

**UNIVERSIDADE FEDERAL DE PERNAMBUCO**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

**MANUTENÇÃO SELETIVA PARA**  
**SISTEMAS ORIENTADOS A MULTIMISSÕES**

**LUCAS FREDERICO ALVES RIBEIRO**

Orientador: Cristiano Alexandre Virgínio Cavalcante, Dr.

Recife

2016

**LUCAS FREDERICO ALVES RIBEIRO**

**MANUTENÇÃO SELETIVA PARA  
SISTEMAS ORIENTADOS A MULTIMISSÕES**

Dissertação de Mestrado apresentada à UFPE para a obtenção do grau de Mestre como parte das exigências do Programa de Pós-Graduação em Engenharia de Produção (Área de Concentração: Pesquisa Operacional).

Orientador: Cristiano Alexandre Virgínio Cavalcante, Dr.

Recife

2016

Catálogo na fonte

Bibliotecária Valdicea Alves, CRB-4 / 1260

R484m Ribeiro, Lucas Frederico Alves.  
Manutenção seletiva para Sistemas orientados a multimissões / Lucas Frederico Alves Ribeiro. 2016.  
64 folhas, Il., e Tabs.

Orientador: Prof<sup>o</sup>. Dr. Cristiano Alexandre Virgínio Cavalcante.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia de Produção, 2016.  
Inclui: Referências.

1. Engenharia de Produção. 2. Manutenção seletiva. 3. Multimissões. 4. Algoritmo genético. 5. Análise de sensibilidade. 6. Modelos alternativos. I. Cavalcante, Cristiano Alexandre Virgínio (Orientador). II. Título.

658.5 CDD (22. ed.)

UFPE  
BCTG/2016-92

**UNIVERSIDADE FEDERAL DE PERNAMBUCO**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

**PARECER DA COMISSÃO EXAMINADORA**  
**DE DEFESA DE DISSERTAÇÃO DE**  
**MESTRADO ACADÊMICO DE**

**LUCAS FREDERICO ALVES RIBEIRO**

**“Manutenção Seletiva Para Sistemas Orientados a Multimissões”**

**ÁREA DE CONCENTRAÇÃO: PESQUISA OPERACIONAL**

A comissão examinadora composta pelos professores abaixo, sob a presidência do(a) primeiro(a) , considera o candidato **LUCAS FREDERICO ALVES RIBEIRO, APROVADO.**

Recife, 29 de fevereiro de 2016.

---

Prof. CRISTIANO ALEXANDRE VIRGÍNIO CAVALCANTE, Doutor (UFPE)

---

Prof. ADIEL TEIXEIRA DE ALMEIDA FILHO, Doutor (UFPE)

---

Prof. ALCIDES CODECEIRA NETO, PhD (UPE)

Aos desígnios do SENHOR, que faz todas as coisas conforme o conselho da Sua vontade e àqueles que buscam no Seu conselho a sua vontade (S.D.G).

## **AGRADECIMENTOS**

Ao SENHOR, que me elegeu antes da fundação do mundo para o louvor da glória de sua graça. Ao Deus de graça - glória e louvor.

Aos meus pais, Luiz Santana e Marina Ribeiro, que têm me ensinado no caminho em que eu devo andar, e, ao meu irmão, Luiz Felipe, que me acompanha na caminhada.

Ao tio Edivan, pelo apoio nesta estrada. Sem ele, a trilha seria mais árdua.

Ao professor Cristiano Cavalcante, minha referência profissional, agradeço por ter sido placa nesta jornada e, por diversas vezes, ter evitado o desperdício de combustível.

Aos Professores, Fátima Rosar, Saul, XKO, Axel e Denise, pela inspiração e ensinamentos, que carregarei por toda vida.

Ao Ricardo Lopes, pela fraternidade, e aos demais amigos e colegas do Programa de Pós-Graduação em Engenharia de Produção, especialmente aos companheiros do RANDOM, pelos momentos de aprendizagem e alegria.

Aos queridos irmãos, John David, Wellington Fidelis, Carrol, Ana, Cláudia e Danilo (e suas respectivas famílias), por terem me acolhido em terra estranha, pelas orações em meu favor e pela amizade sincera.

Aos irmãos da IPNE, IPCB e IEBV pelo amor, em especial, aos pastores Dilvan Oliveira, José Deusarte e Pedro Serafim, pelo zelo e instruções.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), por prover parte dos recursos financeiros que me mantiveram longe de casa.

“A maior riqueza do homem é a sua incompletude.”

Manoel de Barros

## RESUMO

A escolha de uma estratégia adequada de manutenção para os sistemas produtivos de uma organização é um pré-requisito para a sua efetividade. Destaca-se que esta escolha é um processo decisório que utiliza modelos matemáticos para encontrar uma estratégia que otimize a relação custo-benefício das ações de manutenção. Tal estratégia deve levar em conta períodos para a execução das intervenções, bem como a existência de metas de produção. Embora seja comum a inclusão de paradas para manutenção entre períodos de operações dos sistemas nos planos de produção, geralmente aqueles modelos ignoram a finitude da duração de tais paradas; o mesmo acontece com relação à escassez dos recursos de manutenção. Entretanto, esses fatores restringem a quantidade de ações que podem ser executadas a cada parada e, portanto, não devem ser desprezados. Em virtude disso, é necessário identificar, dentre as ações de manutenção passíveis de serem executadas no sistema, aquelas que são críticas para seu(s) indicador(es) de performance. Isso é uma prerrogativa dos modelos de manutenção seletiva. Não obstante, a resolução desses modelos é tarefa árdua, já que problemas combinatórios necessitam de métodos heurísticos para serem solucionados. Neste trabalho, ambas as necessidades foram trabalhadas. O fim principal da investigação foi contribuir com os modelos de manutenção seletiva dedicados a sistemas orientados a múltiplas missões. Para isso, expandiu-se um modelo de manutenção seletiva voltado a sistemas orientados a multimissões e desenvolveu-se um algoritmo genético para resolver o problema. Estes foram postos à prova em uma aplicação numérica. Atestados a efetividade do método e a aplicabilidade do modelo, fez-se análises de sensibilidade e formulou-se modelos alternativos. Ainda se fez recomendações para a canalização de esforços em trabalhos futuros. No todo, a pesquisa configura-se como tendo natureza básica e aplicada, bem como caráter explicativo. Quanto à abordagem, é quantitativa e utiliza o método da modelagem e simulação.

Palavras-chave: Manutenção Seletiva. Multimissões. Algoritmo Genético. Análise de Sensibilidade. Modelos Alternativos.

## **ABSTRACT**

The choice of a suitable maintenance strategy for productive systems of an organization is a requirement for its effectiveness. It is emphasized that this choice is a decision-making process that uses mathematical models to find a strategy that optimizes the cost-effectiveness of maintenance actions. This strategy must take into account periods for the implementation of assistance, as well as the existence of production goals. Although it is common to include maintenance downtime between periods of systems operations in production schedules, generally those models ignore the finite length of these stops; the same applies regarding to the shortage of maintenance resources. However, these factors constrain the number of actions that can be performed at each break and, therefore, should not be neglected. As a result, it is necessary to identify, among the maintenance actions that can be performed on the system, those that are critical to the performance indicator(s). This is a prerogative of selective maintenance models. Nevertheless, the resolution of these models is a difficult task, as combinatorial problems require heuristic methods to be solved. In this work, both requirements were addressed. The main purpose of the research was to contribute to the selective maintenance models dedicated to multiple mission's oriented systems. For this it has been expanded a multiple mission oriented maintenance model and was developed a genetic algorithm for solving the problem. These were tested in a numerical application. Attested the effectiveness of the method and the applicability of the model, a sensitivity analysis were performed and alternative models were developed. Still it has made recommendations for concentrating efforts in future work. Overall, the research is characterized as having basic and applied nature, as well as explanatory character. As for the approach, it is quantitative and uses the modeling and simulation method.

**Keywords:** Selective Maintenance. Multiple Missions. Genetic Algorithm. Sensitivity Analysis. Alternative Models.

## LISTA DE FIGURAS

Figura 2.1 – Terminologia empregada nos Algoritmos Genéticos.....	26
Figura 2.2 – Funcionamento Básico de um Algoritmo Genético.....	27
Figura 2.3 – Exemplo ilustrativo da Seleção por Torneio.....	28
Figura 2.4 – Exemplo ilustrativo da Seleção por Roleta.....	29
Figura 2.5 - Exemplo ilustrativo do Cruzamento com um (a) e dois (b) Pontos de Corte.....	29
Figura 2.6 - Exemplo ilustrativo do Crossover Uniforme.....	30
Figura 2.7 - Exemplo ilustrativo da Mutação.....	30
Figura 3.1 – Exemplo de um Sistema Série-Paralelo.....	31
Figura 3.2 – Estratégia de Solução Implementada.....	37
Figura 3.3 – Exemplo ilustrativo dos Operadores de Cruzamento (a) e Mutação (b) .....	38
Figura 3.4 – Diagrama de Bloco do Sistema estudado no Exemplo Numérico.....	39
Figura 3.5 – Confiabilidade e Custo Acumulados ao longo das Missões para as Soluções Ótima e Null.....	42
Figura 3.6 – Tempos Disponíveis e Alocados às Ações (superpostos) nos Breaks.....	44
Figura 4.1 – Sensibilidade das Soluções a Variações no Custo de Penalidade.....	45
Figura 4.2 – Sensibilidade dos Custos por Penalidade a Variações na Redundância do Sistema.....	46
Figura 4.3 – Sensibilidade dos Custos Totais a Variações na Composição do Sistema.....	48

## LISTA DE TABELAS

Tabela 3.1 – Parâmetros dos Componentes do Sistema.....	39
Tabela 3.2 – Duração das Missões (M) e Breaks (B) e Requisito de Confiabilidade (R) .....	40
Tabela 3.3 – Parâmetros das Ações Preventivas passíveis de serem executadas no Sistema.....	40
Tabela 3.4 – Solução Ótima encontrada.....	41
Tabela 3.5 – Estratificação dos Custos para a Solução Ótima.....	43
Tabela 3.6 – Estratificação dos Custos para a Solução Null.....	43
Tabela 4.1 – Parâmetros dos Componentes do Sistema (caso IV) .....	47
Tabela 4.2 – Parâmetros das Ações Preventivas passíveis de serem executadas no Sistema (caso IV) .....	47
Tabela 4.3 – Soluções ótimas – caso base e caso V.....	48
Tabela 4.4 – Soluções ótimas – caso base e caso VI.....	49
Tabela 4.5 – Solução Ótima Encontrada - Modelo 2.....	51
Tabela 4.6 – Conf., Cust. Tot. Ac. e Tempo Alocado à Manutenção - Soluções Ótimas (Modelos 1 e 2) .....	52
Tabela 4.7 – Solução Ótima Encontrada – Modelo 3.....	54
Tabela 4.8 – Conf. Méd., Cust. Tot. Ac. e Tempo Alocado à Manutenção Sol. Ótimas (Modelos 1, 2 e 3) .....	54
Tabela 4.9 – Solução Ótima Encontrada – Modelo 4.....	55
Tabela 4.10 – Conf. Méd., Cust. Tot. Ac. e Tempo. Tot. Alocado à Manutenção – Sol. Ótima (Modelos 3 e 4) .....	56

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>12</b>
<b>1.1</b>	<b>Objetivos</b> .....	<b>13</b>
1.1.1	Objetivo Geral .....	13
1.1.2	Objetivos Específicos .....	13
<b>1.2</b>	<b>Metodologia</b> .....	<b>13</b>
<b>1.3</b>	<b>Estrutura do Trabalho</b> .....	<b>14</b>
<b>2</b>	<b>REFERENCIAL TEÓRICO E REVISÃO DA LITERATURA</b> .....	<b>15</b>
<b>2.1</b>	<b>Políticas de Manutenção</b> .....	<b>15</b>
<b>2.2</b>	<b>Modelos de Manutenção</b> .....	<b>16</b>
<b>2.3</b>	<b>Efeito das Intervenções de Manutenção no Sistema</b> .....	<b>18</b>
2.3.1	Manutenção Imperfeita - Modelos e Políticas.....	19
<b>2.4</b>	<b>Manutenção Seletiva</b> .....	<b>21</b>
<b>2.5</b>	<b>Algoritmos Genéticos</b> .....	<b>25</b>
2.5.1	Terminologia e Funcionamento dos Algoritmos Genéticos.....	26
2.5.2	Operações Genéticas .....	28
<b>3</b>	<b>DO MODELO AOS RESULTADOS</b> .....	<b>31</b>
<b>3.1</b>	<b>Descrição do Sistema e Bases Matemáticas do Modelo</b> .....	<b>31</b>
<b>3.2</b>	<b>Formulação do Problema e o Modelo Matemático</b> .....	<b>34</b>
<b>3.3</b>	<b>Estratégia de Resolução do Problema</b> .....	<b>35</b>
3.3.1	Representação, Geração e Avaliação do Fitness dos Indivíduos .....	36
3.3.2	Operadores Genéticos e Critérios de Parada.....	37
<b>3.4</b>	<b>Exemplo Numérico</b> .....	<b>39</b>
<b>4</b>	<b>ANÁLISES DE SENSIBILIDADE E MODELOS ALTERNATIVOS</b> .....	<b>45</b>
<b>4.1</b>	<b>Análises de Sensibilidade</b> .....	<b>45</b>
4.1.1	Primeiro Cenário .....	45
4.1.2	Segundo Cenário .....	46
4.1.3	Terceiro Cenário.....	48
<b>4.2</b>	<b>Modelos Alternativos</b> .....	<b>50</b>
4.2.1	Primeiro Modelo Alternativo .....	50
4.2.2	Segundo Modelo Alternativo .....	52
<b>5</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS</b> .....	<b>57</b>
	<b>REFERÊNCIAS</b> .....	<b>60</b>

## 1 INTRODUÇÃO

A manutenção industrial é uma função organizacional que engloba ações técnicas e administrativas que visem restaurar ou manter um sistema produtivo em um estado em que possa desempenhar uma função predeterminada (SWANSON, 2001). Nesse contexto, a efetividade dessas organizações é dependente da escolha de uma estratégia adequada de manutenção (BOGONOVO, MARSEGUERRA & ZIO, 2000).

Cabe destacar que a escolha dessa estratégia está vinculada a modelos matemáticos cujo objetivo é encontrar o equilíbrio entre os custos (num sentido amplo) das atividades de manutenção e os benefícios que elas proporcionavam ao sistema (SANDVE & AVEN, 1999).

Além disso, essas estratégias conduzem à utilização eficiente dos sistemas de manufatura, o que é refletido na aderência ao plano de produção. Esse, por sua vez, deve levar em conta períodos para a realização das ações de manutenção, dos quais o correto desempenho dos sistemas é dependente (TSAI, WANG & TENG, 2001).

Assim, é comum planejar-se a operação dos sistemas por períodos de tempo (missões) dentre os quais se estabelece um intervalo finito (parada ou *break*) que figura como uma oportunidade para a realização das atividades de manutenção (PANDEY et al., 2013). Equipamentos industriais, que operaram durante a semana e são mantidos nos fins de semana, e caixas eletrônicos, que são demandados durante o dia e mantidos a noite, são exemplos de sistemas que operam segundo essa sistemática.

Contudo, muitos dos modelos dedicados à determinação desses planos desprezam a finitude da duração dessas paradas, bem como ignoram a escassez de recursos de manutenção – orçamento, peças, pessoal etc. (MAILLART et al., 2009). Logo, é improvável que a execução de todas as ações de manutenção desejáveis para o sistema seja concretizada.

Desse modo, deve-se identificar, dentre as ações possíveis para a manutenção do sistema, aquelas que são críticas para seu(s) indicador(es) de performance – confiabilidade e custo, por exemplo. A esse processo decisório denomina-se Problema de Manutenção Seletiva (LIU & HUANG, 2010).

Entretanto, a resolução desse problema – inserido na classe dos problemas combinatórios – não é trivial e, muitas vezes, necessita do uso de métodos heurísticos para serem solucionados. Nesse contexto, algoritmos genéticos são uma boa alternativa.

## 1.1 Objetivos

Nesse panorama, este trabalho concentra esforços para a determinação de estratégias ótimas de manutenção seletiva, considerando o caráter limitado dos intervalos entre missões e restrições operacionais.

### 1.1.1 Objetivo Geral

Devido à grande quantidade de contextos aos quais os modelos de manutenção seletiva podem ser aplicados, e sendo tais problemas um tema aberto para exploração, o fim principal daqueles esforços é contribuir com os modelos de manutenção seletiva dedicados a sistemas orientados a múltiplas missões. Para tanto, desdobrou-se o objetivo geral em específicos.

### 1.1.2 Objetivos Específicos

- Expansão/flexibilização de um modelo de manutenção seletiva voltado a sistemas orientados a múltiplas missões;
- Construção de uma estratégia para a resolução do problema reformulado;
- Resolução de um exemplo numérico com vistas a ratificar a aplicabilidade do modelo e a efetividade do método desenvolvido;
- Análises dos resultados visando à medição de indicadores de performance do interesse do tomador de decisões;
- Análises de sensibilidade do referido modelo a mudanças nos parâmetros do problema e do método de resolução;
- Construção de modelos alternativos, cujas funções objetivo variem com relação à métrica de desempenho do modelo base;
- Indicação de propostas que direcionem futuros estudos sobre o tema.

## 1.2 Metodologia

Além do encadeamento dos objetivos específicos, que descrevem a sequência lógica de desenvolvimento deste texto, a fim de caracterizá-lo, faz-se necessária a apresentação da metodologia adotada, que possibilita a sistematização da pesquisa.

É conveniente mencionar que a “[...] *classificação das pesquisas científicas pode ser um assunto bastante controverso, pelo fato da mesma se basear no enfoque dado pelo autor*” (TURRIONI & MELLO, 2012). Nesse sentido, a classificação desta investigação foi feita

segundo a forma clássica de classificação das pesquisas em engenharia de produção, apresentada pelos aludidos autores.

Assim, o presente trabalho é classificado, quanto à sua natureza, em básico, já que contribui com avanços da literatura no que se refere à extensão e proposição de modelos, bem como pela construção de uma estratégia de resolução para o problema. É também aplicado, dado o interesse de que seja utilizado nos processos decisórios aos quais se aplique.

Quanto aos objetivos, a pesquisa se enquadra na categoria explicativa em decorrência de identificar os fatores que influenciam nos resultados e na sensibilidade do modelo. Além disso, quanto à abordagem do problema, esta investigação é classificada como quantitativa. Por fim, utiliza o método da modelagem e simulação para atingir os fins a que se propõe.

### **1.3 Estrutura do Trabalho**

Esta dissertação está estruturada em cinco partes - sequencialmente: Introdução; Referencial Teórico e Revisão da Literatura; Do modelo aos Resultados; Análises de Sensibilidade e Modelos Alternativos; e Conclusões e Trabalhos Futuros – de forma que o embasamento que possibilitou a concretização deste trabalho e a sumarização de estudos relevantes no tema são apresentados no próximo capítulo.

Nos dois capítulos seguintes se concretiza a maior parte dos objetivos específicos elencados. No terceiro capítulo, expande-se um modelo de manutenção seletiva e constrói-se uma estratégia de resolução; ambos são postos à prova em uma aplicação numérica. No quarto capítulo, modificam-se parâmetros do caso base e se analisam as alterações nos resultados, bem como são propostos modelos baseados em métricas alternativas.

Por fim, no capítulo cinco apresentam-se as conclusões deste trabalho, as dificuldades em realizá-lo e direcionamentos para trabalhos futuros que, além de permitirem a continuidade deste estudo, apontam novas fronteiras no domínio dos problemas de manutenção seletiva.

## **2 REFERENCIAL TEÓRICO E REVISÃO DA LITERATURA**

O escopo deste capítulo é apresentar as bases teóricas que fundamentam este trabalho. Primeiramente, apresenta-se a relevância da função manutenção e destaca-se a importância da adoção de uma estratégia adequada de manutenção nas organizações. Depois, expõe-se os modelos que conduzem a determinação de tais estratégias e a consequência das intervenções no sistema. Por fim, apresenta-se o problema de Manutenção Seletiva e descreve-se um método que pode ser utilizado para resolvê-lo – Algoritmos Genéticos.

### **2.1 Políticas de Manutenção**

Conforme já mencionado, a efetividade das organizações depende da gestão eficiente da manutenção e, por conseguinte, da escolha de uma estratégia de manutenção adequada para o sistema (BOGONOVO, MARSEGUERRA & ZIO, 2000).

Por um lado, tal dependência se dá em função da criticidade e da repercussão de uma falha no sistema – que, além de elevar os custos, pode comprometer todo o plano de produção (CHUNG et al., 2009). Por outro lado, uma política adequada de manutenção representa um diferencial competitivo para a organização (ALSYOUF, 2007).

Tais políticas podem ser agrupadas em função de como agem com relação a falhas. Usando esse critério, Ding & Kamaruddin (2015) identificaram cinco tipos de política e enquadraram-nas em três categorias distintas, quais sejam: políticas cujo objetivo é a restauração do sistema para o estado operacional; políticas cujo objetivo é preservar o sistema no estado operacional; políticas cujo objetivo é estratégico.

A primeira categoria se restringe à manutenção do tipo corretiva (ações reativas), de forma que ações de manutenção só são realizadas quando ocorrer uma falha (SAMROUT et al., 2009). Em decorrência disso, não é necessário empenho científico quando essas políticas são usadas de forma isolada (DING & KAMARUDDIN, 2015).

Destaca-se que, embora essa política possa ser adotada quando existe grande margem de lucro, conforme aduzem Sharma, Yadava & Deshmukh (2011), Ding & Kamaruddin (2015) associam à prática o aumento do risco para as pessoas e meio ambiente, bem como a possibilidade de perdas na produção e danos ao sistema produtivo.

Assim, as consequências de uma falha para as organizações, potencializadas pelas complexas interações entre os componentes dos sistemas produtivos, conduziram a um novo

paradigma na manutenção: prevenir a ocorrência de uma falha e preservar o sistema no estado operacional (DING & KAMARUDDIN, 2015).

Nesse sentido, adotou-se a manutenção do tipo preventiva onde as atividades de manutenção são executadas periodicamente de forma a reduzir a probabilidade de falha (PENG, DONG & ZUO, 2010). No entanto, a estratégia preventiva pressupõe a existência de dados históricos, sem os quais não se obtém um período otimizado, e, numa perspectiva conservadora, desperdiça-se vida útil dos componentes (MECHEFSKE & WANG, 2001).

Ressalta-se que essa necessidade pode ser atenuada pela estimação de parâmetros dos modelos ou pelo monitoramento das condições dos componentes e a execução de ações baseada nessas condições – prerrogativa da manutenção preditiva. Contudo, nem sempre essa estratégia pode ser implementada devido à dependência de tecnologia e a restrições financeiras das organizações (ARUNRAJ & MAITI, 2010).

A última categoria diz respeito às políticas que vinculam a manutenção industrial às estratégias organizacionais. Ela passa a ser vista como geradora de lucro e tratada como uma das principais funções das organizações (ALSYOUF, 2007).

Nesse contexto, Ding & Kamaruddin (2015) destacam que as fronteiras da manutenção também são ampliadas e a responsabilidade pelas ações de manutenção é compartilhada por todos - manutenção autônoma. Outrossim, além de simplesmente manter os sistemas produtivos, as políticas se preocupam com a melhoria deste sistema (manutenção apoiada por melhoria) com vistas a facilitar (e até mesmo eliminar) a manutenção (DING & KAMARUDDIN, 2015). Em ambos os casos, evidencia-se a necessidade de treinamento e a aquisição de conhecimento.

## **2.2 Modelos de Manutenção**

Convém salientar que a adoção de uma estratégia apropriada de manutenção não só permite a restauração e/ou a conservação do sistema produtivo em um estado em que apresente determinada performance, mas também pode apoiar e alavancar a estratégia organizacional.

A determinação de tal estratégia, conforme já foi pontuado, depende de processos decisórios apoiados em modelos matemáticos. Numa perspectiva macro, tais modelos são classificados em determinísticos ou probabilísticos em função de como são tratadas a variabilidade e a incerteza inerentes aos sistemas (VASILI et al., 2011).

Assim, os primeiros são simplistas e limitados por uma grande quantidade de suposições; os outros tentam retratar a variabilidade e incerteza (condições de trabalho, qualidade dos componentes etc.) na formulação, resultando em resultados mais coerentes com a realidade (GHOSH & ROY, 2009).

De forma mais específica, os modelos de manutenção podem ser classificados quanto aos diferentes níveis de certeza neles retratados. Tais níveis refletem a disponibilidade de informações acerca dos estados de natureza que influenciam o sistema. Seguindo essa sistemática, Ding & Kamaruddin (2015) classificam os modelos de manutenção em três categorias: certeza, risco e incerteza.

Na categoria certeza, encontram-se os modelos determinísticos, ou seja, no que se refere aos efeitos dos estados de natureza, a disponibilidade de informações é considerada completa; e o conhecimento, perfeito (DING & KAMARUDDIN, 2015).

Embora essa pareça uma situação ideal, tais modelos retratam a realidade de forma simplista e a solução ótima, obtida via enumeração exaustiva, é pautada em uma grande quantidade de suposições (GHOSH & ROY, 2009). Em virtude disso, tais modelos não exigem procedimentos de busca bem elaborados; modelos gráficos são suficientes para encontrar ótimos (LABIB, 1998).

Nos modelos abrangidos pela categoria ‘risco’, os estados da natureza são conhecidos e representados por distribuições de probabilidades que orientam o procedimento de otimização e possibilitam a determinação apropriada da política de manutenção (DING & KAMARUDDIN, 2015).

Em virtude da limitação de informação, geralmente são utilizados modelos matemáticos para estimar os efeitos das variáveis que atuam sobre o sistema, por exemplo, o mecanismo de desgaste dos componentes. A informação predita é usada na busca da política ótima e para a análise de cenários (ANDERS & SUGIER, 2006).

Contudo, devido ao aumento da complexidade dos sistemas e à dificuldade crescente em modelá-los matematicamente, esses modelos vêm sendo integrados a modelos de simulação computacional. Esses últimos se tornam, cada vez mais, populares dado que facilitam o entendimento da dinâmica de operação dos sistemas (ALRABGHI & TIWARI, 2015).

Outra abordagem para contornar a supracitada complexidade são os modelos baseados em inteligência artificial, que, geralmente, conduzem a resultados mais rápidos e precisos;

efeito esse que é potencializado com a integração desses modelos a modelos de simulação. Mahadevan, Paul Robert & Sridahar (2010), por exemplo, combinaram os métodos de Simulação de Monte Carlo e de Algoritmos Genéticos na busca de uma política ótima de manutenção.

Na categoria ‘incerteza’, os estados da natureza possíveis de serem experimentados pelo sistema não são conhecidos. Assim, para dar prosseguimento ao processo de otimização, faz-se necessária a determinação de tais estados através do uso de julgamentos e probabilidades subjetivas (TERSINE, 1995). Isso confere caráter mais flexível e prático a esses modelos, quando comparados à categoria ‘risco’ (DING & KAMARUDDIN, 2015).

Uma das estratégias, nessa categoria, utiliza-se do conhecimento prévio do decisor, obtido por meio da observação do sistema - modelos baseados em heurísticas (TERSINE, 1995). Tal estratégia conduz a uma solução satisfatória, enquanto a busca exaustiva é impraticável (DING & KAMARUDDIN, 2015).

Outra tática empregada, nesse contexto, é o uso de modelos baseados em risco, que visam à melhoria da segurança dos sistemas. Em virtude da subjetividade dos julgamentos associados a essa estratégia, Braglia, Frosolini & Montanari (2003) desenvolveram um método que utiliza lógica *fuzzy* para permitir o julgamento correto das análises de falhas, que conduz à identificação adequada de uma política de manutenção.

Além disso, nessa categoria encontram-se ainda as abordagens multicritério que permitem a inserção de objetivos conflitantes no processo decisório, como exemplo, maximizar a confiabilidade e minimizar os custos (VINODH & VARADHARAJAN, 2012). A integração desse método à lógica *fuzzy*, por sua vez, viabiliza o trabalho com informações subjetivas e conduz a resultados mais consistentes (SHARMA, YADAVA & DESHMUKH, 2011).

### **2.3 Efeito das Intervenções de Manutenção no Sistema**

A despeito da disponibilidade de informações acerca dos estados de natureza que influenciam um determinado sistema, a determinação de uma estratégia de manutenção para esse sistema pressupõe a intersecção das várias classes de políticas de manutenção. Para isso, deve-se considerar os efeitos das intervenções de manutenção sobre cada um desses estados - efeito parcial (manutenção preventiva imperfeita ou corretiva do tipo mínimo reparo) ou total (substituição preventiva ou substituição corretiva).

Em um extremo, a intervenção perfeita abrange as substituições corretivas e preventivas e restaura o estado do sistema para “tão bom quanto novo”. Dado os altos custos de tais ações, quando associados a sistemas complexos, Hadidi & Rahim (2015) indicam que apenas sistemas com poucos componentes e estruturalmente simples devam ser submetidos a essas ações.

No outro extremo, os mínimos reparos restauram para operacional a condição de um componente falho, porém, para o estágio “tão ruim quanto antes”. Le & Tan (2013) associam esse fenômeno a sistemas muito complexos, onde apenas alguns componentes são substituídos.

Por fim, a manutenção imperfeita agrupa as ações preventivas que mantêm o estado do sistema em estágios intermediários entre “tão ruim quanto antes” e “tão bom quanto novo”. Do et al. (2015) apontam duas causas principais para que isso aconteça: execução imprecisa de atividades de manutenção perfeita e limitações no orçamento da organização, o que as levam a utilizarem peças e pessoal de menor “qualidade”.

Além do efeito sobre a idade dos sistemas, essas formas de manutenção também impactam sobre a taxa de falha dos sistemas. Enquanto as manutenções perfeitas e imperfeitas implicam em redução da taxa de falha dos componentes, no mínimo reparo ela não é modificada (LIAO, CHEN & SHEU, 2009).

Ademais, no que diz respeito aos modelos de manutenção, na manutenção perfeita e no mínimo reparo, os parâmetros analisados estão ligados à taxa de degradação dos sistemas; já, na manutenção imperfeita, o efeito da ação sobre o sistema deve, também, ser avaliado (TOLEDO et al., 2015). A modelagem sob consideração de ações imperfeitas ainda é dificultada em virtude da necessidade de modificação da taxa de deterioração do sistema a cada ação de manutenção (KALLEN, 2011).

### 2.3.1 Manutenção Imperfeita - Modelos e Políticas

No que tange aos modelos de manutenção imperfeita, o mais simples considera que um componente pode ser reparado minimamente, com probabilidade  $p$ , ou de forma perfeita, com a probabilidade complementar (BROWN & PROSCHAM, 1983). Uma primeira expansão desse modelo considerou que essas probabilidades são funções da idade do componente (PHAM & WANG, 1996).

Mais tarde, tais modelos passaram a utilizar um fator de melhoria sobre a taxa de falha do sistema, a cada vez que uma ação era executada (NAKAGAWA, 1998). Uma formulação

semelhante envolve o conceito de idade virtual – idade do sistema é reduzida quando da execução de uma atividade de manutenção (KIJIMA, MORIMURA & SUZUKI, 1998).

Outros modelos ainda consideraram a possibilidade de choques, que implicam danos sobre os componentes (KIJIMA & NAKAGAWA, 1992); dependência entre os tempos de vida dos componentes (PHAM e WANG, 1996); processos de quase renovação (WANG & PHAM, 2006). Esses últimos vinculam o conceito de fator de melhoria a um aumento no tempo de reparo do sistema a cada nova intervenção.

Já no que diz respeito às políticas de manutenção imperfeita encontram-se: aquelas que dependem da idade – reparar preventivamente o componente na idade  $T$  ou em caso de falha, o que ocorrer primeiro (FLAGE, 2014); as periódicas – reparo preventivo baseado em intervalos de tempo fixo (LIAO, 2012); as sequenciais – as intervenções preventivas devem ser executadas em intervalos decrescentes (NAKAGAWA, 1998).

Outrossim, encontram-se, ainda, as políticas com limite de falha e as políticas com limite de reparo. Nas primeiras, uma ação preventiva deve ser executada sempre que a taxa de falha de um sistema alcançar um limite predefinido (DO et al., 2015). Na segunda, o limite a ser observado é de custo ou de tempo. No caso de limite de custo, o sistema é reparado se a previsão de custos com reparo for menor que um limite predeterminado, caso contrário, o sistema deve ser substituído (PHAM & WANG, 1996).

Nesse panorama, Xia et al. (2012) agregaram o conceito de teoria do valor multiatributo e manutenção imperfeita sequencial para determinação do intervalo ótimo de manutenção. Para isso, os autores assumiram que esse intervalo provém da maximização da disponibilidade e da minimização do custo de manutenção do sistema (a cada ciclo).

Outro modelo híbrido de manutenção imperfeita pode ser encontrado em Ding & Tian (2012), que a combinaram a um modelo de manutenção oportunista. Esses autores utilizaram um modelo de redução de idade para determinação da idade ótima – menor custo médio – para se intervir em um sistema.

Lin, Zuo & Yam (2000) também desenvolveram um modelo híbrido, agregando os conceitos de redução de idade e ajustamento da taxa de risco para determinar a programação sequencial das atividades de manutenção imperfeita, de forma a minimizar o custo médio de manutenção e encontrar um número ótimo de intervenções e os intervalos ótimos entre elas.

Ressalta-se que esse modelo foi expandido por Khatab, Dahane & Ait-Kadi (2014) e por Khatab (2015). No primeiro caso, a modificação se deu na função objetivo – os autores visavam à maximização da disponibilidade do sistema. A segunda variação se diferencia das demais pela forma como se avalia o custo de manutenção, bem como, por considerar um limite para a confiabilidade do componente.

É importante acrescentar que antes de Khatab (2015), Zhou, Xi & Lee (2007) já haviam considerado um limiar de confiabilidade em um modelo de manutenção baseada em condição, cujo intuito foi determinar um valor ótimo para esse limite, tal que o custo acumulado de manutenção por unidade de tempo fosse minimizado por ações sequenciais.

Do et al. (2015), por sua vez, desenvolveram uma política adaptativa – diferentes regras de decisão a cada inspeção - de manutenção baseada em condição. Esses autores, usando o conceito de vida útil residual, fizeram uma avaliação do impacto de intervenções de manutenção em um sistema sujeito a inspeções aperiódicas.

Em outra direção, Le & Tan (2013) consideraram a modelagem de um sistema multiestados, aos quais estava associado um determinado nível de degradação, detectáveis por meio de inspeção ou monitoramento contínuo. Daí, decidia-se qual ação de manutenção – substituir, melhorar ou ignorar - devia ser executada de forma a se minimizar o custo médio de manutenção, em longo prazo, desse sistema. Abordagem semelhante é encontrada em Sheu et al. (2015), que introduziram a possibilidade de mínimo reparo dos componentes.

Quanto aos métodos de busca, Levitin & Lisnianski (2000) e Tsai, Wang & Teng (2001) contribuíram com os modelos de manutenção imperfeita no sentido de usarem algoritmos genéticos para a determinação do plano ótimo de manutenção. O algoritmo desenvolvido aponta quando, onde (qual componente) e quais ações devem ser executadas para manter o nível de desempenho exigido para o sistema, para intervalos de tempo predeterminados.

## **2.4 Manutenção Seletiva**

Devido à facilidade de se conformar o planejamento da produção e, por conseguinte, da manutenção aos moldes da manutenção seletiva, esse problema tem tido particular importância nos ambientes organizacionais e acadêmicos. Isso é potencializado em virtude de tais modelos não ignorarem restrições nos recursos de manutenção.

Contudo, salienta-se que Almeida et al. (2015) enfatizam a complexidade dessa categoria de modelos, dada a quantidade e qualidade de informações que devem ser fornecidas

como *input* para o problema. Em virtude disso, o planejamento da manutenção, que deveria ser atualizado periodicamente, não costuma passar por revisões (SCARF & CAVALCANTE, 2012).

Historicamente, a formulação do problema de manutenção seletiva é atribuída a Rice, Cassady & Nachlas (1998), que estudaram um sistema constituído de subsistemas independentes, conectados em série, compostos por componentes idênticos e com taxas de falha constantes, ligados em paralelo. O modelo teve a maximização da confiabilidade do sistema como função objetivo; o tempo como restrição; a quantidade de componentes que deveriam ser substituídos em cada subsistema como variáveis de decisão.

A aplicabilidade do modelo foi ilustrada através da resolução de um exemplo numérico para a qual um método enumerativo foi suficiente. Visto que o método exaustivo proposto por Rice, Cassady & Nachlas (1998) era ineficiente para cenários mais complexos, Rajagopalan & Cassady (2006) propuseram um método enumerativo melhorado, mas ainda pouco eficiente. A respeito disso, Rice, Cassady & Nachlas (1998) destacaram que um procedimento heurístico deveria ser desenvolvido para instâncias maiores.

O modelo de Rice, Cassady & Nachlas (1998) foi expandido por Chen, Meng & Zuo (1999) que consideraram múltiplos estados passíveis de representarem a condição dos componentes. Assim, a formulação binária (operando ou falho) adotada por Rice, Cassady & Nachlas (1998) consiste num caso particular do novo modelo.

Além disso, Chen, Meng & Zuo (1999) assumiram como indicador de performance do sistema o custo, cuja minimização passou a figurar como função objetivo; níveis esperados de confiabilidade para a próxima missão, por sua vez, foram usados como restrição. Para resolução do problema, os autores empregaram um método baseado no algoritmo de Dijkstra para o problema do caminho mínimo.

É conveniente acrescentar também que os aludidos autores utilizaram uma rede para representar o problema. O nó de origem representava o estado do sistema ao final da corrente missão; os demais nós representavam um possível estado do sistema no início da próxima missão, e as ligações entre tais nós correspondiam a conjuntos de ações de manutenção cujos custos eram dados pelos pesos das arestas. Os nós que cumpriam as expectativas de custo eram ditos viáveis, dentre eles, o que está à menor distância do nó de origem representava a solução ótima.

Esse método, contudo, a exemplo do método desenvolvido por Rice, Cassady & Nachlas (1998), é computacionalmente dispendioso dado que os requisitos de memória crescem com o aumento do número de componentes do sistema. Diante disso, Chen, Meng & Zuo (1999) também apontam para a necessidade do desenvolvimento de métodos heurísticos.

Posteriormente, Cassady, Pohl & Murdock (2001.a) complementaram o modelo de Rice, Cassady & Nachlas (1998), no sentido de modelarem a taxa de falha dos componentes segundo uma distribuição Weibull – logo, a confiabilidade do sistema era dependente da idade de tais componentes e da duração das missões.

Além disso, os referidos autores assumiram que os componentes poderiam ser mantidos de três formas: mínimo reparo, substituição corretiva ou preventiva – a primeira, se a taxa de falha fosse constante ou decrescente; as demais, no caso complementar. Convém destacar que esses autores utilizaram um método exaustivo para resolver o problema para uma missão (problema míope), e, adicionalmente, empregaram o método de Monte Carlo para resolver o problema para múltiplas missões.

Ademais, Cassady, Pohl & Murdock (2001.b) ainda flexibilizaram o modelo de Rice, Cassady & Nachlas (1998) quanto à estruturação qualquer do sistema. Nesse contexto, os autores desenvolveram três modelos de manutenção seletiva - maximização da confiabilidade do sistema sujeito a restrições de tempo e custo; minimização dos custos de reparo do sistema sujeito a restrições de tempo e expectativa de confiabilidade para a próxima missão; minimização do tempo alocado à manutenção do sistema sujeito a restrições de confiabilidade e custo.

Enfatiza-se que Schneider & Cassady (2004) ampliam as fronteiras dos modelos prévios de manutenção seletiva no sentido de terem formulado o problema para frotas - conjuntos de sistemas. Isso, no entanto, foi limitado pela premissa de que as frotas deveriam consistir em sistemas independentes e idênticos, compostos por subsistemas de componentes também independentes e idênticos, com taxas de falhas constantes. Além disso, as missões deveriam ter as mesmas durações.

O problema modelado por esses autores consistiu na maximização da confiabilidade da frota – probabilidade de que todos os sistemas completem uma missão – sujeita a limitações em recursos. As variáveis de decisão apontavam, no início de cada conjunto de missões, se os componentes falhos deveriam ser reparados ou ignorados.

Para isso, os supracitados autores utilizaram o método de Monte Carlo - para simular conjuntos de missões - combinado a um método exaustivo - para avaliar o processo estocástico correspondente ao número de sucessos em cada conjunto de missões. A combinação dos métodos era tal que a etapa de simulação fornecia o estado dos subsistemas, pós-missões, à rotina de otimização, que, por sua vez, alimentava a simulação com o estado, pós-manutenção, de cada sistema. Isso foi testado através de uma aplicação numérica.

Lust, Roux & Riane (2009) também propuseram uma sistemática híbrida para a resolução de problemas de manutenção seletiva. Os aludidos autores integraram uma heurística - usada para encontrar uma solução inicial – cujos resultados alimentavam um procedimento *branch-and-bound* ou busca tabu; este último, mais eficiente que o primeiro.

Em outra direção, Maillart et al. (2009) também contribuíram com a expansão das fronteiras dos modelos de manutenção seletiva. Esses autores investigaram os efeitos da transição da formulação míope do problema para a formulação orientada a múltiplas missões.

Para isso, consideraram a manutenção seletiva para uma ou múltiplas missões em um horizonte finito, e múltiplas missões em um horizonte infinito, como um problema de programação dinâmica estocástica. Os planos e o desempenho dos sistemas foram comparados para as três formulações e concluiu-se que a esperança de um maior desempenho do sistema não justifica o aumento do esforço computacional.

No entanto, esses resultados são limitados à estrutura série-paralelo de um sistema, cujos subsistemas eram constituídos por componentes idênticos com falhas randômicas (o que justifica o fato de a única ação disponível ter sido a substituição dos componentes falhos). Além disso, as missões, bem como os *breaks* deveriam ter mesma duração.

Essas limitações motivaram Khatab, Dahane & Ait-Kadi (2014) a flexibilizarem o modelo de Maillart et al. (2009), no sentido de inserirem a possibilidade de componentes não idênticos, cuja vida seguia uma distribuição Weibull; as missões e os *breaks* poderiam ter durações diferentes e os componentes poderiam ser mantidos por mínimo reparo (dentro das missões) ou preventivamente (durante as paradas).

O problema consistiu na determinação de uma sequência ótima de ações preventivas que minimizasse o custo total de manutenção do sistema e atendesse a uma expectativa de confiabilidade para cada missão e restrição de tempo. A variável de decisão indicava qual

componente, qual ação e em qual parada a manutenção deveria ser executada. Para isso, fez-se uso de um algoritmo genético.

Vale lembrar que antes de Khatab, Dahane & Ait-Kadi (2014), Liu & Huang (2010) e, posteriormente, Maaroufi, Chelbi & Rezg (2013) já haviam considerado a possibilidade de manutenção imperfeita em modelos de manutenção seletiva. Pandey et al. (2013) também fizeram essa abordagem, mas, enquanto os primeiros autores consideram a existência de múltiplos estados representando a condição dos componentes, estes se limitaram à consideração dicotômica – falho ou operacional.

Além de incluírem a possibilidade de manutenção imperfeita no modelo, Dao, Zuo & Pandey (2014) também consideraram a existência de interação econômica entre os componentes. Essa situação implica que o custo da manutenção conjunta de um grupo de componentes é diferente do custo total da manutenção individual desses componentes (NICOLAI & DEKKER, 2008).

Embora essa consideração aumente a complexidade do modelo, negligenciá-la conduz a uma programação ineficiente da manutenção, dado que uma oportunidade de melhoria dos indicadores de desempenho dos sistemas é ignorada (VAN HORENBEEK & PINTELON, 2013). Em decorrência da complexidade do modelo, Dao, Zuo & Pandey (2014) utilizaram um algoritmo genético para resolver o problema de manutenção seletiva formulado.

## **2.5 Algoritmos Genéticos**

Dada a complexidade dos atuais modelos de manutenção, evidencia-se a tendência do uso de métodos heurísticos para a busca de soluções, dentro os quais, os Algoritmos Genéticos (AGs) têm destaque. Formalmente, os AGs são técnicas computacionais de busca iterativa fundamentada nos conceitos de seleção natural e evolução, segundo os mecanismos da genética (GOLDBERG, 1989).

Deveras, esses algoritmos são particularmente importantes em problemas de otimização, pois encontram boas soluções (ótimas ou aproximadamente ótimas) para problemas onde a resolução exaustiva é impraticável em tempo computacional factível (HICKS, 2006); também não fazem uso de informações locais (derivadas e gradientes), logo, podem ser utilizados na resolução de problemas cuja função objetivo seja complexa (COIT & SMITH, 1996).

Além disso, Castro (2001) acrescenta que perturbações nos parâmetros de um problema - necessárias para análises de sensibilidades de modelos, por exemplo – não causam grandes

prejuízos para os algoritmos genéticos, enquanto podem ser fatais para outros métodos de otimização.

### 2.5.1 Terminologia e Funcionamento dos Algoritmos Genéticos

Huang (1998) aduz que o fato do algoritmo trabalhar com códigos (genótipo) demanda baixo esforço computacional ao longo das iterações (gerações). Conquanto, a eficiência do método é muito dependente do processo de representação (codificação) das possíveis soluções do problema (SIVANANDAM & DEEPA, 2008).

Destaca-se que essas soluções são denominadas indivíduos e suas características estão codificadas no código genético (cromossomos). Cada cromossomo é constituído por cadeias de caracteres e cada caractere (gene) contém informações acerca de características particulares dos indivíduos. As diferentes possibilidades assumidas por um gene são denominadas alelos.

Além disso, ao conjunto das características que determinam um indivíduo denomina-se genótipo. O fenótipo, por sua vez, consiste na manifestação dessas características. Ambos os conceitos estão ligados pelos processos de codificação e decodificação. Dentre as várias possibilidades de codificação, a representação binária é a mais popular, e, embora não seja adequada a todos os problemas, será adotada (dada sua simplicidade) aqui, com o fim de ilustrar os termos empregados pela rotina – figura 2.1.

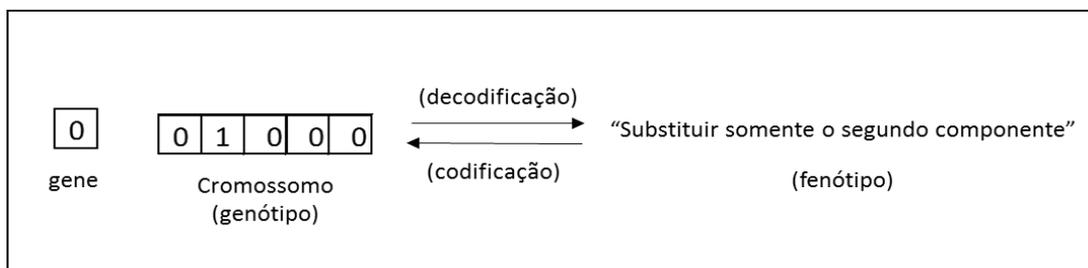


Figura 2.1 – Terminologia empregada nos Algoritmos Genéticos

Fonte: Esta Pesquisa (2016)

Outrossim, denomina-se população ao conjunto de indivíduos participantes de cada geração. Já o desempenho/aptidão desses indivíduos, quanto à função objetivo, é medido pelo *fitness*.

A inspiração para o método, conforme já se pontuou, provém do conceito de seleção natural que diz respeito ao processo natural onde indivíduos competem por recursos limitados, de forma que os mais aptos/adaptados têm maiores chances de terem suas características propagadas ao longo do tempo (BLICKLE & THIELE, 1995).

Mais especificamente, o processo de transmissão das informações genéticas se baseia no processo de cruzamento - intercâmbio do material genético dos indivíduos (pais) para formar novos indivíduos (filhos). Esse processo permite a evolução da população dos indivíduos, assim como a convergência do algoritmo em problemas de otimização.

Além disso, os indivíduos ainda estão sujeitos à mutação, que consiste na alteração da informação genética de um gene. Isso se dá de maneira aleatória e pouco frequente. Destaca-se que esse processo é responsável pelo aumento da diversidade genética da população ao longo do tempo; o que diminui a chance de convergência dos algoritmos para ótimos locais (KONAK, COIT & SMITH, 2006).

Quanto à otimização, sendo o espaço de busca limitado pelas restrições do problema, o indivíduo ótimo é alcançado, atingido um critério de parada do algoritmo, após sucessivas operações genéticas – seleção, cruzamento e mutação – entre os indivíduos da população (KANCEV, GJORGIEV & CEPIN, 2011). Essa dinâmica está ilustrada na figura 2.2.

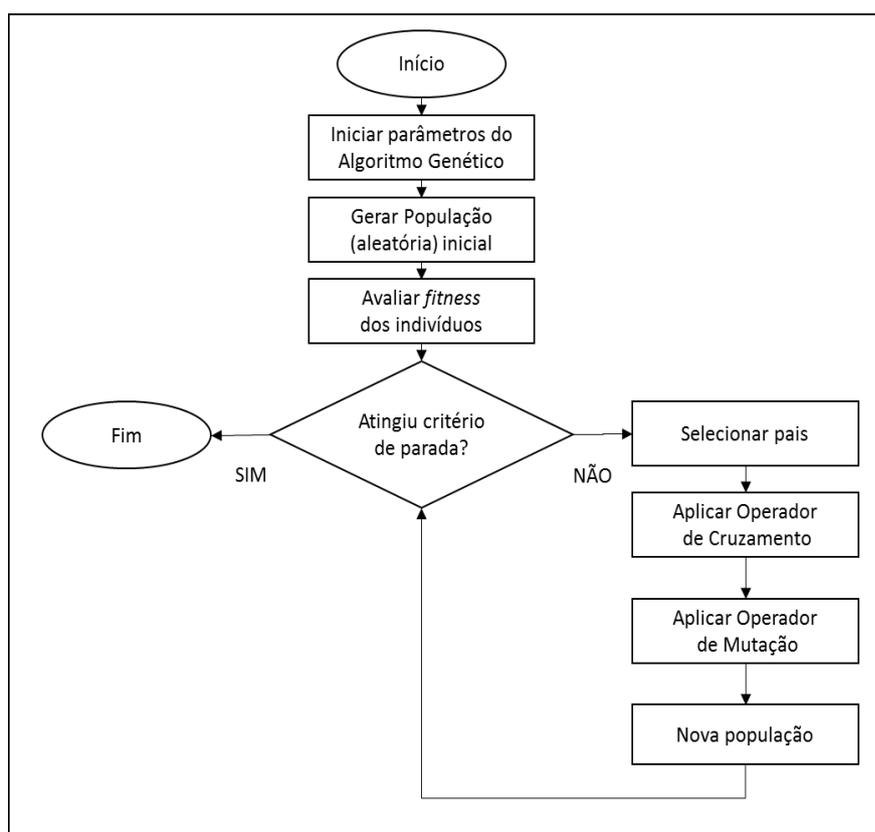


Figura 2.2 – Funcionamento Básico de um Algoritmo Genético  
Fonte: Adaptado de Kancev, Gjorgiev & Cepin. (2011)

Tsai, Wang & Teng (2001) acrescentam que, além do processo de mutação, o fato de o método trabalhar com uma população de soluções potenciais para o problema permite que o processo de otimização seja realizado, simultaneamente, em várias regiões do espaço de busca, reduzindo as chances de estagnação do algoritmo em torno de mínimos locais.

No que diz respeito à população inicial, na maioria das vezes, os indivíduos são criados de forma aleatória. Entretanto, existem ocasiões nas quais há integração com métodos heurísticos, que criam indivíduos potencialmente melhores, em virtude da utilização de informação que guiem as buscas. Contudo, essa etapa não é crítica para a eficiência do algoritmo, desde que a população seja suficientemente heterogênea (GOLDBERG, 1989).

### 2.5.2 Operações Genéticas

O intuito dessa seção é a exposição dos operadores genéticos. Assim, discriminar-se-á os principais operadores – seleção, cruzamento e mutação – bem como suas formas mais comuns de ocorrência.

#### 2.5.2.1 Seleção

Esse operador distingue os indivíduos que poderão se reproduzir e propagar seu material genético pela sequência das gerações (KANCEV, GJORGIEV & CEPIN, 2011). Deve-se dedicar atenção quanto à forma como o operador é formulado, dado que a simples exclusão dos indivíduos menos aptos pode fazer com que o algoritmo convirja para ótimos locais (RAZALI & GERAGHTY, 2011). Essa formulação depende da natureza do problema e da forma de representação dos indivíduos. Dentre as diferentes possibilidades encontram-se a seleção por torneio e a seleção por roleta.

A seleção por torneio, segundo Glover & Kochenberger (2003), é a formulação mais popular do operador de seleção devido à sua eficiência e facilidade de implementação. Consiste na formação aleatória de subconjuntos da população e promoção dos indivíduos mais aptos (figura 2.3), baseada no conceito de competição.

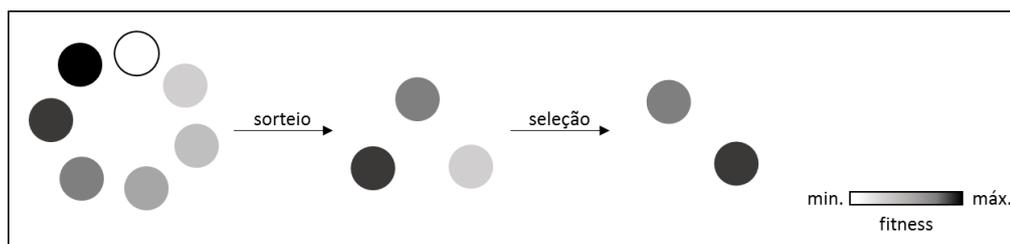


Figura 2.3 – Exemplo ilustrativo da Seleção por Torneio

Fonte: Esta Pesquisa (2016)

Razali & Geraghty (2011) apontam que essa formulação dá chance a todos os indivíduos de serem selecionados. Além disso, Glover & Kochenberger (2003) destacam que essa abordagem pode ser facilmente adaptada para problemas com funções objetivo subjetivas.

Já, na seleção por roleta, a seleção é probabilística tal que a chance de um indivíduo ser selecionado é proporcional à sua aptidão (*fitness*) em relação à função objetivo (GLOVER & KOCHENBERGER, 2003). Para isso, geram-se números aleatórios que determinam quais indivíduos, dispostos em uma roleta com fatias proporcionais às suas aptidões, serão promovidos – figura 2.4. Assim, se o número aleatório gerado (ponteiro) for 0.5, o indivíduo 3 deverá ser promovido.

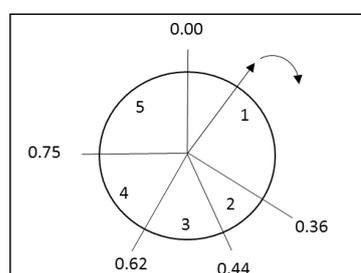


Figura 2.4 – Exemplo ilustrativo da Seleção por Roleta  
 Fonte: Esta Pesquisa (2016)

### 2.5.2.2 Recombinação, Crossover ou Cruzamento

Esse operador é responsável pela combinação do material genético dos indivíduos selecionados (pais), formando novos indivíduos (KONAK, COIT & SMITH, 2006). Dentre as formas de ocorrência figuram os cruzamentos com um ou mais pontos de corte e o *crossover* uniforme.

O cruzamento com ponto(s) de corte é a formulação mais simples do operador de recombinação. Ele consiste na determinação, por sorteio, de um ponto de corte – fronteira entre dois genes de um cromossomo - seguida do intercâmbio de uma das partes homólogas, conforme ilustra a figura 2.5 (a) e (b).

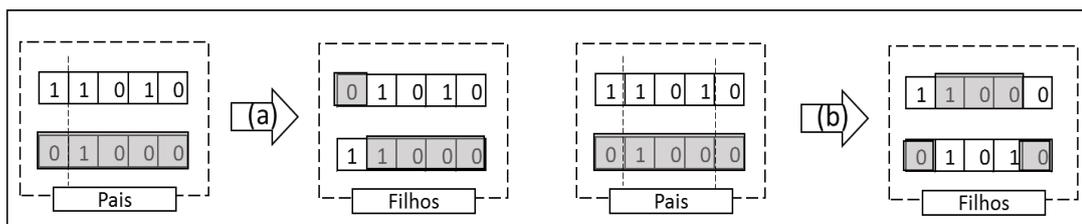


Figura 2.5 - Exemplo ilustrativo do Cruzamento com um (a) e dois (b) Pontos de Corte  
 Fonte: Esta Pesquisa (2016)

Uma generalização dessa abordagem é o *crossover* uniforme. Para cada *loco* sorteia-se o número 0 ou 1; caso o valor sorteado seja não nulo, o primeiro filho recebe o gene do primeiro pai e assim, sucessivamente, até que os dois filhos estejam determinados (figura 2.6).

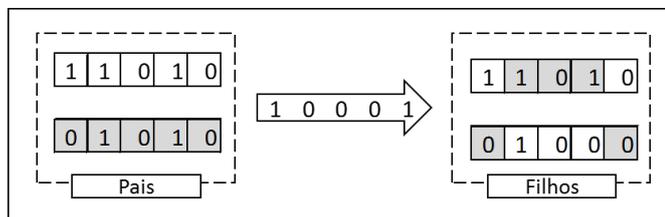


Figura 2.6 - Exemplo ilustrativo do Crossover Uniforme

Fonte: Esta Pesquisa (2016)

Razali & Geraghty (2011) ainda destacam que, quanto maior o número de pontos de corte (mistura do material genético), maior o poder de preservação de bons genes, porém, menor a velocidade de execução desse operador.

### 2.5.2.3 Mutação

É importante ressaltar que esse operador modifica a informação contida no gene de um cromossomo, conforme ilustra a figura 2.7. Isso ocorre de maneira esporádica e dependente da dimensão do cromossomo (SIVANANDAM & DEEPA, 2008). Konak, Coit & Smith (2006) ratificam a importância desse operador para a variabilidade da população e redução das chances de convergência precoce.

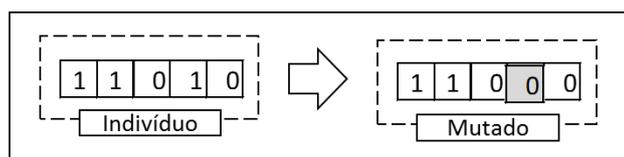


Figura 2.7 - Exemplo ilustrativo da Mutação

Fonte: Esta Pesquisa (2016)

A respeito disso, Sivanandam & Deepa (2008) chamam a atenção para o fato de que, se a taxa (probabilidade) de mutação for demasiadamente baixa, a população ‘estagnará’ após um certo número de gerações. Ao contrário, se a taxa for alta demais, o processo de busca perde a característica de guiado. Assim, o autor sugere que, para representações binárias, essa taxa varie ao longo das iterações.

### 3 DO MODELO AOS RESULTADOS

Neste capítulo, expande-se o modelo de Khatab, Dahane & Ait-Kadi (2014) - que almejam determinar uma sequência de ações preventivas para os componentes de um sistema orientado a múltiplas missões, de forma que ele atendesse a um determinado patamar de confiabilidade a cada missão, e que o custo total de manutenção fosse minimizado. Além disso, constrói-se uma estratégia para resolvê-lo e faz-se uma aplicação numérica.

Para isso, primeiro, apresenta-se as bases matemáticas do modelo e a forma algébrica do problema. Depois, detalha-se o algoritmo desenvolvido para encontrar uma boa solução (tempo computacional factível) para o modelo. Por fim, esse algoritmo é provado em uma instância adaptada dos aludidos autores.

#### 3.1 Descrição do Sistema e Bases Matemáticas do Modelo

Seja um sistema  $S$  composto por  $n$  subsistemas  $S_i$  ( $i= 1, \dots, n$ ) ligados em série, cada qual composto por  $N_i$  componentes  $C_{ij}$  ( $j= 1, \dots, N_i$ ) dispostos em paralelo, homólogos (mas não necessariamente idênticos) e independentes - figura 3.1.

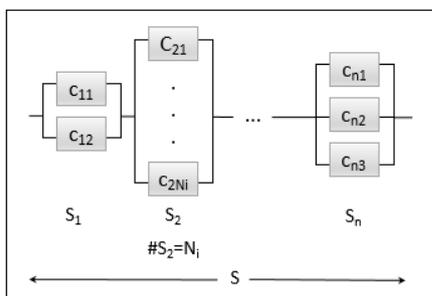


Figura 3.1 – Exemplo de um Sistema Série-Paralelo  
 Fonte: Esta Pesquisa (2016)

A dinâmica de operações desse sistema é tal que ele deve executar uma sequência de  $M$  missões, cada qual com uma duração conhecida  $U(m)$  ( $m=1, \dots, M$ ) e, entre duas missões consecutivas, deve haver a paralização do sistema (*break*), com duração igualmente conhecida  $D(m, l)$  ( $m=1, \dots, M-1; l=m+1$ ).

Por conveniência, assume-se que cada um dos componentes (cada um dos subsistemas e o próprio sistema) possa se encontrar em dois possíveis estados - operacional ou falho. A falha

de um componente se dá dentro de uma missão e está relacionada ao nível de desgaste desse componente (vida virtual). Além disso, inicialmente, o sistema está novo (sem desgaste).

Assim, sendo  $A_{ij}(m)$  e  $B_{ij}(m)$  as idades virtuais do componente  $C_{ij}$ , respectivamente, no início e no final da  $m$ -ésima missão ( $m=1, \dots, M$ ),  $B_{ij}(m)$  pode ser escrito como a soma de  $A_{ij}(m)$  e  $U(m)$ :

$$B_{ij} = A_{ij} + U(m) \quad (3.1)$$

Além disso, a probabilidade  $R_{ij}(m)$  do componente  $C_{ij}$  sobreviver à missão  $m$  dado  $A_{ij}(m)$  pode ser determinada pela equação:

$$R_{ij}(m) = \exp\left(-\int_{A_{ij}(m)}^{B_{ij}(m)} h_{ij}(t) dt\right) \quad (3.2)$$

onde  $h_{ij}(t)$  corresponde à função de risco do componente  $C_{ij}$ .

Da equação 3.2, seguem que a confiabilidade do subsistema  $S_i$  e do sistema  $S$ , respectivamente, denotadas por  $R_i(m)$  e  $R(m)$ , são dadas pelas expressões:

$$R_i(m) = 1 - \prod_{j=1}^{N_i} (1 - R_{ij}(m)) \quad (3.3)$$

$$R(m) = \prod_{i=1}^n R_i(m) \quad (3.4)$$

Tal sistema está sujeito a ser mantido de forma corretiva, por meio de ações de mínimo reparo, caso um componente falhe durante uma dada missão. Essa intervenção visa a reestabelecer o estado operacional do componente dentro da própria missão, tem duração desprezível (quando comparada à duração da missão) e custo  $cmr_{ij}$  inerente ao componente  $C_{ij}$ .

Dentro de um *break*, o sistema pode ser mantido de forma planejada - através de ações preventivas - o que melhora a confiabilidade do sistema para a próxima missão. Isso ocorre devido à redução das idades virtuais dos componentes, quando da execução de uma ação preventiva nesse componente (Nakagawa, 1988).

As  $P$  ações preventivas, passíveis de serem realizadas nos componentes do sistema, são agrupadas no vetor  $V_{PM} = [a_1, \dots, a_p, \dots, a_P]$ . A cada ação  $a_p$  ( $p = 1, \dots, P$ ) está associado um coeficiente de redução de idade  $\alpha(a_p) \in [0,1]$ , um custo  $cpm(a_p)$  e a duração  $dpm(a_p)$  da atividade, bem como o conjunto de componentes nos quais a ação pode ser executada -  $Comp(a_p)$ .

No que tange aos valores dos coeficientes de redução da idade, quando  $\alpha(a_p)=1$ , a atividade  $a_p$  não tem nenhum efeito sobre a idade do componente e a condição do componente permanece “tão ruim quanto antes”. Já, se  $\alpha(a_p)=0$ , a idade do componente é zerada e a condição do componente se torna “tão bom quanto novo”. Nos casos em que  $\alpha(a_p) \in ]0,1[$ , a idade virtual do componente é atualizada e ele apresentará condição intermediária entre as duas discriminadas.

Ora, os modelos de manutenção seletiva se propõem a determinar quais ações preventivas devem ser executadas e em quais componentes e *breaks* isso se dará. Para tanto, neste estudo, fez-se necessário o uso de uma variável auxiliar binária  $a_p(C_{ij}, m)$  que assume valor não nulo, caso a ação  $a_p$  seja executada no componente  $C_{ij}$  ao final da  $m$ -ésima missão ( $m=1, \dots, M$ ).

Dentro dessa proposta, a expansão implementada no modelo de Khatab, Dahane & Ait-Kadi (2014) consistiu na possibilidade de se requisitar diferentes níveis para a confiabilidade do sistema a cada missão e na inclusão da penalidade *cpar* relacionada à falha do sistema durante uma missão. Esse adendo aproxima o modelo da realidade, uma vez que uma falha no subsistema, durante uma missão, implica em custo de oportunidade, custos ambientais etc.

Nessa abordagem, o custo total de manutenção do sistema  $C_{total}$  é composto por três parcelas: uma associada à realização de mínimos reparos; outra, à execução de atividades preventivas; a última, àquela penalização.

Mais especificamente, o custo de mínimo reparo  $CMR_{ij}(m)$  decorrente da execução de uma ação corretiva no componente  $C_{ij}$  durante a missão  $m$  é tal que:

$$CMR_{ij}(m) = cmr_{ij} \int_{A_{ij}(m)}^{B_{ij}(m)} h_{ij}(x) dx ; m = 1, \dots, M \quad (3.5)$$

onde o valor da integral corresponde à frequência esperada de falha do componente durante a missão (Xia et. al., 2012). Assim, o custo total incorrido por mínimos reparos  $CMR$  é:

$$CMR = \sum_{m=1}^{M-1} \sum_{i=1}^n \sum_{j=1}^{N_i} cmr_{ij} \int_{A_{ij}(m)}^{B_{ij}(m)} h_{ij}(x) dx \quad (3.6)$$

Dado o pressuposto de duração desprezível desse tipo de intervenção, o custo de penalidade foi subordinado à probabilidade de falha do sistema durante uma missão. Assim, o custo decorrente da falha durante a  $m$ -ésima missão  $CPAR(m)$  é dado pela equação:

$$CPAR(m) = (1 - R(m))cpar \quad (3.7)$$

Logo, o custo total  $CPAR$  vinculado às penalidades é:

$$CPAR = \sum_{m=1}^{M-1} CPAR(m) \quad (3.8)$$

Por fim, o custo das atividades preventivas  $CPM_{ij}(m)$  associado ao componente  $C_{ij}$  e à missão  $m$  é dado por:

$$CPM_{ij}(m) = \sum_{p=1}^P cpm(a_p) \cdot a_p(C_{ij}, m) \quad (3.9)$$

Daí, determina-se  $CPM_{ij}$ ,  $CPM$  e  $C_{total}$ , respectivamente, os custos preventivos totais relacionados aos componentes, ao sistema e o custo total de manutenção do sistema:

$$CPM_{ij} = \sum_{m=1}^{M-1} CPM_{ij}(m) \quad (3.10)$$

$$CPM = \sum_{i=1}^n \sum_{j=1}^{N_i} CPM_{ij} \quad (3.11)$$

$$C_{total} = CMR + CPAR + CPM \quad (3.12)$$

Além disso, é necessário considerar que existe pouca disponibilidade de tempo entre duas missões sucessivas para que seja realizada a manutenção dos componentes do sistema. Assim, a duração total das atividades de manutenção preventiva realizadas no  $m$ -ésimo *break* -  $DPM(m)$  - deve estar presente no modelo como uma restrição operacional. Esse valor é dado pela equação:

$$DPM(m) = \sum_{p=1}^P \sum_{i=1}^n \sum_{j=1}^{N_i} dpm(a_p) \cdot a_p(C_{ij}, m) \quad (3.13)$$

Complementarmente, denota-se  $R(l)$  o nível de confiabilidade requerida para o início da  $m+1$ -ésima missão ( $m=2, \dots, M$ ).

### 3.2 Formulação do Problema e o Modelo Matemático

Do conjunto das  $P$  ações preventivas, passivas de serem realizadas nos componentes do sistema ( $V_{PM}$ ), quer-se determinar uma sequência de atividades que minimize o custo total de manutenção do sistema  $C_{total}$ , e, que possibilite o alcance da confiabilidade desejada para o início da operação do sistema a cada missão, respeitando o tempo dedicado a cada *break*.

Segue o modelo de programação matemática que corresponde ao problema:

$$P1: \text{Minimize } C_{total} = CMR + CPAR + CPM \quad (3.14)$$

sujeito a:

$$R(m + 1) \geq R(l) \quad (3.15)$$

$$DPM(m) \leq D(m, l) \quad (3.16)$$

$$\sum_{p=1}^P a_p(C_{ij}, m) \leq 1 \quad (3.17)$$

$$a_p(C_{ij}, m) \in \{0,1\} \quad (3.18)$$

$$i = 1, \dots, n; j = 1, \dots, N_i; p = s_1, \dots, s_k \quad (3.19)$$

$$m = 1, \dots, M - 1; l = m + 1 \quad (3.20)$$

A primeira restrição (inequação 3.15) expressa as expectativas de confiabilidade para o início de cada missão; a segunda restrição (inequação 3.16) limita a duração das ações preventivas a serem executadas ao final de uma dada missão ao tempo planejado para o *break* correspondente; a restrição posterior (inequação 3.17) impõe que cada componente só pode receber uma ação por *break*.

### 3.3 Estratégia de Resolução do Problema

Dada a natureza combinatória dos problemas de Manutenção Seletiva, resolvê-los por enumeração exaustiva das soluções torna-se, para determinadas instâncias, impraticável. Assim, visando à obtenção de uma boa solução em tempo computacional factível, faz-se necessário o uso de métodos (meta)heurísticos.

Sabendo-se que o problema outrora formulado se conforma aos tais casos, o uso de um algoritmo genético passa a figurar como alternativa à técnica de otimização. Ressalta-se que a escolha desse método se deu, dentre outras coisas, pela sua adaptabilidade a diferentes contextos e pela qualidade das soluções obtidas.

Uma vez determinada a técnica de solução a ser empregada, faz-se necessário discriminar como se deu: a configuração dos operadores genéticos; a especificação dos parâmetros do código; a forma de representação das soluções e outras peculiaridades dos algoritmos genéticos.

### 3.3.1 Representação, Geração e Avaliação do Fitness dos Indivíduos

A solução do problema é uma matriz (*Plan*) que determina a sequência de atividades preventivas que minimiza (de forma ótima ou aproximada) o custo total de manutenção do sistema  $C_{total}$  e permite o alcance dos níveis especificados de confiabilidade do sistema a cada nova missão.

Essa matriz tem dimensão  $(\sum_{i=1}^n N_i) \times (M-1)$  e representa o melhor indivíduo da população em uma dada geração. Nessa forma de representação, os componentes são ordenados do primeiro componente no primeiro subsistema ao último componente no último subsistema. Assim, uma célula na matriz *Plan* corresponde a uma ação preventiva a ser executada no componente determinado pela linha da matriz, ao final da missão determinada pela coluna dessa matriz.

A título de ilustração, seja um sistema composto por quatro componentes e orientado a executar cinco missões; seja, ainda, a matriz *Plan* para esse sistema tal que:

$$Plan = \begin{pmatrix} 1 & 2 & 2 & 0 \\ 3 & 0 & 5 & 0 \\ 6 & 0 & 0 & 6 \\ 9 & 10 & 9 & 0 \end{pmatrix} \quad (3.21)$$

onde o valor numérico 0 representa o não planejamento de uma ação para um dado componente numa dada missão. Nessa matriz, a célula  $Plan_{2,3} = 5$  representa que a ação 5 está planejada para ser executada no componente 2 ao final da missão 3.

Na primeira iteração do algoritmo, criam-se indivíduos atribuindo-se valores (viáveis) randômicos a cada uma das células de matrizes até que o tamanho da população seja de  $N_p$  indivíduos. A avaliação da performance (*fitness*) desses indivíduos, por sua vez, é feita com base no custo total de cada indivíduo.

Ademais, destaca-se que os indivíduos também são avaliados quanto às restrições do problema. À medida que os indivíduos são gerados, verifica-se se eles infringem as restrições de duração das atividades ou nível de confiabilidade desejada para a próxima missão. Caso as restrições não sejam violadas, esses indivíduos são inseridos na população até que  $N_p$  indivíduos estejam presentes.

Por um lado, isso garante que, ao final das iterações do algoritmo, a solução será viável; por outro lado, a exclusão de indivíduos inviáveis prejudica a velocidade de convergência e a

qualidade das soluções, dado que operações genéticas com indivíduo(s) inviável(eis) podem produzir um excelente indivíduo viável, em termos de *fitness*.

Para preservar o benefício da estratégia aqui adotada e minimizar seus pontos negativos, introduziu-se uma componente gulosa no algoritmo que impõe um limite superior para o custo total do indivíduo. Esse limite pode corresponder ao valor da solução corretiva, por exemplo. Assim, relaxa-se a necessidade de robustez do algoritmo, pois, se existir solução “preventiva”, ela será, pelo menos, tão boa quanto à corretiva (em termos de custo).

### 3.3.2 Operadores Genéticos e Critérios de Parada

A lógica do algoritmo desenvolvido está descrita na figura 3.2.

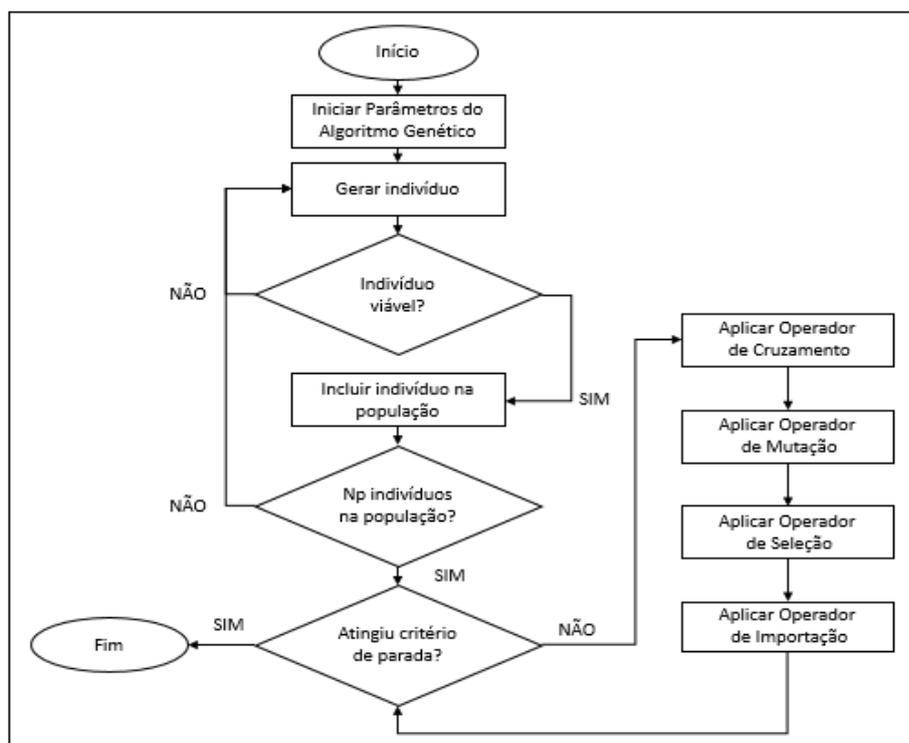


Figura 3.2 – Estratégia de Solução Implementada.

Fonte: Esta Pesquisa (2016)

Assim, partindo-se de uma dada geração – formada, exclusivamente, por indivíduos viáveis – ela é submetida ao operador de cruzamento. Nessa operação, os referidos indivíduos (pais) são aleatoriamente agrupados em pares (casais); cada casal gera dois novos indivíduos (filhos) – independente do julgamento de viabilidade - pela troca de material genético, segundo a estratégia de cruzamento parcialmente mapeado. Essa sistemática está ilustrada na figura 3.3 (a) e se dá com probabilidade 1.

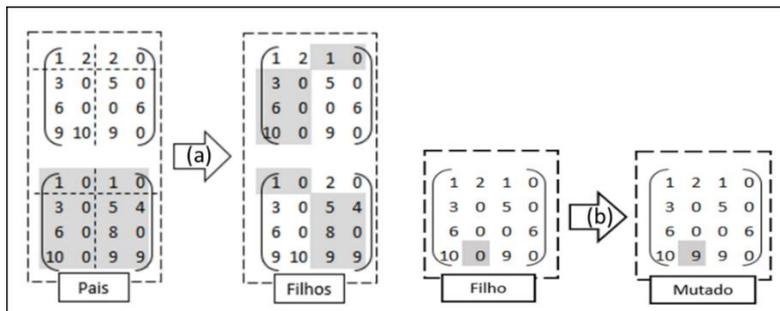


Figura 3.3 – Exemplo ilustrativo dos Operadores de Cruzamento (a) e Mutação (b)

Fonte: Esta Pesquisa (2016)

Daí, visando evitar a convergência do algoritmo para ótimos locais, bem como assegurar a preservação da diversidade genética entre as gerações, os filhos são submetidos ao operador de mutação. Aqui, essa operação modifica um gene (célula da matriz) randomicamente escolhido para cada um dos filhos, conforme ilustra a figura 3.3 (b). Cabe destacar que inclusive filhos inviáveis são submetidos à mutação dada a possibilidade de, após esse procedimento, um indivíduo (mutante) viável ser obtido.

A exclusão de indivíduos inviáveis da próxima geração, a preservação das informações genéticas e a melhoria da qualidade das soluções são tarefas do operador de seleção. Nessa operação, os pais, os filhos e os indivíduos mutantes formam três conjuntos; os indivíduos inviáveis são excluídos e é feita uma ordenação dos indivíduos (dentro de cada conjunto) com base no *fitness*.

Do conjunto dos pais promove-se o melhor indivíduo (*Plan*) para a próxima geração como forma de manter a rastreabilidade da melhor solução ao longo das gerações. Quanto aos filhos e aos mutantes, um subconjunto de cada grupo é selecionado para a geração subsequente. Isso se dá de forma que a quantidade de indivíduos dos subconjuntos seja menor ou igual a porcentagens do tamanho da população  $C_p$  e  $M_p$  ( $I + C_p N_p + M_p N_p < N_p$ ).

Sabendo-se que a contribuição do operador de seleção para manter o tamanho da população é parcial, fez-se necessária a adoção de um operador de importação no algoritmo. Tal operação injeta indivíduos viáveis, obtidos randomicamente na próxima geração. Fisicamente, esse operador representa a chegada de indivíduos alóctones na comunidade local e, geneticamente, aumenta a diversidade da geração futura.

Uma vez que a nova geração está determinada, mais uma vez os operadores genéticos são executados. Isso se repete até que um critério de parada seja atingido – número máximo de gerações  $NG_{máx}$  ou um indivíduo permanece como ótimo por  $NG_{imp}$  gerações sucessivas.

### 3.4 Exemplo Numérico

Com o fim de atestar o caráter prático do modelo e a efetividade do método propostos nesse texto, realizou-se uma aplicação numérica. Para tanto, utilizou-se uma instância baseada na encontrada em Khatab, Dahane & Ait-Kadi (2014).

A nova instância – caso base - consiste em um sistema série-paralelo composto por  $n=3$  subsistemas  $S_i$  ( $i= 1, 2, 3$ ), cada qual composto, respectivamente, por  $N_1=2$ ,  $N_2=4$  e  $N_3=3$  componentes, conforme estruturado na figura 3.4.

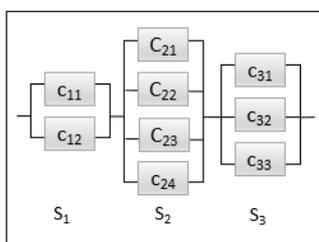


Figura 3.4 – Diagrama de Bloco do Sistema estudado no Exemplo Numérico

Fonte: Esta Pesquisa (2016)

A confiabilidade de cada um dos componentes é estabelecida da função de risco de uma distribuição Weibull –  $h(t) = \gamma/\beta \cdot (t/\beta)^{\gamma-1}$  – onde  $\gamma$  e  $\beta$  são, respectivamente, os parâmetros de forma e de escala. Para cada componente  $C_{ij}$  ( $i=1, 2, 3; j = 1, \dots, N_i$ ), os parâmetros  $\gamma_{ij}$  e  $\beta_{ij}$ , bem como os custos de mínimo reparo  $cmr_{ij}$  (em unidades monetárias) foram randomicamente gerados e estão discriminados na tabela 3.1.

Tabela 3.1 – Parâmetros dos Componentes do Sistema

Componente	$\beta_{ij}$	$\gamma_{ij}$	$cmr_{ij}$
C <sub>11</sub>	400	1,98	0,9
C <sub>12</sub>	320	1,76	1,2
C <sub>21</sub>	400	1,98	0,9
C <sub>22</sub>	560	1,32	0,8
C <sub>23</sub>	80	1,65	0,5
C <sub>24</sub>	80	1,98	2,4
C <sub>31</sub>	160	1,98	1,3
C <sub>32</sub>	64	2,20	0,4
C <sub>33</sub>	240	2,31	0,7

Fonte: Esta Pesquisa (2016)

O custo da penalização *cpar* em decorrência da falha do sistema durante uma missão recebeu o valor de 25 unidades monetárias.

Ressalta-se que o sistema é orientado para executar 20 missões cujas durações e tamanho dos *breaks* (ambos em unidades temporais) estão indicados na tabela 3.2. Também estão discriminados os diferentes requisitos de confiabilidade para o início de cada missão (dependentes da duração dessas missões).

Tabela 3.2 – Duração das Missões (M) e Breaks (B) e Requisito de Confiabilidade (R)

<b>M</b>	52	48	48	40	52	52	52	44	52	48	44	48	44	52	44	52	40	40	52	44
<b>B</b>	5	6	6	7	8	9	5	9	8	9	5	7	4	10	9	5	8	7	8	-
<b>R</b>	-	0,85	0,85	0,70	0,90	0,90	0,90	0,75	0,90	0,85	0,75	0,85	0,75	0,90	0,75	0,90	0,70	0,70	0,90	0,75

Fonte: Esta Pesquisa (2016)

Além disso, o vetor  $V_{PM}$ , também gerado de forma randômica, e os parâmetros das *P* ações preventivas, passíveis de serem executadas no sistema (componente ao qual a ação pode ser aplicada -  $Comp(p)$ ; coeficiente de redução de idade -  $\alpha(p)$ ; custo -  $cpm(p)$  (em unidades monetárias); e duração -  $dpm(p)$  - (em unidades temporais)) definidos anteriormente - são apresentados na tabela 3.3.

Tabela 3.3 – Parâmetros das Ações Preventivas passíveis de serem executadas no Sistema

p	Comp(p)	$\alpha(p)$	cpm(p)	dpm(p)	p	Comp(p)	$\alpha(p)$	cpm(p)	dpm(p)
1	C <sub>11</sub>	0,6	2,9	0,025	12	C <sub>24</sub>	0,55	4,3	0,875
2	C <sub>11</sub>	0,56	4,2	0,225	13	C <sub>24</sub>	0	7,25	2,5
3	C <sub>11</sub>	0	8	0,5	14	C <sub>31</sub>	0,62	3	0,375
4	C <sub>12</sub>	0,52	2,9	0,025	15	C <sub>31</sub>	0	7,5	0,65
5	C <sub>12</sub>	0	4,1	0,375	16	C <sub>32</sub>	0,61	3,8	0,25
6	C <sub>21</sub>	0,46	3,7	0,3	17	C <sub>32</sub>	0,49	4,2	0,375
7	C <sub>21</sub>	0	5,5	0,575	18	C <sub>32</sub>	0	5,4	0,8
8	C <sub>22</sub>	0,41	9	0,375	19	C <sub>33</sub>	0,6	6	0,025
9	C <sub>22</sub>	0	14,2	0,75	20	C <sub>33</sub>	0,43	12	0,25
10	C <sub>23</sub>	0,36	14,1	0,25	21	C <sub>33</sub>	0,22	14	0,45
11	C <sub>23</sub>	0	16	2,25	22	C <sub>33</sub>	0	16,5	3

Fonte: Adaptado de Khatab, Dahane & Ait-Kadi (2014).

Assim, o valor outrora atribuído a *cpar* é adequado, dado que, em muitos sistemas, o custo de uma falha é muito maior que o custo das atividades preventivas.

No que diz respeito ao algoritmo genético, utilizou-se uma população de tamanho  $N_p=60$  indivíduos e os parâmetros  $C_p = M_p = 0,35$  para o operador de seleção. Quanto à componente gulosa, utilizou-se a cifra de 844 unidades monetárias – valor aproximado do custo do indivíduo (*null*), onde nenhuma ação preventiva é realizada (matriz nula).

Por fim, utilizou-se os valores  $NG_{máx} = 200$  gerações e  $NG_{imp} = 30$  gerações, respectivamente, para o número máximo de gerações e número de gerações sucessivas pelas quais um indivíduo permanece como ótimo; condições de parada do algoritmo.

Para a aludida instância do problema, o algoritmo retornou, após 75 iterações, a solução apresentada na tabela 3.4 a um custo total de 537,054 unidades monetárias.

Tabela 3.4 – Solução Ótima encontrada

Break	Ação	Componente	Break	Ação	Componente
1	1,7,12,14,17,19	$C_{11}, C_{21}, C_{24}, C_{31}, C_{32}, C_{33}$	11	1,6,8	$C_{11}, C_{21}, C_{22}$
2	12,15,21	$C_{24}, C_{31}, C_{33}$	12	1,6,12,15	$C_{11}, C_{21}, C_{24}, C_{31}$
3	1.19	$C_{11}, C_{33}$	13	1	$C_{11}$
4	4,7,18	$C_{12}, C_{21}, C_{32}$	14	12,14,16,19	$C_{24}, C_{31}, C_{32}, C_{33}$
5	22	$C_{33}$	15	2,5,15,20	$C_{11}, C_{12}, C_{31}, C_{33}$
6	1,10,12,15,19	$C_{11}, C_{23}, C_{24}, C_{31}, C_{33}$	16	1,7,14,17,19	$C_{11}, C_{21}, C_{31}, C_{32}, C_{33}$
7	3,6,10,18,20	$C_{11}, C_{21}, C_{23}, C_{32}, C_{33}$	17	13,16,20	$C_{24}, C_{32}, C_{33}$
8	1,13,17	$C_{11}, C_{24}, C_{32}$	18	6	$C_{21}$
9	4,12,19	$C_{12}, C_{14}, C_{33}$	19	3,13,18,19	$C_{11}, C_{24}, C_{32}, C_{33}$
10	1,12,21	$C_{11}, C_{24}, C_{33}$			

Fonte: Esta Pesquisa (2016).

Assim, no quinto *break* (final da quinta missão) a ação 22 deverá ser e executada no componente  $C_{33}$ .

A execução do referido plano conduz ao cumprimento da restrição dos níveis de confiabilidade para cada missão, conforme se observa na figura 3.5. Nela estão plotados os níveis de confiabilidade desejados para o início de cada missão; a evolução da confiabilidade proveniente da não aplicação de ações preventivas (solução *null*) e a evolução da confiabilidade procedente da solução ótima.

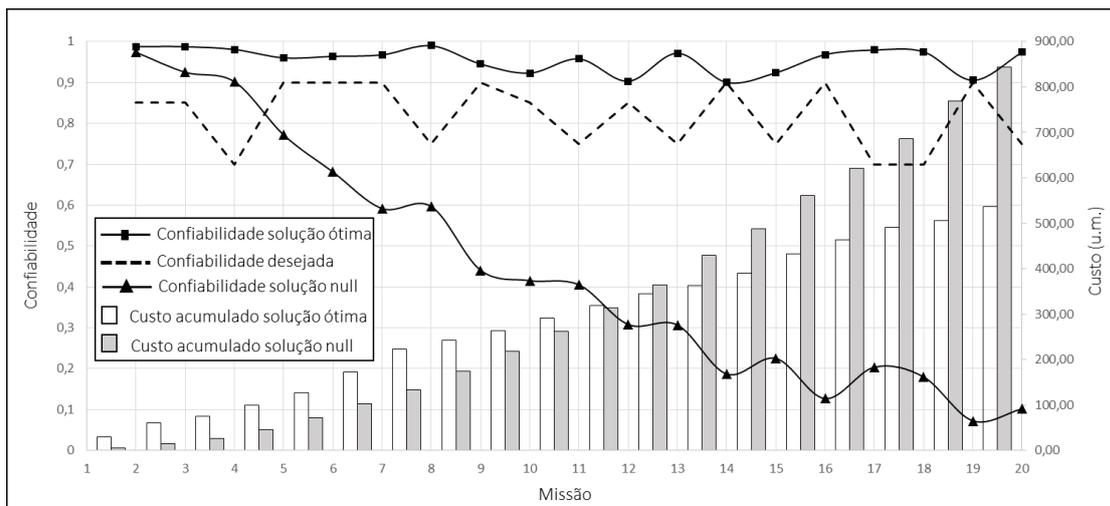


Figura 3.5 – Confiabilidade e Custo Acumulados ao longo das Missões para as Soluções Ótima e Null  
 Fonte: Esta Pesquisa (2016)

No que diz respeito à otimalidade, embora não se possa garantir que o indivíduo preventivo seja ótimo global, ele trata-se de uma boa solução para o problema dado que o nível de confiabilidade do sistema, atingido no décimo nono *break*, é numericamente igual à expectativa de confiabilidade para início da vigésima missão – fato que atesta minimização do indicador de performance (custo) e a eficiência do algoritmo desenvolvido.

Além disso, o gráfico mostra a evolução dos custos ao longo das missões. Também por essa perspectiva, evidencia-se a dominância da estratégia “preventiva” – que além de garantir níveis de confiabilidade acima dos desejados, possui custo acumulado menor que o decorrente pela política *null*.

Embora a tendência de crescimento dos custos totais das duas soluções seja linear, é notório que o coeficiente angular da reta ligada à solução *null* é maior. Contudo, isso é camuflado para horizontes de planejamento pequeno (poucas missões). Na figura, por exemplo, os custos da primeira estratégia só se mostram mais atrativos que os da *null* depois do décimo primeiro *break*.

Em longo prazo, os custos da solução ótima (tabela 3.5) são explicados por falhas esporádicas durante as missões, implicando em poucos gastos com mínimos reparos e penalizações por paradas durante missões. No que diz respeito aos gastos com ações preventivas, o valor é relativamente baixo; em virtude da função objetivo, gasta-se apenas o necessário para atender às exigências de confiabilidade.

Tabela 3.5 – Estratificação dos Custos para a Solução Ótima

Missão-Break	Custos				Custos Acumulados			
	MR	Penalidade	PM	Total	MR	Penalidade	PM	Total
1	3,38	0,30	25,90	29,58	3,38	0,30	25,90	29,58
2	4,58	0,31	25,80	30,69	7,96	0,61	51,70	60,27
3	5,98	0,48	8,90	15,35	13,93	1,09	60,60	75,62
4	8,27	0,99	13,80	23,07	22,21	2,08	74,40	98,69
5	11,31	0,90	16,50	28,71	33,51	2,98	90,90	127,39
6	9,02	0,81	34,80	44,63	42,54	3,79	125,70	172,03
7	7,89	0,25	43,20	51,34	50,43	4,04	168,90	223,37
8	3,56	1,37	14,35	19,28	53,99	5,41	183,25	242,65
9	5,22	1,92	13,20	20,35	59,21	7,33	196,45	263,00
10	6,07	1,06	21,20	28,33	65,28	8,39	217,65	291,32
11	9,28	2,42	15,60	27,30	74,56	10,81	233,25	318,62
12	7,83	0,71	18,40	26,95	82,39	11,52	251,65	345,56
13	12,44	2,50	2,90	17,84	94,84	14,02	254,55	363,40
14	8,73	1,90	17,10	27,73	103,56	15,92	271,65	391,13
15	12,32	0,80	27,80	40,91	115,88	16,71	299,45	432,04
16	9,62	0,52	21,60	31,74	125,50	17,23	321,05	463,79
17	4,04	0,62	23,05	27,72	129,54	17,86	344,10	491,50
18	8,23	2,37	3,70	14,30	137,78	20,22	347,80	505,80
19	3,95	0,66	26,65	31,25	141,72	20,88	374,45	537,05

Fonte: Esta Pesquisa (2016)

Por outro lado, os custos procedentes da solução *null* - tabela 3.6 - são inevitáveis. As falhas dos componentes, ao longo das missões, tornam-se cada vez mais frequentes; o que implica na incidência mais significativa de custos de penalidade. Entretanto, não se consegue sustentar níveis aceitáveis de confiabilidade por muito tempo.

Tabela 3.6 – Estratificação dos Custos para a Solução Null

Missão-Break	Custos			Custos Acumulados		
	MR	Penalidade	Total	MR	Penalidade	Total
1	4,684	0,651	5,335	4,68	0,65	5,34
2	7,582	1,872	9,454	12,27	2,52	14,79
3	8,545	2,453	10,998	20,81	4,98	25,79
4	14,153	5,708	19,861	34,96	10,68	45,65
5	17,613	7,970	25,583	52,58	18,65	71,23
6	21,095	10,208	31,303	73,67	28,86	102,53
7	20,584	10,087	30,671	94,26	38,95	133,21
8	27,573	13,981	41,554	121,83	52,93	174,76
9	28,588	14,619	43,207	150,42	67,55	217,97
10	28,863	14,877	43,740	179,28	82,43	261,71
11	34,396	17,299	51,695	213,68	99,73	313,40
12	34,206	17,332	51,538	247,88	117,06	364,94
13	43,738	20,329	64,067	291,62	137,39	429,01
14	39,822	19,372	59,194	331,44	156,76	488,20
15	50,399	21,830	72,229	381,84	178,59	560,43
16	41,235	19,908	61,143	423,08	198,50	621,57
17	43,385	20,505	63,890	466,46	219,00	685,46
18	59,626	23,187	82,813	526,09	242,19	768,28
19	53,308	22,459	75,767	579,40	264,65	844,04

Fonte: Esta Pesquisa (2016)

Outrossim, a solução ótima, também, cumpre os requisitos de duração dos *breaks*. Na figura 3.6 estão plotados o tempo disponível nos *breaks* e os tempos alocados para a execução de atividades preventivas planejadas.

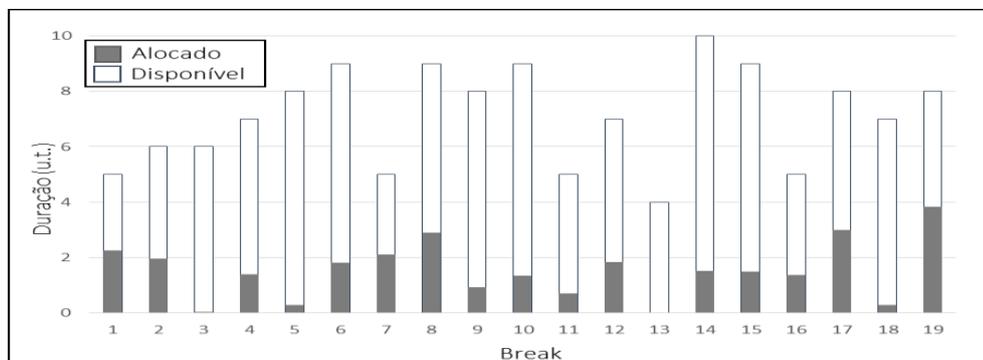


Figura 3.6 – Tempos Disponíveis e Alocados às Ações (superpostos) nos Breaks

Fonte: Esta Pesquisa (2016)

A análise do gráfico evidencia um superdimensionamento dos *breaks* e uma consequente ociosidade do sistema (apenas um quinto do tempo disponível está alocado). Assim, o simples replanejamento da dinâmica de operação do sistema, no que diz respeito à quantidade e duração de *breaks* e missões, mostra-se uma interessante alternativa para o aumento da eficiência do sistema.

## 4 ANÁLISES DE SENSIBILIDADE E MODELOS ALTERNATIVOS

Para mais da constatação da dominância da estratégia “preventiva” no caso base, neste capítulo buscou-se analisar a sensibilidade do modelo em cenários modificados. Além disso, propõe-se modelos alternativos de manutenção seletiva para sistemas orientados a multimissões.

### 4.1 Análises de Sensibilidade

No que diz respeito às análises de sensibilidade, em diferentes momentos, perturbou-se a instância base quanto à penalidade, quanto aos componentes do sistema e quanto ao planejamento do modelo.

#### 4.1.1 Primeiro Cenário

No primeiro cenário - caso I e caso II - modificou-se os custos de penalidade para  $cpar^I = (cpar - 5)$  e  $cpar^{II} = (cpar + 5)$  unidades monetárias. A solução ótima, mantendo-se os demais parâmetros constantes, independe dessa alteração.

Comparado ao caso base (figura 4.1), os custos totais ótimos praticamente não aumentaram. Por outro lado, os custos das soluções *null* tiveram variações consideráveis. Esses fatos já eram esperados, dado ao impacto da penalidade nas duas estratégias.

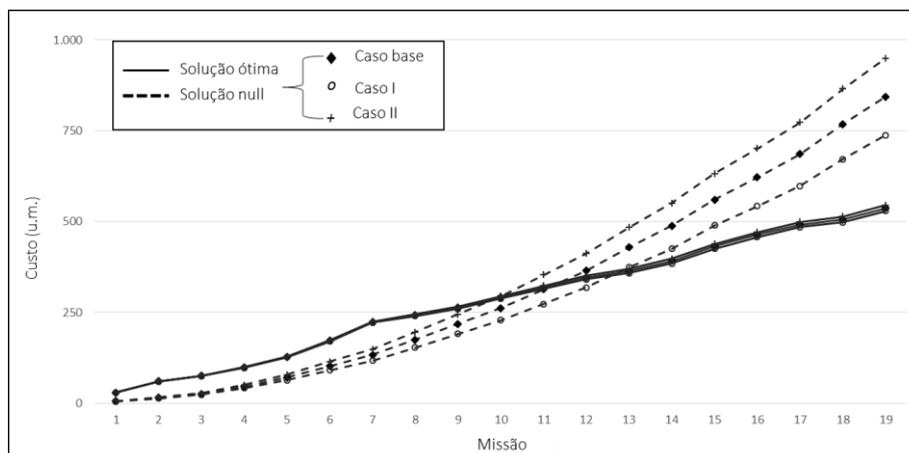


Figura 4.1 – Sensibilidade das Soluções a Variações no Custo de Penalidade

Fonte: Esta Pesquisa (2016)

Além disso, observando-se a intersecção das curvas das duas soluções (para um mesmo caso), é interessante notar, não levando em conta a restrição de confiabilidade, que a alteração no custo de penalidade muda o momento (missão) em que a solução ótima passa a “dominar”

a solução null. Essa análise é, principalmente, importante para a defesa da estratégia “preventiva” em situações onde não se consegue uma aproximação para os custos de penalidades e as expectativas de confiabilidade para o sistema não são altas.

#### 4.1.2 Segundo Cenário

A fim de se investigar o efeito da diminuição das redundâncias no sistema, retirou-se os componentes  $C_{23}$ ,  $C_{24}$  e  $C_{33}$  (caso III). Além disto, essa ação foi atrelada a uma diminuição de quinze pontos percentuais nas expectativas de confiabilidade do sistema para o início de cada missão e na atualização da componente gulosa do algoritmo para 575 unidades monetárias (que corresponde ao custo aproximado da solução *null*<sup>III</sup>).

Mantendo-se os demais parâmetros constantes, o algoritmo retornou, após 61 iterações, um indivíduo ótimo a um custo total de 322.764 unidades monetárias. Comparado ao caso base, os custos por penalidade (em ambas as soluções) tiveram um aumento significativo, conforme se observa na figura 4.2. Isso já era esperado em virtude da diminuição das redundâncias e, conseqüentemente, da confiabilidade do sistema.

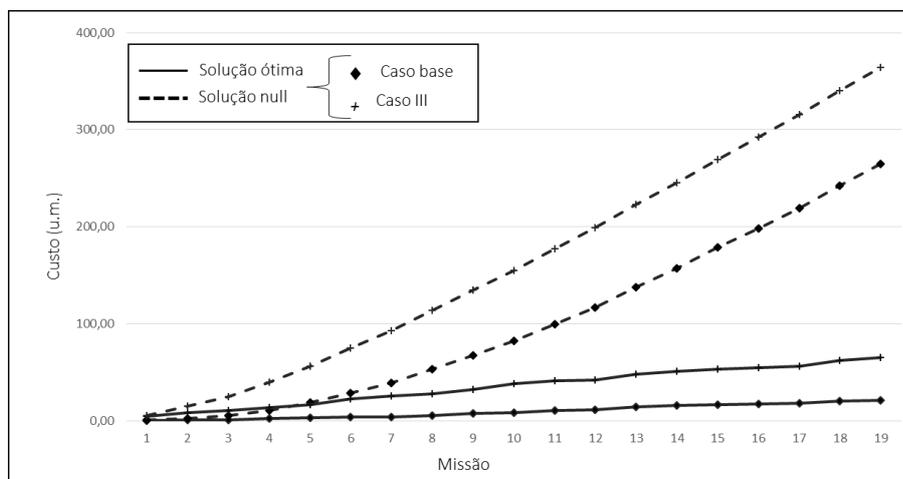


Figura 4.2 – Sensibilidade dos Custos por Penalidade a Variações na Redundância do Sistema

Fonte: Esta Pesquisa (2016)

No mais, deve-se atentar para o fato de que, embora os custos totais das soluções para o caso III sejam menores que para o caso base, a angulação das curvas sugere que, em longo prazo, essa situação se inverte. Isso provoca uma reflexão quanto a investimentos em redundância, posto que se pode optar por incorrer no pagamento de penalidades ou investir-se no aumento da confiabilidade do sistema.

Ainda no que tange às considerações acerca das redundâncias, investigou-se o efeito de variações dos tipos de componentes no sistema. Para tanto, modificou-se a constituição dos subsistemas, que passaram a ser formados por componentes idênticos, cujos parâmetros estão discriminados na tabela 4.1.

Tabela 4.1 – Parâmetros dos Componentes do Sistema (caso IV)

Componente	$\beta_{ij}$	$\nu_{ij}$	$cmr_{ij}$
C <sub>11</sub>	320	1,76	1,2
C <sub>12</sub>	320	1,76	1,2
C <sub>21</sub>	400	1,98	0,9
C <sub>22</sub>	400	1,98	0,9
C <sub>23</sub>	400	1,98	0,9
C <sub>24</sub>	400	1,98	0,9
C <sub>31</sub>	160	1,98	1,3
C <sub>32</sub>	160	1,98	1,3
C <sub>33</sub>	160	1,98	1,3

Fonte: Esta Pesquisa (2016)

Por conseguinte, o conjunto das ações preventivas, passivas de serem executadas nos componentes desse sistema, foi adaptado para se adequar à nova configuração dele. Esse conjunto e os parâmetros das ações são apresentados na tabela 4.2.

Tabela 4.2 – Parâmetros das Ações Preventivas passíveis de serem executadas no Sistema (caso IV)

p	Comp(p)	$\alpha(p)$	$c_{pm}(p)$	$d_{pm}(p)$
1	C <sub>11</sub> , C <sub>12</sub>	0,52	2,9	0,025
2	C <sub>11</sub> , C <sub>12</sub>	0	4,1	0,375
3	C <sub>21</sub> , C <sub>22</sub> , C <sub>23</sub> , C <sub>24</sub>	0,46	3,7	0,3
4	C <sub>21</sub> , C <sub>22</sub> , C <sub>23</sub> , C <sub>24</sub>	0	5,5	0,575
5	C <sub>31</sub> , C <sub>32</sub> , C <sub>33</sub>	0,62	3	0,375
6	C <sub>31</sub> , C <sub>32</sub> , C <sub>33</sub>	0	7,5	0,65

Fonte: Esta Pesquisa (2016)

O algoritmo retornou, após 64 iterações, um indivíduo ótimo a um custo total de 287.957 unidades monetárias. No todo, foi expressivo o efeito da “homogeneização” do sistema no que se refere aos custos por penalidade e total para as soluções *ótima* e *null* - os custos totais foram reduzidos pela metade. Isso se deu em virtude da redução das cifras vinculadas a mínimos reparos e a ações preventivas, conforme se verifica na figura 4.3.

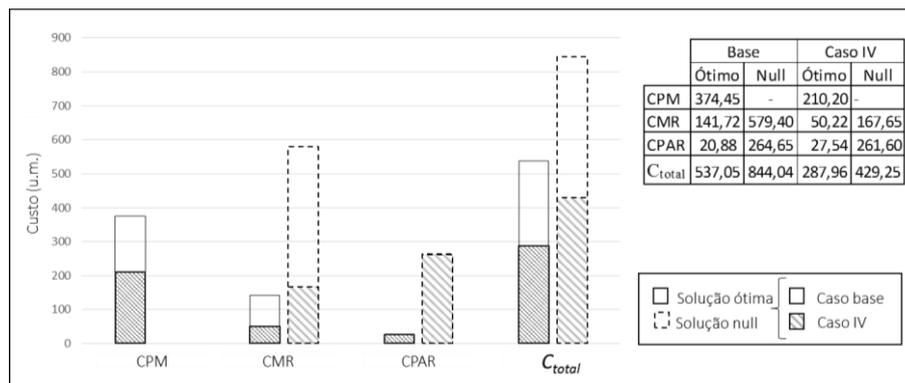


Figura 4.3 – Sensibilidade dos Custos Totais a Variações na Composição do Sistema

Fonte: Esta Pesquisa (2016)

A exploração dessas avaliações é relevante para a tomada de decisão quanto às redundâncias e aponta em qual subsistema se deve investir e qual componente deve ser adquirido.

#### 4.1.3 Terceiro Cenário

O problema de manutenção seletiva, outrora formulado, requer que se forneça o plano de operação do sistema – quantidade e duração das missões e dos breaks, bem como requisitos de confiabilidade para o início das missões - como parâmetro de entrada do modelo.

A esse respeito, quanto maior o horizonte de planejamento, maiores as incertezas quanto aos valores desses parâmetros. Assim, buscou-se avaliar o efeito da variação no tamanho do horizonte de planejamento para o modelo. Para isso, reduziu-se a quantidade de missões para dezesseis (caso V).

Atualizando-se a componente gulosa para 560 unidades monetárias (valor aproximado do custo do indivíduo *null*<sup>V</sup>) e mantendo-se os demais parâmetros constantes, o algoritmo retornou, após 69 iterações, um indivíduo ótimo (tabela 4.3) a um custo total de 386,373 unidades monetárias.

Tabela 4.3 – Soluções ótimas – caso base e caso V

Break	Ações		Break	Ações		Break	Ações	
	Caso base	Caso V		Caso base	Caso V		Caso base	Caso V
1	1,7,12,14,17,19	18	6	1,10,12,15,19	2,17,20	11	1,6,8	2,5,6,18,22
2	12,15,21	19	7	3,6,10,18,20	6,12	12	1,6,12,15	8,12,20
3	1,19	5,6,19	8	1,13,17	7,15	13	1	4,6,19
4	4,7,18	2,14,21	9	4,12,19	1,4,13,14,18,19	14	12,14,16,19	4,18
5	22	1,8,10,13,18,19	10	1,12,21	1,6,13,14	15	2,5,15,20	13,14,18

Fonte: Esta Pesquisa (2016)

Embora a cifra obtida seja menor que o custo total acumulado para o mesmo período do caso base, é pertinente destacar que essa é uma comparação indevida, dado que a otimização no caso base é feita para um maior horizonte que nesse caso alternativo. Isso, adicionalmente aos fenômenos de camuflagem de custos anteriormente relatados, ilustra a relevância de se trabalhar com um horizonte de planejamento adequado.

Fora a perturbação do planejamento quanto à quantidade de missões, faz-se necessária a análise do efeito da variação na duração das missões, decorrente da revisão do plano de operação do sistema.

Para isso, revisou-se o plano de operação do sistema no final do décimo break (caso VI) e modificou-se as durações das missões restantes para 52 unidades temporais (e, conseqüentemente, a expectativa dos níveis de confiabilidade para 0.9) - o que pode ser justificado em função de demanda extra do sistema, por exemplo.

Mantendo-se constantes os demais parâmetros do algoritmo, após 46 iterações, obteve-se o plano complementar discriminado na tabela 4.4.

Tabela 4.4 – Soluções ótimas – caso base e caso VI

Break	Ações	
	Caso base	Caso VI
11	1,6,8	15,16,19
12	1,6,12,15	1,5,13,18,22
13	1	2,14,18
14	12,14,16,19	7,8,13,15,17,21
15	2,5,15,20	5,8,18,19
16	1,7,14,17,19	3,5,12
17	13,16,20	9,14,18,19
18	6	1,13,17,21
19	3,13,18,19	18,19

Fonte: Esta Pesquisa (2016)

Dada a modificação dos parâmetros de operação do sistema, também, nesse caso não é adequada a comparação dos custos entre os casos.

Destaca-se que muitos são os fatores que podem influenciar na modificação da duração das missões e alta é a incidência deles sobre os sistemas. Assim, conquanto maiores horizontes de planejamento sejam necessários para minimizar os fenômenos que camuflam os custos de manutenção do sistema, é evidente a necessidade de uma revisão periódica do plano de operação do sistema.

## 4.2 Modelos Alternativos

Enquanto o comportamento dos custos do caso base motivou as análises de sensibilidade, a constatação de existência de ociosidade provocou a formulação de modelos alternativos. Para isso, modificou-se o indicador de performance na função objetivo e adaptou-se as restrições.

### 4.2.1 Primeiro Modelo Alternativo

A ociosidade identificada nas análises dos resultados para o caso base foi atribuída ao superdimensionamento dos *breaks*. Daí, apontou-se o replanejamento do cronograma de paradas e missões como meio para aumentar a eficiência do sistema. Essa alternativa é razoável no contexto de sistemas de manufatura, por exemplo, onde ociosidade é traduzida como custo, e minimizá-lo é uma constante preocupação.

Por outro lado, no contexto de serviços, tal qual manutenção de servidores, as paradas entre missões têm maior criticidade, pois representam a perda do serviço para os clientes. Nessa situação, tempo é um indicador de desempenho mais adequado que custo.

Esse fato impulsiona a formulação de um outro problema de manutenção seletiva, qual seja: Do conjunto das  $P$  ações preventivas, passivas de serem realizadas nos componentes do sistema ( $V_{PM}$ ), determinar uma sequência de atividades que minimize o tempo total de manutenção do sistema  $DPM$  e que possibilite o alcance da confiabilidade desejada para o início da operação do sistema a cada missão, sem violar o orçamento dedicado à manutenção ( $BGT$ ).

Segue o modelo de programação matemática que corresponde ao problema:

$$P2: \text{Minimize } DPM = \sum_{m=1}^{M-1} DPM(m) \quad (4.1)$$

sujeito a:

$$R(m+1) \geq R(l) \quad (4.2)$$

$$C_{total} \leq BGT \quad (4.3)$$

$$\sum_{p=1}^P a_p(C_{ij}, m) \leq 1 \quad (4.4)$$

$$a_p(C_{ij}, m) \in \{0,1\} \quad (4.5)$$

$$i = 1, \dots, n; j = 1, \dots, N_i; p = s_1, \dots, s_k \quad (4.6)$$

$$m = 1, \dots, M-1; l = m+1 \quad (4.7)$$

A primeira restrição (inequação 4.2) expressa as expectativas de confiabilidade para o início de cada missão; a restrição posterior (inequação 4.3) limita o gasto total com ações de manutenção e a terceira restrição (inequação 4.4) impõe que cada componente só possa receber uma ação por *break*.

Dada a flexibilidade dos algoritmos genéticos outrora destacada, poucas alterações foram necessárias para adaptar o método de resolução desenvolvido ao novo problema. No geral, manteve-se a mesma lógica que a estratégia anterior, fazendo-se adequações à nova formulação.

Contudo, mais uma vez utilizou-se o custo como componente gulosa. Isso se deu com vistas a relacionar as soluções preventiva e corretiva, dado que nessa última, desconsiderando-se a restrição de confiabilidade, não é necessário alocar tempo aos *breaks*. Para tanto, a cifra escolhida mais uma vez corresponde ao custo da solução corretiva que também figura como orçamento de manutenção.

Além do mais, a adaptação da instância trabalhada na primeira configuração do problema permite a comparação entre as formulações de ambos os modelos. Para isso, manteve-se os parâmetros dos componentes, a configuração e os requisitos do sistema, bem como o vetor  $V_{PM}$ . De igual modo, preservou-se os valores dos parâmetros do algoritmo genético, alterando-se a forma de cálculo do *fitness* e de viabilidade das soluções.

Diante disso, o algoritmo retornou, após 35 iterações, a solução apresentada na tabela 4.5, consumindo 25,79 unidades temporais a um custo de 646,325 unidades monetárias.

Tabela 4.5 – Solução Ótima Encontrada - Modelo 2

Break	Ação	Break	Ação	Break	Ação	Break	Ação
1	3,8,17	6	1,17,20	11	10,12,17	16	1,9,15,18,19
2	12,15,22	7	2,18,19	12	17,21	17	1,5,6,8,15
2	11,19	8	1,4,6,19	13	2,7,10,12,19	18	4,7,10
4	3,18,19	9	15,16	14	8,16	19	2,8,17,20
5	1,5,10,20	10	7,13,17,21	15	1,4,22		

Fonte: Esta Pesquisa (2016).

A execução de tal plano, a exemplo da solução para o modelo base, cumpre os requisitos de confiabilidade e custo da instância.

Ademais, a análise da tabela 4.6 sugere indiferença entre a relevância do indicador confiabilidade para ambos os modelos. Adicionalmente, identifica-se uma maior representatividade do indicador custo para a primeira solução em contraste com a maior

importância do indicador tempo para segunda, fato que condiz com as funções objetivo analisadas.

Tabela 4.6 – Confiabilidade, Custo Total Acumulado e Tempo Alocado à Manutenção  
Soluções Ótimas (Modelos 1 e 2)

Missão-Break	Confiabilidade			Custo Acumulado		Tempo Acumulado	
	Requisito	Modelo 1	Modelo 2	Modelo 1	Modelo 2	Modelo 1	Modelo 2
1	0.85	0.99	0.98	29.58	26.00	2.25	1.25
2	0.85	0.99	0.99	60.27	59.50	4.225	3.08
3	0.70	0.98	0.98	75.62	87.80	4.275	5.36
4	0.90	0.96	0.97	98.69	116.20	5.675	6.69
5	0.90	0.96	0.95	127.39	161.40	5.975	7.59
6	0.90	0.97	0.94	172.03	195.50	7.8	8.24
7	0.75	0.99	0.96	223.37	224.70	9.9	9.29
8	0.90	0.95	0.91	242.65	260.30	12.8	9.67
9	0.85	0.92	0.96	263.00	289.60	13.725	10.57
10	0.75	0.96	0.97	291.32	324.55	15.075	14.47
11	0.85	0.90	0.93	318.62	353.25	15.775	15.97
12	0.75	0.97	0.95	345.56	378.45	17.625	16.8
13	0.90	0.90	0.92	363.40	421.95	17.65	18.75
14	0.75	0.92	0.89	391.13	445.65	19.175	19.38
15	0.90	0.97	0.95	432.04	481.45	20.675	19.73
16	0.70	0.98	0.98	463.79	526.05	22.05	21.98
17	0.70	0.98	0.99	491.50	563.15	25.05	23.71
18	0.90	0.91	0.94	505.80	601.85	25.35	24.56
19	0.75	0.97	0.96	537.05	646.35	29.175	25.79

Fonte: Esta Pesquisa (2016).

Cabe destacar que o baixo contraste entre os indicadores principais das duas soluções pode ser explicado pelo fato de que as ações menos custosas são, também, as que demandam menor tempo de execução.

#### 4.2.2 Segundo Modelo Alternativo

Existem ainda contextos, como manutenção de aeronaves, onde a consequência de uma falha é tamanha que a métrica confiabilidade se torna mais adequada que custo ou tempo para medir a performance dos sistemas.

Assim, faz-se necessária a determinação de uma sequência de atividades procedentes do conjunto das  $P$  ações preventivas, passivas de serem realizadas nos componentes do sistema ( $V_{PM}$ ), que maximize a confiabilidade média  $\bar{R}$  do sistema e que não viole o orçamento ( $BGT$ ) e o tempo disponíveis para manutenção.

Segue o modelo de programação matemática que corresponde ao problema:

$$P3: \text{Maximize } \bar{R} = \sum_{m=1}^{M-1} R(m+1)/M - 1 \quad (4.8)$$

sujeito a:

$$DPM(m) \leq D(m, l) \quad (4.9)$$

$$C_{total} \leq BGT \quad (4.10)$$

$$\sum_{p=1}^P a_p(C_{ij}, m) \leq 1 \quad (4.11)$$

$$a_p(C_{ij}, m) \in \{0,1\} \quad (4.12)$$

$$i = 1, \dots, n; j = 1, \dots, N_i; p = s_1, \dots, s_k \quad (4.13)$$

$$m = 1, \dots, M - 1; l = m + 1 \quad (4.14)$$

A primeira restrição (inequação 4.9) limita a duração das ações preventivas a serem executas ao final de uma dada missão ao tempo planejado para o *break* correspondente; a restrição posterior (inequação 4.10) limita o gasto total com ações de manutenção e a terceira restrição (inequação 4.11) impõe que cada componente só possa receber uma ação por *break*.

Mais uma vez reestruturou-se o algoritmo genético outrora desenvolvido para que fosse utilizado como estratégia de resolução da nova formulação - alterando-se a forma de cálculo do *fitness* e de viabilidade das soluções. Além disso, manteve-se o custo como componente gulosa, uma vez que a solução corretiva não atende às expectativas de confiabilidade do sistema. Novamente, a cifra escolhida corresponde ao custo da solução corretiva e ao orçamento disponível para manutenção.

Em seguida, adaptou-se a instância trabalhada nas configurações anteriores do problema. Contudo, preservou-se os parâmetros dos componentes, a configuração e os requisitos do sistema, bem como o vetor  $V_{PM}$  e os parâmetros do algoritmo genético. Este, após 77 iterações, retornou um indivíduo ótimo (tabela 4.7), a um custo de 741,594 unidades monetárias, que proporciona uma confiabilidade média de 0,98 ao sistema.

Tabela 4.7 – Solução Ótima Encontrada – Modelo 3

Break	Ação	Break	Ação	Break	Ação	Break	Ação
1	1,12,22	6	5,6,13,17,22	11	3,4,15,22	16	1,6,13,15,17,20
2	3,15,17,19	7	5,15,16,20	12	6,9,16,20	17	3,5,12,14,17,22
2	3,7,10,12,18	8	11,13,17,21	13	2,12,16,19	18	2,5,11,17,20
4	2,10,15,18	9	5,8,11,14,19	14	7,9,20	19	1,4,12,15,18,21
5	3,6,13,22	10	9,10,18	15	4,8,13,15		

Fonte: Esta Pesquisa (2016).

A execução desse plano, também, cumpre os requisitos de tempo e custo da instância.

Ao se analisar os indicadores dessa solução, constata-se grande contraste em comparação às soluções dos modelos 1 e 2 – tabela 4.8. Isso pode ser explicado pelo fato de que as ações que têm maior impacto sobre a confiabilidade do sistema custam mais e demoram mais tempo para serem executadas.

Tabela 4.8 – Confiabilidade Média, Custo Total Acumulado e Tempo Alocado à Manutenção

Soluções Ótimas (Modelos 1, 2 e 3)

M-B	Confiabilidade Média			Custo Acumulado			Tempo Acumulado		
	Mod. 1	Mod. 2	Mod. 3	Mod. 1	Mod. 2	Mod. 3	Mod. 1	Mod. 2	Mod. 3
1	0.99	0.98	0.99	29.58	26.00	27.72	2.25	1.25	1.20
2	0.99	0.99	0.99	60.27	59.50	59.11	4.23	3.08	2.75
3	0.99	0.98	0.99	75.62	87.80	100.35	4.28	5.36	5.75
4	0.98	0.98	0.99	98.69	116.20	138.56	5.68	6.69	7.68
5	0.98	0.98	0.99	127.39	161.40	177.77	5.98	7.59	11.28
6	0.97	0.97	0.99	172.03	195.50	217.56	7.80	8.24	15.13
7	0.98	0.97	0.99	223.37	224.70	249.65	9.90	9.29	16.66
8	0.97	0.96	0.99	242.65	260.30	294.62	12.80	9.67	22.24
9	0.97	0.96	0.99	263.00	289.60	338.67	13.73	10.57	25.64
10	0.97	0.96	0.98	291.32	324.55	378.58	15.08	14.47	27.44
11	0.96	0.96	0.98	318.62	353.25	421.28	15.78	15.97	28.92
12	0.96	0.96	0.99	345.56	378.45	464.22	17.63	16.80	30.47
13	0.96	0.96	0.98	363.40	421.95	492.62	17.65	18.75	31.85
14	0.95	0.95	0.98	391.13	445.65	535.33	19.18	19.38	33.43
15	0.96	0.95	0.98	432.04	481.45	568.20	20.68	19.73	36.98
16	0.96	0.95	0.98	463.79	526.05	609.41	22.05	21.98	41.08
17	0.96	0.96	0.98	491.50	563.15	653.11	25.05	23.71	43.88
18	0.96	0.95	0.98	505.80	601.85	699.39	25.35	24.56	47.36
19	0.96	0.96	0.98	537.05	646.35	741.59	29.18	25.79	50.39

Fonte: Esta Pesquisa (2016).

No mais, a depender do tamanho da organização, no início das operações, não é viável disponibilizar uma grande cifra (de forma integral) como orçamento para a manutenção. Assim, é mais razoável presumir que, ao longo das missões, se vá disponibilizando capital (de forma parcelada).

Além disso, para as grandes organizações, que podem disponibilizar aquele valor em uma única parcela, pode ser mais vantajoso a liberação parcelada do orçamento, o que possibilita um maior investimento nas demais funções organizacionais. Destarte, ao problema de manutenção seletiva associa-se um problema orçamentário.

Mais uma vez, modificou-se o algoritmo genético e a instância trabalhada nas demais formulações, segundo à sistemática outrora adotada. Além disso, a equação 4.10 foi alterada para  $C_{total}(m + 1) \leq BGT(m, l)$ , que limita o gasto de cada ciclo missão-break à parcela de orçamento alocada ao ciclo correspondente.

Para efeitos de ilustração, disponibilizou-se 19 parcelas iguais de 39,5 u.m. como orçamento e 750 u.m. como componente gulosa, permitindo-se que o capital não utilizado em um ciclo pudesse ser aproveitado no(s) subsequente(s). Daí, o algoritmo retornou, após 93 iterações, o indivíduo discriminado na tabela 4.9, a um custo de 698,219 u.m e que proporciona uma confiabilidade média de 0,98 ao sistema.

Tabela 4.9 – Solução Ótima Encontrada – Modelo 4

Break	Ação	Break	Ação	Break	Ação	Break	Ação
1	2,10,12	6	3,12,15,17,22	11	13,15,17,20	16	13,20
2	7,12,21	7	3,7	12	3,7,13,18	17	4,9,10,14,19
2	2,5,7,11,17,22	8	5,13,15,16,22	13	2,6,8,18	18	1,15,18,22
4	8,13,16,20	9	3,7,9,14,18	14	1,6,8,15,17,21	19	1,5,6,14,18,20
5	3,13,15,19	10	4,9,22	15	1,6,16,21		

Fonte: Esta Pesquisa (2016).

A análise dos indicadores dessa solução evidencia um resultado inesperado: apesar de no modelo 3 se disponibilizar todo o orçamento no início das operações, o que permite um maior poder de decisão, a solução do modelo 4 conduz a melhores resultados em termos de custo, tempo e, praticamente, à mesma confiabilidade média – tabela 4.10.

Tabela 4.10 – Confiabilidade Média, Custo Total Acumulado e Tempo Total Alocado à Manutenção

*Soluções Ótimas (Modelos 3 e 4)*

	Modelo 3	Modelo 4
Confiabilidade média	0.983	0.981
Custo Acumulado	741.59	698.22
Tempo Acumulado	50.39	45.36

*Fonte: Esta Pesquisa (2016).*

Isso se dá em virtude do algoritmo para o modelo 3 tentar alcançar maior confiabilidade, à medida que exaure o orçamento disponível para a manutenção. Já as restrições de viabilidade do modelo 4 geram indivíduos mais eficientes, melhorando o desempenho do algoritmo genético ao longo das gerações.

## 5 CONCLUSÕES E TRABALHOS FUTUROS

Embora a escolha de uma política adequada de manutenção seja essencial para prover a efetividade dos sistemas de produção - à medida que apoia e alavanca as estratégias empresariais - as organizações nem sempre dedicam a devida atenção quanto aos modelos e métodos utilizados para obtê-las.

Prova disso é que muitos modelos de manutenção desprezam a duração das atividades de manutenção e/ou a necessidade/finitude de intervalos, bem como as restrições dos recursos para a realização de tais ações. Nesse panorama, os modelos de manutenção seletiva surgiram como alternativa para transpor tais simplificações.

Todavia, muitas estratégias de resolução de problemas conduzem a ótimos locais (como as heurísticas ineficientes) ou demorariam tanto para encontrar um ótimo global (métodos exaustivos, por exemplo) que são inviáveis como método de busca; daí a necessidade de utilização de (meta)heurísticas na resolução de determinados problemas.

Diante disso, neste trabalho concentrou-se esforços pretendendo contribuir com os modelos de manutenção seletiva dedicados a sistemas multicomponentes orientados a múltiplas missões. Parte disso deu-se pela modelagem de problemas de manutenção seletiva e construção de um método híbrido de busca.

Os diversos problemas trabalhados no decorrer do texto foram facilmente modelados. A manipulação algébrica com a qual o autor se familiarizou ao longo da construção do referencial teórico e revisão da literatura permitiu a expansão e a formulação dos modelos.

Por outro lado, a programação da estratégia de resolução não foi tão natural, conquanto, o algoritmo desenvolvido rendeu resultados satisfatórios. Nesse contexto, os pontos mais críticos estão relacionados à robustez do algoritmo e à adaptação do método aos cenários perturbados.

No primeiro caso, a utilização de uma componente gulosa foi suficiente para garantir a obtenção de boas soluções; no outro, a característica de flexibilidade dos algoritmos genéticos foi fundamental para diminuir a quantidade de retrabalho.

A aplicabilidade do modelo expandido foi atestada por uma aplicação numérica, que também verificou a efetividade do algoritmo desenvolvido. Para a instância estudada, evidenciou-se a dominância da estratégia seletiva em relação à corretiva. Além disso, discriminou-se os fatores que influenciam no perfil dos custos ao longo das missões e constatou-

-se ociosidade no sistema. Isso motivou, respectivamente, a análise da sensibilidade e formulações alternativas para o modelo.

No que tange às análises de sensibilidade, perturbou-se aquela instância quanto aos custos relacionados à penalidade; quanto aos componentes do sistema e quanto ao planejamento de operações do sistema.

Na primeira perturbação, verificou-se a relevância de se ter uma estimativa correta para os custos de penalidade. Assim, em situações quando essa aproximação não se dá de forma consciente, recomenda-se que sejam feitas análises para vários valores, antes que se tome uma decisão.

Na segunda perturbação, atestou-se a importância de se investir no aumento da redundância dos sistemas. Contudo, isso não deve ser feito de forma indiscriminada - propõe-se uma integração dos modelos de manutenção seletiva a modelos de análise de investimentos e a modelos de alocação de redundâncias.

Em ambos os casos se observou o efeito camuflagem, que pode ser atenuado ao se trabalhar com um horizonte de planejamento suficientemente grande. Porém, conforme se anunciou na terceira perturbação, quanto maior o horizonte, maiores as incertezas relacionadas ao planejamento de operações do sistema; isso evidencia a importância de se especificar uma quantidade adequada de missões. Dessa forma, aconselha-se que o balanceamento entre as duas constatações seja feito por métodos dinâmicos.

Para mais, modificou-se o indicador de performance na função objetivo e adaptou-se as restrições do modelo base para conformá-lo ao contexto de serviços e aos casos de sistemas cujas falhas são críticas. Essas abordagens revelaram a importância de se trabalhar a manutenção seletiva no contexto de problemas multiobjetivos/multicritério.

Complementarmente, o último modelo foi ampliado para permitir diferentes formas de orçamento para a manutenção. Com isso, obteve-se um resultado inesperado, uma vez que a disponibilização parcelada do capital proporcionou maior performance ao sistema que em uma única parcela. Esse efeito foi atribuído à dinâmica de funcionamento do algoritmo.

No mais, propõe-se que iniciativas futuras canalizem esforços no sentido de trabalharem modelos com parâmetros de entrada não determinísticos. Em outra direção, sugere-se que se testem outros métodos de resolução para o problema, pois, embora o algoritmo desenvolvido tenha se mostrado flexível e eficiente, não se verificou robustez.

Espera-se que este trabalho, mais que a contribuição com a literatura, possa ser relevante para o ambiente industrial. Ressalta-se que os modelos desenvolvidos se mostraram adaptáveis às diversas realidades organizacionais; cabe aos profissionais da produção a tarefa de aplicá-los. Por fim, destaca-se a significância desta dissertação na vida do autor, que aplicou os conceitos-chave aprendidos na academia, pretendendo contribuir com a sociedade.

---

## REFERÊNCIAS

- ALMEIDA, A.T.; CAVALCANTE, C.A.V.; ALNCAR, M.H.; FERREIRA, R.J.P.; ALMEIDA-FILHO, A.T., GARCEZ, T.V. *Multicriteria and Multiobjective Models for Risk, Reliability and Maintenance Decision Analysis. S.L. 2015, 417p.*
- ALRABGHI, A.; Ashutosh TIWARI, A. State of the art in simulation-based optimization for maintenance systems. *Computers & Industrial Engineering*, 82: 167-182, 2015.
- ALSYOUF, I. The role of maintenance in improving companies' productivity and profitability. *International Journal of Production Economics*, 105(1):70–78, 2007.
- ANDERS, G.J.; SUGIER, J. Risk assessment tool for maintenance selection. In: *DEPENDABILITY OF COMPUTER SYSTEMS INTERNATIONAL CONFERENCE PROCEEDINGS*, Szklarska Poreba, 2006, p.306–313.
- ARUNRAJ, N.S.; MAITI, J. Risk-based maintenance policy selection using AHP and goal programming. *Safety Science* 48(2):238–247, 2010.
- BLICKLE, T.; THIELE, L.A. *A comparison of selection schemes used in genetic algorithms. Computer Engineering and communication Networks Lab (TIK), Swiss Federal Institute of Technology, Zurich, 1995.*
- BOGONOVO, E.; MARSEGUERRA, M.; ZIO, E. A Monte Carlo methodological approach to plant availability modelling with maintenance, aging and obsolescence. *Reliability Engineering & System Safety*, 67(1):61–73, 2000.
- BRAGLIA, M.; FROSOLINI, M.; MONTANARI, R. Fuzzy criticality assessment model for failure modes and effects analysis. *International Journal of Quality & Reliability Management*, 20(4):503–524, 2003.
- BROWN, M.; PROSCHAN, F. Imperfect Repair. *Journal of Applied Probability*, 851-859, 1983.
- CASSADY, C.R; POHL, A.E.; MURDOCK, W.P. Selective maintenance modeling for industrial systems. *Journal of Quality in Maintenance Engineering*, 7(02):104–117, 2001.a.
- CASSADY, C.R; POHL, A.E.; MURDOCK, W.P. Selective maintenance for support equipment involving multiple maintenance actions. *European Journal of Operational Research*, 129(02):252-258, 2001.b.
- CASTRO, R.E. Otimização de Estruturas Multi-objetivos Via Algoritmos Genéticos de Pareto. Rio de Janeiro, Brasil, 2001. (Doutorado – Coordenação do Programa de Pós-Graduação em Engenharias de Universidade Federal do Rio de Janeiro, COPPE/UFRJ).
- CHEN, C.; MENG, M.; ZUO, M. Selective Maintenance Optimization for Multi-state Systems. *Proceedings of the 1999 IEEE Canadian Conference on Electrical and Computer Engineering*, 1999.

- CHUNG, S.H.; LAU, H.C.W.; HO, G.T.S.; IP, W.H. Optimization of system reliability in multi-factory production networks by maintenance approach. *Expert Systems with Applications*, 36(6):10188–10196, 2009.
- COIT, D. W.; SMITH, A. E. Reliability Optimization of Series-Parallel Systems Using a Genetic Algorithm. *IEEE Transactions on Reliability*, 45(02):254 – 266, 1996.
- DAO, C. D.; ZUO, M. J.; PANDEY, M. Selective maintenance for multi-state series–parallel systems under economic dependence. *Reliability Engineering & System Safety*, 121:240-249 2014l.
- DING, F.; TIAN, Z. Opportunistic maintenance for wind farms considering multi-level imperfect maintenance thresholds. *Renewable Energy*, 45:175-182, 2012.
- DING, S.H.; KAMARUDDIN, S. Maintenance policy optimization - literature review and directions. *International Journal of Advanced Manufacturing Technology*, 76:1263–1283, 2015.
- DO, P.; VOISIN, A.; LEVRAT, E.; IUNG, B. A proactive condition-based maintenance strategy with both perfect and imperfect maintenance actions. *Reliability Engineering & System Safety*, 113:22-32, 2015.
- FLAGE, R. A delay time model with imperfect and failure-inducing inspections. *Reliability Engineering & System Safety*, 114:1-12, 2014.
- GHOSH, D.; ROY, S. Maintenance optimization using probabilistic cost-benefit analysis. *Journal of Loss Prevention in the Process Industries*, 22(4):403-407, 2009.
- GLOVER, F.; KOCHENBERGER, G. A. *Handbook of Metaheuristics*. Kluwer Academic Publishers, 2003, 570 p.
- GOLDBERG, D.E. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley, Reading, 1989.
- HADIDI, L.A.; RAHIM, A. Reliability for multiple units adopting sequential imperfect maintenance policies. *International Journal of System Assurance Engineering and Management*, 6(2):103-109, 2015.
- HICKS, C. A Genetic Algorithm tool for optimizing cellular or functional layouts in the capital goods industry. *International Journal of Production Economics*, 104:598 – 614, 2006.
- HUANG, S. A genetic-evolved fuzzy system for maintenance scheduling of generating units. *Electrical Power & Energy Systems*, 20: 191-195, 1998.
- KALLEN, M. J. Modelling imperfect maintenance and the reliability of complex systems using superposed renewal processes. *Reliability Engineering & System Safety*, 96(6): 636–641, 2011.
- KANCEV, D.; GJORGIEV, B.; CEPIN, M. Optimization of test interval for ageing equipment: A multi-objective genetic algorithm approach. *Journal of Loss Prevention in the Process Industries*, 24: 397-404, 2011.

- KIJIMA, M.; NAKAGAWA, T. Replacement policies of a shock model with imperfect preventive maintenance. *European Journal of Operational Research*, 57(1): 100–110, 1992.
- KIJIMA, M.; MORIMURA, H.; SUZUKI, Y. Periodical replacement problem without assuming minimal repair. *European Journal of Operational Research*, 37(2): 194–203, 1998.
- KHATAB, A.; DAHANE, M.; AIT-KADI, D. Genetic algorithm for selective maintenance optimization of multi-mission oriented systems. IN: 22<sup>nd</sup> EUROPEAN SAFETY AND REABILITY ANNUAL CONFERENCE PROCEEDINGS, Amsterdam, 2014 p. 859 -865.
- KHATAB, A. Hybrid hazard rate model for imperfect preventive maintenance of systems subject to random deterioration. *Journal of Intelligent Manufacturing*, 26(03):601-608, 2015.
- KONAK, A.; COIT, D. W.; SMITH, A. E. Multi-objective optimization using genetic algorithms: a tutorial. *Reliability Engineering and System Safety*, 91(09):992-1007, 2006.
- LABIB, A.W. World-class maintenance using a computerized maintenance management system. *Journal of Quality in Maintenance Engineering*, 4 (1):66–75, 1998.
- LE, D. M.; TAN, C. M. Optimal maintenance strategy of deteriorating system under imperfect maintenance and inspection using mixed inspection scheduling. *Reliability Engineering & System Safety*, 113:21-29, 2013.
- LEVITIN, G.; LISNIANSKI, A. Optimization of imperfect preventive maintenance for multi-state systems. *Reliability Engineering and System Safety*, 67(02): 193-203, 2000.
- LIAO, G-L.; CHEN, Y. H.; SHEU, S-H. Optimal economic production quantity policy for imperfect process with imperfect repair and maintenance. *European Journal of Operational Research*, 195(1): 348-357, 2009.
- LIAO, G-L. Optimum policy for a production system with major repair and preventive maintenance. *Applied Mathematical Modelling*, 36(11):5408-5417, 2012.
- LIN, D.; ZUO, M. J.; YAM, R. C. M. General sequential imperfect preventive maintenance models. *International Journal of Reliability, Quality and Safety Engineering*, 07(03): 253-266, 2000.
- LIU, Y.; HUANG, H. Z. Optimal selective maintenance strategy for multi-state systems under imperfect maintenance. *IEEE Transactions on Reliability*, 59(02): 356–367, 2010.
- LUST, T.; ROUX, O; RIANE, F. Exact and heuristic methods for the selective maintenance problem. *European Journal of Operational Research*, 197(03):1166-1177, 2009.
- MAAROUFI, G.; CHELBI, A.; REZG, N. A selective maintenance policy for multi-component systems involving replacement and imperfect preventive maintenance actions. In: 5TH IESM CENFERENCE, 2013. Proceedings. Rabat, 2013. p. 1-8.
- MAHADEVAN, M.L.; PAUL ROBERT, T.; SRIDHAR, V. Optimizing maintenance activities using HGA and Monte Carlo simulation. *International Journal of Computer Applications*, 1(21):106–110, 2010.

- MAILLART, L. M.; CASSADY, C. R.; RAINWATER, C.; SCHNEIDER, K. Selective Maintenance Decision-Making Over Extended Planning Horizons. *IEEE Transactions on Reliability*, 58(03): 462 – 469, 2009.
- MECHEFSKE, C.K.; WANG, Z. Using fuzzy linguistics to select optimum maintenance and condition monitoring strategies. *Mechanical Systems and Signal Processing*, 15(6):1129–1140, 2001.
- NAKAGAWA, T. Sequential imperfect preventive maintenance policies. *IEEE Transactions on Reliability* 37(3) 295-308, 1998.
- NICOLAI, R. P.; DEKKER, R. Optimal maintenance of multi-component systems: a review. In: *Complex system maintenance handbook*. London: Springer; p. 263–86, 2008.
- PANDEY, M.; ZUO, M. J.; MOGHADDASS, R.; TIWARI, M. K. Selective maintenance for binary systems under imperfect repair. *Reliability Engineering and System Safety*, 113:42 – 51, 2013.
- PENG, Y.; DONG, M.; ZUO, M.J. Current status of machine prognostics in condition- based maintenance - a review. *International Journal of Advanced Manufacturing Technology*, 34:1181–1193, 2010.
- PHAM, H.; WANG, H. Imperfect Maintenance. *European Journal of Operation Research*, 425- 438, 1996.
- RAJAGOPALAN, R.; CASSADY, C. R. An improved selective maintenance solution approach. *Journal of Quality in Maintenance Engineering*, 12(02):172–185, 2006.
- RAZALI, N. M.; GERAGHTY, J. Genetic Algorithm Performance with Different Selection Strategies in Solving TSP. In: PROCEEDINGS OF THE WORLD CONGRESS ON ENGINEERING, 2011.
- RICE, W. F.; CASSADY, C. R.; NACHLAS, J. A. Optimal maintenance plans under limited maintenance time. *Proceedings of the Seventh Industrial Engineering Research Conference*, 1998.
- SAMROUT, M.; CHATELET, E.; KOUTA, R.; CHEBBO, N. Optimization of maintenance policy using the proportional hazard model. *Reliability Engineering & System Safety* 94(1):44–52, 2009.
- SANDVE, K.; AVEN, T. Cost optimal replacement of monotone, repairable systems. *European Journal of Operational Research*, 116(2):235–248, 1999.
- SCARF, P.A.; CAVALCANTE, C.A.V. Modelling quality in replacement and inspection maintenance. *International Journal of Production Economics*, 135(1):372–381, 2012.
- SCHNEIDER, K.; CASSADY, C.R. Fleet performance under selective maintenance. *Proceedings of the Annual Reliability and Maintainability Symposium*, p. 571-576, 2004.

- SHARMA, A.; YADAVA. G.S.; DESHMUKH, S.G. A literature review and future perspectives on maintenance optimization. *Journal of Quality in Maintenance Engineering*, 17(1):5–25, 2011.
- SHEU, S.-H. S.; CHIH, C. C.; CHEN, Y.-L.; ZHANG, Z. G. Optimal preventive maintenance and repair policies for multi-state systems. *Reliability Engineering & System Safety*, 140:78-87, 2015.
- SIVANANDAM, S.N.; DEEPA, S.N. *Introduction to Genetic Algorithms*. Berlin, Springer, 2008, 453 p.
- SWANSON, L. Linking maintenance strategies to performance. *International Journal of Production Economics*, 709(3):237–244, 2001.
- TERSINE, R.J. *Production/operations management: concepts, structure, and analysis*. Elsevier Science Publisher, New York, 1995.
- TOLEDO, M. L. G.; FREITAS, M. A.; COLOSIMO, E. A.; GILARDONI, G. L. ARA and ARI imperfect repair models: Estimation, goodness-of-fit and reliability prediction. *Reliability Engineering & System Safety*, 140:107-115, 2015.
- TSAI, Y.; WANG, K.; TENG, H. Optimizing preventive maintenance for mechanical components using genetic algorithms. *Reliability Engineering and System Safety*, 74(01): 89-97, 2001.
- TURRIONI, J. B.; MELLO, C. H. P. *Metodologia da pesquisa em Engenharia de Produção*. Minas Gerais: UNIFEI, 2012.
- VAN HORENBEEK A.; PINTELON, L. A dynamic predictive maintenance policy for complex multi-component systems. *Reliability Engineering & System Safety* 120:39–50, 2013.
- VASILI, V.; HONG, T.S.; ISMAIL, N.; VASILI, M. Maintenance optimization models: a review and analysis. IN: PROCEEDINGS OF THE 2011 INTERNATIONAL CONFERENCE ON INDUSTRIAL ENGINEERING AND OPERATIONS MANAGEMENT, Kuala Lumpur, Malaysia, 2011 p.1131-1138.
- VINODH, S.; VARADHARAJAN, A.R. Application of fuzzy VIKOR for concept selection in agile environment. *International Journal of Advanced Manufacturing Technology* 42:1025–1033, 2012.
- XIA, T.; XI, L.; ZHOU, X.; DU, S. Modeling and optimizing maintenance schedule for energy systems subject to degradation. *Computers & Industrial Engineering*, 63: 607-614, 2012.
- WANG, H.; PHAM, H. *Reliability and Optimal Maintenance*. London, Springer, 2006.
- ZHOU, X.; XI, L.; LEE, J. Reliability-centered predictive maintenance scheduling for a continuously monitored system subject to degradation. *Reliability Engineering and System Safety*, 92(04): 530-534 2007.