

ABORDAGEM MULTI OBJETIVO PARA DECISÕES SOBRE A POLÍTICA DE SUBSTITUIÇÃO DE UM SISTEMA SUJEITO A REPAROS IMPERFEITOS VIA ALGORITMO GENÉTICO MULTI OBJETIVO E SIMULAÇÃO DISCRETA DE EVENTOS

Rafael Valença Azevedo
azevedo144@hotmail.com

Márcio das Chagas Moura
marciocmoura@gmail.com

Enrique López Droguett
ealopez@uol.com.br

Universidade Federal de Pernambuco (UFPE), Departamento de Engenharia de Produção (DEP),
Centro de Estudos e Ensaio em Risco e Modelagem Ambiental (CEERMA).
Av. da Arquitetura S/N, Cidade Universitária, CEP: 50740-550, Recife-PE.

RESUMO

Grande parte dos sistemas complexos de engenharia está sujeito a ações de reparos imperfeitos. Modelos de otimização da manutenção que negligenciam a oportunidade de reparos imperfeitos podem ser ineficientes para alguns casos práticos. Este artigo apresenta um modelo multiobjetivo de decisão simultânea da política de substituição e da quantidade de sobressalente para sistemas sujeitos a reparos imperfeitos. Processos de Renovação Generalizados (PRG) são utilizados para modelagem do reparo imperfeitos e uma combinação de Algoritmos Genéticos (AG) Multiobjetivos com Simulação Discreta de Eventos (SDE) é proposta para busca da solução. Este trabalho demonstra a aplicabilidade de modelos que consideram reparos imperfeitos, ressaltando que a consideração de uma eficácia de reparo diferente da realidade pode conduzir a soluções inverídicas.

PALAVRAS CHAVE. Políticas de Substituição, Processo de Renovação Generalizado, Algoritmo Genético Multiobjetivo.

Área principal (indique, em ordem de prioridade a área de conhecimento de seu artigo pois o sistema JEMS coloca em ordem alfabética)

ABSTRACT

Engineering complex systems are subject to imperfect repair actions. Maintenance optimization models that neglect the opportunity to imperfect repairs may be inefficient for some practical cases. This paper presents a multi-objective model of simultaneous decision of the substitution policy and the amount of spare to systems subject to imperfect repairs. Generalized Renewal Process (GRP) is used for modeling imperfect repair and a combination of Multi-objective Genetic Algorithm (GA) with Discrete Event Simulation (SDE) is proposed to search for solutions. This study demonstrates the applicability of models that consider imperfect repairs, noting that consideration of a repair effective different from reality can lead to solutions untrue.

KEYWORDS. Replacement Policies, Generalized Renewal Process, Multi-objective Genetic Algorithm.

Main area (inform by priority the area of the article because JEMS system makes the classification alphabetically)

1. Introdução

O papel da manutenção em sistemas modernos de manufatura tem se tornado ainda mais importante, com companhias adotando as atividades estratégicas da manutenção como um elemento de negócio gerador de lucro, impulsionando o sistema produtivo a operar de forma mais eficiente, eficaz e econômica, para sustentar a sua sobrevivência em longo prazo (Almeida & Souza, 2001). Logo, dentro da indústria e da comunidade acadêmica cresce consideravelmente o número de trabalhos que buscam melhores políticas de manutenção, levando em consideração aspectos pertinentes à prática produtiva (Sharma *et al*, 2011). Este tipo de modelagem, em geral, consiste no desenvolvimento de funções matemáticas que representam objetivos de interesse nas atividades de manutenção em termos da(s) variável(eis) para a(s) qual(ais) o gestor de manutenção deve definir um valor associado.

Jiang & Ji (2002) e Sharma *et al* (2011) criticam que, em geral, problemas de otimização da política de substituição são tratados em uma abordagem monobjetivo, onde apenas uma função objetivo é formulada, normalmente representando custos de manutenção ou, menos frequentemente, disponibilidade do sistema. Ambos os autores ressaltando que alguns eventos indesejáveis, como acidentes e atrasos de produção, não são quantificados na avaliação dos custos de manutenção e, portanto, defendem uma abordagem multiobjetivo que considera critérios relacionados à confiabilidade e segurança do sistema, além do custo, quando da decisão em manutenção.

Através de métodos de análise de processos estocásticos (Rausand & Oien, 1996), é possível avaliar características de confiabilidade e segurança de sistemas produtivos. Esse tipo de análise consiste na modelagem do comportamento aleatório dos tempos de falha de sistemas, bem como dos tempos de reparo, de forma que operações futuras de tais sistemas possam ser compreendidas e funções de interesse possam ser estimadas. Com isso, espera-se que as métricas de confiabilidade representem os cenários modelados. Entretanto, grande parte dos modelos estocásticos utiliza hipóteses simplificadoras, as quais, conservadoras ou não, não conseguem representar de forma fidedigna alguns sistemas, sendo ineficientes para tais casos reais.

Por exemplo, de maneira geral, uma ação de reparo pode ser classificada em cinco maneiras diferentes em relação ao grau de melhoria que proporcionam ao sistema: (i) reparo melhor - recupera o sistema a um estado melhor do que era quando novo; (ii) reparo perfeito - retorna o sistema a um estado igual a novo; (iii) reparo imperfeito - traz o sistema a um estado pior do que um novo, mas melhor do que no instante da falha; (iv) reparo mínimo - traz o sistema ao mesmo estado que se encontrava no instante da falha; (v) reparo pior - retorna o sistema a um estado pior do que antes da falha. Por questões de simplicidade, diversos modelos existentes na literatura assumem as hipóteses de reparo perfeito ou reparo mínimo tratando estas situações, respectivamente, através de Processos de Renovação (PR) ou Processos Não Homogêneos de Poisson (PNHP). Todavia, em sistemas reparáveis diversas ações de reparo melhora o desempenho do equipamento a uma condição intermediária entre o reparo perfeito e o reparo mínimo, anteriormente definido como reparo imperfeito (Moura *et al*, 2007).

Kijima & Sumita (1986) propuseram um modelo probabilístico que trata reparos imperfeitos denominado de Processo de Renovação Generalizado (PRG). O PRG é um modelo de idade virtual, que determina o tipo do reparo de acordo com o grau de redução que proporciona sob a idade operacional do sistema, mensurada através de um parâmetro q de rejuvenescimento. Alguns autores, como Kijima *et al* (1988), Makis & Jardine (1993), Love *et al* (2000) propuseram modelos de otimização da política de substituição, considerando que, antes do instante definido para a substituição preventiva, o sistema pode sofrer reparos imperfeitos, se vier a falhar, ou ser substituído. Ambos os autores utilizaram PRG para modelagem do reparo imperfeito. Entretanto, todos eles consideraram apenas critérios de custo de manutenção para determinação da política ótima de substituição.

Nossohi & Hejazi (2011) propuseram um modelo multiobjetivo para determinação simultânea de intervalos de substituição e quantidade de peças sobressalente, considerando a taxa média de custo de manutenção, o número esperado de falhas por ciclo de substituição, a vida residual média do sistema e o investimento em sobressalentes como critérios de decisão, tendo a

disponibilidade por restrição. Todavia, Nossahi & Hejazi (2011) não consideram a possibilidade de reparos imperfeitos no modelo, ou seja, o sistema é substituído na primeira falha.

Apesar do crescimento dos estudos envolvendo reparos imperfeitos nos últimos anos, com diversos conceitos e técnicas de estimação para os mais variados casos (ver Pham & Wang, 1996), a aplicabilidade destes modelos, em especial PRG, na modelagem de sistemas reparáveis ainda é limitada, principalmente, devido à complexidade matemática. Não foram encontradas publicações de modelos de decisão multiobjetivo da política de substituição para sistemas sujeitos a reparos imperfeitos, modelos via PRG.

A utilização do PRG para modelagem dos tempos entre falhas do sistema, quando da ação de um reparo imperfeito, pode tornar complexo um tratamento analítico para avaliação das funções de confiabilidade de interesse do modelo. Conforme Banks (2001), uma alternativa possível é a utilização da Simulação Discreta de Eventos (SDE) para tentar imitar o comportamento do sistema e obter uma aproximação média das funções desejáveis.

Ainda, a natureza combinatória de problemas de otimização multiobjetivo de políticas de substituição pode tornar proibitivo o uso de procedimentos exaustivos. A classe de problemas de tomada de decisão computacionalmente tratáveis com as tecnologias de otimização disponíveis inclui cada vez mais aspectos de estocasticidade. Neste contexto, heurísticas de otimização probabilísticas, como Algoritmos Genéticos (AG), podem fornecer soluções de uma maneira inteligente (Goldberg, 1989). Assim, neste artigo, um método combinado de SDE e AG Multiobjetivo será proposto. Sharma *et al* (2011) destacam a tendência dessa hibridização na solução de problemas complexos da otimização da manutenção.

Este artigo tem como objetivo propor um modelo multiobjetivo de otimização simultânea da política de substituição e da quantidade de sobressalentes para sistemas sujeitos a reparos imperfeitos, modelados via PRG. AG Multiobjetivo e SDE serão utilizados para busca e avaliação das soluções. Este artigo está organizado como segue: A seção 2 discute os principais conceitos teóricos necessários à compreensão do modelo, a seção 3 apresenta o modelo proposto para determinação da política de substituição e da quantidade de sobressalentes e a seção 4 apresenta um exemplo de aplicação e discute os resultados. Conclusões são feitas na seção 5.

2. Fundamentação Teórica

Esta seção apresenta os principais conceitos das teorias propostas na metodologia e referencia alguns trabalhos que servirão de base literária para o desenvolvimento do modelo proposto no capítulo 3. Primeiramente, os conceitos de Processos de Renovação Generalizados, Otimização Multiobjetivo e Algoritmos Genéticos são apresentados. Posteriormente, uma seção resume a literatura base.

2.1. Processo de Renovação Generalizado (PRG)

O Processo de Renovação Generalizado (PRG) é um processo estocástico pontual, pertencente à classe de modelos de idade virtual, utilizado para modelagem dos tempos entre falhas de sistemas reparáveis considerando os efeitos da eficácia dos reparos, representada pelo parâmetro de rejuvenescimento q . Em resumo, se a i -ésima falha do sistema ocorre no instante x_i (idade real do equipamento), após ser reparado, o sistema desempenhará sua função como se tivesse com uma idade y_i (idade virtual). A relação entre x_i e y_i dependerá do tipo de reparo, ou seja, do valor assumido por q . A Figura 1 ilustra esta relação para três valores diferentes de q .

Em (a) tem-se um “reparo perfeito”, em (b) um “reparo mínimo” e em (c) um “reparo imperfeito” que é uma generalização dos demais. Outros valores para o parâmetro q são também possíveis, como $q < 0$ e $q > 1$ que correspondem ao “reparo melhor” e ao “reparo pior”, respectivamente. Logo, o parâmetro q é também denominado de eficácia da manutenção, podendo modelar todos os tipos de reparos citados.




Figura 1 - Relação entre idade virtual e idade real.

Como já dito, a eficácia da manutenção, q , determinará o valor de y_i e sua relação com x_i . Em Kijima e Sumita (1986) foram propostos dois tipos de modelos de idade virtual. O primeiro, chamado de *Kijima tipo I*, fundamenta-se na ideia que o i -ésimo reparo atua apenas nos danos acumulados entre a $i-1$ e a i -ésima falha (h_i). O segundo, chamado de *Kijima tipo II*, considera que o reparo pode atuar nas falhas decorrentes de todo intervalo operacional, logo, a idade virtual sofre incrementos proporcionais durante todo o intervalo. As Equações (01) e (02) ilustram as relações entre a idade virtual e a idade real, em função de q , para o *Kijima tipo I* e para o *Kijima tipo II*, respectivamente.

$$y_i = y_{i-1} + q \cdot h_i = qx_i \quad (01)$$

$$y_i = q(h_i + y_{i-1}) = q(q^{i-1}h_1 + q^{i-2}h_2 + \dots + h_i) \quad (02)$$

Qualquer que seja o modelo Kijima considerado é possível prever o intervalo h_i compreendido pelo tempo decorrido entre a $i-1$ e a i -ésima falha através da função de distribuição acumulada do tempo até a primeira falha do sistema, condicionada à idade virtual y_{i-1} , conforme visto na Equação (03):

$$F(h_i|y_{i-1}) = P(T \leq h_i | T \geq y_{i-1}) = \frac{F(h_i + y_{i-1}) - F(y_{i-1})}{1 - F(y_{i-1})} \quad (03)$$

onde $F(\cdot)$ é a função de distribuição acumulada do tempo até a primeira falha.

Assim, o problema de caracterização de um PRG consiste em um problema de estimação dos parâmetros da distribuição do tempo da primeira falha e do parâmetro de rejuvenescimento q .

2.2. Algoritmos Genéticos Multiobjetivo

O Algoritmo Genético (AG) é uma técnica de busca fundamentada no processo evolutivo de seleção natural proposto por Charles Darwin e nos mecanismos da genética. Foram inicialmente propostos por John Holland (1975). Em problemas de otimização, os AG's transformam uma população de indivíduos (possíveis soluções do problema), numa nova geração de indivíduos "melhores" usando os princípios Darwianos de reprodução e sobrevivência dos mais aptos, pela aplicação de operações genéticas tais como seleção, recombinação e mutação (Goldberg, 1989), buscando aquela solução que seja muito boa, ou a melhor para o problema analisado. A Figura 2 ilustra as etapas genéricas de um AG.

Em problemas multiobjetivo, devido à propriedade de conflito entre as funções objetivo (*tradeoff*), pode não ser possível obter uma solução que seja a melhor em todos os critérios, dentre as avaliadas. A principal diferença entre o AG monobjetivo e o AG multiobjetivo são as fases de avaliação e seleção dos indivíduos (Lins & Droguett, 2011). O conceito de dominância e de otimalidade de Pareto é comumente utilizado em problemas multiobjetivo. Dessa forma, o AG multiobjetivo busca amostrar uma fronteira de Pareto, um conjunto de soluções não dominadas, que convirja para a real fronteira de Pareto do problema, mantendo, a cada passo, uma população de indivíduos a uma distribuição tão uniforme quanto possível das reais soluções não dominadas. A menos que um processo de preferência de solução seja implementado, um AG multiobjetivo

fornece, como solução, um conjunto de indivíduos não dominados pertencentes à fronteira de Pareto. Para um maior entendimento dos conceitos de dominância e otimalidade de Pareto em AG's Multiobjetivo, ver Castro (2011).

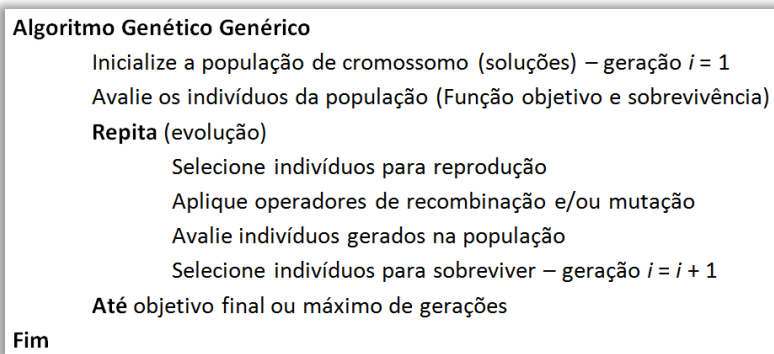


Figura 2 – Etapas do AG Genérico
Fonte: Castro (2011)

3. Modelo Multiobjetivo para determinação simultânea da política de substituição e da quantidade de sobressalentes para sistemas sujeitos a reparos imperfeitos

Nesta seção é apresentado um modelo para otimização simultânea da política de substituição e da quantidade de peças sobressalentes, a ser comprada no início de um horizonte de planejamento, tendo como foco sistemas reparáveis sujeitos a reparos imperfeitos. O modelo é multiobjetivo e o reparo imperfeito é modelado via PRG. Será utilizado o caractere x para representar o tempo operacional de vida do sistema, sem considerar as paradas para manutenção; o tempo de vida de calendário do sistema, considerando os tempos de manutenção, é representado pela letra t . A técnica de solução utilizada é baseada em AG Multiobjetivo, onde os valores dos objetivos de cada solução são obtidos por Simulação Discreta de Eventos (SDE), mais especificamente a Simulação Monte Carlo (SMC). A Figura 3 resume os passos da metodologia aplicada neste trabalho.

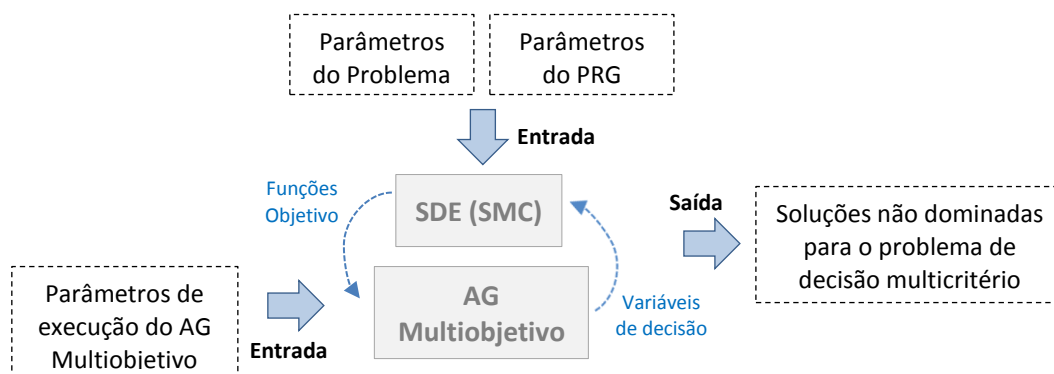


Figura 3 - Metodologia

3.1. Definição do Problema

Deseja-se definir o intervalo ótimo de substituição (T) de um sistema sob as seguintes hipóteses iniciais: (1) O sistema é substituído em T e (2) é reparado por um reparo imperfeito se falhar antes de T . Ainda, semelhante a Love *et al* (2000) é definido um valor máximo de falhas (m) antes da substituição, tratado, aqui, como variável de decisão, ampliando o número de combinação de soluções possíveis em comparação a Love *et al* (2000). Assim, seja t_m a idade real do sistema na m -ésima falha, a substituição pode ser realizada de duas maneiras:

1. Substituição planejada: o equipamento é substituído em T , se $t_m \geq T$;

2. Substituição corretiva: o equipamento é substituído em t_m , se $t_m < T$.

Como o instante t_m é incerto e varia a cada ciclo, não é possível saber, com certeza, o número e os momentos exatos de substituição em cada ciclo. Assim, melhores resultados de custo, investimento e disponibilidade podem ser obtidos comprando um lote de sobressalentes (y) no início de um horizonte de tempo, assim é viável definir, também, y como variável de decisão do modelo e um parâmetro H que representa o horizonte de planejamento da política de substituição. Jiang & Ji (2002) destaca a tendência atual de inclusão de variáveis de decisão ao modelo, implicando na possibilidade de obtenção de melhores soluções.

Assim, T , y e m são as variáveis de decisão do problema. T e m definem a política de substituição e y o recurso de manutenção. Recursos de mão-de-obra e de materiais que influenciam o tempo e a eficácia da manutenção são considerados como parâmetros do problema implícitos nos valores médios dos tempos de manutenção e do parâmetro q do PRG. Não há outras ações de manutenção que resultem em paradas do equipamento ou em alterações no seu estado de desempenho, apenas os reparos imperfeitos e as substituições são considerados.

3.2. Modelo Multiobjetivo

O modelo multiobjetivo apresentado nesta seção se baseia nas funções objetivo do modelo de, incluindo a possibilidade de ocorrência de reparos imperfeitos nas falhas anteriores a T . Além dos 4 objetivos definidos em Nossohi & Hejazi (2011) (taxa média de custo de manutenção, número esperado de falhas corretivas por ciclo de substituição, vida residual média e o investimento em sobressalente), a disponibilidade, tratada como restrição pelos autores, é também função objetivo do modelo proposto neste artigo. Uma vez que, no modelo de Nossohi & Hejazi (2011), não há reparos imperfeitos, sendo o sistema substituído sempre que falhar, o modelo aqui proposto pode ser considerado uma generalização do modelo de Nossohi & Hejazi (2011), sendo este um caso específico do modelo aqui apresentado para o caso em que $m = 1$. As seções seguintes apresentam as funções do modelo multiobjetivo.

3.2.1. Taxa média de Custo de Manutenção

Este objetivo consiste em minimizar a taxa média do custo da manutenção (TC) em um ciclo de substituição. A função taxa média de custo de manutenção é definida na Equação (04), onde $C_R(i)$ é o custo do i -ésimo reparo imperfeito, C_P e C_S são os custos das substituições preventiva e corretiva, respectivamente, e S_P e S_C são, concomitantemente, os tempos médios das substituições preventiva e corretiva. É possível demonstrar que $P(t_m \geq T) = \sum_{i=0}^{m-1} P(t_i < T \cap t_{i+1} \geq T)$, assim, TC é ponderada pela confiabilidade e pela distribuição de probabilidade acumulada do tempo da m -ésima falha. O numerador corresponde ao custo médio de manutenção por ciclo e o denominador ao tempo esperado do ciclo.

$$TC = \frac{\sum_{i=0}^{m-1} [C_R(i) + C_P] P(t_i < T \cap t_{i+1} \geq T) + [C_R(m-1) + C_S] P(t_m < T)}{(T + S_P) P(t_m \geq T) + (T + S_C) P(t_m < T)} \quad (04)$$

Sejam C_{P1} e C_{S1} os custos da substituição preventiva e corretiva, utilizando o sobressalente comprado no início do horizonte, e C_{P2} e C_{S2} os mesmos custos, porém, utilizando um sobressalente comprado por demanda durante o horizonte, e seja P_{est} a probabilidade de se ter sobressalente em estoque, quando da substituição, então $C_P = C_{P1} P_{est} + C_{P2} (1 - P_{est})$ e $C_S = C_{S1} P_{est} + C_{S2} (1 - P_{est})$. O mesmo raciocínio pode ser utilizado para S_P e S_C , onde S_{P1} e S_{C1} são os tempos médios das substituições com sobressalente em estoque e S_{P2} e S_{C2} são os tempos médios das substituições sem sobressalente em estoque.

3.2.2. Número Esperado de Falhas

O número esperado de falhas corretivas em um ciclo é dado pela Equação (05). Cada parcela da equação corresponde a um número possível de falhas em um ciclo multiplicado pela probabilidade de ocorrer tal quantidade de falhas no ciclo. Em um ciclo pode-se ter, no máximo, m falhas; a probabilidade de ocorrerem m falhas no ciclo é a probabilidade de $t_m < T$.

$$N_f = \sum_{i=0}^{m-1} i \times P(t_i < T \cap t_{i+1} \geq T) + m \times P(t_m < T) \quad (05)$$

3.2.3. Vida Residual Esperada

A fim de ampliar o tempo de vida útil do sistema, é interessante que a substituição ocorra imediatamente antes da ocorrência de falha, censurando um pequeno tempo de utilização do serviço do sistema. Isto implica em manutenção oportuna e no uso suficiente da vida útil do sistema. Neste objetivo, buscamos minimizar o tempo esperado de vida restante no momento da substituição preventiva em cada ciclo. Considerando que a vida útil do sistema se encerra em t_m , a vida residual média é dada pela Equação (06).

$$Res = \int_T^{\infty} (t - T) f_{t_m}(t) dt = E(t_m - T | t_m \geq T) P(t_m \geq T) \quad (06)$$

3.2.4. Disponibilidade Média

A disponibilidade é sempre um objetivo de interesse na manutenção, tendo influência direta em prazos de entrega do produto final. A função disponibilidade é, portanto, definida pela Equação (07), onde o numerador corresponde ao tempo médio operacional do sistema por ciclo, onde Rep é o tempo médio do reparo imperfeito e τ_m é o tempo médio da m -ésima falha, dado que ela ocorra antes de $T - E(t_m | t_m < T)$.

$$A = \frac{\sum_{i=0}^{m-1} (T - i \cdot Rep) P(t_i < T \cap t_{i+1} \geq T) + [\tau_m - (m - 1) \cdot Rep] P(t_m < T)}{E(C)} \quad (07)$$

3.2.5. Investimento

Este é um objetivo de termos práticos, sem relação com o comportamento de falha/reparo do sistema. Economizando em orçamento de peças sobressalentes, mais orçamento estará disponível para ser utilizado em outros planos de investimento. A função investimento seria dada pela Equação (08), onde C_y é o preço do sobressalente, comprado em lote, e g é custo fixo envolvido na compra.

$$I = g + yC_y \quad (08)$$

3.2.6. Restrições

Naturalmente, há uma restrição para a quantidade mínima de sobressalentes a ser comprada no início do horizonte de planejamento. O maior tempo de ciclo possível é aquele que o sistema é substituído em T , portanto, ao longo do horizonte de planejamento, o sistema sofrerá, no mínimo, $H/T + S_{P1}$ substituições, onde H é o horizonte de planejamento e S_{P1} é o tempo médio da substituição preventiva com sobressalente em estoque. Esta observação corresponde a uma restrição do limite inferior de y , em função de um dado valor de T , logo, o valor de y deve ser maior ou igual a $H/T + S_{P1}$.

Ainda, na maioria dos casos práticos, há uma restrição de orçamento para compra de sobressalente e um valor mínimo aceitável de disponibilidade do sistema. Dessa forma, as Equações (09), (10) e (11) apresentam as restrições do modelo, onde L representa o orçamento disponível e d a mínima disponibilidade aceitável para o sistema analisado:

$$\text{Quantidade mínima de sobressalente: } y \geq H/T + S_{P1} \quad (09)$$

$$\text{Orçamento máximo: } g + yC_y \leq L \quad (10)$$

$$\text{Disponibilidade mínima: } A \geq d \quad (11)$$

3.3. Algoritmo Genético Multiobjetivo

Esta seção resume o Algoritmo Genético Multiobjetivo utilizado neste trabalho. Seja N o tamanho fixado da população P , $P[i]$ o i -ésimo indivíduo de P (que representa uma solução do problema), cada indivíduo tem um vetor *fitness* associado de tamanho igual ao número de

objetivos considerados, onde cada posição do vetor armazena o valor de uma função objetivo da respectiva solução/indivíduo. P_{aux} é a população auxiliar que armazena indivíduos não dominados, atualizada a cada iteração, os passos e características do Algoritmo proposto são demonstrados a seguir:

I. Representação dos Indivíduos – Consiste em definir um intervalo admissível de busca para cada variável do modelo. Seja H o horizonte de planejamento e $m_{máx}$ o valor máximo aceitável de falhas em um ciclo, pode-se definir que $T \in (0, H]$ e $m \in [1, m_{máx}]$ são os intervalos admissíveis de T e m . Pela restrição de orçamento é possível determinar um intervalo admissível para y fazendo: $y \in [0, \text{menor inteiro da razão entre } (L - s) \text{ e } C_y]$;

II. Geração da população inicial – Cada um dos N indivíduos da população inicial é gerado a partir da obtenção aleatória de N valores para cada uma das variáveis de decisão dentro dos intervalos definidos na Etapa I. Indivíduos inviáveis podem ser gerados;

III. Seleção e atualização de P_{aux} – Nesta etapa, a relação de dominância entre os indivíduos é avaliada de acordo com o valor de *fitness* de cada indivíduo. Aqui, o AG chama o algoritmo de simulação para calcular o vetor de *fitness* das soluções. Indivíduos inviáveis recebem uma penalidade no seu vetor de *fitness* de forma que este seja muito ruim. Primeiramente, a relação de dominância é avaliada entre pares de indivíduos de P e os indivíduos dominados são descartados e o tamanho de P é reduzido para N_{aux} . Em seguida, P_{aux} é atualizada de acordo com as seguintes regras: (i) se uma solução de P é dominada por algum indivíduo de P_{aux} , ela é descartada; (ii) se uma solução de P domina indivíduos em P_{aux} , todos esses são deletados de P_{aux} e uma cópia da solução dominante é armazenada em P_{aux} ; (iii) soluções de P que não dominam e não são dominadas são inseridas em P_{aux} . Para manter P com N indivíduos, $N - N_{aux}$ soluções são selecionadas aleatoriamente de P_{aux} e inseridas em P .

IV. Crossover – Após a etapa III, um número aleatório entre 0 e 1 é gerado para cada indivíduo em P . Se este número é menor do que a probabilidade de *crossover* (p_{cr}) o indivíduo participará do *crossover*. Cada par de indivíduos que participam do *crossover* (pais) troca os valores armazenados de k variáveis de decisão fim de gerar os filhos;

V. Substituição – No *crossover*, dois filhos são gerados. A estratégia de substituição adotada é “Filhos substituem Pais”, ou seja, após o *crossover*, os pais são imediatamente substituídos pelos seus respectivos filhos, independentemente das possíveis relações de dominância entre eles;

VI. Mutação – A etapa de Mutação consiste na mudança do conteúdo de uma posição no fenótipo do indivíduo. Se uma posição j é selecionada de acordo com a probabilidade de mutação predefinida (p_m), seu conteúdo é substituído por um valor aleatório uniformemente gerado nos intervalos definidos na etapa I.

Os passos III, IV, V e VI são repetidos N_{gen} vezes. N_{gen} é o número predefinido de gerações, o qual também corresponde ao critério de parada do algoritmo. Os indivíduos inviáveis são retirados apenas na etapa III. No fim, o algoritmo retorna os indivíduos não dominados de P_{aux} . A seção seguinte descreve o algoritmo da SDE aplicada para avaliação de *fitness*.

3.4. Simulação Discreta de Eventos

A solução do modelo multiobjetivo apresentado neste capítulo acopla o AG Multiobjetivo com técnicas de Simulação Discreta de Eventos (SDE), mais necessariamente a Simulação Monte Carlo (SMC) (Kaminskiy & Krivtsov, 1998). Esta hibridização ocorre no momento da avaliação do *fitness* dos indivíduos, na etapa de seleção e atualização de P_{aux} . As subseções seguintes apresentam os passos da SMC aplicados para estimação dos valores das funções objetivos de um indivíduo $P[i]$.

3.4.1. Geração dos tempos de falha

O primeiro passo do processo de simulação é a geração dos instantes de falha do equipamento. Pela definição do problema, o equipamento pode sofrer, no máximo, m falhas a

cada ciclo, logo, são gerados apenas os instantes das m possíveis falhas. Seja o tempo da primeira falha distribuído por um Weibull, os tempos entre falhas de um PRG com parâmetros α , β e q podem ser gerados pelo método da Transformada Inversa conforme demonstrado em Yañez *et al* (2002) para o modelo *Kijima Tipo I*, demonstrado na Equação (12).

$$x_i = \alpha \left[\left(\frac{q}{\alpha} \sum_{j=1}^{i-1} x_j \right)^\beta - \ln(u) \right]^{1/\beta} - q \sum_{j=1}^{i-1} x_j \quad (3.9)$$

Todavia, x_i corresponde a um tempo operacional do sistema, sem considerar o tempo do reparo. Para obter os tempos reais entre falhas, é, ainda, gerado o tempo dos reparos pelo método da Transformação Inversa assumindo que seguem uma distribuição exponencial, segundo Equação (3.10). Assim, os tempos reais de cada uma das m falhas são armazenados em um vetor $t[]$ de tamanho m .

$$x_{rep} = \frac{1}{\mu} [-\ln(1-u)] = Rep[-\ln(1-u)] \quad (3.10)$$

3.4.2. Estimação das Funções Objetivo

Os m primeiros instantes de falha do sistema, gerados conforme seção 3.4.1, são comparados com T , caracterizando um ciclo de substituição. O tempo da substituição é gerado pelo Método da Transformada Inversa assim como o tempo do reparo (ver equação 3.10) e duas variáveis acumulam o tempo de calendário e o número de substituições (N). N é comparado com y para avaliar as substituições com e sem sobressalente em estoque. Quando o tempo de calendário ultrapassa H , uma simulação é concluída. N_s simulações são realizadas e os elementos de probabilidade e tempos médios, presentes nas funções do modelo multiobjetivo podem ser determinados das seguintes formas:

- $P(t_i < T \cap t_{i+1} \geq T) =$ Proporção dos casos em que $t_i < T$ e $t_{i+1} \geq T$ ($j = 0, 1, \dots, m-1$);
- $P(t_m < T) =$ Proporção dos casos em que $t_m < T$;
- $P_{est} =$ Proporção dos casos em que a substituição ocorre com sobressalente em estoque;
- $\tau_m = E(t_m | t_m < T) =$ Valor médio de t_m para os casos em que $t_m < T$;
- $E(t_m - T | t_m \geq T) =$ Valor médio de $t_m - T$ para os casos em que $t_m \geq T$.

4. Aplicação e análise dos resultados

O modelo da seção anterior foi aplicado em um exemplo de ilustração. Os parâmetro do PRG são $\alpha = 3072$ hrs = 4,2667 meses, $\beta = 1,62$ e $q = 0,7$. O tempo de missão do equipamento é $H = 48$ meses e determinou-se que $m \in [1, 10]$. O custo do reparo imperfeito varia com o número de reparos realizados no equipamento, conforme função definida em Love *et al* (2000). Os valores de cada parâmetro do problema são apresentados a seguir:

$$C_y = 800\$; L = 10000\$; d = 0,9; C_{S1} = 1500\$; C_{S2} = 1900\$; C_{P1} = 1300\$; \\ C_{P2} = 1700\$; g = 0; S_{P1} = 0,04; S_{P2} = 0,05667; S_{C1} = 0,05; S_{C2} = 0,08.$$

Os algoritmos descritos nas seções 3.3 e 3.4 foram implementados em linguagem de programação C++, com $N = 200$ (tamanho da população), $p_{cr} = 0,95$ (probabilidade de *crossover*), $p_m = 0,1$ (probabilidade de mutação), $N_{gen} = 400$ (número de gerações) e $N_s = 1000$ (Número de simulações). Foram obtidas 288 soluções que formam o conjunto de soluções não dominadas de pareto. A Figura 4 ilustra um gráfico com os valores normalizados das funções objetivo em cada solução. Observou-se que as soluções possuem ou bons ou ruins valores para TC , com poucos valores intermediários. Nota-se que as funções TC e A possuem uma correlação direta, assim como as funções N_f e Res . Porém, a medida que TC e A crescem, N_f e Res decrescem suavemente. O Investimento, logicamente, varia aleatoriamente.

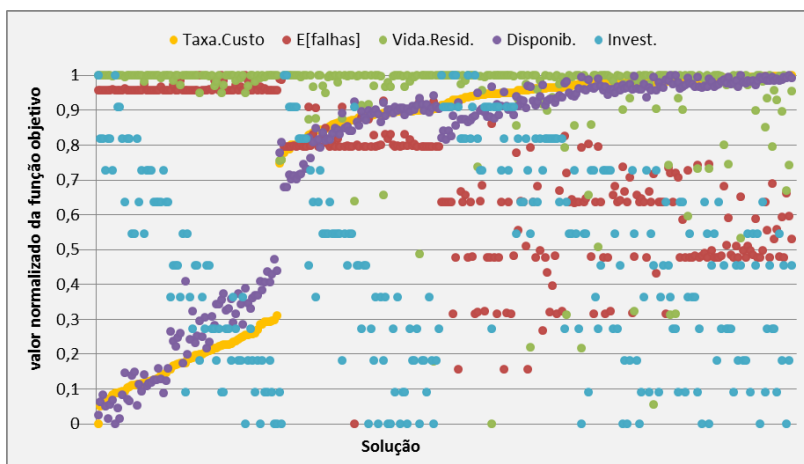


Figura 4 – Valores normalizados das funções objetivo para cada uma das 288 soluções não dominadas.

Ainda, a fim de analisar o impacto de diferentes tipos de reparo nas decisões, o mesmo exemplo de aplicação foi resolvido três vezes, cada um considerando um tipo de reparo (mínimo, imperfeito e perfeito). Para o reparo imperfeito foi-se adotado $q = 0,5$. A Tabela 1 mostra o número de soluções não dominadas em cada situação. As Figuras 5, 6 e 7 mostram o mesmo tipo de gráfico da Figura 4 para os três novos exemplos. Verificou-se que, quanto maior a eficácia da manutenção, maior o número de soluções não dominadas obtidas pelo modelo. Este comportamento é observado na literatura (Lins & Droguett, 2011), apesar de não ter uma comprovação teórica. Observou-se, também que a eficácia do reparo não influencia na relação entre os valores das funções objetivos das soluções da fronteira de pareto. Todavia, a análise é válida para demonstrar possíveis desvios das soluções reais que podem ser obtidos com hipóteses irrealistas sobre a eficácia do reparo no sistema. Todos os experimentos foram realizados em um PC com sistema operacional Windows®, processador 2.5 GHz e 3GB de memória RAM.




Figura 5 - Valores normalizados das funções objetivo para as soluções do problema com $q = 0$.

Tabela 1 – Soluções não dominadas do exemplo de aplicação considerando diferentes tipos de reparo.

q	número de soluções não dominadas
0	356
0,5	144
1	139

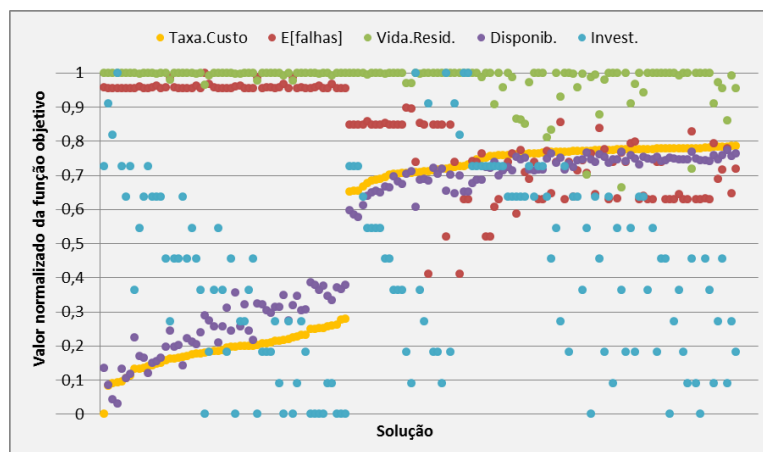


Figura 6 – Valores normalizados das funções objetivo para as soluções do problema com $q = 1$.




Figura 7 – Valores normalizados das funções objetivo para as soluções do problema com $q = 0,5$.

5. Conclusão

Este artigo apresentou uma abordagem multiobjetivo para decisão simultânea da política e de manutenção e da quantidade de sobressalentes a ser comprada no início de um horizonte de planejamento para sistemas sujeitos a reparos imperfeitos modelados segundo um Processo de Renovação Generalizado. A solução foi obtida pela combinação emergente de Algoritmos Genéticos com a Simulação Discreta de Eventos, mais especificamente a técnica de Simulação Monte Carlo.

Cinco objetivos foram considerados, representando funções de interesse para o decisor em casos reais. Para as soluções não dominadas do caso de aplicação, a disponibilidade e a taxa de custo crescem à medida que a vida residual esperada e o nº esperado de falhas decrescem suavemente, mas, a maioria das soluções possui um bom valor de vida residual esperada. O investimento varia aleatoriamente, pois possui uma relação linear com a quantidade de sobressalente comprada no início do horizonte de planejamento. Verificou-se que a eficácia de reparo não altera o comportamento da fronteira de pareto, mas pode definir valores inverídicos para as funções objetivos e, portanto, soluções dominadas na fronteira de pareto.

Entre as principais vantagens do PRG pode-se citar sua flexibilidade para tratar os diferentes tipos de reparo (inclusive os reparos mínimo e perfeito), além de agregar estimativas de eficácia do serviço prestado pela equipe de manutenção para um reparo específico, sendo eficiente na modelagem de sistemas reparáveis. Todavia, devido à dificuldade de se obter um tratamento analítico, ainda é defasada a aplicação do PRG em diversos problemas da manutenção. A Simulação Discreta de Eventos é importante neste sentido. Algoritmos de Simulação Discreta de Eventos possuem boa interface com o Algoritmo Genético, já que este

último depende apenas do valor de *fitness* de cada indivíduo da população, o que pode ser otimamente aproximado por Simulação.

A utilização de modelos com grande quantidade de funções objetivo e restrições, bem como variáveis, necessita de técnicas de busca de solução que amostram otimamente a fronteira de Pareto, dada uma quantidade finita de recursos computacionais. Amostragem otimamente implica em obter e manter soluções não dominadas que se distribuam uniformemente por toda a fronteira de Pareto. Esta é a principal razão pela qual as heurísticas populacionais probabilísticas são reconhecidas como as mais adequadas para a busca de solução de problemas de otimização multiobjetivo de elevada dimensão, dentre as quais o AG Multiobjetivo está entre as mais competitivas.

6. Referências

- Almeida, A. T. & Souza, F. M. C.** *Gestão da Manutenção. Na direção da competitividade*, Editora Universitária/UFPE, Recife, PE, Brasil, 2001.
- Banks, J. et al.** *Discrete Event System Simulation*, 3ª ed, Upper Saddle River, Prentice Hall, 2001.
- Goldberg, D. E.** *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley, Reading, 1989.
- Holland, J. H.** *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor, 1975.
- Jiang, R.; Ji, P.** (2002) Age replacement policy: a multi-attribute value model, *Reliability Engineering and System Safety*, [s.l.], 76, 311-318.
- Kijima, M.; Sumita, N.** (1986) A useful generalization of renewal theory: counting processes governed by non-negative markovian increments, *Journal of Applied Probability*, [s.l.], 23, 71-78.
- Kijima, M.; Morimura, H.; Suzuki, Y.** (1988) Periodical replacement problem without assuming minimal repair, *European Journal of Operational Research*, 37, 194-203.
- Lins, I. D.; Droguett, E. A. L.** (2011) Redundancy allocation problems considering systems with imperfect repairs using multi-objective genetic algorithms and discrete event simulation, *Simulation Modeling Practice and Theory*, [s.l.], 19, 362-381.
- Love, C. et al.** (2000) A discrete semi-Markov decision model to determine the optimal repair/replacement policy under general repairs, *European Journal of Operational Research*, [s.l.], 125, 398-409.
- Makis, V.; Jardine, A. K. S.** (1993) A note on optimal replacement policy under general repair, *European Journal of Operational Research*, [s.l.], 69, 75-82.
- Moura, M. et al.** (2007) Avaliação bayesiana da eficácia da manutenção via processo de renovação generalizado, *Pesquisa Operacional*, Rio de Janeiro, Brasil, 27, 3, 569-589.
- Nossohi, I.; Hejazi, S. R.** (2011) A multi-objective approach to simultaneous determination of spare part numbers and preventive replacement times, *Applied Mathematical Modelling*, [s.l.], 35, 1157-1166.
- Pham, H.; Wang, H.** (1996) Imperfect Maintenance, *European Journal of Operational Research*, [s.l.], 94, 425-438.
- Rausand, M.; Oien, K.** (1996) The basic concepts of failure analysis. *Reliability Engineering and System Safety*, Northern Ireland, 53, 73-83.
- Sharma, A.; Yadava, G.S.; Deshmukh, S.G.** (2011) Reviews and Case Studies: a literature review and future perspectives on maintenance optimization, *Journal of Quality in Maintenance Engineering*, [s.l.], 17, 5-25.
- Yañez, M.; Joglar, F. e Modarres, M.** (2002), Generalized renewal process for analysis of repairable systems with limited failure experience, *Reliability Engineering and System Safety* [S.I.], 77, 167-180.