. A análise estatística completa da regressão e da ANOVA para este último modelo ($EPG_{Box-Cox}$ com três réplicas) estão apresentados no APÊNDICE C deste trabalho.

Reescrevendo o modelo quártico somente com os termos significativos, como determinado pelo último modelo analisado, têm-se a equação para os dados transformados para o EPG como:

$$\begin{aligned}
 EPG_{Box-Cox} = & 0,79w_1 + 4,27w_2 + 2,21w_3 + 4,07w_4 + 1,07w_1w_3 + 1,61w_2w_3 \\
 & + 1,67w_1w_2(w_1-w_2) - 1,93w_2w_3(w_2-w_3) \\
 & - 3,00w_2w_4(w_2-w_4) + 26,56w_1w_3w_4^2 - 5,22w_3w_4(w_3-w_4)^2 \\
 & - 0,22w_4T_p - 0,64w_2w_3T_p + 0,79w_2w_4T_p + 0,93w_3w_4T_p \\
 & - 4,89w_1w_3(w_1-w_3)^2T_p + 6,75w_2w_3(w_2-w_3)^2T_p \\
 & - 1,74w_1w_3(w_1-w_3)T_c + 1,49w_2w_3(w_2-w_3)T_c \\
 & - 18,28w_1^2w_3w_4T_c - 12,77w_1w_2w_3^2T_c + 60,22w_1w_2w_3w_4T_c \\
 & - 0,95w_1w_3T_m - 0,90w_1w_4T_m - 0,94w_2w_3T_m + 0,54w_2w_4T_m \\
 & - 1,90w_1w_4(w_1-w_4)T_m + 29,05w_1^2w_3w_4T_m + 21,08w_2^2w_3w_4T_m \\
 & - 14,58w_1w_2^2w_3T_m - 24,02w_1w_3w_4^2T_m - 23,86w_2w_3w_4^2T_m \\
 & + 6,79w_2w_3(w_2-w_3)^2T_m
 \end{aligned} \tag{4.1}$$

Com a função EPG modelada, o próximo passo é a análise da influência dos parâmetros e a otimização final para determinação dos pesos e parâmetros ótimos.

4.2 Análise da Influência dos Parâmetros

Com a função $EPG_{Box-Cox}$ devidamente modelada, é possível então avaliar a influência dos parâmetros no resultado da otimização e realizar otimização desta função.

A Figura 4.7 apresenta a relação entre os dados calculados para EPG e os dados após a aplicação da transformação de Box-Cox. Verifica-se que, quanto menor o valor do EPG, maior é o valor para $EPG_{Box-Cox}$.

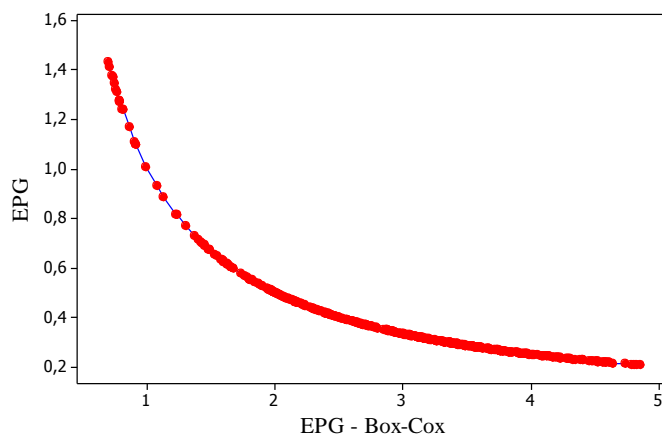


Figura 4.7 - Relação entre EPG e $EPG_{Box-Cox}$

Avaliando a Figura 4.7, percebe-se que a transformação dos dados calculados do EPG causou a mudança do sentido de otimização do problema, que passou a ser um problema de maximização. Ou seja, agora deseja-se encontrar a combinação de pesos e parâmetros que maximiza a função $EPG_{\text{Box-Cox}}$. Sendo assim, identificação dos pesos e parâmetros ótimos deverá ser obtida por meio da solução do problema descrito na Equação (4.2).

$$\begin{aligned}
\text{Maximizar } & EPG_{\text{Box-Cox}} \\
& = 0,79w_1 + 4,27w_2 + 2,21w_3 + 4,07w_4 + 1,07w_1w_3 + 1,61w_2w_3 \\
& + 1,67w_1w_2(w_1-w_2) - 1,93w_2w_3(w_2-w_3) - 3,00w_2w_4(w_2-w_4) \\
& + 26,56w_1w_3w_4^2 - 5,22w_3w_4(w_3-w_4)^2 - 0,22w_4T_p \\
& - 0,64w_2w_3T_p + 0,79w_2w_4T_p + 0,93w_3w_4T_p - 4,89w_1w_3(w_1-w_3)^2T_p \\
& + 6,75w_2w_3(w_2-w_3)^2T_p - 1,74w_1w_3(w_1-w_3)T_c \\
& + 1,49w_2w_3(w_2-w_3)T_c - 18,28w_1^2w_3w_4T_c - 12,77w_1w_2w_3^2T_c \\
& + 60,22w_1w_2w_3w_4T_c - 0,95w_1w_3T_m - 0,90w_1w_4T_m - 0,94w_2w_3T_m \\
& + 0,54w_2w_4T_m - 1,90w_1w_4(w_1-w_4)T_m + 29,05w_1^2w_3w_4T_m \\
& + 21,08w_2^2w_3w_4T_m - 14,58w_1w_2^2w_3T_m - 24,02w_1w_3w_4^2T_m \\
& - 23,86w_2w_3w_4^2T_m + 6,79w_2w_3(w_2-w_3)^2T_m
\end{aligned} \tag{4.2}$$

$$\begin{aligned}
\text{Sujeito a: } & w_1 + w_2 + w_3 + w_4 = 1 \\
& w_1, w_2, w_3, w_4 \leq 1 \\
& w_1, w_2, w_3, w_4 \geq 0 \\
& 20 \leq T_p \leq 100 \\
& 0,15 \leq T_c \leq 0,85 \\
& -1 \leq T_m \leq 1
\end{aligned}$$

O fato de que o modelo encontrado para a função $EPG_{\text{Box-Cox}}$ apresenta interações significativas entre os pesos das funções e os parâmetros do algoritmo já é suficiente para afirmar que a mudança na configuração do algoritmo vai influenciar no resultado final. Além disso, é possível avaliar a influência dos parâmetros do GA através da análise dos gráficos de efeitos principais destes parâmetros, apresentados na Figura 4.8.

A análise da Figura 4.8 mostra que todos os parâmetros apresentam efeito negativo sobre o resultado obtido para $EPG_{\text{Box-Cox}}$. Isso significa que a mudança dos níveis inferiores (-1) para os níveis superiores (+1) do arranjo gera uma piora nos resultados. Percebe-se também que o fator Tipo de mutação é o parâmetro que mais influencia no valor do $EPG_{\text{Box-Cox}}$.

Os gráficos de resposta de componentes apresentados na Figura 4.9 mostram como a resposta ($EPG_{\text{Box-Cox}}$) é afetada com a mudança dos pesos, a partir da mistura de referência, que corresponde ao centróide dos vértices do arranjo (onde todos os pesos são iguais a 0,25).

Nota-se a diferença do comportamento dos componentes (pesos) quando tem-se a utilização de diferentes configurações dos parâmetros do GA.

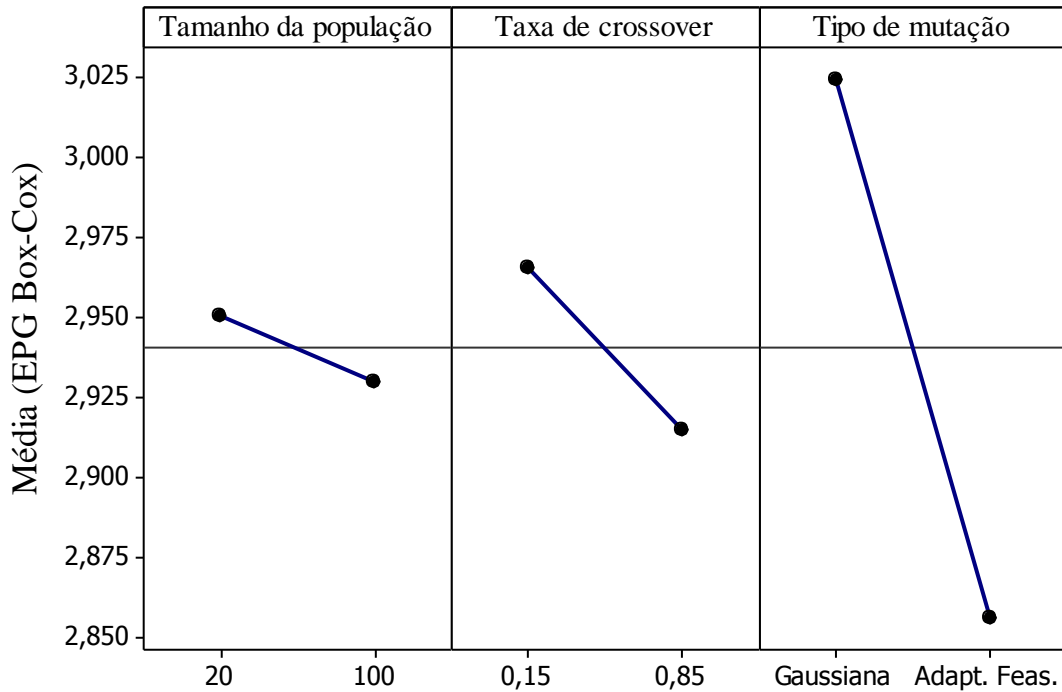


Figura 4.8 - Gráficos de efeitos principais dos parâmetros do algoritmo genético

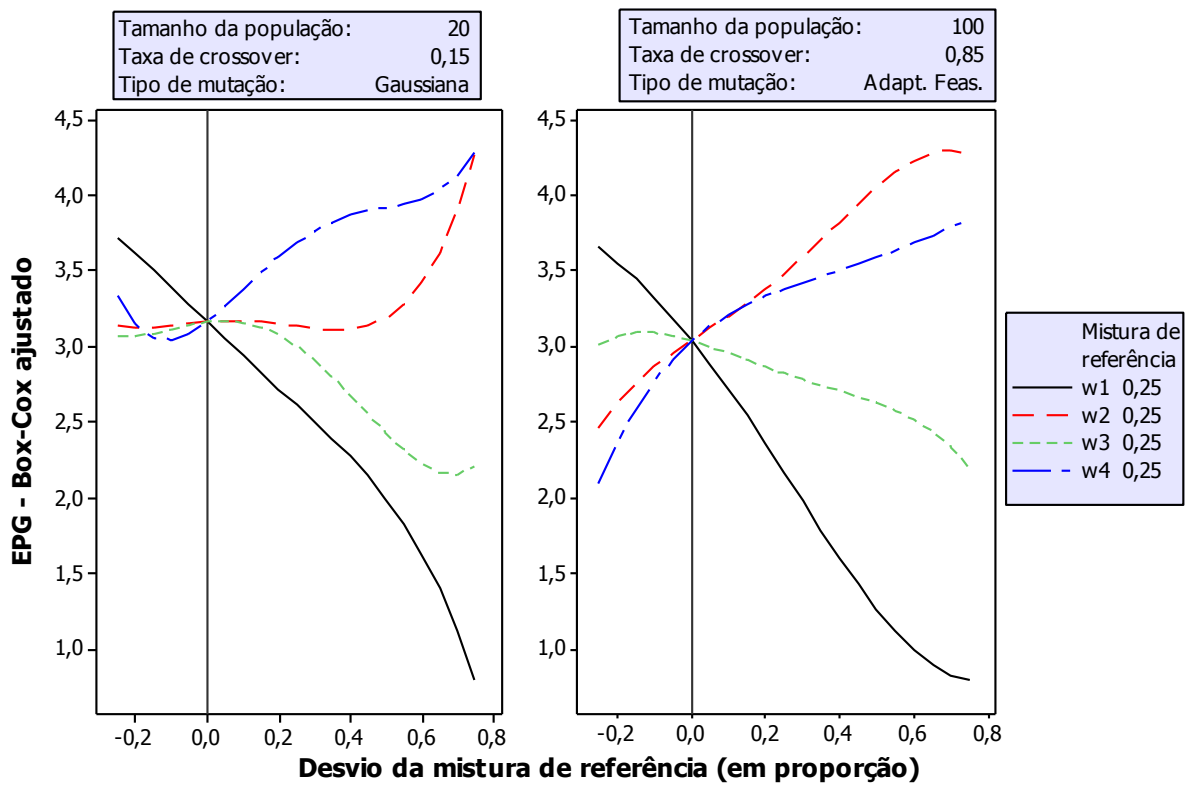


Figura 4.9 - Gráficos de resposta dos componentes

Os gráficos de contorno para as diferentes configurações de pesos e parâmetros apresentados nas Figura 4.10 e Figura 4.11 indicam as regiões onde encontram-se os valores mínimos e máximos para a função $EPG_{\text{Box-Cox}}$, para algumas configurações testadas no arranjo. Esses gráficos estão distribuídos nos vértices do cubo de acordo com as configurações do GA.




Figura 4.10 - Gráficos de contorno para a função $EPG_{\text{Box-Cox}}$ para $w_4 = 0$

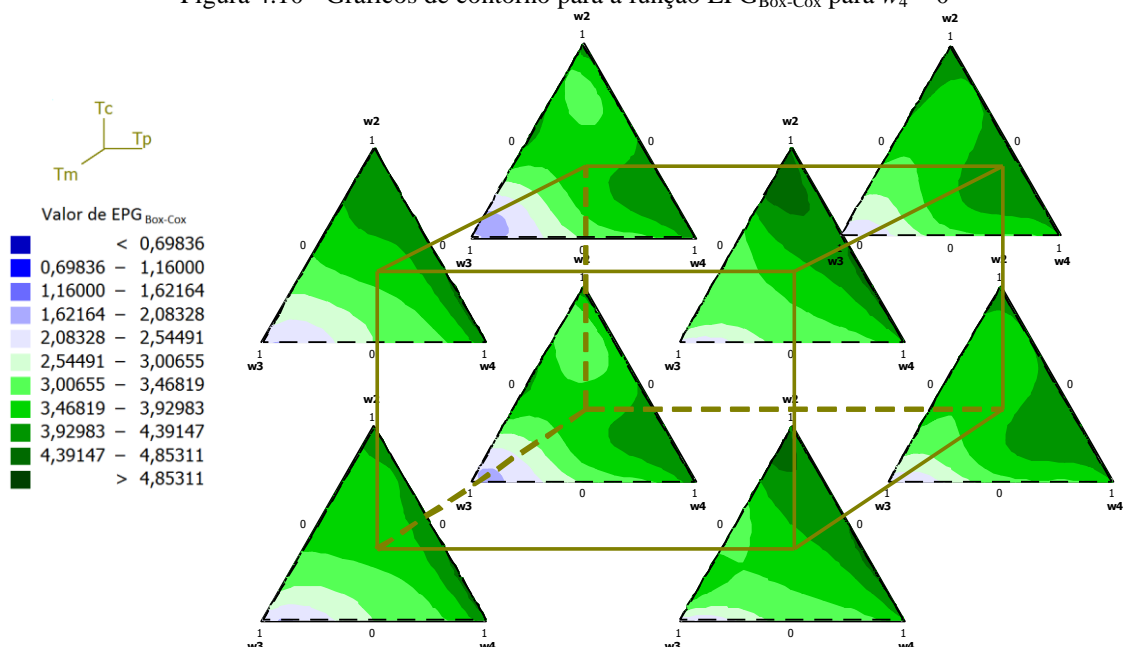


Figura 4.11 - Gráficos de contorno para a função $EPG_{\text{Box-Cox}}$ para $w_1 = 0$

Analisando-se a Figura 4.10 fica clara a influência dos parâmetros do algoritmo nos resultados, já que nenhuma superfície é igual a outra, nas diferentes combinações de parâmetros, apesar de possuírem as mesmas combinações de pesos.

Ainda com relação à análise dos gráficos de contorno, nota-se também a grande influência dos pesos das funções no resultado. Por exemplo, é possível constatar que nas superfícies onde o peso w_1 é mantido zerado, as áreas correspondentes aos maiores valores para $EPG_{\text{Box-Cox}}$, são maiores do que nas superfícies onde o w_4 é mantido zerado.

É possível visualizar como é o comportamento desta função, através de gráficos de superfície. A Figura 4.12 apresenta alguns exemplos dos gráficos de superfície de resposta para a função $EPG_{\text{Box-Cox}}$. É possível verificar que existem pontos onde as configurações dos pesos e parâmetros podem levar a resultados máximos para a função.

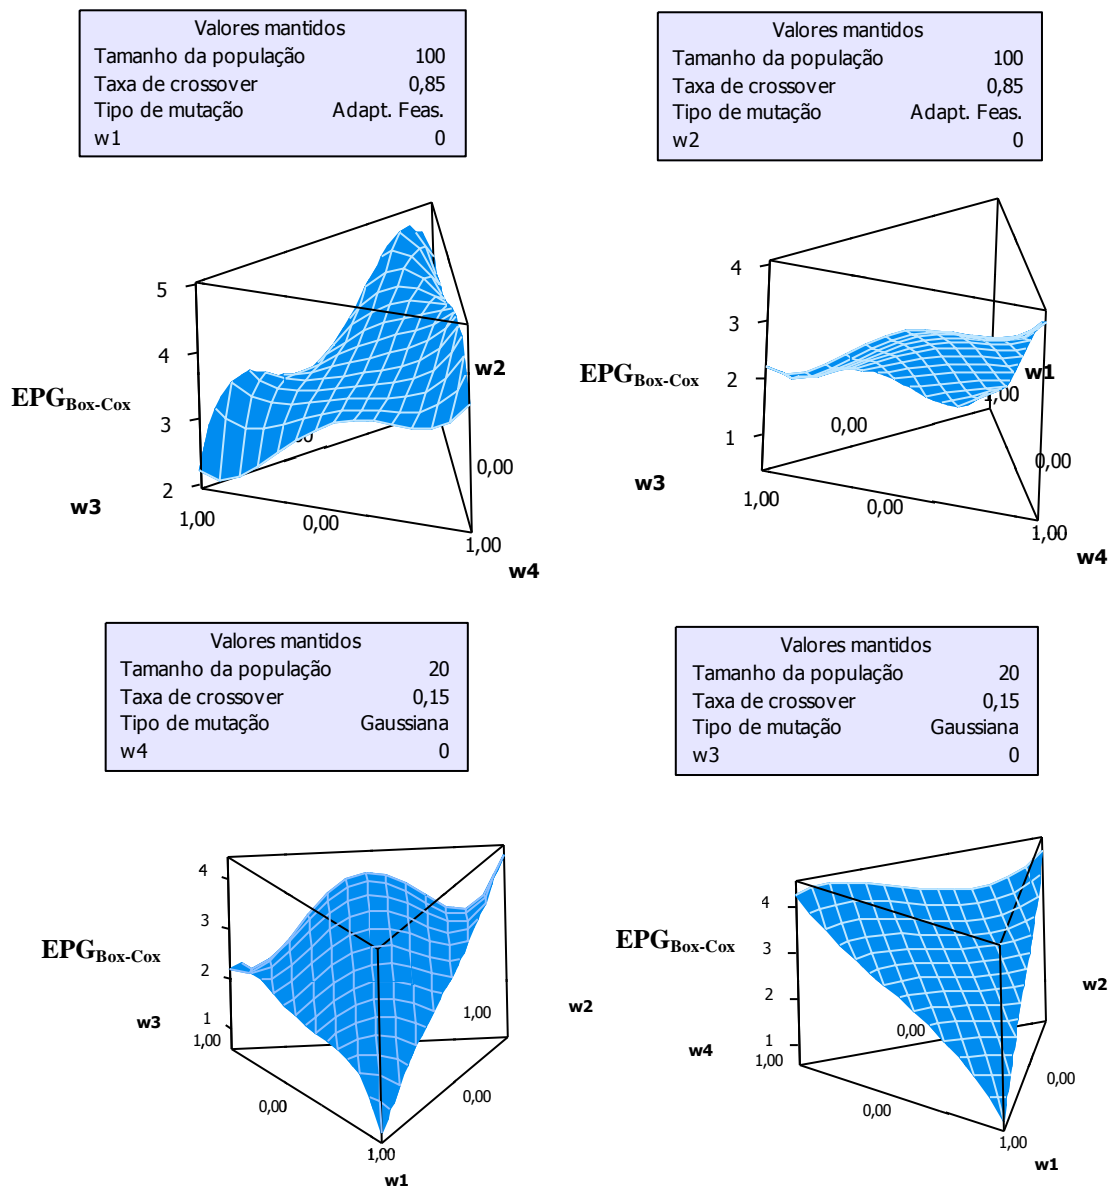


Figura 4.12 - Gráficos de superfície de resposta para a função $EPG_{\text{Box-Cox}}$

4.3 Otimização da Função EPG

Para a determinação dos pesos e parâmetros ótimos do problema de otimização da função $EPG_{\text{Box-Cox}}$, definido pela Equação (4.2), utilizou-se o *Response Optimizer* disponível no *Minitab*[®], que utiliza a função *desirability* para identificar a combinação de configurações das variáveis de entrada que otimizam em conjunto uma única resposta ou várias respostas. As configurações utilizadas para a função *desirability* estão apresentadas na Tabela 4.3.

Tabela 4.3 - Configurações do *desirability*

Resposta	Objetivo	Limite Inferior	Target	Peso	Importância
EPGBox-Cox	Maximizar	0	5	1	1

De acordo com a solução ótima encontrada, os pesos w_1 e w_3 devem ser zerados, w_2 deve ser igual a 0,2626 e w_4 igual a 0,7374. Os parâmetros que devem ser configurados no GA, para este problema, são um tamanho de população igual a 60, uma taxa de *crossover* de 0,5 e a função de mutação que deve ser utilizada é a função *Adaptive Feasible*. O valor máximo para $EPG_{\text{Box-Cox}}$ encontrado nesta otimização foi de 4,4981, como mostra a Figura 4.13.




Figura 4.13 - Resultados da otimização da função $EPG_{\text{Box-Cox}}$

4.3.1 Confirmação

Os resultados ótimos encontrados na otimização da função $EPG_{\text{Box-Cox}}$ na seção 4.2 foram utilizados para a solução do problema inicial de otimização do processo de soldagem, definido na Equação (3.6) para confirmação de que as combinações de pesos e parâmetros encontrados neste estudo levarão ao melhor resultado da otimização deste processo, especificamente.

A otimização foi realizada novamente no *Matlab*[®], através do *Optimization Toolbox*, com a utilização dos parâmetros $T_p=60$, $T_c=0,5$ e $T_m=Adaptive Feasible$ e os pesos $w_1=0$, $w_2=0,2626$, $w_3=0$ e $w_4=0,7374$. Foram realizadas 13 réplicas e os resultados calculados para o EPG para cada uma das réplicas, assim como os dados após a transformação Box-Cox, estão

apresentados na Tabela 4.4. O número de réplicas para a confirmação foi calculado para que o teste *One-Sample T* seja capaz de garantir um poder de teste maior que 90% e de detectar uma diferença de 0,4, para um desvio padrão amostral de 0,4 e um nível de significância de 5%, como apresentado na Figura 4.14.

Tabela 4.4 - Resultados dos experimentos de confirmação

Réplicas	EPG	EPG _{Box-Cox}
1	0,2027	4,934235
2	0,2476	4,039476
3	0,2060	4,853846
4	0,2104	4,752899
5	0,2140	4,671918
6	0,2136	4,680886
7	0,2353	4,250169
8	0,2107	4,745247
9	0,2359	4,238431
10	0,2053	4,870214
11	0,2685	3,72414
12	0,2333	4,286131
13	0,2215	4,514348

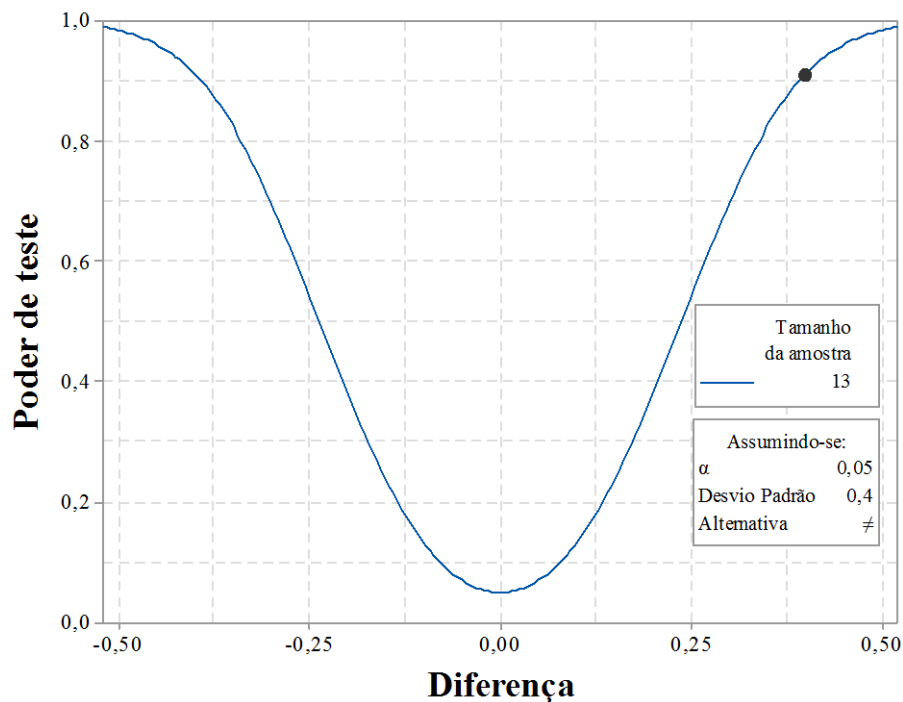
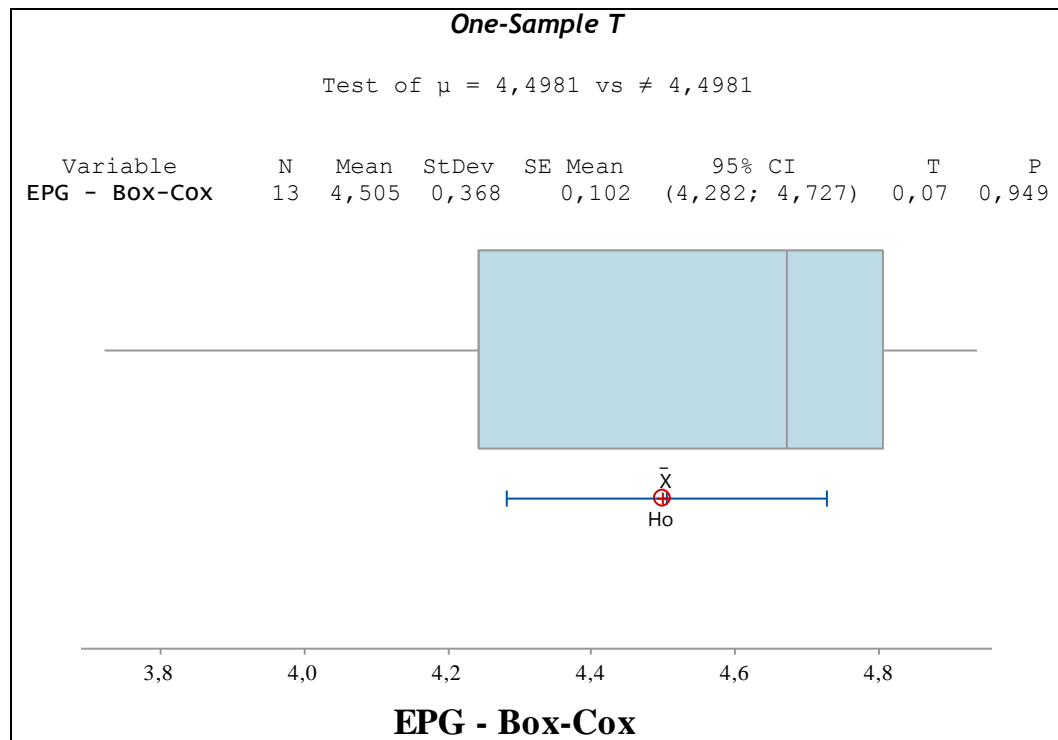


Figura 4.14 - Curva de poder de teste para determinação do número de réplicas do experimento de confirmação. Um teste *One-Sample T* foi utilizado para determinar se a média dos dados obtidos para EPG_{Box-Cox} nos experimentos de confirmação são estatisticamente iguais ao valor obtido para EPG_{Box-Cox} na otimização realizada na seção 4.2, onde $EPG_{Box-Cox_{m\acute{a}x}} = 4,4981$. Os resultados desta análise esto apresentados na

Figura 4.15.

Figura 4.15 - Teste *One-Sample T* e *Boxplot* para os dados dos experimentos de confirmação

O teste realizado mostra que a média dos resultados dos experimentos de confirmação é estatisticamente igual ao valor máximo de $EPG_{\text{Box-Cox}}$ (4,4981) encontrado na otimização de pesos e parâmetros, pois o *p-value* do teste é maior que 0,05 e o valor máximo encontra-se dentro do intervalo de confiança para a média de $EPG_{\text{Box-Cox}}$ dos experimentos de confirmação.

Sendo assim, os experimentos de confirmação mostram que as combinações ótimas de pesos e parâmetros para o algoritmo genético encontradas através da metodologia proposta neste estudo garantem os melhores resultados para o problema de otimização do processo de soldagem definido neste trabalho.

4.3.2 Avaliação dos pesos e parâmetros ótimos

A partir dos experimentos de confirmação, foi possível determinar qual o comportamento das respostas do processo para a configuração de pesos e parâmetros ótimos determinados na otimização da função $EPG_{\text{Box-Cox}}$. Foi possível calcular os parâmetros de entrada do processo de soldagem, assim como os valores para cada uma das respostas analisadas, para cada uma das réplicas realizadas. Estes resultados estão apresentados na Tabela 4.5.

Tabela 4.5 – Resultados ótimos

Réplicas	Variáveis de Controle				Respostas			
	Va	T	Vs	N	W	P	R	D
1	9,1	27,6	23,6	23,8	12,86	0,84	3,30	16,34
2	9,1	27,3	25,2	24,7	12,30	0,84	3,30	16,40
3	9,2	27,7	24,1	24,2	12,82	0,84	3,31	16,39
4	9,1	27,5	24,0	23,9	12,75	0,84	3,30	16,31
5	9,1	27,5	24,1	24,2	12,67	0,84	3,30	16,34
6	9,1	27,6	23,8	23,9	12,80	0,84	3,30	16,38
7	9,1	27,5	24,4	24,1	12,61	0,85	3,30	16,43
8	9,1	27,5	24,0	24,0	12,73	0,84	3,30	16,32
9	9,2	27,3	24,9	24,3	12,45	0,85	3,31	16,32
10	9,1	27,6	23,7	23,9	12,80	0,84	3,30	16,33
11	9,2	27,2	25,8	24,7	12,14	0,85	3,31	16,42
12	9,2	27,4	24,7	24,3	12,52	0,84	3,31	16,38
13	9,1	27,5	24,1	24,0	12,71	0,84	3,30	16,39
Média:	9,1	27,5	24,3	24,2	12,63	0,84	3,30	16,37

A Tabela 4.6 apresenta uma comparação entre os valores encontrados para as respostas através da utilização dos pesos e parâmetros ótimos (tomando-se como base os valores médios para as respostas, como apresentado na Tabela 4.5) e os valores alvo estabelecidos na otimização individual de cada uma das respostas. Pode-se observar que, com exceção da resposta largura do cordão (W), os valores ótimos encontrados para as outras três respostas se aproximaram bastante dos valores definidos como alvos, através das otimizações individuais.

Tabela 4.6 - Comparação entre os resultados ótimos e os ótimos individuais das respostas

	Respostas			
	W	P	R	D
Ponto de ótimo (médio)	12,63	0,84	3,30	16,37
Ótimos individuais	15,58	0,83	3,34	16,27
Objetivo	max	min	max	min
Unidades	mm	mm	mm	%

O fato de os pesos ótimos encontrados para w_1 e w_3 serem iguais a zero pode ser justificado pelo fato de que algumas respostas são correlacionadas. A Tabela 4.7 apresenta a estrutura de correlação das respostas otimizadas, onde os valores destacados indicam a presença de correlação moderada ($0,40 < |\text{coeficiente de Pearson}| < 0,70$) e estatisticamente significativa ($p\text{-value}$ inferior a 0,05) para alguns pares de respostas.

Tabela 4.7 - Estrutura de correlação das respostas otimizadas

	W	P	R
P	0,221		

	0,232		
<i>R</i>	0,445	-0,141	
	0,015	0,465	
<i>D</i>	-0,127	0,496	-0,679
	0,817	0,000	0,000

Valores das células: coeficiente de Pearson
p-value

Percebe-se que existe uma correlação negativa entre as respostas *R* e *D* ($r_{RD}=-0,679$) e que estas duas respostas possuem sentidos de otimização diferentes (*R* deve ser maximizada enquanto *D* deve ser minimizada). Este fato pode explicar o fato de w_3 ter sido zerado na otimização da função EPG, pois, dando um peso maior para *D* (w_4) tem-se a priorização da minimização desta resposta, mas que, involuntariamente, leva à maximização de *R*. A presença de correlação positiva entre os pares de respostas *W* e *R* ($r_{WR}=0,445$) e *P* e *D* ($r_{PD}=0,496$) e o fato destas respostas correlacionadas terem o mesmo sentido de otimização são, também, indicadores de que quando *W* é maximizado, *R* é maximizado e ainda, quando *P* é minimizado, *D* também é minimizado.

Em relação aos parâmetros ótimos encontrados para a configuração do algoritmo genético, o tamanho da população ótimo ($T_p=60$) é condizente com os valores sugeridos por Candan e Yazgan (2014), por não ser um valor nem muito alto nem muito baixo. Apesar de o levantamento feito na literatura ter apontado para uma utilização de taxas de crossover mais altas (acima de 0,8), segundo Ortiz *et al.* (2004), altas taxas de crossover podem causar o descarte de boas soluções, enquanto taxas muito baixa podem estagnar a busca, o que indica que o valor ótimo para a taxa de crossover encontrado neste trabalho ($T_c=0,5$) é um valor adequado. Por fim, o tipo de mutação determinado na otimização ($T_m=Adaptive Feasible$) também pode ser considerado adequado, pois é indicada a utilização da função de mutação *Adaptive Feasible* para a solução de problemas restritos, como foi o caso da otimização do processo de soldagem.

5 CONCLUSÕES

No contexto da busca por métodos de otimização multiobjetivo eficientes, o presente trabalho foi desenvolvido com o propósito de apresentar uma nova alternativa para a determinação dos melhores valores para os parâmetros de um algoritmo genético utilizado na solução de um problema com ponderação das funções objetivo e avaliar a influência destes parâmetros na qualidade da solução encontrada para o problema.

Foi proposto neste trabalho um procedimento experimental capaz de otimizar, ao mesmo tempo, os pesos atribuídos às funções de um problema multiobjetivo e os parâmetros do algoritmo genético utilizado na solução deste problema, através da utilização de um arranjo de misturas combinado com variáveis de processo e a avaliação do Erro Percentual Global das respostas encontradas em relação à alvos estabelecidos. O método proposto foi aplicado na otimização de um processo de soldagem com arame tubular empregado para operações de revestimento de chapas de aço carbono utilizando um aço inoxidável.

Um dos principais objetivos deste trabalho era avaliar a existência de interação entre os pesos atribuídos para as respostas e os parâmetros utilizados no algoritmo. Através da modelagem da função EPG foi possível determinar a existência de interações significativas entre pesos e parâmetros. Apesar de não ser possível a generalização da existência destas interações em outros processos, pode-se concluir que os pesos das funções devem ser levados em consideração em pesquisas de otimização dos parâmetros do algoritmo, pois diferenças nas combinações de pesos atribuídos podem levar à necessidade de utilização de diferentes valores e funções para os parâmetros. O procedimento experimental proposto também mostrou ser útil na determinação dos pesos e parâmetros ótimos, determinando a melhor distribuição de pesos para as respostas e a melhor configuração dos parâmetros do algoritmo para serem utilizados na otimização do processo de soldagem.

O procedimento proposto também mostrou algumas desvantagens. A primeira dificuldade encontrada foi o grande número de experimentos para a avaliação de métodos com a utilização de muitas respostas e de avaliação de muitos parâmetros ao mesmo tempo. Porém, o número de experimentos pode ser reduzido com a utilização do arranjo de misturas combinado com arranjos fatoriais fracionados. Outra dificuldade encontrada foi o fato de que a inicialização aleatória do algoritmo genético faz com que os resultados das réplicas sejam muito diferentes em alguns casos, o que gerou falta de ajuste na modelagem da função EPG com todas as réplicas realizadas para o arranjo. Entretanto, a utilização da análise de cluster

foi de grande utilidade para o agrupamento e seleção das réplicas com maior grau de similaridade, possibilitando a modelagem da função com alto ajuste mesmo com a utilização de um número menor de réplicas.

É importante ressaltar que os resultados encontrados neste trabalho não podem ser generalizados, porém espera-se que o procedimento proposto neste trabalho possa ser aplicado em outros processos e também na avaliação de outros parâmetros do algoritmo genético, para que se possa obter um melhor *setup* destes parâmetros que seja capaz de encontrar resultados mais adequados a cada tipo de aplicação.

5.1 Sugestões para trabalhos futuros

Para dar continuidade a esta pesquisa, ou até mesmo encontrar restrições da aplicação do procedimento experimental proposto neste trabalho, sugere-se:

- Aplicar o método proposto a diferentes problemas multiobjetivo, para verificação da funcionalidade do método e da existência de interações entre pesos e parâmetros em outros processos.
- Investigar a influência de um número maior de parâmetros do algoritmo genético e avaliar as interações entre eles.
- Realizar um número maior de réplicas, com o intuito de conseguir normalidade dos resíduos sem a utilização da Análise de *Cluster* ou utilizar um *D-Optimal design* com um número definido de experimentos, ao invés de fazer uma grande quantidade de réplicas.
- Realizar réplicas apenas do centroide e não do arranjo completo.

REFERÊNCIAS BIBLIOGRÁFICAS

ABU-DAKKA, F. J.; VALERO, F. J.; SUÑER, J. L.; MATA, V. A direct approach to solving trajectory planning problems using genetic algorithms with dynamics considerations in complex environments. **Robotica**, v. 33, p. 669–683, 2014.

ALAJMI, A.; WRIGHT, J. Selecting the Most Efficient Genetic Algorithm Sets in Solving Unconstrained Building Optimization Problem. **International Journal of Sustainable Built Environment**, v. 3, n. 1, p. 18–26, 2014. The Gulf Organisation for Research and Development.

ALMEIDA, F. S.; AWRUCH, A. M. Design optimization of composite laminated structures using genetic algorithms and finite element analysis. **Composite Structures**, v. 88, n. 3, p. 443–454, 2009. Elsevier Ltd.

ALRASHDAN, A.; BATAINEH, O.; SHBOOL, M. Multi-criteria end milling parameters optimization of AISI D2 steel using genetic algorithm. **International Journal of Advanced Manufacturing Technology**, v. 73, p. 1201–1212, 2014.

ÁLVAREZ, M. J.; ILZARBE, L.; VILES, E.; TANCO, M. The Use of Genetic Algorithms in Response Surface Methodology. **Quality Technology & Quantitative Management**, v. 6, n. 3, p. 295–307, 2009.

ANAGUN, A. S.; OZCELIK, F. Optimization of genetic algorithm parameters for multi-channel manufacturing systems by Taguchi method. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, v. 3809 LNAI, p. 1021–1024, 2005.

ANGELOVA, M.; PENCHEVA, T. Tuning genetic algorithm parameters to improve convergence time. **International Journal of Chemical Engineering**, v. 2011, 2011.

BARIL, C.; YACOUT, S.; CLÉMENT, B. Design for Six Sigma through collaborative multiobjective optimization. **Computers and Industrial Engineering**, v. 60, p. 43–55, 2011.

BOIX, M.; PIBOULEAU, L.; MONTASTRUC, L.; AZZARO-PANTEL, C.; DOMENECH, S. Minimizing water and energy consumptions in water and heat exchange networks. **Applied Thermal Engineering**, v. 36, p. 442–455, 2012. Elsevier Ltd.

CALDAS, L. G.; NORFORD, L. K. A design optimization tool based on a genetic algorithm. **Automation in Construction**, v. 11, p. 173–184, 2002.

CANDAN, G.; YAZGAN, H. R. Genetic algorithm parameter optimisation using Taguchi method for a flexible manufacturing system scheduling problem. **International Journal of Production Research**, v. 53, n. 3, p. 897–915, 2014. Taylor and Francis Ltd.

CARVALHO, A. C. P. L. F.; BRAGA, A. P.; LUDEMIR, T. B. **Computação Evolutiva. Sistemas Inteligentes - Fundamentos e Aplicações**. 1st ed., 2003. São Paulo: Manole.

CHANG, C. K.; JIANG, H.; DI, Y.; ZHU, D.; GE, Y. Time-line based model for software project scheduling with genetic algorithms. **Information and Software Technology**, v. 50, p. 1142–1154, 2008.

CHAUDHURI, S.; KHAN, F.; PAL, J.; GOSWAMI, S.; MIDDEY, A. An investigation on the evolution process of thunderstorms over a metropolis of India using DWR Max_Z products and genetic algorithm. **Meteorology and Atmospheric Physics**, v. 127, p. 75–93, 2014.

CIENIAWSKI, S. E.; EHEART, J. W.; RANJITHAN, S. Using Genetic Algorithms to Solve a Multiobjective Groundwater Monitoring Problem. **Water Resources Research**, v. 31, n. 2, p. 399, 1995.

COELLO, C. A.; CHRISTIANSEN, A. D. Multiobjective optimization of trusses using genetic algorithms. **Computers & Structures**, v. 75, p. 647–660, 2000.

COLLETTE, Y.; SIARRY, P. Three new metrics to measure the convergence of metaheuristics towards the Pareto frontier and the aesthetic of a set of solutions in biobjective optimization. **Computers and Operations Research**, v. 32, p. 773–792, 2005.

CORNELL, J. A. **A Primer on Experiments with Mixtures**. 3rd ed. New Jersey: John Wiley & Sons, 2011.

COSTA, C. B. B.; MACIEL, M. R. W.; FILHO, R. M. Factorial design technique applied to genetic algorithm parameters in a batch cooling crystallization optimisation. **Computers and Chemical Engineering**, v. 29, p. 2229–2241, 2005.

COSTA, C. B. B.; RIVERA, E. A. C.; REZENDE, M. C. A. F.; MACIEL, M. R. W.; FILHO, R. M. Prior detection of genetic algorithm significant parameters: Coupling factorial design technique to genetic algorithm. **Chemical Engineering Science**, v. 62, p. 4780–4801, 2007.

CUS, F.; BALIC, J. Optimization of cutting process by GA approach. **Robotics and Computer-Integrated Manufacturing**, v. 19, p. 113–121, 2003.

DAS, I.; DENNIS, J. E. A closer look at drawbacks of minimizing weighted sums of objectives for Pareto set generation in multicriteria optimization problems. **Structural Optimization**, v. 14, p. 63–69, 1997.

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**, v. 8, n. 3, p. 631–657, 1998.

DEB, K. **Multi-objective Optimization using Evolutionary Algorithms**. New York: John Wiley & Sons, 2001.

DEB, M.; BANERJEE, R.; MAJUMDER, A.; SASTRY, G. R. K. Multi objective optimization of performance parameters of a single cylinder diesel engine with hydrogen as a dual fuel using pareto-based genetic algorithm. **International Journal of Hydrogen Energy**, v. 39, n. 15, p. 8063–8077, 2014. Elsevier Ltd.

DIANATI, M.; SONG, I.; TREIBER, M. An introduction to genetic algorithms and evolution strategies. **University of Waterloo, Canada**, 2002.

EIBEN, A. E.; SMIT, S. K. Evolutionary Algorithm Parameters and Methods to Tune them. **Autonomus Search**. p.15–36, 2012. Springer Berlin Heidelberg.

FERNANDEZ-PRIETO, J. A.; CANADA-BAGO, J.; GADEO-MARTOS, M. A.; VELASCO, J. R. Optimisation of control parameters for genetic algorithms to test computer networks under realistic traffic loads. **Applied Soft Computing Journal**, v. 12, n. 4, p. 1875–1883, 2011. Elsevier B.V.

FLEMING, P. .; PURSHOUSE, R. . Evolutionary algorithms in control systems engineering: a survey. **Control Engineering Practice**, v. 10, n. October 2001, p. 1223–1241, 2002.

GANGULY, S.; DATTA, S.; CHAKRABORTI, N. Genetic Algorithms in Optimization of Strength and Ductility of Low-Carbon Steels. **Materials and Manufacturing Processes**, v. 22, n. August 2014, p. 650–658, 2007.

GOLDBERG, D. E. **Genetic Algorithm in Search, Optimization and Machine Learning**. Addison-Wesley Publishing Company, 1989.

GOMES, J. H. D. F. **Análise e otimização da soldagem de revestimento de chapas de aço ABNT 1020 com utilização de arame tubular inoxidável austenítico**. Dissertação de Mestrado - Programa de Pós Graduação em Engenharia de Produção - Universidade Federal de Itajubá, 2010.

GOMES, J. H. F. **Método dos polinômios canônicos de misturas para otimização multi-objetivo**. Itajubá, Minas Gerais, Brazil: Tese de Doutorado - Programa de Pós Graduação em Engenharia de Produção - Universidade Federal de Itajubá, 2013.

GOMES, J. H. F.; JÚNIOR, A. R. S.; PAIVA, A. P.; et al. Global Criterion Method based on principal components to the optimization of manufacturing processes with multiple responses. **Journal of Mechanical Engineering**, v. 58, p. 345–353, 2012.

GOPALAKRISHNAN, H.; KOSANOVIC, D. Computers & Operations Research Operational planning of combined heat and power plants through genetic algorithms for mixed 0 – 1 nonlinear programming. **Computers and Operation Research**, v. 56, p. 51–67, 2015. Elsevier.

GREFENSTETTE, J. J. Optimization of Control Parameters for Genetic Algorithms. **IEEE Transactions on Systems, Man and Cybernetics**, v. 16, n. February, p. 122–128, 1986.

HANNE, T.; NICKEL, S. A multiobjective evolutionary algorithm for scheduling and inspection planning in software development projects. **European Journal of Operational Research**, v. 167, p. 663–678, 2005.

HEREDIA-LANGNER, A.; MONTGOMERY, D. C.; CARLYLE, W. M. Solving a multistage partial inspection problem using genetic algorithms. **International Journal of Production Research**, v. 40, n. October 2014, p. 1923–1940, 2002.

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**, 1975. University of Michigan Press.

HOSSEINI, S. A.; NIAEI, A.; SALARI, D.; NABAVI, S. R. Modeling and optimization of combustion process of 2-propanol over perovskite-type $\text{LaMnyCo}_{1-y}\text{O}_3$ nanocatalysts by an unrepliated experimental design with mixture-process variables and genetic algorithm methodology. **Journal of the Taiwan Institute of Chemical Engineers**, v. 45, n. 1, p. 85–91, 2014. Taiwan Institute of Chemical Engineers.

JAIMES, A. L.; COELLO, C. A. C.; MARTÍNEZ, Z. S. An introduction to Multiobjective Optimization Techniques. **Optimization in Polymer Processing**. p.29–57, 2011. Nova Science Pub Inc.

KASAT, R. B.; GUPTA, S. K. Multi-objective optimization of an industrial fluidized-bed catalytic cracking unit (FCCU) using genetic algorithm (GA) with the jumping genes operator. **Computers and Chemical Engineering**, v. 27, p. 1785–1800, 2003.

KLEIJNEN, J. P. C.; SANCHEZ, S. M.; LUCAS, T. W.; CIOPPA, T. M. State-of-the-Art Review: A User's Guide to the Brave New World of Designing Simulation Experiments. **INFORMS Journal on Computing**, v. 17, n. 3, p. 263–289, 2005.

KONAK, A.; COIT, D. W.; SMITH, A. E. Multi-objective optimization using genetic algorithms: A tutorial. **Reliability Engineering and System Safety**, v. 91, p. 992–1007, 2006.

KOZENY, V. Genetic algorithms for credit scoring: Alternative fitness function performance comparison. **Expert Systems with Applications**, v. 42, n. 6, p. 2998–3004, 2015. Elsevier Ltd.

KULTUREL-KONAK, S.; SMITH, A. E.; NORMAN, B. A. Multi-objective tabu search using a multinomial probability mass function. **European Journal of Operational Research**, v. 169, p. 918–931, 2006.

KUMAR, A. S.; KHAN, M. A.; THIRAVIAM, R.; SORNAKUMAR, T. Machining Parameters Optimization for Alumina Based Ceramic Cutting Tools Using Genetic Algorithm. **Machining Science and Technology**, v. 10, n. 1, p. 471–489, 2006.

LI, J.; YANG, X.; REN, C.; CHEN, G.; WANG, Y. Multiobjective optimization of cutting parameters in Ti-6Al-4V milling process using nondominated sorting genetic algorithm-II. **The International Journal of Advanced Manufacturing Technology**, v. 76, p. 941–953, 2014.

LIEPINS, G. E.; HILLIARD, M. R. Genetic Algorithms: foundations and applications. **Annals of Operations Research**, v. 21, p. 31–58, 1989.

LIM, T. Y.; AL-BETAR, M. A.; KHADER, A. T. Adaptive pair bonds in genetic algorithm : An application to real-parameter optimization. **Applied Mathematics and Computation**, v. 252, p. 503–519, 2015. Elsevier Inc.

LOBO, F. G.; LIMA, C. F.; MICHALEWICZ, Z. Parameter Setting in Evolutionary Algorithms. **Studies in Computational Intelligence**.

LOGIST, F.; HOUSKA, B.; DIEHL, M.; IMPE, J. VAN. Fast Pareto set generation for nonlinear optimal control problems with multiple objectives. **Structural and Multidisciplinary Optimization**, v. 42, p. 591–603, 2010.

LOUGHLIN, D. H.; RANJITHAN, S. R.; BAUGH, J. W.; BRILL, E. D. Application of Genetic Algorithms for the Design of Ozone Control Strategies. **Journal of the Air & Waste Management Association**, v. 50, n. May 2015, p. 1050–1063, 2000.

MAGNIER, L.; HAGHIGHAT, F. Multiobjective optimization of building design using TRNSYS simulations, genetic algorithm, and Artificial Neural Network. **Building and Environment**, v. 45, n. 3, p. 739–746, 2010. Elsevier Ltd.

MAITI, S. K.; LANTZ, A. E.; BHUSHAN, M.; WANGIKAR, P. P. Multi-objective optimization of glycopeptide antibiotic production in batch and fed batch processes. **Bioresource Technology**, v. 102, n. 13, p. 6951–6958, 2011. Elsevier Ltd.

MALARD, J. M.; HEREDIA-LANGNER, A.; CANNON, W. R.; MOONEY, R.; BAXTER, D. J. Peptide identification via constrained multi-objective optimization: Pareto-based genetic algorithms. **Concurrency Computation Practice and Experience**, v. 17, n. December 2003, p. 1687–1704, 2005.

MARLER, R. T.; ARORA, J. S. Survey of multi-objective optimization methods for engineering. **Structural and Multidisciplinary Optimization**, v. 26, p. 369–395, 2004.

MAYER, D. G.; BELWARD, J. A.; BURRAGE, K. Robust parameter settings of evolutionary algorithms for the optimisation of agricultural systems models. **Agricultural Systems**, v. 69, p. 199–213, 2001.

MONTAZER-RAHMATI, M. M.; BINAEE, R. Multi-objective optimization of an industrial hydrogen plant consisting of a CO₂ absorber using DGA and a methanator. **Computers and Chemical Engineering**, v. 34, n. 11, p. 1813–1821, 2010. Elsevier Ltd.

MONTGOMERY, D. **Design and Analysis of Experiments**. 7th ed. New York: John Wiley & Sons, 2009.

MYERS, R. H.; MONTGOMERY, D. C.; ANDERSON-COOK, C. M. **Response Surface Methodology**. 3rd ed. 2009.

NILO JUNIOR, L. P. **Otimização de um processo de solda MIG/MAG para aplicação na indústria automobilística através da utilização da técnica do projeto e análise de experimentos**. Dissertação de Mestrado - Programa de Pós Graduação em Engenharia de Produção - Universidade Federal de Itajubá, 2003.

NÚÑEZ-LETAMENDIA, L. Fitting the control parameters of a genetic algorithm: An application to technical trading systems design. **European Journal of Operational Research**, v. 179, p. 847–868, 2007.

OLIVEIRA, A. L. I.; BRAGA, P. L.; LIMA, R. M. F.; CORNÉLIO, M. L. GA-based method for feature selection and parameters optimization for machine learning regression applied to software effort estimation. **Information and Software Technology**, v. 52, n. 11, p. 1155–1166, 2010. Elsevier B.V.

ORTIZ, F.; SIMPSON, J. R.; PIGNATIELLO, J. J.; HEREDIA-LANGNER, A. A Genetic Algorithm Approach to Multiple-Response Optimization. **Journal of Quality Technology**, v. 36, n. 4, p. 432–450, 2004.

PAIS, M. S.; FERREIRA, J. C.; TEIXEIRA, M. B.; YAMANAKA, K.; CARRIJO, G. A. Cost Optimization of a Localized Irrigation. 11th International Conference on Intelligent Data Engineering and Automated Learning. **Anais...** . p.29–36, 2010. Paisley, UK.

PAIVA, A. P. DE. **Metodologia de Superfície de Resposta e Análise de Componentes Principais em Otimização de Processos de Manufatura com Múltiplas Respostas Correlacionadas**. Tese de Doutorado - Programa de Pós Graduação em Engenharia Mecânica - Universidade Federal de Itajubá, 2006.

PAIVA, E. J. **Erro Quadrático Médio Multivariado na otimização do torneamento do aço ABNT 52100 endurecido Erro Quadrático Médio Multivariado na otimização do torneamento do aço ABNT 52100 endurecido**. Tese de Doutorado - Programa de Pós Graduação em Engenharia Mecânica - Universidade Federal de Itajubá, 2012.

PINHO, A. F. DE. **Metodologia para utilização de Algoritmos Genéticos em modelos de simulação computacional em ambientes de manufatura**. Tese de Doutorado - Universidade Estadual Paulista, 2008.

RAJESH, J. K.; GUPTA, S. K.; RANGAIAH, G. P.; RAY, A. K. Multi-objective optimization of industrial hydrogen plants. **Chemical Engineering Science**, v. 56, p. 999–1010, 2001.

RAO, S. S. **Engineering optimization: theory and practice**. 4th ed. New Jersey: John Wiley & Sons, 2009.

RAO, S. S.; FREIHEIT, T. I. A Modified Game Theory Approach to Multiobjective Optimization. **Journal of Mechanical Design**, v. 113, n. September 1991, p. 286, 1991.

RYU, J. H.; KIM, S.; WAN, H. Pareto front approximation with adaptive weighted sum method in multiobjective simulation optimization. **Proceedings - Winter Simulation Conference**, , n. x, p. 623–633, 2009.

SALOMON, R. Re-evaluating Genetic Algorithm Performane under Coordinate Rotatation of Benchmark Functions. **BioSystems**, v. 39:3, p. 263–278, 1996.

SANKAR, S. S.; PONNANBALAM, S. G.; RAJENDRAN, C. A multiobjective genetic algorithm for scheduling a flexible manufacturing system. **The International Journal of Advanced Manufacturing Technology**, v. 22, p. 229–236, 2003.

SANTOS, M. C.; MACHADO, A. R.; BARROZO, M. A. S.; JACKSON, M. J.; EZUGWU, E. O. Multi-objective optimization of cutting conditions when turning aluminum alloys

(1350-O and 7075-T6 grades) using genetic algorithm. **The International Journal of Advanced Manufacturing Technology**, v. 76, p. 1123–1138, 2014.

SARDIÑAS, R. Q.; SANTANA, M. R.; BRINDIS, E. A. Genetic algorithm-based optimization of cutting parameters in turning processes. **Procedia CIRP**, v. 7, p. 323–328, 2013.

SCHEFFÉ, H. Experiments With Mixtures. **Journal of the Royal Statistical Society.**, 1958.

SRINIVAS, M.; PATNAIK, L. M. Adaptive Probabilities of Crossover and Mutation in Genetic Algorithms. , v. 24, n. 4, p. 656–667, 1994.

VAHIDINASAB, V.; JADID, S. Normal boundary intersection method for suppliers' strategic bidding in electricity markets: An environmental/economic approach. **Energy Conversion and Management**, v. 51, n. 6, p. 1111–1119, 2010.

WANG, W.; ZMEUREANU, R.; RIVARD, H. Applying multi-objective genetic algorithms in green building design optimization. **Building and Environment**, v. 40, p. 1512–1525, 2005.

ZAIN, A. M.; HARON, H.; SHARIF, S. Application of GA to optimize cutting conditions for minimizing surface roughness in end milling machining process. **Expert Systems with Applications**, v. 37, n. 6, p. 4650–4659, 2010. Elsevier Ltd.

ZHANG, Z.; MAZZOTTI, M.; MORBIDELLI, M. Multiobjective optimization of simulated moving bed and Varicol processes using a genetic algorithm. **Journal of Chromatography A**, v. 989, p. 95–108, 2003.

APÊNDICES

APÊNDICE A - Matriz Experimental utilizada, resultados calculados para EPG e resultados transformados (EPG_{Box-Cox})

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG _{Box-Cox}
1	1	0	0	0	20	0,15	Adapt. Feas.	1,278	0,7823
2	0,75	0,25	0	0	20	0,15	Adapt. Feas.	0,637	1,5692
3	0,75	0	0,25	0	20	0,15	Adapt. Feas.	0,959	1,0424
4	0,75	0	0	0,25	20	0,15	Adapt. Feas.	0,768	1,3025
5	0,5	0,5	0	0	20	0,15	Adapt. Feas.	0,661	1,5135
6	0,5	0,25	0,25	0	20	0,15	Adapt. Feas.	0,428	2,3363
7	0,5	0,25	0	0,25	20	0,15	Adapt. Feas.	0,439	2,2767
8	0,5	0	0,5	0	20	0,15	Adapt. Feas.	1,121	0,8922
9	0,5	0	0,25	0,25	20	0,15	Adapt. Feas.	0,462	2,1654
10	0,5	0	0	0,5	20	0,15	Adapt. Feas.	0,710	1,4094
11	0,25	0,75	0	0	20	0,15	Adapt. Feas.	0,318	3,1443
12	0,25	0,5	0,25	0	20	0,15	Adapt. Feas.	0,469	2,1324
13	0,25	0,5	0	0,25	20	0,15	Adapt. Feas.	0,376	2,6572
14	0,25	0,25	0,5	0	20	0,15	Adapt. Feas.	0,391	2,5547
15	0,25	0,25	0,25	0,25	20	0,15	Adapt. Feas.	0,430	2,3244
16	0,25	0,25	0	0,5	20	0,15	Adapt. Feas.	0,266	3,7632
17	0,25	0	0,75	0	20	0,15	Adapt. Feas.	0,548	1,8257
18	0,25	0	0,5	0,25	20	0,15	Adapt. Feas.	0,349	2,8684
19	0,25	0	0,25	0,5	20	0,15	Adapt. Feas.	0,307	3,2613
20	0,25	0	0	0,75	20	0,15	Adapt. Feas.	0,270	3,7067
21	0	1	0	0	20	0,15	Adapt. Feas.	0,356	2,8095
22	0	0,75	0,25	0	20	0,15	Adapt. Feas.	0,376	2,6564
23	0	0,75	0	0,25	20	0,15	Adapt. Feas.	0,429	2,3311
24	0	0,5	0,5	0	20	0,15	Adapt. Feas.	0,266	3,7587
25	0	0,5	0,25	0,25	20	0,15	Adapt. Feas.	0,287	3,4881
26	0	0,5	0	0,5	20	0,15	Adapt. Feas.	0,202	4,9564
27	0	0,25	0,75	0	20	0,15	Adapt. Feas.	0,404	2,4760
28	0	0,25	0,5	0,25	20	0,15	Adapt. Feas.	0,362	2,7602
29	0	0,25	0,25	0,5	20	0,15	Adapt. Feas.	0,240	4,1638
30	0	0,25	0	0,75	20	0,15	Adapt. Feas.	0,550	1,8190
31	0	0	1	0	20	0,15	Adapt. Feas.	0,420	2,3831
32	0	0	0,75	0,25	20	0,15	Adapt. Feas.	0,342	2,9278
33	0	0	0,5	0,5	20	0,15	Adapt. Feas.	0,317	3,1514
34	0	0	0,25	0,75	20	0,15	Adapt. Feas.	0,293	3,4091
35	0	0	0	1	20	0,15	Adapt. Feas.	0,281	3,5543
36	1	0	0	0	20	0,15	Adapt. Feas.	1,313	0,7618
37	0,75	0,25	0	0	20	0,15	Adapt. Feas.	0,501	1,9946

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
38	0,75	0	0,25	0	20	0,15	Adapt. Feas.	0,815	1,2273
39	0,75	0	0	0,25	20	0,15	Adapt. Feas.	0,554	1,8042
40	0,5	0,5	0	0	20	0,15	Adapt. Feas.	0,418	2,3895
41	0,5	0,25	0,25	0	20	0,15	Adapt. Feas.	0,384	2,6061
42	0,5	0,25	0	0,25	20	0,15	Adapt. Feas.	0,505	1,9809
43	0,5	0	0,5	0	20	0,15	Adapt. Feas.	0,676	1,4795
44	0,5	0	0,25	0,25	20	0,15	Adapt. Feas.	0,340	2,9417
45	0,5	0	0	0,5	20	0,15	Adapt. Feas.	0,463	2,1582
46	0,25	0,75	0	0	20	0,15	Adapt. Feas.	0,312	3,2068
47	0,25	0,5	0,25	0	20	0,15	Adapt. Feas.	0,341	2,9345
48	0,25	0,5	0	0,25	20	0,15	Adapt. Feas.	0,282	3,5418
49	0,25	0,25	0,5	0	20	0,15	Adapt. Feas.	0,511	1,9572
50	0,25	0,25	0,25	0,25	20	0,15	Adapt. Feas.	0,319	3,1378
51	0,25	0,25	0	0,5	20	0,15	Adapt. Feas.	0,261	3,8358
52	0,25	0	0,75	0	20	0,15	Adapt. Feas.	0,462	2,1645
53	0,25	0	0,5	0,25	20	0,15	Adapt. Feas.	0,348	2,8726
54	0,25	0	0,25	0,5	20	0,15	Adapt. Feas.	0,335	2,9810
55	0,25	0	0	0,75	20	0,15	Adapt. Feas.	0,296	3,3781
56	0	1	0	0	20	0,15	Adapt. Feas.	0,217	4,6154
57	0	0,75	0,25	0	20	0,15	Adapt. Feas.	0,279	3,5867
58	0	0,75	0	0,25	20	0,15	Adapt. Feas.	0,233	4,2931
59	0	0,5	0,5	0	20	0,15	Adapt. Feas.	0,278	3,6007
60	0	0,5	0,25	0,25	20	0,15	Adapt. Feas.	0,264	3,7829
61	0	0,5	0	0,5	20	0,15	Adapt. Feas.	0,232	4,3106
62	0	0,25	0,75	0	20	0,15	Adapt. Feas.	0,334	2,9957
63	0	0,25	0,5	0,25	20	0,15	Adapt. Feas.	0,312	3,2029
64	0	0,25	0,25	0,5	20	0,15	Adapt. Feas.	0,284	3,5214
65	0	0,25	0	0,75	20	0,15	Adapt. Feas.	0,244	4,1056
66	0	0	1	0	20	0,15	Adapt. Feas.	0,510	1,9607
67	0	0	0,75	0,25	20	0,15	Adapt. Feas.	0,463	2,1619
68	0	0	0,5	0,5	20	0,15	Adapt. Feas.	0,343	2,9168
69	0	0	0,25	0,75	20	0,15	Adapt. Feas.	0,264	3,7815
70	0	0	0	1	20	0,15	Adapt. Feas.	0,236	4,2315
71	1	0	0	0	20	0,15	Adapt. Feas.	1,560	0,6412
72	0,75	0,25	0	0	20	0,15	Adapt. Feas.	0,534	1,8735
73	0,75	0	0,25	0	20	0,15	Adapt. Feas.	1,074	0,9315
74	0,75	0	0	0,25	20	0,15	Adapt. Feas.	0,498	2,0092
75	0,5	0,5	0	0	20	0,15	Adapt. Feas.	0,573	1,7438
76	0,5	0,25	0,25	0	20	0,15	Adapt. Feas.	0,434	2,3015
77	0,5	0,25	0	0,25	20	0,15	Adapt. Feas.	0,382	2,6144
78	0,5	0	0,5	0	20	0,15	Adapt. Feas.	0,599	1,6698
79	0,5	0	0,25	0,25	20	0,15	Adapt. Feas.	0,608	1,6452
80	0,5	0	0	0,5	20	0,15	Adapt. Feas.	0,456	2,1908

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
81	0,25	0,75	0	0	20	0,15	Adapt. Feas.	0,345	2,8985
82	0,25	0,5	0,25	0	20	0,15	Adapt. Feas.	0,379	2,6365
83	0,25	0,5	0	0,25	20	0,15	Adapt. Feas.	0,413	2,4212
84	0,25	0,25	0,5	0	20	0,15	Adapt. Feas.	0,351	2,8483
85	0,25	0,25	0,25	0,25	20	0,15	Adapt. Feas.	0,359	2,7877
86	0,25	0,25	0	0,5	20	0,15	Adapt. Feas.	0,405	2,4711
87	0,25	0	0,75	0	20	0,15	Adapt. Feas.	0,907	1,1028
88	0,25	0	0,5	0,25	20	0,15	Adapt. Feas.	0,446	2,2420
89	0,25	0	0,25	0,5	20	0,15	Adapt. Feas.	0,349	2,8650
90	0,25	0	0	0,75	20	0,15	Adapt. Feas.	0,272	3,6699
91	0	1	0	0	20	0,15	Adapt. Feas.	0,270	3,6971
92	0	0,75	0,25	0	20	0,15	Adapt. Feas.	0,496	2,0153
93	0	0,75	0	0,25	20	0,15	Adapt. Feas.	0,371	2,6963
94	0	0,5	0,5	0	20	0,15	Adapt. Feas.	0,394	2,5405
95	0	0,5	0,25	0,25	20	0,15	Adapt. Feas.	0,282	3,5464
96	0	0,5	0	0,5	20	0,15	Adapt. Feas.	0,241	4,1467
97	0	0,25	0,75	0	20	0,15	Adapt. Feas.	0,289	3,4589
98	0	0,25	0,5	0,25	20	0,15	Adapt. Feas.	0,268	3,7284
99	0	0,25	0,25	0,5	20	0,15	Adapt. Feas.	0,318	3,1435
100	0	0,25	0	0,75	20	0,15	Adapt. Feas.	0,298	3,3610
101	0	0	1	0	20	0,15	Adapt. Feas.	0,506	1,9779
102	0	0	0,75	0,25	20	0,15	Adapt. Feas.	0,345	2,9021
103	0	0	0,5	0,5	20	0,15	Adapt. Feas.	0,308	3,2449
104	0	0	0,25	0,75	20	0,15	Adapt. Feas.	0,324	3,0845
105	0	0	0	1	20	0,15	Adapt. Feas.	0,309	3,2403
106	1	0	0	0	20	0,15	Adapt. Feas.	1,718	0,5819
107	0,75	0,25	0	0	20	0,15	Adapt. Feas.	0,707	1,4145
108	0,75	0	0,25	0	20	0,15	Adapt. Feas.	0,627	1,5937
109	0,75	0	0	0,25	20	0,15	Adapt. Feas.	0,682	1,4663
110	0,5	0,5	0	0	20	0,15	Adapt. Feas.	0,401	2,4910
111	0,5	0,25	0,25	0	20	0,15	Adapt. Feas.	0,656	1,5243
112	0,5	0,25	0	0,25	20	0,15	Adapt. Feas.	0,378	2,6469
113	0,5	0	0,5	0	20	0,15	Adapt. Feas.	0,947	1,0554
114	0,5	0	0,25	0,25	20	0,15	Adapt. Feas.	0,413	2,4238
115	0,5	0	0	0,5	20	0,15	Adapt. Feas.	0,441	2,2659
116	0,25	0,75	0	0	20	0,15	Adapt. Feas.	0,734	1,3627
117	0,25	0,5	0,25	0	20	0,15	Adapt. Feas.	0,448	2,2330
118	0,25	0,5	0	0,25	20	0,15	Adapt. Feas.	0,276	3,6217
119	0,25	0,25	0,5	0	20	0,15	Adapt. Feas.	0,333	3,0070
120	0,25	0,25	0,25	0,25	20	0,15	Adapt. Feas.	0,303	3,2973
121	0,25	0,25	0	0,5	20	0,15	Adapt. Feas.	0,358	2,7926
122	0,25	0	0,75	0	20	0,15	Adapt. Feas.	0,590	1,6962
123	0,25	0	0,5	0,25	20	0,15	Adapt. Feas.	0,481	2,0777

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
124	0,25	0	0,25	0,5	20	0,15	Adapt. Feas.	0,322	3,1096
125	0,25	0	0	0,75	20	0,15	Adapt. Feas.	0,290	3,4538
126	0	1	0	0	20	0,15	Adapt. Feas.	0,358	2,7898
127	0	0,75	0,25	0	20	0,15	Adapt. Feas.	0,268	3,7314
128	0	0,75	0	0,25	20	0,15	Adapt. Feas.	0,335	2,9853
129	0	0,5	0,5	0	20	0,15	Adapt. Feas.	0,496	2,0172
130	0	0,5	0,25	0,25	20	0,15	Adapt. Feas.	0,315	3,1737
131	0	0,5	0	0,5	20	0,15	Adapt. Feas.	0,272	3,6715
132	0	0,25	0,75	0	20	0,15	Adapt. Feas.	0,313	3,1954
133	0	0,25	0,5	0,25	20	0,15	Adapt. Feas.	0,444	2,2538
134	0	0,25	0,25	0,5	20	0,15	Adapt. Feas.	0,272	3,6827
135	0	0,25	0	0,75	20	0,15	Adapt. Feas.	0,298	3,3591
136	0	0	1	0	20	0,15	Adapt. Feas.	0,646	1,5475
137	0	0	0,75	0,25	20	0,15	Adapt. Feas.	0,705	1,4183
138	0	0	0,5	0,5	20	0,15	Adapt. Feas.	0,294	3,3990
139	0	0	0,25	0,75	20	0,15	Adapt. Feas.	0,381	2,6242
140	0	0	0	1	20	0,15	Adapt. Feas.	0,293	3,4152
141	1	0	0	0	20	0,15	Adapt. Feas.	1,374	0,7280
142	0,75	0,25	0	0	20	0,15	Adapt. Feas.	0,631	1,5853
143	0,75	0	0,25	0	20	0,15	Adapt. Feas.	0,804	1,2439
144	0,75	0	0	0,25	20	0,15	Adapt. Feas.	0,844	1,1843
145	0,5	0,5	0	0	20	0,15	Adapt. Feas.	0,386	2,5940
146	0,5	0,25	0,25	0	20	0,15	Adapt. Feas.	0,574	1,7425
147	0,5	0,25	0	0,25	20	0,15	Adapt. Feas.	0,521	1,9186
148	0,5	0	0,5	0	20	0,15	Adapt. Feas.	0,772	1,2946
149	0,5	0	0,25	0,25	20	0,15	Adapt. Feas.	0,580	1,7235
150	0,5	0	0	0,5	20	0,15	Adapt. Feas.	0,452	2,2112
151	0,25	0,75	0	0	20	0,15	Adapt. Feas.	0,427	2,3400
152	0,25	0,5	0,25	0	20	0,15	Adapt. Feas.	0,318	3,1444
153	0,25	0,5	0	0,25	20	0,15	Adapt. Feas.	0,353	2,8357
154	0,25	0,25	0,5	0	20	0,15	Adapt. Feas.	0,347	2,8805
155	0,25	0,25	0,25	0,25	20	0,15	Adapt. Feas.	0,339	2,9532
156	0,25	0,25	0	0,5	20	0,15	Adapt. Feas.	0,292	3,4221
157	0,25	0	0,75	0	20	0,15	Adapt. Feas.	0,734	1,3617
158	0,25	0	0,5	0,25	20	0,15	Adapt. Feas.	0,574	1,7424
159	0,25	0	0,25	0,5	20	0,15	Adapt. Feas.	0,382	2,6200
160	0,25	0	0	0,75	20	0,15	Adapt. Feas.	0,320	3,1295
161	0	1	0	0	20	0,15	Adapt. Feas.	0,345	2,9027
162	0	0,75	0,25	0	20	0,15	Adapt. Feas.	0,264	3,7815
163	0	0,75	0	0,25	20	0,15	Adapt. Feas.	0,200	4,9900
164	0	0,5	0,5	0	20	0,15	Adapt. Feas.	0,450	2,2225
165	0	0,5	0,25	0,25	20	0,15	Adapt. Feas.	0,254	3,9316
166	0	0,5	0	0,5	20	0,15	Adapt. Feas.	0,424	2,3589

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
167	0	0,25	0,75	0	20	0,15	Adapt. Feas.	0,308	3,2475
168	0	0,25	0,5	0,25	20	0,15	Adapt. Feas.	0,315	3,1758
169	0	0,25	0,25	0,5	20	0,15	Adapt. Feas.	0,291	3,4316
170	0	0,25	0	0,75	20	0,15	Adapt. Feas.	0,251	3,9803
171	0	0	1	0	20	0,15	Adapt. Feas.	0,551	1,8143
172	0	0	0,75	0,25	20	0,15	Adapt. Feas.	0,332	3,0095
173	0	0	0,5	0,5	20	0,15	Adapt. Feas.	0,523	1,9108
174	0	0	0,25	0,75	20	0,15	Adapt. Feas.	0,293	3,4187
175	0	0	0	1	20	0,15	Adapt. Feas.	0,248	4,0369
176	1	0	0	0	20	0,15	Adapt. Feas.	1,369	0,7303
177	0,75	0,25	0	0	20	0,15	Adapt. Feas.	0,626	1,5975
178	0,75	0	0,25	0	20	0,15	Adapt. Feas.	0,813	1,2301
179	0,75	0	0	0,25	20	0,15	Adapt. Feas.	0,495	2,0191
180	0,5	0,5	0	0	20	0,15	Adapt. Feas.	0,410	2,4404
181	0,5	0,25	0,25	0	20	0,15	Adapt. Feas.	0,447	2,2349
182	0,5	0,25	0	0,25	20	0,15	Adapt. Feas.	0,365	2,7378
183	0,5	0	0,5	0	20	0,15	Adapt. Feas.	0,692	1,4457
184	0,5	0	0,25	0,25	20	0,15	Adapt. Feas.	0,436	2,2959
185	0,5	0	0	0,5	20	0,15	Adapt. Feas.	0,483	2,0693
186	0,25	0,75	0	0	20	0,15	Adapt. Feas.	0,311	3,2167
187	0,25	0,5	0,25	0	20	0,15	Adapt. Feas.	0,405	2,4683
188	0,25	0,5	0	0,25	20	0,15	Adapt. Feas.	0,329	3,0408
189	0,25	0,25	0,5	0	20	0,15	Adapt. Feas.	0,341	2,9284
190	0,25	0,25	0,25	0,25	20	0,15	Adapt. Feas.	0,316	3,1627
191	0,25	0,25	0	0,5	20	0,15	Adapt. Feas.	0,291	3,4311
192	0,25	0	0,75	0	20	0,15	Adapt. Feas.	0,454	2,2035
193	0,25	0	0,5	0,25	20	0,15	Adapt. Feas.	0,374	2,6753
194	0,25	0	0,25	0,5	20	0,15	Adapt. Feas.	0,326	3,0718
195	0,25	0	0	0,75	20	0,15	Adapt. Feas.	0,289	3,4543
196	0	1	0	0	20	0,15	Adapt. Feas.	0,218	4,5950
197	0	0,75	0,25	0	20	0,15	Adapt. Feas.	0,269	3,7239
198	0	0,75	0	0,25	20	0,15	Adapt. Feas.	0,283	3,5379
199	0	0,5	0,5	0	20	0,15	Adapt. Feas.	0,277	3,6147
200	0	0,5	0,25	0,25	20	0,15	Adapt. Feas.	0,297	3,3671
201	0	0,5	0	0,5	20	0,15	Adapt. Feas.	0,219	4,5609
202	0	0,25	0,75	0	20	0,15	Adapt. Feas.	0,273	3,6659
203	0	0,25	0,5	0,25	20	0,15	Adapt. Feas.	0,411	2,4327
204	0	0,25	0,25	0,5	20	0,15	Adapt. Feas.	0,271	3,6945
205	0	0,25	0	0,75	20	0,15	Adapt. Feas.	0,251	3,9815
206	0	0	1	0	20	0,15	Adapt. Feas.	0,463	2,1618
207	0	0	0,75	0,25	20	0,15	Adapt. Feas.	0,469	2,1310
208	0	0	0,5	0,5	20	0,15	Adapt. Feas.	0,426	2,3455
209	0	0	0,25	0,75	20	0,15	Adapt. Feas.	0,297	3,3684

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
210	0	0	0	1	20	0,15	Adapt. Feas.	0,227	4,4108
211	1	0	0	0	20	0,15	Adapt. Feas.	1,338	0,7474
212	0,75	0,25	0	0	20	0,15	Adapt. Feas.	0,506	1,9779
213	0,75	0	0,25	0	20	0,15	Adapt. Feas.	0,859	1,1642
214	0,75	0	0	0,25	20	0,15	Adapt. Feas.	0,492	2,0330
215	0,5	0,5	0	0	20	0,15	Adapt. Feas.	0,409	2,4469
216	0,5	0,25	0,25	0	20	0,15	Adapt. Feas.	0,495	2,0202
217	0,5	0,25	0	0,25	20	0,15	Adapt. Feas.	0,378	2,6432
218	0,5	0	0,5	0	20	0,15	Adapt. Feas.	1,049	0,9533
219	0,5	0	0,25	0,25	20	0,15	Adapt. Feas.	0,569	1,7561
220	0,5	0	0	0,5	20	0,15	Adapt. Feas.	0,466	2,1456
221	0,25	0,75	0	0	20	0,15	Adapt. Feas.	0,329	3,0414
222	0,25	0,5	0,25	0	20	0,15	Adapt. Feas.	0,313	3,1916
223	0,25	0,5	0	0,25	20	0,15	Adapt. Feas.	0,390	2,5661
224	0,25	0,25	0,5	0	20	0,15	Adapt. Feas.	0,370	2,7017
225	0,25	0,25	0,25	0,25	20	0,15	Adapt. Feas.	0,289	3,4627
226	0,25	0,25	0	0,5	20	0,15	Adapt. Feas.	0,274	3,6549
227	0,25	0	0,75	0	20	0,15	Adapt. Feas.	0,668	1,4964
228	0,25	0	0,5	0,25	20	0,15	Adapt. Feas.	0,481	2,0811
229	0,25	0	0,25	0,5	20	0,15	Adapt. Feas.	0,321	3,1127
230	0,25	0	0	0,75	20	0,15	Adapt. Feas.	0,295	3,3849
231	0	1	0	0	20	0,15	Adapt. Feas.	0,293	3,4112
232	0	0,75	0,25	0	20	0,15	Adapt. Feas.	0,370	2,7027
233	0	0,75	0	0,25	20	0,15	Adapt. Feas.	0,427	2,3430
234	0	0,5	0,5	0	20	0,15	Adapt. Feas.	0,549	1,8230
235	0	0,5	0,25	0,25	20	0,15	Adapt. Feas.	0,293	3,4149
236	0	0,5	0	0,5	20	0,15	Adapt. Feas.	0,216	4,6263
237	0	0,25	0,75	0	20	0,15	Adapt. Feas.	0,374	2,6774
238	0	0,25	0,5	0,25	20	0,15	Adapt. Feas.	0,298	3,3515
239	0	0,25	0,25	0,5	20	0,15	Adapt. Feas.	0,296	3,3828
240	0	0,25	0	0,75	20	0,15	Adapt. Feas.	0,247	4,0405
241	0	0	1	0	20	0,15	Adapt. Feas.	0,473	2,1136
242	0	0	0,75	0,25	20	0,15	Adapt. Feas.	0,401	2,4918
243	0	0	0,5	0,5	20	0,15	Adapt. Feas.	0,295	3,3859
244	0	0	0,25	0,75	20	0,15	Adapt. Feas.	0,297	3,3690
245	0	0	0	1	20	0,15	Adapt. Feas.	0,280	3,5758
246	1	0	0	0	20	0,15	Adapt. Feas.	1,511	0,6617
247	0,75	0,25	0	0	20	0,15	Adapt. Feas.	0,580	1,7228
248	0,75	0	0,25	0	20	0,15	Adapt. Feas.	0,835	1,1971
249	0,75	0	0	0,25	20	0,15	Adapt. Feas.	0,782	1,2795
250	0,5	0,5	0	0	20	0,15	Adapt. Feas.	0,503	1,9894
251	0,5	0,25	0,25	0	20	0,15	Adapt. Feas.	0,369	2,7092
252	0,5	0,25	0	0,25	20	0,15	Adapt. Feas.	0,780	1,2828

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
253	0,5	0	0,5	0	20	0,15	Adapt. Feas.	0,747	1,3383
254	0,5	0	0,25	0,25	20	0,15	Adapt. Feas.	0,454	2,2015
255	0,5	0	0	0,5	20	0,15	Adapt. Feas.	0,522	1,9142
256	0,25	0,75	0	0	20	0,15	Adapt. Feas.	0,508	1,9673
257	0,25	0,5	0,25	0	20	0,15	Adapt. Feas.	0,305	3,2797
258	0,25	0,5	0	0,25	20	0,15	Adapt. Feas.	0,329	3,0354
259	0,25	0,25	0,5	0	20	0,15	Adapt. Feas.	0,360	2,7785
260	0,25	0,25	0,25	0,25	20	0,15	Adapt. Feas.	0,340	2,9444
261	0,25	0,25	0	0,5	20	0,15	Adapt. Feas.	0,324	3,0892
262	0,25	0	0,75	0	20	0,15	Adapt. Feas.	0,376	2,6586
263	0,25	0	0,5	0,25	20	0,15	Adapt. Feas.	0,363	2,7562
264	0,25	0	0,25	0,5	20	0,15	Adapt. Feas.	0,388	2,5780
265	0,25	0	0	0,75	20	0,15	Adapt. Feas.	0,280	3,5757
266	0	1	0	0	20	0,15	Adapt. Feas.	0,245	4,0736
267	0	0,75	0,25	0	20	0,15	Adapt. Feas.	0,262	3,8108
268	0	0,75	0	0,25	20	0,15	Adapt. Feas.	0,230	4,3425
269	0	0,5	0,5	0	20	0,15	Adapt. Feas.	0,397	2,5164
270	0	0,5	0,25	0,25	20	0,15	Adapt. Feas.	0,232	4,3075
271	0	0,5	0	0,5	20	0,15	Adapt. Feas.	0,409	2,4450
272	0	0,25	0,75	0	20	0,15	Adapt. Feas.	0,382	2,6174
273	0	0,25	0,5	0,25	20	0,15	Adapt. Feas.	0,298	3,3604
274	0	0,25	0,25	0,5	20	0,15	Adapt. Feas.	0,240	4,1663
275	0	0,25	0	0,75	20	0,15	Adapt. Feas.	0,261	3,8383
276	0	0	1	0	20	0,15	Adapt. Feas.	0,564	1,7732
277	0	0	0,75	0,25	20	0,15	Adapt. Feas.	0,866	1,1545
278	0	0	0,5	0,5	20	0,15	Adapt. Feas.	0,511	1,9563
279	0	0	0,25	0,75	20	0,15	Adapt. Feas.	0,465	2,1493
280	0	0	0	1	20	0,15	Adapt. Feas.	0,296	3,3743
281	1	0	0	0	20	0,15	Adapt. Feas.	1,061	0,9428
282	0,75	0,25	0	0	20	0,15	Adapt. Feas.	0,531	1,8849
283	0,75	0	0,25	0	20	0,15	Adapt. Feas.	0,713	1,4018
284	0,75	0	0	0,25	20	0,15	Adapt. Feas.	0,497	2,0110
285	0,5	0,5	0	0	20	0,15	Adapt. Feas.	0,385	2,5991
286	0,5	0,25	0,25	0	20	0,15	Adapt. Feas.	0,587	1,7023
287	0,5	0,25	0	0,25	20	0,15	Adapt. Feas.	0,442	2,2610
288	0,5	0	0,5	0	20	0,15	Adapt. Feas.	0,891	1,1218
289	0,5	0	0,25	0,25	20	0,15	Adapt. Feas.	0,414	2,4156
290	0,5	0	0	0,5	20	0,15	Adapt. Feas.	0,635	1,5745
291	0,25	0,75	0	0	20	0,15	Adapt. Feas.	0,360	2,7796
292	0,25	0,5	0,25	0	20	0,15	Adapt. Feas.	0,449	2,2276
293	0,25	0,5	0	0,25	20	0,15	Adapt. Feas.	0,363	2,7522
294	0,25	0,25	0,5	0	20	0,15	Adapt. Feas.	0,348	2,8721
295	0,25	0,25	0,25	0,25	20	0,15	Adapt. Feas.	0,507	1,9738

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
296	0,25	0,25	0	0,5	20	0,15	Adapt. Feas.	0,319	3,1327
297	0,25	0	0,75	0	20	0,15	Adapt. Feas.	0,649	1,5407
298	0,25	0	0,5	0,25	20	0,15	Adapt. Feas.	0,452	2,2139
299	0,25	0	0,25	0,5	20	0,15	Adapt. Feas.	0,340	2,9436
300	0,25	0	0	0,75	20	0,15	Adapt. Feas.	0,350	2,8578
301	0	1	0	0	20	0,15	Adapt. Feas.	0,295	3,3861
302	0	0,75	0,25	0	20	0,15	Adapt. Feas.	0,320	3,1230
303	0	0,75	0	0,25	20	0,15	Adapt. Feas.	0,391	2,5607
304	0	0,5	0,5	0	20	0,15	Adapt. Feas.	0,326	3,0653
305	0	0,5	0,25	0,25	20	0,15	Adapt. Feas.	0,392	2,5494
306	0	0,5	0	0,5	20	0,15	Adapt. Feas.	0,201	4,9744
307	0	0,25	0,75	0	20	0,15	Adapt. Feas.	0,296	3,3729
308	0	0,25	0,5	0,25	20	0,15	Adapt. Feas.	0,401	2,4948
309	0	0,25	0,25	0,5	20	0,15	Adapt. Feas.	0,304	3,2905
310	0	0,25	0	0,75	20	0,15	Adapt. Feas.	0,260	3,8485
311	0	0	1	0	20	0,15	Adapt. Feas.	0,557	1,7965
312	0	0	0,75	0,25	20	0,15	Adapt. Feas.	0,331	3,0188
313	0	0	0,5	0,5	20	0,15	Adapt. Feas.	0,256	3,8997
314	0	0	0,25	0,75	20	0,15	Adapt. Feas.	0,347	2,8830
315	0	0	0	1	20	0,15	Adapt. Feas.	0,258	3,8779
316	1	0	0	0	20	0,15	Adapt. Feas.	1,323	0,7561
317	0,75	0,25	0	0	20	0,15	Adapt. Feas.	0,597	1,6760
318	0,75	0	0,25	0	20	0,15	Adapt. Feas.	0,628	1,5923
319	0,75	0	0	0,25	20	0,15	Adapt. Feas.	0,674	1,4838
320	0,5	0,5	0	0	20	0,15	Adapt. Feas.	0,380	2,6323
321	0,5	0,25	0,25	0	20	0,15	Adapt. Feas.	0,459	2,1770
322	0,5	0,25	0	0,25	20	0,15	Adapt. Feas.	0,486	2,0564
323	0,5	0	0,5	0	20	0,15	Adapt. Feas.	0,888	1,1258
324	0,5	0	0,25	0,25	20	0,15	Adapt. Feas.	0,371	2,6957
325	0,5	0	0	0,5	20	0,15	Adapt. Feas.	0,491	2,0373
326	0,25	0,75	0	0	20	0,15	Adapt. Feas.	0,304	3,2884
327	0,25	0,5	0,25	0	20	0,15	Adapt. Feas.	0,329	3,0386
328	0,25	0,5	0	0,25	20	0,15	Adapt. Feas.	0,367	2,7281
329	0,25	0,25	0,5	0	20	0,15	Adapt. Feas.	0,316	3,1686
330	0,25	0,25	0,25	0,25	20	0,15	Adapt. Feas.	0,332	3,0097
331	0,25	0,25	0	0,5	20	0,15	Adapt. Feas.	0,291	3,4341
332	0,25	0	0,75	0	20	0,15	Adapt. Feas.	0,463	2,1597
333	0,25	0	0,5	0,25	20	0,15	Adapt. Feas.	0,453	2,2094
334	0,25	0	0,25	0,5	20	0,15	Adapt. Feas.	0,344	2,9082
335	0,25	0	0	0,75	20	0,15	Adapt. Feas.	0,261	3,8248
336	0	1	0	0	20	0,15	Adapt. Feas.	0,224	4,4736
337	0	0,75	0,25	0	20	0,15	Adapt. Feas.	0,272	3,6737
338	0	0,75	0	0,25	20	0,15	Adapt. Feas.	0,242	4,1406

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
339	0	0,5	0,5	0	20	0,15	Adapt. Feas.	0,248	4,0270
340	0	0,5	0,25	0,25	20	0,15	Adapt. Feas.	0,245	4,0840
341	0	0,5	0	0,5	20	0,15	Adapt. Feas.	0,234	4,2749
342	0	0,25	0,75	0	20	0,15	Adapt. Feas.	0,341	2,9297
343	0	0,25	0,5	0,25	20	0,15	Adapt. Feas.	0,284	3,5185
344	0	0,25	0,25	0,5	20	0,15	Adapt. Feas.	0,328	3,0515
345	0	0,25	0	0,75	20	0,15	Adapt. Feas.	0,206	4,8531
346	0	0	1	0	20	0,15	Adapt. Feas.	0,513	1,9479
347	0	0	0,75	0,25	20	0,15	Adapt. Feas.	0,475	2,1041
348	0	0	0,5	0,5	20	0,15	Adapt. Feas.	0,370	2,7040
349	0	0	0,25	0,75	20	0,15	Adapt. Feas.	0,295	3,3884
350	0	0	0	1	20	0,15	Adapt. Feas.	0,249	4,0209
351	1	0	0	0	100	0,15	Gaussiana	1,437	0,6961
352	0,75	0,25	0	0	100	0,15	Gaussiana	0,422	2,3701
353	0,75	0	0,25	0	100	0,15	Gaussiana	0,758	1,3192
354	0,75	0	0	0,25	100	0,15	Gaussiana	0,517	1,9355
355	0,5	0,5	0	0	100	0,15	Gaussiana	0,430	2,3239
356	0,5	0,25	0,25	0	100	0,15	Gaussiana	0,327	3,0548
357	0,5	0,25	0	0,25	100	0,15	Gaussiana	0,392	2,5543
358	0,5	0	0,5	0	100	0,15	Gaussiana	0,962	1,0392
359	0,5	0	0,25	0,25	100	0,15	Gaussiana	0,442	2,2607
360	0,5	0	0	0,5	100	0,15	Gaussiana	0,337	2,9635
361	0,25	0,75	0	0	100	0,15	Gaussiana	0,280	3,5750
362	0,25	0,5	0,25	0	100	0,15	Gaussiana	0,290	3,4439
363	0,25	0,5	0	0,25	100	0,15	Gaussiana	0,310	3,2309
364	0,25	0,25	0,5	0	100	0,15	Gaussiana	0,302	3,3061
365	0,25	0,25	0,25	0,25	100	0,15	Gaussiana	0,345	2,8996
366	0,25	0,25	0	0,5	100	0,15	Gaussiana	0,367	2,7219
367	0,25	0	0,75	0	100	0,15	Gaussiana	0,478	2,0914
368	0,25	0	0,5	0,25	100	0,15	Gaussiana	0,356	2,8126
369	0,25	0	0,25	0,5	100	0,15	Gaussiana	0,329	3,0372
370	0,25	0	0	0,75	100	0,15	Gaussiana	0,311	3,2187
371	0	1	0	0	100	0,15	Gaussiana	0,222	4,4954
372	0	0,75	0,25	0	100	0,15	Gaussiana	0,225	4,4520
373	0	0,75	0	0,25	100	0,15	Gaussiana	0,201	4,9775
374	0	0,5	0,5	0	100	0,15	Gaussiana	0,238	4,2045
375	0	0,5	0,25	0,25	100	0,15	Gaussiana	0,267	3,7518
376	0	0,5	0	0,5	100	0,15	Gaussiana	0,242	4,1271
377	0	0,25	0,75	0	100	0,15	Gaussiana	0,300	3,3375
378	0	0,25	0,5	0,25	100	0,15	Gaussiana	0,327	3,0555
379	0	0,25	0,25	0,5	100	0,15	Gaussiana	0,248	4,0276
380	0	0,25	0	0,75	100	0,15	Gaussiana	0,206	4,8446
381	0	0	1	0	100	0,15	Gaussiana	0,574	1,7427

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
382	0	0	0,75	0,25	100	0,15	Gaussiana	0,332	3,0142
383	0	0	0,5	0,5	100	0,15	Gaussiana	0,304	3,2893
384	0	0	0,25	0,75	100	0,15	Gaussiana	0,249	4,0150
385	0	0	0	1	100	0,15	Gaussiana	0,202	4,9575
386	1	0	0	0	100	0,15	Gaussiana	1,168	0,8565
387	0,75	0,25	0	0	100	0,15	Gaussiana	0,507	1,9735
388	0,75	0	0,25	0	100	0,15	Gaussiana	0,578	1,7287
389	0,75	0	0	0,25	100	0,15	Gaussiana	0,504	1,9848
390	0,5	0,5	0	0	100	0,15	Gaussiana	0,437	2,2868
391	0,5	0,25	0,25	0	100	0,15	Gaussiana	0,358	2,7934
392	0,5	0,25	0	0,25	100	0,15	Gaussiana	0,361	2,7716
393	0,5	0	0,5	0	100	0,15	Gaussiana	0,616	1,6225
394	0,5	0	0,25	0,25	100	0,15	Gaussiana	0,479	2,0892
395	0,5	0	0	0,5	100	0,15	Gaussiana	0,351	2,8486
396	0,25	0,75	0	0	100	0,15	Gaussiana	0,342	2,9204
397	0,25	0,5	0,25	0	100	0,15	Gaussiana	0,281	3,5528
398	0,25	0,5	0	0,25	100	0,15	Gaussiana	0,249	4,0193
399	0,25	0,25	0,5	0	100	0,15	Gaussiana	0,327	3,0614
400	0,25	0,25	0,25	0,25	100	0,15	Gaussiana	0,261	3,8282
401	0,25	0,25	0	0,5	100	0,15	Gaussiana	0,332	3,0126
402	0,25	0	0,75	0	100	0,15	Gaussiana	0,605	1,6531
403	0,25	0	0,5	0,25	100	0,15	Gaussiana	0,495	2,0183
404	0,25	0	0,25	0,5	100	0,15	Gaussiana	0,264	3,7820
405	0,25	0	0	0,75	100	0,15	Gaussiana	0,294	3,3958
406	0	1	0	0	100	0,15	Gaussiana	0,265	3,7796
407	0	0,75	0,25	0	100	0,15	Gaussiana	0,310	3,2210
408	0	0,75	0	0,25	100	0,15	Gaussiana	0,245	4,0830
409	0	0,5	0,5	0	100	0,15	Gaussiana	0,255	3,9139
410	0	0,5	0,25	0,25	100	0,15	Gaussiana	0,253	3,9562
411	0	0,5	0	0,5	100	0,15	Gaussiana	0,244	4,0934
412	0	0,25	0,75	0	100	0,15	Gaussiana	0,260	3,8512
413	0	0,25	0,5	0,25	100	0,15	Gaussiana	0,255	3,9147
414	0	0,25	0,25	0,5	100	0,15	Gaussiana	0,257	3,8972
415	0	0,25	0	0,75	100	0,15	Gaussiana	0,242	4,1317
416	0	0	1	0	100	0,15	Gaussiana	0,407	2,4594
417	0	0	0,75	0,25	100	0,15	Gaussiana	0,344	2,9092
418	0	0	0,5	0,5	100	0,15	Gaussiana	0,347	2,8801
419	0	0	0,25	0,75	100	0,15	Gaussiana	0,326	3,0646
420	0	0	0	1	100	0,15	Gaussiana	0,208	4,8079
421	1	0	0	0	100	0,15	Gaussiana	1,340	0,7465
422	0,75	0,25	0	0	100	0,15	Gaussiana	0,510	1,9590
423	0,75	0	0,25	0	100	0,15	Gaussiana	0,738	1,3552
424	0,75	0	0	0,25	100	0,15	Gaussiana	0,445	2,2488

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
425	0,5	0,5	0	0	100	0,15	Gaussiana	0,376	2,6628
426	0,5	0,25	0,25	0	100	0,15	Gaussiana	0,339	2,9518
427	0,5	0,25	0	0,25	100	0,15	Gaussiana	0,455	2,1964
428	0,5	0	0,5	0	100	0,15	Gaussiana	0,588	1,7020
429	0,5	0	0,25	0,25	100	0,15	Gaussiana	0,444	2,2517
430	0,5	0	0	0,5	100	0,15	Gaussiana	0,404	2,4778
431	0,25	0,75	0	0	100	0,15	Gaussiana	0,326	3,0703
432	0,25	0,5	0,25	0	100	0,15	Gaussiana	0,340	2,9385
433	0,25	0,5	0	0,25	100	0,15	Gaussiana	0,305	3,2747
434	0,25	0,25	0,5	0	100	0,15	Gaussiana	0,420	2,3833
435	0,25	0,25	0,25	0,25	100	0,15	Gaussiana	0,303	3,2999
436	0,25	0,25	0	0,5	100	0,15	Gaussiana	0,253	3,9494
437	0,25	0	0,75	0	100	0,15	Gaussiana	0,446	2,2423
438	0,25	0	0,5	0,25	100	0,15	Gaussiana	0,409	2,4455
439	0,25	0	0,25	0,5	100	0,15	Gaussiana	0,318	3,1431
440	0,25	0	0	0,75	100	0,15	Gaussiana	0,291	3,4337
441	0	1	0	0	100	0,15	Gaussiana	0,231	4,3359
442	0	0,75	0,25	0	100	0,15	Gaussiana	0,353	2,8300
443	0	0,75	0	0,25	100	0,15	Gaussiana	0,258	3,8803
444	0	0,5	0,5	0	100	0,15	Gaussiana	0,253	3,9507
445	0	0,5	0,25	0,25	100	0,15	Gaussiana	0,207	4,8210
446	0	0,5	0	0,5	100	0,15	Gaussiana	0,256	3,9063
447	0	0,25	0,75	0	100	0,15	Gaussiana	0,290	3,4438
448	0	0,25	0,5	0,25	100	0,15	Gaussiana	0,336	2,9737
449	0	0,25	0,25	0,5	100	0,15	Gaussiana	0,315	3,1740
450	0	0,25	0	0,75	100	0,15	Gaussiana	0,226	4,4315
451	0	0	1	0	100	0,15	Gaussiana	0,430	2,3261
452	0	0	0,75	0,25	100	0,15	Gaussiana	0,464	2,1544
453	0	0	0,5	0,5	100	0,15	Gaussiana	0,311	3,2179
454	0	0	0,25	0,75	100	0,15	Gaussiana	0,383	2,6078
455	0	0	0	1	100	0,15	Gaussiana	0,230	4,3479
456	1	0	0	0	100	0,15	Gaussiana	1,447	0,6909
457	0,75	0,25	0	0	100	0,15	Gaussiana	0,539	1,8550
458	0,75	0	0,25	0	100	0,15	Gaussiana	0,852	1,1743
459	0,75	0	0	0,25	100	0,15	Gaussiana	0,480	2,0845
460	0,5	0,5	0	0	100	0,15	Gaussiana	0,423	2,3651
461	0,5	0,25	0,25	0	100	0,15	Gaussiana	0,427	2,3402
462	0,5	0,25	0	0,25	100	0,15	Gaussiana	0,377	2,6510
463	0,5	0	0,5	0	100	0,15	Gaussiana	0,541	1,8467
464	0,5	0	0,25	0,25	100	0,15	Gaussiana	0,347	2,8820
465	0,5	0	0	0,5	100	0,15	Gaussiana	0,558	1,7909
466	0,25	0,75	0	0	100	0,15	Gaussiana	0,279	3,5803
467	0,25	0,5	0,25	0	100	0,15	Gaussiana	0,310	3,2252

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
468	0,25	0,5	0	0,25	100	0,15	Gaussiana	0,279	3,5813
469	0,25	0,25	0,5	0	100	0,15	Gaussiana	0,343	2,9154
470	0,25	0,25	0,25	0,25	100	0,15	Gaussiana	0,418	2,3936
471	0,25	0,25	0	0,5	100	0,15	Gaussiana	0,333	3,0074
472	0,25	0	0,75	0	100	0,15	Gaussiana	0,342	2,9229
473	0,25	0	0,5	0,25	100	0,15	Gaussiana	0,346	2,8894
474	0,25	0	0,25	0,5	100	0,15	Gaussiana	0,295	3,3864
475	0,25	0	0	0,75	100	0,15	Gaussiana	0,263	3,8007
476	0	1	0	0	100	0,15	Gaussiana	0,255	3,9202
477	0	0,75	0,25	0	100	0,15	Gaussiana	0,256	3,9124
478	0	0,75	0	0,25	100	0,15	Gaussiana	0,245	4,0773
479	0	0,5	0,5	0	100	0,15	Gaussiana	0,238	4,1931
480	0	0,5	0,25	0,25	100	0,15	Gaussiana	0,230	4,3501
481	0	0,5	0	0,5	100	0,15	Gaussiana	0,218	4,5836
482	0	0,25	0,75	0	100	0,15	Gaussiana	0,244	4,1022
483	0	0,25	0,5	0,25	100	0,15	Gaussiana	0,324	3,0894
484	0	0,25	0,25	0,5	100	0,15	Gaussiana	0,347	2,8811
485	0	0,25	0	0,75	100	0,15	Gaussiana	0,248	4,0260
486	0	0	1	0	100	0,15	Gaussiana	0,404	2,4766
487	0	0	0,75	0,25	100	0,15	Gaussiana	0,331	3,0182
488	0	0	0,5	0,5	100	0,15	Gaussiana	0,290	3,4462
489	0	0	0,25	0,75	100	0,15	Gaussiana	0,240	4,1734
490	0	0	0	1	100	0,15	Gaussiana	0,232	4,3066
491	1	0	0	0	100	0,15	Gaussiana	1,128	0,8863
492	0,75	0,25	0	0	100	0,15	Gaussiana	0,509	1,9666
493	0,75	0	0,25	0	100	0,15	Gaussiana	0,453	2,2083
494	0,75	0	0	0,25	100	0,15	Gaussiana	0,492	2,0346
495	0,5	0,5	0	0	100	0,15	Gaussiana	0,464	2,1557
496	0,5	0,25	0,25	0	100	0,15	Gaussiana	0,416	2,4041
497	0,5	0,25	0	0,25	100	0,15	Gaussiana	0,383	2,6127
498	0,5	0	0,5	0	100	0,15	Gaussiana	0,647	1,5457
499	0,5	0	0,25	0,25	100	0,15	Gaussiana	0,419	2,3850
500	0,5	0	0	0,5	100	0,15	Gaussiana	0,440	2,2709
501	0,25	0,75	0	0	100	0,15	Gaussiana	0,347	2,8855
502	0,25	0,5	0,25	0	100	0,15	Gaussiana	0,292	3,4278
503	0,25	0,5	0	0,25	100	0,15	Gaussiana	0,270	3,7038
504	0,25	0,25	0,5	0	100	0,15	Gaussiana	0,297	3,3695
505	0,25	0,25	0,25	0,25	100	0,15	Gaussiana	0,318	3,1457
506	0,25	0,25	0	0,5	100	0,15	Gaussiana	0,339	2,9536
507	0,25	0	0,75	0	100	0,15	Gaussiana	0,314	3,1854
508	0,25	0	0,5	0,25	100	0,15	Gaussiana	0,356	2,8120
509	0,25	0	0,25	0,5	100	0,15	Gaussiana	0,248	4,0385
510	0,25	0	0	0,75	100	0,15	Gaussiana	0,238	4,2044

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG _{Box-Cox}
511	0	1	0	0	100	0,15	Gaussiana	0,287	3,4902
512	0	0,75	0,25	0	100	0,15	Gaussiana	0,207	4,8395
513	0	0,75	0	0,25	100	0,15	Gaussiana	0,207	4,8372
514	0	0,5	0,5	0	100	0,15	Gaussiana	0,223	4,4764
515	0	0,5	0,25	0,25	100	0,15	Gaussiana	0,275	3,6339
516	0	0,5	0	0,5	100	0,15	Gaussiana	0,200	4,9923
517	0	0,25	0,75	0	100	0,15	Gaussiana	0,386	2,5927
518	0	0,25	0,5	0,25	100	0,15	Gaussiana	0,272	3,6757
519	0	0,25	0,25	0,5	100	0,15	Gaussiana	0,257	3,8969
520	0	0,25	0	0,75	100	0,15	Gaussiana	0,286	3,4913
521	0	0	1	0	100	0,15	Gaussiana	0,446	2,2430
522	0	0	0,75	0,25	100	0,15	Gaussiana	0,246	4,0698
523	0	0	0,5	0,5	100	0,15	Gaussiana	0,261	3,8267
524	0	0	0,25	0,75	100	0,15	Gaussiana	0,269	3,7201
525	0	0	0	1	100	0,15	Gaussiana	0,233	4,2857
526	1	0	0	0	100	0,15	Gaussiana	1,241	0,8061
527	0,75	0,25	0	0	100	0,15	Gaussiana	0,561	1,7833
528	0,75	0	0,25	0	100	0,15	Gaussiana	0,768	1,3014
529	0,75	0	0	0,25	100	0,15	Gaussiana	0,492	2,0309
530	0,5	0,5	0	0	100	0,15	Gaussiana	0,376	2,6564
531	0,5	0,25	0,25	0	100	0,15	Gaussiana	0,380	2,6307
532	0,5	0,25	0	0,25	100	0,15	Gaussiana	0,380	2,6288
533	0,5	0	0,5	0	100	0,15	Gaussiana	0,449	2,2282
534	0,5	0	0,25	0,25	100	0,15	Gaussiana	0,330	3,0320
535	0,5	0	0	0,5	100	0,15	Gaussiana	0,385	2,5968
536	0,25	0,75	0	0	100	0,15	Gaussiana	0,278	3,5922
537	0,25	0,5	0,25	0	100	0,15	Gaussiana	0,336	2,9804
538	0,25	0,5	0	0,25	100	0,15	Gaussiana	0,330	3,0263
539	0,25	0,25	0,5	0	100	0,15	Gaussiana	0,307	3,2522
540	0,25	0,25	0,25	0,25	100	0,15	Gaussiana	0,324	3,0893
541	0,25	0,25	0	0,5	100	0,15	Gaussiana	0,297	3,3698
542	0,25	0	0,75	0	100	0,15	Gaussiana	0,553	1,8083
543	0,25	0	0,5	0,25	100	0,15	Gaussiana	0,396	2,5234
544	0,25	0	0,25	0,5	100	0,15	Gaussiana	0,266	3,7642
545	0,25	0	0	0,75	100	0,15	Gaussiana	0,346	2,8863
546	0	1	0	0	100	0,15	Gaussiana	0,218	4,5828
547	0	0,75	0,25	0	100	0,15	Gaussiana	0,267	3,7436
548	0	0,75	0	0,25	100	0,15	Gaussiana	0,278	3,5993
549	0	0,5	0,5	0	100	0,15	Gaussiana	0,281	3,5622
550	0	0,5	0,25	0,25	100	0,15	Gaussiana	0,287	3,4879
551	0	0,5	0	0,5	100	0,15	Gaussiana	0,223	4,4849
552	0	0,25	0,75	0	100	0,15	Gaussiana	0,264	3,7876
553	0	0,25	0,5	0,25	100	0,15	Gaussiana	0,263	3,8027

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
554	0	0,25	0,25	0,5	100	0,15	Gaussiana	0,244	4,0971
555	0	0,25	0	0,75	100	0,15	Gaussiana	0,228	4,3844
556	0	0	1	0	100	0,15	Gaussiana	0,604	1,6565
557	0	0	0,75	0,25	100	0,15	Gaussiana	0,372	2,6853
558	0	0	0,5	0,5	100	0,15	Gaussiana	0,300	3,3313
559	0	0	0,25	0,75	100	0,15	Gaussiana	0,322	3,1092
560	0	0	0	1	100	0,15	Gaussiana	0,292	3,4223
561	1	0	0	0	100	0,15	Gaussiana	1,188	0,8419
562	0,75	0,25	0	0	100	0,15	Gaussiana	0,528	1,8933
563	0,75	0	0,25	0	100	0,15	Gaussiana	0,787	1,2706
564	0,75	0	0	0,25	100	0,15	Gaussiana	0,536	1,8640
565	0,5	0,5	0	0	100	0,15	Gaussiana	0,455	2,1973
566	0,5	0,25	0,25	0	100	0,15	Gaussiana	0,394	2,5397
567	0,5	0,25	0	0,25	100	0,15	Gaussiana	0,412	2,4272
568	0,5	0	0,5	0	100	0,15	Gaussiana	0,506	1,9760
569	0,5	0	0,25	0,25	100	0,15	Gaussiana	0,501	1,9948
570	0,5	0	0	0,5	100	0,15	Gaussiana	0,365	2,7363
571	0,25	0,75	0	0	100	0,15	Gaussiana	0,334	2,9914
572	0,25	0,5	0,25	0	100	0,15	Gaussiana	0,273	3,6656
573	0,25	0,5	0	0,25	100	0,15	Gaussiana	0,348	2,8768
574	0,25	0,25	0,5	0	100	0,15	Gaussiana	0,248	4,0275
575	0,25	0,25	0,25	0,25	100	0,15	Gaussiana	0,295	3,3919
576	0,25	0,25	0	0,5	100	0,15	Gaussiana	0,279	3,5897
577	0,25	0	0,75	0	100	0,15	Gaussiana	0,449	2,2252
578	0,25	0	0,5	0,25	100	0,15	Gaussiana	0,394	2,5409
579	0,25	0	0,25	0,5	100	0,15	Gaussiana	0,320	3,1254
580	0,25	0	0	0,75	100	0,15	Gaussiana	0,425	2,3539
581	0	1	0	0	100	0,15	Gaussiana	0,205	4,8724
582	0	0,75	0,25	0	100	0,15	Gaussiana	0,314	3,1865
583	0	0,75	0	0,25	100	0,15	Gaussiana	0,216	4,6371
584	0	0,5	0,5	0	100	0,15	Gaussiana	0,370	2,7024
585	0	0,5	0,25	0,25	100	0,15	Gaussiana	0,239	4,1807
586	0	0,5	0	0,5	100	0,15	Gaussiana	0,344	2,9061
587	0	0,25	0,75	0	100	0,15	Gaussiana	0,379	2,6351
588	0	0,25	0,5	0,25	100	0,15	Gaussiana	0,221	4,5160
589	0	0,25	0,25	0,5	100	0,15	Gaussiana	0,340	2,9448
590	0	0,25	0	0,75	100	0,15	Gaussiana	0,388	2,5763
591	0	0	1	0	100	0,15	Gaussiana	0,404	2,4735
592	0	0	0,75	0,25	100	0,15	Gaussiana	0,444	2,2519
593	0	0	0,5	0,5	100	0,15	Gaussiana	0,427	2,3441
594	0	0	0,25	0,75	100	0,15	Gaussiana	0,301	3,3226
595	0	0	0	1	100	0,15	Gaussiana	0,332	3,0146
596	1	0	0	0	100	0,15	Gaussiana	1,137	0,8795

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
597	0,75	0,25	0	0	100	0,15	Gaussiana	0,460	2,1754
598	0,75	0	0,25	0	100	0,15	Gaussiana	0,616	1,6232
599	0,75	0	0	0,25	100	0,15	Gaussiana	0,566	1,7667
600	0,5	0,5	0	0	100	0,15	Gaussiana	0,417	2,4005
601	0,5	0,25	0,25	0	100	0,15	Gaussiana	0,476	2,1023
602	0,5	0,25	0	0,25	100	0,15	Gaussiana	0,389	2,5712
603	0,5	0	0,5	0	100	0,15	Gaussiana	0,422	2,3689
604	0,5	0	0,25	0,25	100	0,15	Gaussiana	0,502	1,9930
605	0,5	0	0	0,5	100	0,15	Gaussiana	0,413	2,4235
606	0,25	0,75	0	0	100	0,15	Gaussiana	0,369	2,7115
607	0,25	0,5	0,25	0	100	0,15	Gaussiana	0,298	3,3549
608	0,25	0,5	0	0,25	100	0,15	Gaussiana	0,277	3,6123
609	0,25	0,25	0,5	0	100	0,15	Gaussiana	0,275	3,6389
610	0,25	0,25	0,25	0,25	100	0,15	Gaussiana	0,276	3,6171
611	0,25	0,25	0	0,5	100	0,15	Gaussiana	0,267	3,7486
612	0,25	0	0,75	0	100	0,15	Gaussiana	0,718	1,3933
613	0,25	0	0,5	0,25	100	0,15	Gaussiana	0,446	2,2411
614	0,25	0	0,25	0,5	100	0,15	Gaussiana	0,340	2,9446
615	0,25	0	0	0,75	100	0,15	Gaussiana	0,287	3,4897
616	0	1	0	0	100	0,15	Gaussiana	0,255	3,9248
617	0	0,75	0,25	0	100	0,15	Gaussiana	0,244	4,1002
618	0	0,75	0	0,25	100	0,15	Gaussiana	0,227	4,4079
619	0	0,5	0,5	0	100	0,15	Gaussiana	0,281	3,5563
620	0	0,5	0,25	0,25	100	0,15	Gaussiana	0,277	3,6160
621	0	0,5	0	0,5	100	0,15	Gaussiana	0,246	4,0718
622	0	0,25	0,75	0	100	0,15	Gaussiana	0,354	2,8259
623	0	0,25	0,5	0,25	100	0,15	Gaussiana	0,300	3,3289
624	0	0,25	0,25	0,5	100	0,15	Gaussiana	0,258	3,8831
625	0	0,25	0	0,75	100	0,15	Gaussiana	0,196	5,0923
626	0	0	1	0	100	0,15	Gaussiana	0,433	2,3108
627	0	0	0,75	0,25	100	0,15	Gaussiana	0,327	3,0556
628	0	0	0,5	0,5	100	0,15	Gaussiana	0,378	2,6435
629	0	0	0,25	0,75	100	0,15	Gaussiana	0,284	3,5272
630	0	0	0	1	100	0,15	Gaussiana	0,231	4,3229
631	1	0	0	0	100	0,15	Gaussiana	1,718	0,5820
632	0,75	0,25	0	0	100	0,15	Gaussiana	0,545	1,8359
633	0,75	0	0,25	0	100	0,15	Gaussiana	0,723	1,3837
634	0,75	0	0	0,25	100	0,15	Gaussiana	0,557	1,7951
635	0,5	0,5	0	0	100	0,15	Gaussiana	0,359	2,7833
636	0,5	0,25	0,25	0	100	0,15	Gaussiana	0,390	2,5670
637	0,5	0,25	0	0,25	100	0,15	Gaussiana	0,366	2,7344
638	0,5	0	0,5	0	100	0,15	Gaussiana	0,684	1,4621
639	0,5	0	0,25	0,25	100	0,15	Gaussiana	0,328	3,0458

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
640	0,5	0	0	0,5	100	0,15	Gaussiana	0,387	2,5860
641	0,25	0,75	0	0	100	0,15	Gaussiana	0,337	2,9685
642	0,25	0,5	0,25	0	100	0,15	Gaussiana	0,296	3,3804
643	0,25	0,5	0	0,25	100	0,15	Gaussiana	0,307	3,2616
644	0,25	0,25	0,5	0	100	0,15	Gaussiana	0,251	3,9868
645	0,25	0,25	0,25	0,25	100	0,15	Gaussiana	0,286	3,5006
646	0,25	0,25	0	0,5	100	0,15	Gaussiana	0,346	2,8924
647	0,25	0	0,75	0	100	0,15	Gaussiana	0,326	3,0642
648	0,25	0	0,5	0,25	100	0,15	Gaussiana	0,384	2,6017
649	0,25	0	0,25	0,5	100	0,15	Gaussiana	0,302	3,3155
650	0,25	0	0	0,75	100	0,15	Gaussiana	0,253	3,9522
651	0	1	0	0	100	0,15	Gaussiana	0,246	4,0581
652	0	0,75	0,25	0	100	0,15	Gaussiana	0,236	4,2459
653	0	0,75	0	0,25	100	0,15	Gaussiana	0,193	5,1833
654	0	0,5	0,5	0	100	0,15	Gaussiana	0,269	3,7150
655	0	0,5	0,25	0,25	100	0,15	Gaussiana	0,285	3,5100
656	0	0,5	0	0,5	100	0,15	Gaussiana	0,215	4,6520
657	0	0,25	0,75	0	100	0,15	Gaussiana	0,268	3,7353
658	0	0,25	0,5	0,25	100	0,15	Gaussiana	0,240	4,1711
659	0	0,25	0,25	0,5	100	0,15	Gaussiana	0,247	4,0481
660	0	0,25	0	0,75	100	0,15	Gaussiana	0,209	4,7844
661	0	0	1	0	100	0,15	Gaussiana	0,612	1,6336
662	0	0	0,75	0,25	100	0,15	Gaussiana	0,359	2,7842
663	0	0	0,5	0,5	100	0,15	Gaussiana	0,381	2,6272
664	0	0	0,25	0,75	100	0,15	Gaussiana	0,263	3,8009
665	0	0	0	1	100	0,15	Gaussiana	0,269	3,7183
666	1	0	0	0	100	0,15	Gaussiana	1,239	0,8073
667	0,75	0,25	0	0	100	0,15	Gaussiana	0,526	1,9017
668	0,75	0	0,25	0	100	0,15	Gaussiana	0,648	1,5432
669	0,75	0	0	0,25	100	0,15	Gaussiana	0,512	1,9537
670	0,5	0,5	0	0	100	0,15	Gaussiana	0,427	2,3445
671	0,5	0,25	0,25	0	100	0,15	Gaussiana	0,432	2,3140
672	0,5	0,25	0	0,25	100	0,15	Gaussiana	0,379	2,6413
673	0,5	0	0,5	0	100	0,15	Gaussiana	0,464	2,1539
674	0,5	0	0,25	0,25	100	0,15	Gaussiana	0,365	2,7360
675	0,5	0	0	0,5	100	0,15	Gaussiana	0,454	2,2042
676	0,25	0,75	0	0	100	0,15	Gaussiana	0,320	3,1216
677	0,25	0,5	0,25	0	100	0,15	Gaussiana	0,269	3,7155
678	0,25	0,5	0	0,25	100	0,15	Gaussiana	0,301	3,3222
679	0,25	0,25	0,5	0	100	0,15	Gaussiana	0,301	3,3236
680	0,25	0,25	0,25	0,25	100	0,15	Gaussiana	0,400	2,4978
681	0,25	0,25	0	0,5	100	0,15	Gaussiana	0,277	3,6047
682	0,25	0	0,75	0	100	0,15	Gaussiana	0,464	2,1538

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
683	0,25	0	0,5	0,25	100	0,15	Gaussiana	0,293	3,4144
684	0,25	0	0,25	0,5	100	0,15	Gaussiana	0,282	3,5489
685	0,25	0	0	0,75	100	0,15	Gaussiana	0,305	3,2741
686	0	1	0	0	100	0,15	Gaussiana	0,207	4,8282
687	0	0,75	0,25	0	100	0,15	Gaussiana	0,251	3,9764
688	0	0,75	0	0,25	100	0,15	Gaussiana	0,252	3,9642
689	0	0,5	0,5	0	100	0,15	Gaussiana	0,242	4,1262
690	0	0,5	0,25	0,25	100	0,15	Gaussiana	0,300	3,3291
691	0	0,5	0	0,5	100	0,15	Gaussiana	0,279	3,5832
692	0	0,25	0,75	0	100	0,15	Gaussiana	0,418	2,3910
693	0	0,25	0,5	0,25	100	0,15	Gaussiana	0,267	3,7485
694	0	0,25	0,25	0,5	100	0,15	Gaussiana	0,278	3,6012
695	0	0,25	0	0,75	100	0,15	Gaussiana	0,215	4,6443
696	0	0	1	0	100	0,15	Gaussiana	0,383	2,6092
697	0	0	0,75	0,25	100	0,15	Gaussiana	0,412	2,4287
698	0	0	0,5	0,5	100	0,15	Gaussiana	0,264	3,7914
699	0	0	0,25	0,75	100	0,15	Gaussiana	0,307	3,2576
700	0	0	0	1	100	0,15	Gaussiana	0,290	3,4443
701	1	0	0	0	20	0,85	Gaussiana	1,739	0,5749
702	0,75	0,25	0	0	20	0,85	Gaussiana	0,499	2,0035
703	0,75	0	0,25	0	20	0,85	Gaussiana	0,579	1,7278
704	0,75	0	0	0,25	20	0,85	Gaussiana	0,490	2,0388
705	0,5	0,5	0	0	20	0,85	Gaussiana	0,389	2,5684
706	0,5	0,25	0,25	0	20	0,85	Gaussiana	0,297	3,3634
707	0,5	0,25	0	0,25	20	0,85	Gaussiana	0,375	2,6655
708	0,5	0	0,5	0	20	0,85	Gaussiana	0,653	1,5322
709	0,5	0	0,25	0,25	20	0,85	Gaussiana	0,365	2,7393
710	0,5	0	0	0,5	20	0,85	Gaussiana	0,384	2,6016
711	0,25	0,75	0	0	20	0,85	Gaussiana	0,332	3,0082
712	0,25	0,5	0,25	0	20	0,85	Gaussiana	0,426	2,3495
713	0,25	0,5	0	0,25	20	0,85	Gaussiana	0,295	3,3940
714	0,25	0,25	0,5	0	20	0,85	Gaussiana	0,363	2,7559
715	0,25	0,25	0,25	0,25	20	0,85	Gaussiana	0,244	4,0966
716	0,25	0,25	0	0,5	20	0,85	Gaussiana	0,294	3,4009
717	0,25	0	0,75	0	20	0,85	Gaussiana	0,373	2,6842
718	0,25	0	0,5	0,25	20	0,85	Gaussiana	0,267	3,7521
719	0,25	0	0,25	0,5	20	0,85	Gaussiana	0,396	2,5249
720	0,25	0	0	0,75	20	0,85	Gaussiana	0,319	3,1396
721	0	1	0	0	20	0,85	Gaussiana	0,248	4,0362
722	0	0,75	0,25	0	20	0,85	Gaussiana	0,211	4,7328
723	0	0,75	0	0,25	20	0,85	Gaussiana	0,191	5,2304
724	0	0,5	0,5	0	20	0,85	Gaussiana	0,232	4,3064
725	0	0,5	0,25	0,25	20	0,85	Gaussiana	0,222	4,5120

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
726	0	0,5	0	0,5	20	0,85	Gaussiana	0,310	3,2276
727	0	0,25	0,75	0	20	0,85	Gaussiana	0,260	3,8524
728	0	0,25	0,5	0,25	20	0,85	Gaussiana	0,366	2,7305
729	0	0,25	0,25	0,5	20	0,85	Gaussiana	0,245	4,0832
730	0	0,25	0	0,75	20	0,85	Gaussiana	0,319	3,1371
731	0	0	1	0	20	0,85	Gaussiana	0,315	3,1791
732	0	0	0,75	0,25	20	0,85	Gaussiana	0,436	2,2916
733	0	0	0,5	0,5	20	0,85	Gaussiana	0,427	2,3409
734	0	0	0,25	0,75	20	0,85	Gaussiana	0,337	2,9671
735	0	0	0	1	20	0,85	Gaussiana	0,247	4,0516
736	1	0	0	0	20	0,85	Gaussiana	1,374	0,7276
737	0,75	0,25	0	0	20	0,85	Gaussiana	0,631	1,5846
738	0,75	0	0,25	0	20	0,85	Gaussiana	0,700	1,4285
739	0,75	0	0	0,25	20	0,85	Gaussiana	0,496	2,0177
740	0,5	0,5	0	0	20	0,85	Gaussiana	0,461	2,1674
741	0,5	0,25	0,25	0	20	0,85	Gaussiana	0,411	2,4314
742	0,5	0,25	0	0,25	20	0,85	Gaussiana	0,364	2,7501
743	0,5	0	0,5	0	20	0,85	Gaussiana	0,450	2,2227
744	0,5	0	0,25	0,25	20	0,85	Gaussiana	0,473	2,1149
745	0,5	0	0	0,5	20	0,85	Gaussiana	0,391	2,5587
746	0,25	0,75	0	0	20	0,85	Gaussiana	0,282	3,5477
747	0,25	0,5	0,25	0	20	0,85	Gaussiana	0,317	3,1582
748	0,25	0,5	0	0,25	20	0,85	Gaussiana	0,261	3,8270
749	0,25	0,25	0,5	0	20	0,85	Gaussiana	0,401	2,4943
750	0,25	0,25	0,25	0,25	20	0,85	Gaussiana	0,241	4,1428
751	0,25	0,25	0	0,5	20	0,85	Gaussiana	0,252	3,9648
752	0,25	0	0,75	0	20	0,85	Gaussiana	0,424	2,3606
753	0,25	0	0,5	0,25	20	0,85	Gaussiana	0,320	3,1239
754	0,25	0	0,25	0,5	20	0,85	Gaussiana	0,291	3,4325
755	0,25	0	0	0,75	20	0,85	Gaussiana	0,300	3,3311
756	0	1	0	0	20	0,85	Gaussiana	0,217	4,6077
757	0	0,75	0,25	0	20	0,85	Gaussiana	0,285	3,5086
758	0	0,75	0	0,25	20	0,85	Gaussiana	0,292	3,4238
759	0	0,5	0,5	0	20	0,85	Gaussiana	0,221	4,5221
760	0	0,5	0,25	0,25	20	0,85	Gaussiana	0,297	3,3642
761	0	0,5	0	0,5	20	0,85	Gaussiana	0,295	3,3939
762	0	0,25	0,75	0	20	0,85	Gaussiana	0,401	2,4947
763	0	0,25	0,5	0,25	20	0,85	Gaussiana	0,265	3,7734
764	0	0,25	0,25	0,5	20	0,85	Gaussiana	0,259	3,8557
765	0	0,25	0	0,75	20	0,85	Gaussiana	0,230	4,3452
766	0	0	1	0	20	0,85	Gaussiana	0,381	2,6238
767	0	0	0,75	0,25	20	0,85	Gaussiana	0,411	2,4323
768	0	0	0,5	0,5	20	0,85	Gaussiana	0,337	2,9667

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
769	0	0	0,25	0,75	20	0,85	Gaussiana	0,295	3,3943
770	0	0	0	1	20	0,85	Gaussiana	0,249	4,0083
771	1	0	0	0	20	0,85	Gaussiana	1,337	0,7479
772	0,75	0,25	0	0	20	0,85	Gaussiana	0,621	1,6091
773	0,75	0	0,25	0	20	0,85	Gaussiana	0,748	1,3360
774	0,75	0	0	0,25	20	0,85	Gaussiana	0,629	1,5910
775	0,5	0,5	0	0	20	0,85	Gaussiana	0,394	2,5356
776	0,5	0,25	0,25	0	20	0,85	Gaussiana	0,364	2,7496
777	0,5	0,25	0	0,25	20	0,85	Gaussiana	0,433	2,3072
778	0,5	0	0,5	0	20	0,85	Gaussiana	0,617	1,6205
779	0,5	0	0,25	0,25	20	0,85	Gaussiana	0,295	3,3920
780	0,5	0	0	0,5	20	0,85	Gaussiana	0,410	2,4401
781	0,25	0,75	0	0	20	0,85	Gaussiana	0,320	3,1258
782	0,25	0,5	0,25	0	20	0,85	Gaussiana	0,407	2,4554
783	0,25	0,5	0	0,25	20	0,85	Gaussiana	0,317	3,1535
784	0,25	0,25	0,5	0	20	0,85	Gaussiana	0,246	4,0583
785	0,25	0,25	0,25	0,25	20	0,85	Gaussiana	0,319	3,1361
786	0,25	0,25	0	0,5	20	0,85	Gaussiana	0,248	4,0302
787	0,25	0	0,75	0	20	0,85	Gaussiana	0,600	1,6670
788	0,25	0	0,5	0,25	20	0,85	Gaussiana	0,498	2,0097
789	0,25	0	0,25	0,5	20	0,85	Gaussiana	0,374	2,6725
790	0,25	0	0	0,75	20	0,85	Gaussiana	0,300	3,3329
791	0	1	0	0	20	0,85	Gaussiana	0,277	3,6041
792	0	0,75	0,25	0	20	0,85	Gaussiana	0,243	4,1120
793	0	0,75	0	0,25	20	0,85	Gaussiana	0,254	3,9431
794	0	0,5	0,5	0	20	0,85	Gaussiana	0,270	3,7061
795	0	0,5	0,25	0,25	20	0,85	Gaussiana	0,217	4,6019
796	0	0,5	0	0,5	20	0,85	Gaussiana	0,232	4,3126
797	0	0,25	0,75	0	20	0,85	Gaussiana	0,324	3,0878
798	0	0,25	0,5	0,25	20	0,85	Gaussiana	0,428	2,3368
799	0	0,25	0,25	0,5	20	0,85	Gaussiana	0,205	4,8671
800	0	0,25	0	0,75	20	0,85	Gaussiana	0,362	2,7597
801	0	0	1	0	20	0,85	Gaussiana	0,467	2,1399
802	0	0	0,75	0,25	20	0,85	Gaussiana	0,260	3,8424
803	0	0	0,5	0,5	20	0,85	Gaussiana	0,288	3,4775
804	0	0	0,25	0,75	20	0,85	Gaussiana	0,343	2,9158
805	0	0	0	1	20	0,85	Gaussiana	0,333	3,0051
806	1	0	0	0	20	0,85	Gaussiana	1,568	0,6376
807	0,75	0,25	0	0	20	0,85	Gaussiana	0,521	1,9189
808	0,75	0	0,25	0	20	0,85	Gaussiana	1,009	0,9909
809	0,75	0	0	0,25	20	0,85	Gaussiana	0,527	1,8981
810	0,5	0,5	0	0	20	0,85	Gaussiana	0,618	1,6178
811	0,5	0,25	0,25	0	20	0,85	Gaussiana	0,452	2,2116

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
812	0,5	0,25	0	0,25	20	0,85	Gaussiana	0,395	2,5303
813	0,5	0	0,5	0	20	0,85	Gaussiana	1,084	0,9228
814	0,5	0	0,25	0,25	20	0,85	Gaussiana	0,637	1,5706
815	0,5	0	0	0,5	20	0,85	Gaussiana	0,386	2,5918
816	0,25	0,75	0	0	20	0,85	Gaussiana	0,302	3,3098
817	0,25	0,5	0,25	0	20	0,85	Gaussiana	0,366	2,7312
818	0,25	0,5	0	0,25	20	0,85	Gaussiana	0,305	3,2832
819	0,25	0,25	0,5	0	20	0,85	Gaussiana	0,371	2,6934
820	0,25	0,25	0,25	0,25	20	0,85	Gaussiana	0,220	4,5403
821	0,25	0,25	0	0,5	20	0,85	Gaussiana	0,292	3,4222
822	0,25	0	0,75	0	20	0,85	Gaussiana	0,412	2,4255
823	0,25	0	0,5	0,25	20	0,85	Gaussiana	0,388	2,5761
824	0,25	0	0,25	0,5	20	0,85	Gaussiana	0,434	2,3027
825	0,25	0	0	0,75	20	0,85	Gaussiana	0,274	3,6505
826	0	1	0	0	20	0,85	Gaussiana	0,335	2,9863
827	0	0,75	0,25	0	20	0,85	Gaussiana	0,253	3,9450
828	0	0,75	0	0,25	20	0,85	Gaussiana	0,224	4,4624
829	0	0,5	0,5	0	20	0,85	Gaussiana	0,298	3,3567
830	0	0,5	0,25	0,25	20	0,85	Gaussiana	0,265	3,7689
831	0	0,5	0	0,5	20	0,85	Gaussiana	0,212	4,7176
832	0	0,25	0,75	0	20	0,85	Gaussiana	0,326	3,0673
833	0	0,25	0,5	0,25	20	0,85	Gaussiana	0,279	3,5894
834	0	0,25	0,25	0,5	20	0,85	Gaussiana	0,232	4,3057
835	0	0,25	0	0,75	20	0,85	Gaussiana	0,233	4,2840
836	0	0	1	0	20	0,85	Gaussiana	0,578	1,7311
837	0	0	0,75	0,25	20	0,85	Gaussiana	0,303	3,3003
838	0	0	0,5	0,5	20	0,85	Gaussiana	0,316	3,1598
839	0	0	0,25	0,75	20	0,85	Gaussiana	0,348	2,8769
840	0	0	0	1	20	0,85	Gaussiana	0,320	3,1292
841	1	0	0	0	20	0,85	Gaussiana	1,771	0,5645
842	0,75	0,25	0	0	20	0,85	Gaussiana	0,594	1,6833
843	0,75	0	0,25	0	20	0,85	Gaussiana	0,712	1,4044
844	0,75	0	0	0,25	20	0,85	Gaussiana	0,518	1,9291
845	0,5	0,5	0	0	20	0,85	Gaussiana	0,350	2,8586
846	0,5	0,25	0,25	0	20	0,85	Gaussiana	0,495	2,0183
847	0,5	0,25	0	0,25	20	0,85	Gaussiana	0,443	2,2592
848	0,5	0	0,5	0	20	0,85	Gaussiana	0,586	1,7065
849	0,5	0	0,25	0,25	20	0,85	Gaussiana	0,435	2,3003
850	0,5	0	0	0,5	20	0,85	Gaussiana	0,415	2,4123
851	0,25	0,75	0	0	20	0,85	Gaussiana	0,321	3,1198
852	0,25	0,5	0,25	0	20	0,85	Gaussiana	0,213	4,6839
853	0,25	0,5	0	0,25	20	0,85	Gaussiana	0,267	3,7403
854	0,25	0,25	0,5	0	20	0,85	Gaussiana	0,388	2,5804

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
855	0,25	0,25	0,25	0,25	20	0,85	Gaussiana	0,307	3,2548
856	0,25	0,25	0	0,5	20	0,85	Gaussiana	0,403	2,4796
857	0,25	0	0,75	0	20	0,85	Gaussiana	0,556	1,7993
858	0,25	0	0,5	0,25	20	0,85	Gaussiana	0,280	3,5767
859	0,25	0	0,25	0,5	20	0,85	Gaussiana	0,540	1,8519
860	0,25	0	0	0,75	20	0,85	Gaussiana	0,330	3,0310
861	0	1	0	0	20	0,85	Gaussiana	0,220	4,5557
862	0	0,75	0,25	0	20	0,85	Gaussiana	0,345	2,8974
863	0	0,75	0	0,25	20	0,85	Gaussiana	0,230	4,3528
864	0	0,5	0,5	0	20	0,85	Gaussiana	0,231	4,3203
865	0	0,5	0,25	0,25	20	0,85	Gaussiana	0,275	3,6371
866	0	0,5	0	0,5	20	0,85	Gaussiana	0,202	4,9538
867	0	0,25	0,75	0	20	0,85	Gaussiana	0,315	3,1763
868	0	0,25	0,5	0,25	20	0,85	Gaussiana	0,343	2,9129
869	0	0,25	0,25	0,5	20	0,85	Gaussiana	0,414	2,4150
870	0	0,25	0	0,75	20	0,85	Gaussiana	0,297	3,3618
871	0	0	1	0	20	0,85	Gaussiana	0,365	2,7393
872	0	0	0,75	0,25	20	0,85	Gaussiana	0,348	2,8703
873	0	0	0,5	0,5	20	0,85	Gaussiana	0,482	2,0766
874	0	0	0,25	0,75	20	0,85	Gaussiana	0,339	2,9496
875	0	0	0	1	20	0,85	Gaussiana	0,287	3,4814
876	1	0	0	0	20	0,85	Gaussiana	1,348	0,7419
877	0,75	0,25	0	0	20	0,85	Gaussiana	0,482	2,0744
878	0,75	0	0,25	0	20	0,85	Gaussiana	0,625	1,5989
879	0,75	0	0	0,25	20	0,85	Gaussiana	0,544	1,8373
880	0,5	0,5	0	0	20	0,85	Gaussiana	0,414	2,4143
881	0,5	0,25	0,25	0	20	0,85	Gaussiana	0,407	2,4586
882	0,5	0,25	0	0,25	20	0,85	Gaussiana	0,435	2,2975
883	0,5	0	0,5	0	20	0,85	Gaussiana	0,732	1,3666
884	0,5	0	0,25	0,25	20	0,85	Gaussiana	0,508	1,9702
885	0,5	0	0	0,5	20	0,85	Gaussiana	0,321	3,1105
886	0,25	0,75	0	0	20	0,85	Gaussiana	0,340	2,9385
887	0,25	0,5	0,25	0	20	0,85	Gaussiana	0,318	3,1421
888	0,25	0,5	0	0,25	20	0,85	Gaussiana	0,312	3,2055
889	0,25	0,25	0,5	0	20	0,85	Gaussiana	0,317	3,1527
890	0,25	0,25	0,25	0,25	20	0,85	Gaussiana	0,272	3,6717
891	0,25	0,25	0	0,5	20	0,85	Gaussiana	0,315	3,1773
892	0,25	0	0,75	0	20	0,85	Gaussiana	0,341	2,9349
893	0,25	0	0,5	0,25	20	0,85	Gaussiana	0,321	3,1184
894	0,25	0	0,25	0,5	20	0,85	Gaussiana	0,289	3,4643
895	0,25	0	0	0,75	20	0,85	Gaussiana	0,311	3,2159
896	0	1	0	0	20	0,85	Gaussiana	0,218	4,5797
897	0	0,75	0,25	0	20	0,85	Gaussiana	0,222	4,5130

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
898	0	0,75	0	0,25	20	0,85	Gaussiana	0,297	3,3660
899	0	0,5	0,5	0	20	0,85	Gaussiana	0,260	3,8522
900	0	0,5	0,25	0,25	20	0,85	Gaussiana	0,307	3,2603
901	0	0,5	0	0,5	20	0,85	Gaussiana	0,264	3,7835
902	0	0,25	0,75	0	20	0,85	Gaussiana	0,410	2,4377
903	0	0,25	0,5	0,25	20	0,85	Gaussiana	0,345	2,8995
904	0	0,25	0,25	0,5	20	0,85	Gaussiana	0,272	3,6721
905	0	0,25	0	0,75	20	0,85	Gaussiana	0,219	4,5655
906	0	0	1	0	20	0,85	Gaussiana	0,504	1,9851
907	0	0	0,75	0,25	20	0,85	Gaussiana	0,397	2,5161
908	0	0	0,5	0,5	20	0,85	Gaussiana	0,297	3,3625
909	0	0	0,25	0,75	20	0,85	Gaussiana	0,265	3,7686
910	0	0	0	1	20	0,85	Gaussiana	0,209	4,7896
911	1	0	0	0	20	0,85	Gaussiana	1,480	0,6756
912	0,75	0,25	0	0	20	0,85	Gaussiana	0,600	1,6666
913	0,75	0	0,25	0	20	0,85	Gaussiana	1,125	0,8889
914	0,75	0	0	0,25	20	0,85	Gaussiana	0,495	2,0189
915	0,5	0,5	0	0	20	0,85	Gaussiana	0,412	2,4255
916	0,5	0,25	0,25	0	20	0,85	Gaussiana	0,383	2,6084
917	0,5	0,25	0	0,25	20	0,85	Gaussiana	0,345	2,8956
918	0,5	0	0,5	0	20	0,85	Gaussiana	0,428	2,3348
919	0,5	0	0,25	0,25	20	0,85	Gaussiana	0,533	1,8746
920	0,5	0	0	0,5	20	0,85	Gaussiana	0,404	2,4729
921	0,25	0,75	0	0	20	0,85	Gaussiana	0,354	2,8225
922	0,25	0,5	0,25	0	20	0,85	Gaussiana	0,246	4,0723
923	0,25	0,5	0	0,25	20	0,85	Gaussiana	0,314	3,1834
924	0,25	0,25	0,5	0	20	0,85	Gaussiana	0,462	2,1658
925	0,25	0,25	0,25	0,25	20	0,85	Gaussiana	0,331	3,0234
926	0,25	0,25	0	0,5	20	0,85	Gaussiana	0,284	3,5151
927	0,25	0	0,75	0	20	0,85	Gaussiana	0,463	2,1605
928	0,25	0	0,5	0,25	20	0,85	Gaussiana	0,351	2,8512
929	0,25	0	0,25	0,5	20	0,85	Gaussiana	0,288	3,4746
930	0,25	0	0	0,75	20	0,85	Gaussiana	0,388	2,5783
931	0	1	0	0	20	0,85	Gaussiana	0,294	3,3993
932	0	0,75	0,25	0	20	0,85	Gaussiana	0,275	3,6412
933	0	0,75	0	0,25	20	0,85	Gaussiana	0,222	4,4976
934	0	0,5	0,5	0	20	0,85	Gaussiana	0,319	3,1353
935	0	0,5	0,25	0,25	20	0,85	Gaussiana	0,248	4,0270
936	0	0,5	0	0,5	20	0,85	Gaussiana	0,296	3,3835
937	0	0,25	0,75	0	20	0,85	Gaussiana	0,232	4,3169
938	0	0,25	0,5	0,25	20	0,85	Gaussiana	0,227	4,4003
939	0	0,25	0,25	0,5	20	0,85	Gaussiana	0,297	3,3671
940	0	0,25	0	0,75	20	0,85	Gaussiana	0,423	2,3644

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
941	0	0	1	0	20	0,85	Gaussiana	0,404	2,4751
942	0	0	0,75	0,25	20	0,85	Gaussiana	0,449	2,2250
943	0	0	0,5	0,5	20	0,85	Gaussiana	0,310	3,2296
944	0	0	0,25	0,75	20	0,85	Gaussiana	0,273	3,6618
945	0	0	0	1	20	0,85	Gaussiana	0,382	2,6189
946	1	0	0	0	20	0,85	Gaussiana	1,309	0,7641
947	0,75	0,25	0	0	20	0,85	Gaussiana	0,649	1,5397
948	0,75	0	0,25	0	20	0,85	Gaussiana	0,528	1,8954
949	0,75	0	0	0,25	20	0,85	Gaussiana	0,554	1,8037
950	0,5	0,5	0	0	20	0,85	Gaussiana	0,419	2,3882
951	0,5	0,25	0,25	0	20	0,85	Gaussiana	0,299	3,3453
952	0,5	0,25	0	0,25	20	0,85	Gaussiana	0,427	2,3429
953	0,5	0	0,5	0	20	0,85	Gaussiana	0,528	1,8944
954	0,5	0	0,25	0,25	20	0,85	Gaussiana	0,323	3,0994
955	0,5	0	0	0,5	20	0,85	Gaussiana	0,324	3,0877
956	0,25	0,75	0	0	20	0,85	Gaussiana	0,349	2,8658
957	0,25	0,5	0,25	0	20	0,85	Gaussiana	0,310	3,2289
958	0,25	0,5	0	0,25	20	0,85	Gaussiana	0,299	3,3467
959	0,25	0,25	0,5	0	20	0,85	Gaussiana	0,534	1,8742
960	0,25	0,25	0,25	0,25	20	0,85	Gaussiana	0,268	3,7345
961	0,25	0,25	0	0,5	20	0,85	Gaussiana	0,306	3,2676
962	0,25	0	0,75	0	20	0,85	Gaussiana	0,720	1,3891
963	0,25	0	0,5	0,25	20	0,85	Gaussiana	0,298	3,3510
964	0,25	0	0,25	0,5	20	0,85	Gaussiana	0,422	2,3675
965	0,25	0	0	0,75	20	0,85	Gaussiana	0,308	3,2415
966	0	1	0	0	20	0,85	Gaussiana	0,267	3,7420
967	0	0,75	0,25	0	20	0,85	Gaussiana	0,224	4,4740
968	0	0,75	0	0,25	20	0,85	Gaussiana	0,205	4,8827
969	0	0,5	0,5	0	20	0,85	Gaussiana	0,321	3,1153
970	0	0,5	0,25	0,25	20	0,85	Gaussiana	0,363	2,7563
971	0	0,5	0	0,5	20	0,85	Gaussiana	0,225	4,4373
972	0	0,25	0,75	0	20	0,85	Gaussiana	0,291	3,4420
973	0	0,25	0,5	0,25	20	0,85	Gaussiana	0,332	3,0083
974	0	0,25	0,25	0,5	20	0,85	Gaussiana	0,296	3,3740
975	0	0,25	0	0,75	20	0,85	Gaussiana	0,196	5,0988
976	0	0	1	0	20	0,85	Gaussiana	0,326	3,0712
977	0	0	0,75	0,25	20	0,85	Gaussiana	0,223	4,4762
978	0	0	0,5	0,5	20	0,85	Gaussiana	0,348	2,8741
979	0	0	0,25	0,75	20	0,85	Gaussiana	0,306	3,2693
980	0	0	0	1	20	0,85	Gaussiana	0,361	2,7686
981	1	0	0	0	20	0,85	Gaussiana	1,569	0,6373
982	0,75	0,25	0	0	20	0,85	Gaussiana	0,496	2,0175
983	0,75	0	0,25	0	20	0,85	Gaussiana	0,676	1,4794

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
984	0,75	0	0	0,25	20	0,85	Gaussiana	0,522	1,9140
985	0,5	0,5	0	0	20	0,85	Gaussiana	0,436	2,2928
986	0,5	0,25	0,25	0	20	0,85	Gaussiana	0,364	2,7473
987	0,5	0,25	0	0,25	20	0,85	Gaussiana	0,391	2,5562
988	0,5	0	0,5	0	20	0,85	Gaussiana	0,806	1,2404
989	0,5	0	0,25	0,25	20	0,85	Gaussiana	0,468	2,1363
990	0,5	0	0	0,5	20	0,85	Gaussiana	0,397	2,5188
991	0,25	0,75	0	0	20	0,85	Gaussiana	0,313	3,1899
992	0,25	0,5	0,25	0	20	0,85	Gaussiana	0,401	2,4950
993	0,25	0,5	0	0,25	20	0,85	Gaussiana	0,283	3,5275
994	0,25	0,25	0,5	0	20	0,85	Gaussiana	0,457	2,1873
995	0,25	0,25	0,25	0,25	20	0,85	Gaussiana	0,252	3,9758
996	0,25	0,25	0	0,5	20	0,85	Gaussiana	0,288	3,4755
997	0,25	0	0,75	0	20	0,85	Gaussiana	0,632	1,5830
998	0,25	0	0,5	0,25	20	0,85	Gaussiana	0,524	1,9097
999	0,25	0	0,25	0,5	20	0,85	Gaussiana	0,419	2,3864
1000	0,25	0	0	0,75	20	0,85	Gaussiana	0,436	2,2955
1001	0	1	0	0	20	0,85	Gaussiana	0,287	3,4838
1002	0	0,75	0,25	0	20	0,85	Gaussiana	0,311	3,2198
1003	0	0,75	0	0,25	20	0,85	Gaussiana	0,234	4,2736
1004	0	0,5	0,5	0	20	0,85	Gaussiana	0,314	3,1884
1005	0	0,5	0,25	0,25	20	0,85	Gaussiana	0,401	2,4928
1006	0	0,5	0	0,5	20	0,85	Gaussiana	0,234	4,2694
1007	0	0,25	0,75	0	20	0,85	Gaussiana	0,389	2,5699
1008	0	0,25	0,5	0,25	20	0,85	Gaussiana	0,230	4,3481
1009	0	0,25	0,25	0,5	20	0,85	Gaussiana	0,205	4,8667
1010	0	0,25	0	0,75	20	0,85	Gaussiana	0,231	4,3248
1011	0	0	1	0	20	0,85	Gaussiana	0,361	2,7696
1012	0	0	0,75	0,25	20	0,85	Gaussiana	0,390	2,5617
1013	0	0	0,5	0,5	20	0,85	Gaussiana	0,399	2,5040
1014	0	0	0,25	0,75	20	0,85	Gaussiana	0,303	3,3038
1015	0	0	0	1	20	0,85	Gaussiana	0,259	3,8626
1016	1	0	0	0	20	0,85	Gaussiana	1,412	0,7082
1017	0,75	0,25	0	0	20	0,85	Gaussiana	0,531	1,8830
1018	0,75	0	0,25	0	20	0,85	Gaussiana	0,528	1,8941
1019	0,75	0	0	0,25	20	0,85	Gaussiana	0,499	2,0046
1020	0,5	0,5	0	0	20	0,85	Gaussiana	0,391	2,5560
1021	0,5	0,25	0,25	0	20	0,85	Gaussiana	0,390	2,5639
1022	0,5	0,25	0	0,25	20	0,85	Gaussiana	0,364	2,7467
1023	0,5	0	0,5	0	20	0,85	Gaussiana	0,515	1,9401
1024	0,5	0	0,25	0,25	20	0,85	Gaussiana	0,568	1,7616
1025	0,5	0	0	0,5	20	0,85	Gaussiana	0,370	2,7026
1026	0,25	0,75	0	0	20	0,85	Gaussiana	0,292	3,4253

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
1027	0,25	0,5	0,25	0	20	0,85	Gaussiana	0,242	4,1276
1028	0,25	0,5	0	0,25	20	0,85	Gaussiana	0,327	3,0592
1029	0,25	0,25	0,5	0	20	0,85	Gaussiana	0,323	3,0990
1030	0,25	0,25	0,25	0,25	20	0,85	Gaussiana	0,319	3,1325
1031	0,25	0,25	0	0,5	20	0,85	Gaussiana	0,268	3,7350
1032	0,25	0	0,75	0	20	0,85	Gaussiana	0,336	2,9775
1033	0,25	0	0,5	0,25	20	0,85	Gaussiana	0,505	1,9813
1034	0,25	0	0,25	0,5	20	0,85	Gaussiana	0,328	3,0516
1035	0,25	0	0	0,75	20	0,85	Gaussiana	0,271	3,6855
1036	0	1	0	0	20	0,85	Gaussiana	0,280	3,5719
1037	0	0,75	0,25	0	20	0,85	Gaussiana	0,294	3,3986
1038	0	0,75	0	0,25	20	0,85	Gaussiana	0,233	4,2974
1039	0	0,5	0,5	0	20	0,85	Gaussiana	0,251	3,9851
1040	0	0,5	0,25	0,25	20	0,85	Gaussiana	0,300	3,3295
1041	0	0,5	0	0,5	20	0,85	Gaussiana	0,257	3,8867
1042	0	0,25	0,75	0	20	0,85	Gaussiana	0,406	2,4632
1043	0	0,25	0,5	0,25	20	0,85	Gaussiana	0,316	3,1629
1044	0	0,25	0,25	0,5	20	0,85	Gaussiana	0,221	4,5248
1045	0	0,25	0	0,75	20	0,85	Gaussiana	0,239	4,1901
1046	0	0	1	0	20	0,85	Gaussiana	0,482	2,0726
1047	0	0	0,75	0,25	20	0,85	Gaussiana	0,402	2,4854
1048	0	0	0,5	0,5	20	0,85	Gaussiana	0,284	3,5229
1049	0	0	0,25	0,75	20	0,85	Gaussiana	0,357	2,7980
1050	0	0	0	1	20	0,85	Gaussiana	0,258	3,8830
1051	1	0	0	0	100	0,85	Adapt. Feas.	1,363	0,7338
1052	0,75	0,25	0	0	100	0,85	Adapt. Feas.	0,488	2,0471
1053	0,75	0	0,25	0	100	0,85	Adapt. Feas.	0,712	1,4053
1054	0,75	0	0	0,25	100	0,85	Adapt. Feas.	0,493	2,0276
1055	0,5	0,5	0	0	100	0,85	Adapt. Feas.	0,536	1,8659
1056	0,5	0,25	0,25	0	100	0,85	Adapt. Feas.	0,465	2,1489
1057	0,5	0,25	0	0,25	100	0,85	Adapt. Feas.	0,754	1,3257
1058	0,5	0	0,5	0	100	0,85	Adapt. Feas.	0,744	1,3441
1059	0,5	0	0,25	0,25	100	0,85	Adapt. Feas.	0,540	1,8524
1060	0,5	0	0	0,5	100	0,85	Adapt. Feas.	0,404	2,4780
1061	0,25	0,75	0	0	100	0,85	Adapt. Feas.	0,302	3,3076
1062	0,25	0,5	0,25	0	100	0,85	Adapt. Feas.	0,407	2,4571
1063	0,25	0,5	0	0,25	100	0,85	Adapt. Feas.	0,399	2,5042
1064	0,25	0,25	0,5	0	100	0,85	Adapt. Feas.	0,509	1,9627
1065	0,25	0,25	0,25	0,25	100	0,85	Adapt. Feas.	0,339	2,9502
1066	0,25	0,25	0	0,5	100	0,85	Adapt. Feas.	0,385	2,5974
1067	0,25	0	0,75	0	100	0,85	Adapt. Feas.	0,802	1,2464
1068	0,25	0	0,5	0,25	100	0,85	Adapt. Feas.	0,426	2,3500
1069	0,25	0	0,25	0,5	100	0,85	Adapt. Feas.	0,387	2,5808

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
1070	0,25	0	0	0,75	100	0,85	Adapt. Feas.	0,336	2,9772
1071	0	1	0	0	100	0,85	Adapt. Feas.	0,257	3,8932
1072	0	0,75	0,25	0	100	0,85	Adapt. Feas.	0,257	3,8874
1073	0	0,75	0	0,25	100	0,85	Adapt. Feas.	0,236	4,2320
1074	0	0,5	0,5	0	100	0,85	Adapt. Feas.	0,256	3,9105
1075	0	0,5	0,25	0,25	100	0,85	Adapt. Feas.	0,269	3,7143
1076	0	0,5	0	0,5	100	0,85	Adapt. Feas.	0,256	3,9001
1077	0	0,25	0,75	0	100	0,85	Adapt. Feas.	0,339	2,9525
1078	0	0,25	0,5	0,25	100	0,85	Adapt. Feas.	0,311	3,2142
1079	0	0,25	0,25	0,5	100	0,85	Adapt. Feas.	0,262	3,8128
1080	0	0,25	0	0,75	100	0,85	Adapt. Feas.	0,234	4,2688
1081	0	0	1	0	100	0,85	Adapt. Feas.	0,407	2,4567
1082	0	0	0,75	0,25	100	0,85	Adapt. Feas.	0,480	2,0815
1083	0	0	0,5	0,5	100	0,85	Adapt. Feas.	0,282	3,5486
1084	0	0	0,25	0,75	100	0,85	Adapt. Feas.	0,606	1,6488
1085	0	0	0	1	100	0,85	Adapt. Feas.	0,261	3,8323
1086	1	0	0	0	100	0,85	Adapt. Feas.	1,276	0,7835
1087	0,75	0,25	0	0	100	0,85	Adapt. Feas.	0,614	1,6294
1088	0,75	0	0,25	0	100	0,85	Adapt. Feas.	1,098	0,9104
1089	0,75	0	0	0,25	100	0,85	Adapt. Feas.	0,930	1,0753
1090	0,5	0,5	0	0	100	0,85	Adapt. Feas.	0,476	2,1013
1091	0,5	0,25	0,25	0	100	0,85	Adapt. Feas.	0,654	1,5283
1092	0,5	0,25	0	0,25	100	0,85	Adapt. Feas.	0,369	2,7135
1093	0,5	0	0,5	0	100	0,85	Adapt. Feas.	0,673	1,4858
1094	0,5	0	0,25	0,25	100	0,85	Adapt. Feas.	0,492	2,0329
1095	0,5	0	0	0,5	100	0,85	Adapt. Feas.	0,417	2,4009
1096	0,25	0,75	0	0	100	0,85	Adapt. Feas.	0,320	3,1214
1097	0,25	0,5	0,25	0	100	0,85	Adapt. Feas.	0,416	2,4017
1098	0,25	0,5	0	0,25	100	0,85	Adapt. Feas.	0,331	3,0204
1099	0,25	0,25	0,5	0	100	0,85	Adapt. Feas.	0,391	2,5607
1100	0,25	0,25	0,25	0,25	100	0,85	Adapt. Feas.	0,415	2,4115
1101	0,25	0,25	0	0,5	100	0,85	Adapt. Feas.	0,287	3,4835
1102	0,25	0	0,75	0	100	0,85	Adapt. Feas.	0,634	1,5777
1103	0,25	0	0,5	0,25	100	0,85	Adapt. Feas.	0,375	2,6680
1104	0,25	0	0,25	0,5	100	0,85	Adapt. Feas.	0,314	3,1819
1105	0,25	0	0	0,75	100	0,85	Adapt. Feas.	0,286	3,4907
1106	0	1	0	0	100	0,85	Adapt. Feas.	0,231	4,3333
1107	0	0,75	0,25	0	100	0,85	Adapt. Feas.	0,227	4,4025
1108	0	0,75	0	0,25	100	0,85	Adapt. Feas.	0,256	3,9063
1109	0	0,5	0,5	0	100	0,85	Adapt. Feas.	0,266	3,7590
1110	0	0,5	0,25	0,25	100	0,85	Adapt. Feas.	0,268	3,7378
1111	0	0,5	0	0,5	100	0,85	Adapt. Feas.	0,240	4,1709
1112	0	0,25	0,75	0	100	0,85	Adapt. Feas.	0,289	3,4645

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
1113	0	0,25	0,5	0,25	100	0,85	Adapt. Feas.	0,367	2,7221
1114	0	0,25	0,25	0,5	100	0,85	Adapt. Feas.	0,269	3,7220
1115	0	0,25	0	0,75	100	0,85	Adapt. Feas.	0,240	4,1692
1116	0	0	1	0	100	0,85	Adapt. Feas.	0,461	2,1687
1117	0	0	0,75	0,25	100	0,85	Adapt. Feas.	0,328	3,0525
1118	0	0	0,5	0,5	100	0,85	Adapt. Feas.	0,281	3,5618
1119	0	0	0,25	0,75	100	0,85	Adapt. Feas.	0,378	2,6490
1120	0	0	0	1	100	0,85	Adapt. Feas.	0,236	4,2346
1121	1	0	0	0	100	0,85	Adapt. Feas.	1,522	0,6572
1122	0,75	0,25	0	0	100	0,85	Adapt. Feas.	0,896	1,1161
1123	0,75	0	0,25	0	100	0,85	Adapt. Feas.	0,689	1,4511
1124	0,75	0	0	0,25	100	0,85	Adapt. Feas.	0,525	1,9045
1125	0,5	0,5	0	0	100	0,85	Adapt. Feas.	0,616	1,6228
1126	0,5	0,25	0,25	0	100	0,85	Adapt. Feas.	0,913	1,0956
1127	0,5	0,25	0	0,25	100	0,85	Adapt. Feas.	0,578	1,7305
1128	0,5	0	0,5	0	100	0,85	Adapt. Feas.	0,947	1,0565
1129	0,5	0	0,25	0,25	100	0,85	Adapt. Feas.	0,416	2,4054
1130	0,5	0	0	0,5	100	0,85	Adapt. Feas.	0,431	2,3180
1131	0,25	0,75	0	0	100	0,85	Adapt. Feas.	0,581	1,7200
1132	0,25	0,5	0,25	0	100	0,85	Adapt. Feas.	0,399	2,5054
1133	0,25	0,5	0	0,25	100	0,85	Adapt. Feas.	0,349	2,8658
1134	0,25	0,25	0,5	0	100	0,85	Adapt. Feas.	0,412	2,4287
1135	0,25	0,25	0,25	0,25	100	0,85	Adapt. Feas.	0,305	3,2783
1136	0,25	0,25	0	0,5	100	0,85	Adapt. Feas.	0,333	3,0004
1137	0,25	0	0,75	0	100	0,85	Adapt. Feas.	0,415	2,4080
1138	0,25	0	0,5	0,25	100	0,85	Adapt. Feas.	0,336	2,9731
1139	0,25	0	0,25	0,5	100	0,85	Adapt. Feas.	0,314	3,1885
1140	0,25	0	0	0,75	100	0,85	Adapt. Feas.	0,289	3,4568
1141	0	1	0	0	100	0,85	Adapt. Feas.	0,326	3,0662
1142	0	0,75	0,25	0	100	0,85	Adapt. Feas.	0,473	2,1145
1143	0	0,75	0	0,25	100	0,85	Adapt. Feas.	0,258	3,8740
1144	0	0,5	0,5	0	100	0,85	Adapt. Feas.	0,266	3,7654
1145	0	0,5	0,25	0,25	100	0,85	Adapt. Feas.	0,238	4,1943
1146	0	0,5	0	0,5	100	0,85	Adapt. Feas.	0,266	3,7578
1147	0	0,25	0,75	0	100	0,85	Adapt. Feas.	0,395	2,5342
1148	0	0,25	0,5	0,25	100	0,85	Adapt. Feas.	0,497	2,0134
1149	0	0,25	0,25	0,5	100	0,85	Adapt. Feas.	0,270	3,7023
1150	0	0,25	0	0,75	100	0,85	Adapt. Feas.	0,263	3,8061
1151	0	0	1	0	100	0,85	Adapt. Feas.	0,430	2,3249
1152	0	0	0,75	0,25	100	0,85	Adapt. Feas.	0,350	2,8572
1153	0	0	0,5	0,5	100	0,85	Adapt. Feas.	0,536	1,8648
1154	0	0	0,25	0,75	100	0,85	Adapt. Feas.	0,315	3,1728
1155	0	0	0	1	100	0,85	Adapt. Feas.	0,415	2,4091

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
1156	1	0	0	0	100	0,85	Adapt. Feas.	1,434	0,6972
1157	0,75	0,25	0	0	100	0,85	Adapt. Feas.	0,520	1,9241
1158	0,75	0	0,25	0	100	0,85	Adapt. Feas.	0,785	1,2747
1159	0,75	0	0	0,25	100	0,85	Adapt. Feas.	0,524	1,9076
1160	0,5	0,5	0	0	100	0,85	Adapt. Feas.	0,512	1,9547
1161	0,5	0,25	0,25	0	100	0,85	Adapt. Feas.	0,501	1,9959
1162	0,5	0,25	0	0,25	100	0,85	Adapt. Feas.	0,376	2,6594
1163	0,5	0	0,5	0	100	0,85	Adapt. Feas.	0,525	1,9046
1164	0,5	0	0,25	0,25	100	0,85	Adapt. Feas.	0,633	1,5788
1165	0,5	0	0	0,5	100	0,85	Adapt. Feas.	0,598	1,6733
1166	0,25	0,75	0	0	100	0,85	Adapt. Feas.	0,445	2,2450
1167	0,25	0,5	0,25	0	100	0,85	Adapt. Feas.	0,304	3,2866
1168	0,25	0,5	0	0,25	100	0,85	Adapt. Feas.	0,284	3,5235
1169	0,25	0,25	0,5	0	100	0,85	Adapt. Feas.	0,402	2,4875
1170	0,25	0,25	0,25	0,25	100	0,85	Adapt. Feas.	0,430	2,3262
1171	0,25	0,25	0	0,5	100	0,85	Adapt. Feas.	0,351	2,8516
1172	0,25	0	0,75	0	100	0,85	Adapt. Feas.	0,727	1,3755
1173	0,25	0	0,5	0,25	100	0,85	Adapt. Feas.	0,365	2,7421
1174	0,25	0	0,25	0,5	100	0,85	Adapt. Feas.	0,410	2,4363
1175	0,25	0	0	0,75	100	0,85	Adapt. Feas.	0,287	3,4804
1176	0	1	0	0	100	0,85	Adapt. Feas.	0,224	4,4697
1177	0	0,75	0,25	0	100	0,85	Adapt. Feas.	0,256	3,9127
1178	0	0,75	0	0,25	100	0,85	Adapt. Feas.	0,253	3,9599
1179	0	0,5	0,5	0	100	0,85	Adapt. Feas.	0,297	3,3714
1180	0	0,5	0,25	0,25	100	0,85	Adapt. Feas.	0,268	3,7373
1181	0	0,5	0	0,5	100	0,85	Adapt. Feas.	0,211	4,7328
1182	0	0,25	0,75	0	100	0,85	Adapt. Feas.	0,310	3,2224
1183	0	0,25	0,5	0,25	100	0,85	Adapt. Feas.	0,329	3,0392
1184	0	0,25	0,25	0,5	100	0,85	Adapt. Feas.	0,312	3,2033
1185	0	0,25	0	0,75	100	0,85	Adapt. Feas.	0,366	2,7341
1186	0	0	1	0	100	0,85	Adapt. Feas.	0,540	1,8524
1187	0	0	0,75	0,25	100	0,85	Adapt. Feas.	0,286	3,4916
1188	0	0	0,5	0,5	100	0,85	Adapt. Feas.	0,499	2,0024
1189	0	0	0,25	0,75	100	0,85	Adapt. Feas.	0,281	3,5641
1190	0	0	0	1	100	0,85	Adapt. Feas.	0,322	3,1053
1191	1	0	0	0	100	0,85	Adapt. Feas.	1,325	0,7548
1192	0,75	0,25	0	0	100	0,85	Adapt. Feas.	0,820	1,2193
1193	0,75	0	0,25	0	100	0,85	Adapt. Feas.	0,925	1,0806
1194	0,75	0	0	0,25	100	0,85	Adapt. Feas.	0,643	1,5548
1195	0,5	0,5	0	0	100	0,85	Adapt. Feas.	0,576	1,7351
1196	0,5	0,25	0,25	0	100	0,85	Adapt. Feas.	0,407	2,4582
1197	0,5	0,25	0	0,25	100	0,85	Adapt. Feas.	0,568	1,7591
1198	0,5	0	0,5	0	100	0,85	Adapt. Feas.	0,901	1,1102

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
1199	0,5	0	0,25	0,25	100	0,85	Adapt. Feas.	0,640	1,5621
1200	0,5	0	0	0,5	100	0,85	Adapt. Feas.	0,407	2,4543
1201	0,25	0,75	0	0	100	0,85	Adapt. Feas.	0,473	2,1127
1202	0,25	0,5	0,25	0	100	0,85	Adapt. Feas.	0,284	3,5265
1203	0,25	0,5	0	0,25	100	0,85	Adapt. Feas.	0,285	3,5098
1204	0,25	0,25	0,5	0	100	0,85	Adapt. Feas.	0,320	3,1231
1205	0,25	0,25	0,25	0,25	100	0,85	Adapt. Feas.	0,374	2,6753
1206	0,25	0,25	0	0,5	100	0,85	Adapt. Feas.	0,267	3,7507
1207	0,25	0	0,75	0	100	0,85	Adapt. Feas.	0,802	1,2466
1208	0,25	0	0,5	0,25	100	0,85	Adapt. Feas.	0,453	2,2086
1209	0,25	0	0,25	0,5	100	0,85	Adapt. Feas.	0,307	3,2529
1210	0,25	0	0	0,75	100	0,85	Adapt. Feas.	0,290	3,4524
1211	0	1	0	0	100	0,85	Adapt. Feas.	0,305	3,2787
1212	0	0,75	0,25	0	100	0,85	Adapt. Feas.	0,300	3,3350
1213	0	0,75	0	0,25	100	0,85	Adapt. Feas.	0,397	2,5192
1214	0	0,5	0,5	0	100	0,85	Adapt. Feas.	0,485	2,0627
1215	0	0,5	0,25	0,25	100	0,85	Adapt. Feas.	0,234	4,2665
1216	0	0,5	0	0,5	100	0,85	Adapt. Feas.	0,356	2,8117
1217	0	0,25	0,75	0	100	0,85	Adapt. Feas.	0,348	2,8730
1218	0	0,25	0,5	0,25	100	0,85	Adapt. Feas.	0,260	3,8449
1219	0	0,25	0,25	0,5	100	0,85	Adapt. Feas.	0,298	3,3597
1220	0	0,25	0	0,75	100	0,85	Adapt. Feas.	0,250	3,9955
1221	0	0	1	0	100	0,85	Adapt. Feas.	0,506	1,9766
1222	0	0	0,75	0,25	100	0,85	Adapt. Feas.	0,485	2,0620
1223	0	0	0,5	0,5	100	0,85	Adapt. Feas.	0,326	3,0701
1224	0	0	0,25	0,75	100	0,85	Adapt. Feas.	0,284	3,5192
1225	0	0	0	1	100	0,85	Adapt. Feas.	0,283	3,5317
1226	1	0	0	0	100	0,85	Adapt. Feas.	1,278	0,7827
1227	0,75	0,25	0	0	100	0,85	Adapt. Feas.	0,517	1,9355
1228	0,75	0	0,25	0	100	0,85	Adapt. Feas.	1,107	0,9035
1229	0,75	0	0	0,25	100	0,85	Adapt. Feas.	1,097	0,9114
1230	0,5	0,5	0	0	100	0,85	Adapt. Feas.	0,437	2,2906
1231	0,5	0,25	0,25	0	100	0,85	Adapt. Feas.	0,714	1,4001
1232	0,5	0,25	0	0,25	100	0,85	Adapt. Feas.	0,461	2,1713
1233	0,5	0	0,5	0	100	0,85	Adapt. Feas.	0,703	1,4227
1234	0,5	0	0,25	0,25	100	0,85	Adapt. Feas.	0,555	1,8029
1235	0,5	0	0	0,5	100	0,85	Adapt. Feas.	0,550	1,8169
1236	0,25	0,75	0	0	100	0,85	Adapt. Feas.	0,371	2,6957
1237	0,25	0,5	0,25	0	100	0,85	Adapt. Feas.	0,417	2,3962
1238	0,25	0,5	0	0,25	100	0,85	Adapt. Feas.	0,293	3,4102
1239	0,25	0,25	0,5	0	100	0,85	Adapt. Feas.	0,436	2,2911
1240	0,25	0,25	0,25	0,25	100	0,85	Adapt. Feas.	0,303	3,3057
1241	0,25	0,25	0	0,5	100	0,85	Adapt. Feas.	0,276	3,6197

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
1242	0,25	0	0,75	0	100	0,85	Adapt. Feas.	0,429	2,3287
1243	0,25	0	0,5	0,25	100	0,85	Adapt. Feas.	0,372	2,6853
1244	0,25	0	0,25	0,5	100	0,85	Adapt. Feas.	0,370	2,7007
1245	0,25	0	0	0,75	100	0,85	Adapt. Feas.	0,316	3,1641
1246	0	1	0	0	100	0,85	Adapt. Feas.	0,238	4,2061
1247	0	0,75	0,25	0	100	0,85	Adapt. Feas.	0,254	3,9356
1248	0	0,75	0	0,25	100	0,85	Adapt. Feas.	0,271	3,6894
1249	0	0,5	0,5	0	100	0,85	Adapt. Feas.	0,369	2,7135
1250	0	0,5	0,25	0,25	100	0,85	Adapt. Feas.	0,247	4,0554
1251	0	0,5	0	0,5	100	0,85	Adapt. Feas.	0,227	4,4052
1252	0	0,25	0,75	0	100	0,85	Adapt. Feas.	0,281	3,5625
1253	0	0,25	0,5	0,25	100	0,85	Adapt. Feas.	0,288	3,4730
1254	0	0,25	0,25	0,5	100	0,85	Adapt. Feas.	0,265	3,7805
1255	0	0,25	0	0,75	100	0,85	Adapt. Feas.	0,255	3,9161
1256	0	0	1	0	100	0,85	Adapt. Feas.	0,440	2,2741
1257	0	0	0,75	0,25	100	0,85	Adapt. Feas.	0,349	2,8685
1258	0	0	0,5	0,5	100	0,85	Adapt. Feas.	0,311	3,2150
1259	0	0	0,25	0,75	100	0,85	Adapt. Feas.	0,301	3,3203
1260	0	0	0	1	100	0,85	Adapt. Feas.	0,268	3,7365
1261	1	0	0	0	100	0,85	Adapt. Feas.	1,349	0,7411
1262	0,75	0,25	0	0	100	0,85	Adapt. Feas.	0,528	1,8926
1263	0,75	0	0,25	0	100	0,85	Adapt. Feas.	0,784	1,2751
1264	0,75	0	0	0,25	100	0,85	Adapt. Feas.	0,692	1,4447
1265	0,5	0,5	0	0	100	0,85	Adapt. Feas.	0,515	1,9408
1266	0,5	0,25	0,25	0	100	0,85	Adapt. Feas.	0,514	1,9438
1267	0,5	0,25	0	0,25	100	0,85	Adapt. Feas.	0,524	1,9066
1268	0,5	0	0,5	0	100	0,85	Adapt. Feas.	0,739	1,3537
1269	0,5	0	0,25	0,25	100	0,85	Adapt. Feas.	0,553	1,8075
1270	0,5	0	0	0,5	100	0,85	Adapt. Feas.	0,766	1,3053
1271	0,25	0,75	0	0	100	0,85	Adapt. Feas.	0,302	3,3075
1272	0,25	0,5	0,25	0	100	0,85	Adapt. Feas.	0,292	3,4295
1273	0,25	0,5	0	0,25	100	0,85	Adapt. Feas.	0,543	1,8405
1274	0,25	0,25	0,5	0	100	0,85	Adapt. Feas.	0,497	2,0114
1275	0,25	0,25	0,25	0,25	100	0,85	Adapt. Feas.	0,404	2,4768
1276	0,25	0,25	0	0,5	100	0,85	Adapt. Feas.	0,389	2,5700
1277	0,25	0	0,75	0	100	0,85	Adapt. Feas.	0,770	1,2986
1278	0,25	0	0,5	0,25	100	0,85	Adapt. Feas.	0,576	1,7376
1279	0,25	0	0,25	0,5	100	0,85	Adapt. Feas.	0,405	2,4687
1280	0,25	0	0	0,75	100	0,85	Adapt. Feas.	0,348	2,8754
1281	0	1	0	0	100	0,85	Adapt. Feas.	0,221	4,5193
1282	0	0,75	0,25	0	100	0,85	Adapt. Feas.	0,258	3,8824
1283	0	0,75	0	0,25	100	0,85	Adapt. Feas.	0,534	1,8709
1284	0	0,5	0,5	0	100	0,85	Adapt. Feas.	0,403	2,4795

Teste	w1	w2	w3	w4	TP	Tc	Tm	EPG	EPG_{Box-Cox}
1285	0	0,5	0,25	0,25	100	0,85	Adapt. Feas.	0,255	3,9283
1286	0	0,5	0	0,5	100	0,85	Adapt. Feas.	0,425	2,3526
1287	0	0,25	0,75	0	100	0,85	Adapt. Feas.	0,264	3,7888
1288	0	0,25	0,5	0,25	100	0,85	Adapt. Feas.	0,317	3,1541
1289	0	0,25	0,25	0,5	100	0,85	Adapt. Feas.	0,321	3,1141
1290	0	0,25	0	0,75	100	0,85	Adapt. Feas.	0,231	4,3307
1291	0	0	1	0	100	0,85	Adapt. Feas.	0,460	2,1755
1292	0	0	0,75	0,25	100	0,85	Adapt. Feas.	0,333	3,0022
1293	0	0	0,5	0,5	100	0,85	Adapt. Feas.	0,389	2,5739
1294	0	0	0,25	0,75	100	0,85	Adapt. Feas.	0,293	3,4118
1295	0	0	0	1	100	0,85	Adapt. Feas.	0,292	3,4218
1296	1	0	0	0	100	0,85	Adapt. Feas.	1,657	0,6035
1297	0,75	0,25	0	0	100	0,85	Adapt. Feas.	0,521	1,9211
1298	0,75	0	0,25	0	100	0,85	Adapt. Feas.	1,426	0,7014
1299	0,75	0	0	0,25	100	0,85	Adapt. Feas.	0,716	1,3957
1300	0,5	0,5	0	0	100	0,85	Adapt. Feas.	0,952	1,0507
1301	0,5	0,25	0,25	0	100	0,85	Adapt. Feas.	0,516	1,9362
1302	0,5	0,25	0	0,25	100	0,85	Adapt. Feas.	0,738	1,3551
1303	0,5	0	0,5	0	100	0,85	Adapt. Feas.	0,687	1,4549
1304	0,5	0	0,25	0,25	100	0,85	Adapt. Feas.	0,836	1,1964
1305	0,5	0	0	0,5	100	0,85	Adapt. Feas.	0,732	1,3658
1306	0,25	0,75	0	0	100	0,85	Adapt. Feas.	0,479	2,0891
1307	0,25	0,5	0,25	0	100	0,85	Adapt. Feas.	0,296	3,3777
1308	0,25	0,5	0	0,25	100	0,85	Adapt. Feas.	0,285	3,5055
1309	0,25	0,25	0,5	0	100	0,85	Adapt. Feas.	0,329	3,0439
1310	0,25	0,25	0,25	0,25	100	0,85	Adapt. Feas.	0,322	3,1084
1311	0,25	0,25	0	0,5	100	0,85	Adapt. Feas.	0,383	2,6123
1312	0,25	0	0,75	0	100	0,85	Adapt. Feas.	0,836	1,1963
1313	0,25	0	0,5	0,25	100	0,85	Adapt. Feas.	0,349	2,8630
1314	0,25	0	0,25	0,5	100	0,85	Adapt. Feas.	0,369	2,7065
1315	0,25	0	0	0,75	100	0,85	Adapt. Feas.	0,287	3,4858
1316	0	1	0	0	100	0,85	Adapt. Feas.	0,375	2,6637
1317	0	0,75	0,25	0	100	0,85	Adapt. Feas.	0,273	3,6632
1318	0	0,75	0	0,25	100	0,85	Adapt. Feas.	0,258	3,8719
1319	0	0,5	0,5	0	100	0,85	Adapt. Feas.	0,247	4,0487
1320	0	0,5	0,25	0,25	100	0,85	Adapt. Feas.	0,573	1,7442
1321	0	0,5	0	0,5	100	0,85	Adapt. Feas.	0,288	3,4756
1322	0	0,25	0,75	0	100	0,85	Adapt. Feas.	0,269	3,7243
1323	0	0,25	0,5	0,25	100	0,85	Adapt. Feas.	0,282	3,5505
1324	0	0,25	0,25	0,5	100	0,85	Adapt. Feas.	0,420	2,3783
1325	0	0,25	0	0,75	100	0,85	Adapt. Feas.	0,381	2,6234
1326	0	0	1	0	100	0,85	Adapt. Feas.	0,428	2,3345
1327	0	0	0,75	0,25	100	0,85	Adapt. Feas.	0,442	2,2633

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
1328	0	0	0,5	0,5	100	0,85	Adapt. Feas.	0,452	2,2127
1329	0	0	0,25	0,75	100	0,85	Adapt. Feas.	0,278	3,5911
1330	0	0	0	1	100	0,85	Adapt. Feas.	0,249	4,0144
1331	1	0	0	0	100	0,85	Adapt. Feas.	1,572	0,6362
1332	0,75	0,25	0	0	100	0,85	Adapt. Feas.	0,747	1,3389
1333	0,75	0	0,25	0	100	0,85	Adapt. Feas.	0,767	1,3046
1334	0,75	0	0	0,25	100	0,85	Adapt. Feas.	0,590	1,6960
1335	0,5	0,5	0	0	100	0,85	Adapt. Feas.	0,400	2,4981
1336	0,5	0,25	0,25	0	100	0,85	Adapt. Feas.	0,538	1,8580
1337	0,5	0,25	0	0,25	100	0,85	Adapt. Feas.	0,510	1,9604
1338	0,5	0	0,5	0	100	0,85	Adapt. Feas.	0,780	1,2828
1339	0,5	0	0,25	0,25	100	0,85	Adapt. Feas.	0,424	2,3572
1340	0,5	0	0	0,5	100	0,85	Adapt. Feas.	0,371	2,6959
1341	0,25	0,75	0	0	100	0,85	Adapt. Feas.	0,419	2,3857
1342	0,25	0,5	0,25	0	100	0,85	Adapt. Feas.	0,370	2,7046
1343	0,25	0,5	0	0,25	100	0,85	Adapt. Feas.	0,289	3,4565
1344	0,25	0,25	0,5	0	100	0,85	Adapt. Feas.	0,331	3,0249
1345	0,25	0,25	0,25	0,25	100	0,85	Adapt. Feas.	0,294	3,4050
1346	0,25	0,25	0	0,5	100	0,85	Adapt. Feas.	0,326	3,0715
1347	0,25	0	0,75	0	100	0,85	Adapt. Feas.	0,956	1,0456
1348	0,25	0	0,5	0,25	100	0,85	Adapt. Feas.	0,375	2,6674
1349	0,25	0	0,25	0,5	100	0,85	Adapt. Feas.	0,388	2,5757
1350	0,25	0	0	0,75	100	0,85	Adapt. Feas.	0,292	3,4290
1351	0	1	0	0	100	0,85	Adapt. Feas.	0,429	2,3314
1352	0	0,75	0,25	0	100	0,85	Adapt. Feas.	0,375	2,6663
1353	0	0,75	0	0,25	100	0,85	Adapt. Feas.	0,324	3,0866
1354	0	0,5	0,5	0	100	0,85	Adapt. Feas.	0,379	2,6411
1355	0	0,5	0,25	0,25	100	0,85	Adapt. Feas.	0,247	4,0468
1356	0	0,5	0	0,5	100	0,85	Adapt. Feas.	0,303	3,2973
1357	0	0,25	0,75	0	100	0,85	Adapt. Feas.	0,277	3,6083
1358	0	0,25	0,5	0,25	100	0,85	Adapt. Feas.	0,273	3,6657
1359	0	0,25	0,25	0,5	100	0,85	Adapt. Feas.	0,563	1,7758
1360	0	0,25	0	0,75	100	0,85	Adapt. Feas.	0,328	3,0523
1361	0	0	1	0	100	0,85	Adapt. Feas.	0,460	2,1744
1362	0	0	0,75	0,25	100	0,85	Adapt. Feas.	0,384	2,6023
1363	0	0	0,5	0,5	100	0,85	Adapt. Feas.	0,337	2,9645
1364	0	0	0,25	0,75	100	0,85	Adapt. Feas.	0,484	2,0652
1365	0	0	0	1	100	0,85	Adapt. Feas.	0,214	4,6826
1366	1	0	0	0	100	0,85	Adapt. Feas.	1,272	0,7862
1367	0,75	0,25	0	0	100	0,85	Adapt. Feas.	0,499	2,0054
1368	0,75	0	0,25	0	100	0,85	Adapt. Feas.	1,432	0,6984
1369	0,75	0	0	0,25	100	0,85	Adapt. Feas.	1,009	0,9907
1370	0,5	0,5	0	0	100	0,85	Adapt. Feas.	0,414	2,4167

Teste	w1	w2	w3	w4	Tp	Tc	Tm	EPG	EPG_{Box-Cox}
1371	0,5	0,25	0,25	0	100	0,85	Adapt. Feas.	0,514	1,9445
1372	0,5	0,25	0	0,25	100	0,85	Adapt. Feas.	0,369	2,7129
1373	0,5	0	0,5	0	100	0,85	Adapt. Feas.	0,614	1,6299
1374	0,5	0	0,25	0,25	100	0,85	Adapt. Feas.	0,689	1,4522
1375	0,5	0	0	0,5	100	0,85	Adapt. Feas.	0,489	2,0468
1376	0,25	0,75	0	0	100	0,85	Adapt. Feas.	0,307	3,2616
1377	0,25	0,5	0,25	0	100	0,85	Adapt. Feas.	0,333	3,0030
1378	0,25	0,5	0	0,25	100	0,85	Adapt. Feas.	0,284	3,5191
1379	0,25	0,25	0,5	0	100	0,85	Adapt. Feas.	0,502	1,9917
1380	0,25	0,25	0,25	0,25	100	0,85	Adapt. Feas.	0,292	3,4287
1381	0,25	0,25	0	0,5	100	0,85	Adapt. Feas.	0,280	3,5711
1382	0,25	0	0,75	0	100	0,85	Adapt. Feas.	0,509	1,9632
1383	0,25	0	0,5	0,25	100	0,85	Adapt. Feas.	0,536	1,8668
1384	0,25	0	0,25	0,5	100	0,85	Adapt. Feas.	0,348	2,8738
1385	0,25	0	0	0,75	100	0,85	Adapt. Feas.	0,318	3,1471
1386	0	1	0	0	100	0,85	Adapt. Feas.	0,237	4,2143
1387	0	0,75	0,25	0	100	0,85	Adapt. Feas.	0,249	4,0135
1388	0	0,75	0	0,25	100	0,85	Adapt. Feas.	0,224	4,4559
1389	0	0,5	0,5	0	100	0,85	Adapt. Feas.	0,274	3,6511
1390	0	0,5	0,25	0,25	100	0,85	Adapt. Feas.	0,255	3,9147
1391	0	0,5	0	0,5	100	0,85	Adapt. Feas.	0,211	4,7397
1392	0	0,25	0,75	0	100	0,85	Adapt. Feas.	0,289	3,4626
1393	0	0,25	0,5	0,25	100	0,85	Adapt. Feas.	0,266	3,7594
1394	0	0,25	0,25	0,5	100	0,85	Adapt. Feas.	0,253	3,9460
1395	0	0,25	0	0,75	100	0,85	Adapt. Feas.	0,218	4,5835
1396	0	0	1	0	100	0,85	Adapt. Feas.	0,555	1,8024
1397	0	0	0,75	0,25	100	0,85	Adapt. Feas.	0,391	2,5589
1398	0	0	0,5	0,5	100	0,85	Adapt. Feas.	0,348	2,8768
1399	0	0	0,25	0,75	100	0,85	Adapt. Feas.	0,303	3,2995
1400	0	0	0	1	100	0,85	Adapt. Feas.	0,266	3,7598

APÊNDICE B - Códigos utilizados para otimização no Matlab®

```

function [ f ] = MCG( x )
%Função de otimização - Método do Critério Global
% Definição das respostas
W=10.640+0.797*x(1)+0.656*x(2)-1.451*x(3)-
0.629*x(4)+0.27*x(3)^2+0.266*x(1)*x(2)-0.114*x(1)*x(3)-
0.102*x(2)*x(3)+0.067*x(3)*x(4);
P=1.639+0.122*x(1)+0.122*x(2)+0.093*x(3)-0.241*x(4)+0.025*x(1)^2-
0.032*x(2)^2-0.118*x(3)^2+0.034*x(1)*x(2)+0.076*x(1)*x(3)-0.1*x(1)*x(4);
R=2.597+0.191*x(1)-0.104*x(2)-
0.223*x(3)+0.115*x(4)+0.034*x(2)^2+0.019*x(3)^2+0.036*x(4)^2-
0.03*x(1)*x(2)-0.023*x(1)*x(4);
D=31.034-0.282*x(1)+2.493*x(2)+3.679*x(3)-4.251*x(4)-0.723*x(2)^2-
1.229*x(3)^2+0.769*x(1)*x(2)+0.497*x(1)*x(3)-0.418*x(1)*x(4)-
0.771*x(3)*x(4);

%Escalonamento das respostas
f1esc=((15.576-W)/(-3.125))^2;
f2esc=((0.828-P)/(0.584))^2;
f3esc=((3.342-R)/(-0.287))^2;
f4esc=((16.275-D)/(7.796))^2;

%Definição da a Função MGC
f=w1*f1esc+w2*f2esc+w3*f3esc+w4*f4esc;

end

```

```

function [c, ceq] = restricao(x)
%Funções de restrição

%Definição de restrição não linear
c=x(1)^2+x(2)^2+x(3)^2+x(4)^2-4;

%Definição de restrição linear
ceq=[];

end

```

**APÊNDICE C - Análise estatística para o modelo Quártico completo de primeira ordem
para a função $EPG_{Box-Cox}$ Realizada no MINITAB®**

Regressão para $EPG_{Box-Cox}$ em função de $w_1, w_2, w_3, w_4, T_p, T_c$ e T_m

- Coeficientes de regressão estimados para $EPG_{Box-Cox}$ (proporções de componentes):

Term	Coef	SE Coef	T	P	VIF
w1	0,79	0,0570	*	*	1,806
w2	4,27	0,0611	*	*	2,072
w3	2,21	0,0739	*	*	3,028
w4	4,07	0,0538	*	*	1,604
w1*w3	1,07	0,3118	3,43	0,001	2,322
w2*w3	1,61	0,3032	5,30	0,000	2,195
w1*w2*(-)	1,67	0,6824	2,45	0,015	1,154
w2*w3*(-)	-1,93	0,6831	-2,83	0,005	1,156
w2*w4*(-)	-3,00	0,6813	-4,40	0,000	1,150
w1*w3*w4*w4	26,56	5,3696	4,95	0,000	1,269
w3*w4*(-)2	-5,22	1,6880	-3,09	0,002	1,525
w4*Tp	-0,22	0,0610	-3,58	0,000	2,068
w2*w3*Tp	-0,64	0,2944	-2,17	0,031	2,070
w2*w4*Tp	0,79	0,2533	3,11	0,002	1,533
w3*w4*Tp	0,93	0,2534	3,67	0,000	1,533
w1*w3*(-)2*Tp	-4,89	1,3703	-3,56	0,000	1,005
w2*w3*(-)2*Tp	6,75	1,9152	3,52	0,000	1,963
w1*w3*(-)*Tc	-1,74	0,6406	-2,71	0,007	1,017
w2*w3*(-)*Tc	1,49	0,6381	2,34	0,020	1,009
w1*w1*w3*w4*Tc	-18,28	4,8841	-3,74	0,000	1,050
w1*w2*w3*w3*Tc	-12,77	4,9012	-2,61	0,010	1,057
w1*w2*w3*w4*Tc	60,22	24,8125	2,43	0,016	1,084
w1*w3*Tm	-0,95	0,2424	-3,91	0,000	1,403
w1*w4*Tm	-0,90	0,2308	-3,89	0,000	1,272
w2*w3*Tm	-0,94	0,3635	-2,58	0,010	3,156
w2*w4*Tm	0,54	0,2309	2,33	0,020	1,273
w1*w4*(-)*Tm	-1,90	0,6666	-2,84	0,005	1,101
w1*w1*w3*w4*Tm	29,05	9,4975	3,06	0,002	3,969
w2*w2*w3*w4*Tm	21,08	9,1708	2,30	0,022	3,701
w1*w2*w2*w3*Tm	-14,58	5,8012	-2,51	0,012	1,481
w1*w3*w4*w4*Tm	-24,02	9,2642	-2,59	0,010	3,777
w2*w3*w4*w4*Tm	-23,86	8,9036	-2,68	0,008	3,488
w2*w3*(-)2*Tm	6,79	2,0314	3,34	0,001	2,208

* NOTE * Coefficients are calculated for coded process variables.

S = 0,322535 PRESS = 48,0083
R-Sq = 89,24% R-Sq(pred) = 87,17% R-Sq(adj) = 88,35%

- Análise de Variância para $EPG_{Box-Cox}$ (proporções de componentes):

Source	DF	Seq SS	Adj SS	Adj MS	F	P
Regression	32	333,819	333,819	10,4318	100,28	0,000
Component Only						
Linear	3	301,093	203,822	67,9406	653,10	0,000
Quadratic	2	6,511	3,653	1,8266	17,56	0,000
w1*w3	1	1,665	1,221	1,2206	11,73	0,001
w2*w3	1	4,847	2,925	2,9253	28,12	0,000
Full Cubic	3	3,249	3,332	1,1107	10,68	0,000
w1*w2*(-)	1	0,457	0,622	0,6219	5,98	0,015
w2*w3*(-)	1	0,939	0,831	0,8312	7,99	0,005
w2*w4*(-)	1	1,852	2,014	2,0138	19,36	0,000
Special Quartic	1	2,571	2,546	2,5459	24,47	0,000
w1*w3*w4*w4	1	2,571	2,546	2,5459	24,47	0,000

Full Quartic1	1	0,996	0,996	0,9964	9,58	0,002
w3*w4*(-)2	1	0,996	0,996	0,9964	9,58	0,002
Component* Tp						
Linear	1	0,077	1,335	1,3351	12,83	0,000
w4*Tp	1	0,077	1,335	1,3351	12,83	0,000
Quadratic	3	1,746	2,140	0,7132	6,86	0,000
w2*w3*Tp	1	0,125	0,488	0,4882	4,69	0,031
w2*w4*Tp	1	0,517	1,003	1,0034	9,65	0,002
w3*w4*Tp	1	1,104	1,400	1,3997	13,45	0,000
Full Quartic1	2	2,680	2,680	1,3398	12,88	0,000
w1*w3*(-)2*Tp	1	1,389	1,322	1,3221	12,71	0,000
w2*w3*(-)2*Tp	1	1,290	1,290	1,2904	12,40	0,000
Component* Tc						
Full Cubic	2	1,466	1,286	0,6429	6,18	0,002
w1*w3*(-)*Tc	1	0,772	0,764	0,7643	7,35	0,007
w2*w3*(-)*Tc	1	0,694	0,570	0,5703	5,48	0,020
Special Quartic	2	1,722	2,179	1,0893	10,47	0,000
w1*w1*w3*w4*Tc	1	1,231	1,457	1,4570	14,01	0,000
w1*w2*w3*w3*Tc	1	0,491	0,707	0,7066	6,79	0,010
Full Quartic2	1	0,613	0,613	0,6128	5,89	0,016
w1*w2*w3*w4*Tc	1	0,613	0,613	0,6128	5,89	0,016
Component* Tm						
Quadratic	4	6,209	4,201	1,0502	10,10	0,000
w1*w3*Tm	1	4,196	1,588	1,5875	15,26	0,000
w1*w4*Tm	1	1,238	1,573	1,5733	15,12	0,000
w2*w3*Tm	1	0,315	0,692	0,6921	6,65	0,010
w2*w4*Tm	1	0,461	0,564	0,5637	5,42	0,020
Full Cubic	1	0,428	0,841	0,8411	8,08	0,005
w1*w4*(-)*Tm	1	0,428	0,841	0,8411	8,08	0,005
Special Quartic	5	3,294	2,542	0,5084	4,89	0,000
w1*w1*w3*w4*Tm	1	0,407	0,973	0,9731	9,35	0,002
w2*w2*w3*w4*Tm	1	0,001	0,550	0,5497	5,28	0,022
w1*w2*w2*w3*Tm	1	1,247	0,657	0,6575	6,32	0,012
w1*w3*w4*w4*Tm	1	0,714	0,700	0,6996	6,72	0,010
w2*w3*w4*w4*Tm	1	0,924	0,747	0,7472	7,18	0,008
Full Quartic1	1	1,163	1,163	1,1630	11,18	0,001
w2*w3*(-)2*Tm	1	1,163	1,163	1,1630	11,18	0,001
Residual Error	387	40,259	40,259	0,1040		
Lack-of-Fit	107	8,514	8,514	0,0796	0,70	0,983
Pure Error	280	31,745	31,745	0,1134		
Total	419	374,078				

ANEXOS

ANEXO A - Matriz Experimental utilizada por Gomes (2013)

Teste	Parâmetros codificados				Geometria			
	<i>Va</i>	<i>T</i>	<i>Vs</i>	<i>N</i>	<i>W</i> (mm)	<i>P</i> (mm)	<i>R</i> (mm)	<i>D</i> (%)
1	-1	-1	-1	-1	11,19	1,37	2,63	26,44
2	1	-1	-1	-1	12,99	1,66	3,12	25,82
3	-1	1	-1	-1	12,70	1,69	2,50	31,49
4	1	1	-1	-1	15,05	1,98	2,78	31,25
5	-1	-1	1	-1	9,21	1,65	2,17	36,22
6	1	-1	1	-1	9,96	1,94	2,67	33,69
7	-1	1	1	-1	9,75	1,54	2,06	37,12
8	1	1	1	-1	11,51	2,18	2,42	41,08
9	-1	-1	-1	1	10,32	1,25	2,87	22,46
10	1	-1	-1	1	11,43	1,00	*	18,32
11	-1	1	-1	1	11,27	1,32	2,85	23,71
12	1	1	-1	1	13,34	1,10	3,18	21,96
13	-1	-1	1	1	7,99	1,11	2,55	24,96
14	1	-1	1	1	8,62	1,23	2,80	23,31
15	-1	1	1	1	8,48	1,37	2,36	28,77
16	1	1	1	1	10,84	1,64	2,60	30,19
17	-2	0	0	0	9,07	1,38	2,21	31,56
18	2	0	0	0	12,21	2,14	3,06	30,95
19	0	-2	0	0	9,42	1,20	3,03	22,84
20	0	2	0	0	11,69	1,86	2,46	35,58
21	0	0	-2	0	14,93	0,95	*	18,58
22	0	0	2	0	8,48	1,43	2,25	35,78
23	0	0	0	-2	11,73	2,18	2,61	40,44
24	0	0	0	2	9,22	1,28	2,89	24,16
25	0	0	0	0	10,82	1,71	2,60	31,05
26	0	0	0	0	10,93	1,72	2,59	31,67
27	0	0	0	0	10,74	1,62	2,65	30,88
28	0	0	0	0	10,61	1,80	2,50	32,83
29	0	0	0	0	10,64	1,49	2,62	29,99
30	0	0	0	0	10,59	1,49	2,61	31,09
31	0	0	0	0	10,57	1,50	2,56	31,02