

Determinação de um cronograma de manutenção preventiva utilizando algoritmos genéticos em equipamento de beneficiamento de aços planos

Daniel Ferreira Flores (UFRGS) danielff.eng@gmail.com

Michel José Anzanello (UFRGS) anzanello@producao.ufrgs.br

Resumo: Em estudos de manutenção centrada na confiabilidade o uso de pesquisa operacional via algoritmos genéticos em problemas de otimização é relatado em abundância na literatura. O presente artigo traz adaptações no método proposto por Tsai et al. (2001) e sua integração a algoritmos genéticos na otimização de agenda de manutenções preventivas em uma máquina de beneficiamento de aços planos. Os resultados numéricos mostram a eficiência do método com base em algoritmos genéticos por conta de sua rápida convergência na resolução de problemas de manutenção. O cronograma de manutenção gerado pelo método encontrou sustentação na avaliação de especialistas de processo da empresa.

Palavras-Chave: Manutenção Centrada em Confiabilidade, algoritmos genéticos

Abstract: In reliability centered maintenance studies the use of optimization relying on Genetic Algorithms is widely available in current literature. This paper proposes modifications on the method suggested Tsai et al. (2001) and integrates it to genetic algorithms aimed at optimizing the preventive maintenance schedule in a steel processing mill. The Genetic Algorithm performed efficiently in term of its fast convergence. The suggested maintenance schedule was approved after experts' assessment.

Keywords: Reliability Centered Maintenance, genetic algorithms

1. INTRODUÇÃO

Métodos quantitativos e estatísticos são centrais para qualquer tomada de decisão baseada em dados e com fundamentação científica, seja gerencial ou técnica. A aplicação deste paradigma aos setores de manutenção das empresas resultou na MCC – Manutenção Centrada na Confiabilidade (*reliability-centered maintenance* ou RCM) (XENOS, 1998).

Juntamente com a difusão da MCC, o setor de manutenção passou por outras modificações tanto no seu estudo acadêmico quanto na aplicação no mercado. A manutenção passou a ser vista, por muitas empresas, como importante fator de competitividade e foi elevada do nível tático para o estratégico (PINJALA, 2006), tanto por sua direta ligação com performance industrial (SWANSON, 2001), quanto por questões emergentes como sustentabilidade (SUPPEN et al., 2006). O desenvolvimento de produtos também passou a incorporar preocupações de mantabilidade após o esgotamento das ópticas financeira, de marketing e industrial como fonte de grande vantagem competitiva (COULIBALY, 2008). Além disso, a maior difusão e implementação da produção enxuta a nível global trouxe consigo impacto positivo nos serviços de manutenção, ampliando a integração dos mesmos com a produção e abrindo caminho para a implantação da manutenção centrada na confiabilidade.

A empresa estudada atua nos setores de mineração, siderurgia e metalurgia. O foco do estudo é uma planta de transformação de bobinas de aços planos em tubos de aço, mais especificamente uma máquina formadora de tubos, que se trata da maior agregadora de valor da fábrica. A divisão de tubos da companhia possuía um programa de manutenção preventiva estruturado e rigorosamente aplicado. Porém, o mesmo deixou de ser executado com a diminuição de quadro de pessoal gerada pela crise financeira mundial, em 2009. O mercado novamente aquecido em 2010 demandou a retomada dos quadros de pessoal e conseqüente reimplantação da manutenção preventiva, a fim de viabilizar as metas de produção do ano, já que as paradas de máquinas por manutenção corretiva e pouca estruturação nos procedimentos de manutenção preventiva acabam por afetar a eficiência da planta.

Dessa forma, o objetivo do artigo é propor uma agenda de manutenção ótima para uma máquina crítica, utilizando um método que possa ser estendido a outras máquinas do processo de formação de tubos de aço. Para tanto, serão considerados fatores de confiabilidade com base na variação dos intervalos de manutenção e os custos de manutenções corretivas estatisticamente esperadas para certo período, e custos das preventivas a serem executadas. Os

fatores serão integrados em uma formulação-objetivo de custo total, a ser minimizada utilizando Algoritmo Genético.

Para cumprir o objetivo do trabalho, ele está estruturado em 5 seções. Além desta introdução, a seção 2 apresenta a fundamentação em torno dos procedimentos de manutenção centrada na confiabilidade, além de breve definição acerca de algoritmos genéticos, ferramenta matemática utilizada para otimização neste artigo. A seção 3 apresenta o método proposto para definição de tipos de manutenção, baseado na adaptação de uma modelagem matemática proposta pela literatura. A seção 4 traz os resultados da aplicação do método em uma máquina específica de uma planta de beneficiamento de aços planos. Por fim, a seção 5 apresenta as conclusões e sugestões para trabalhos futuros.

2. REFERENCIAL TEÓRICO

Na sequência, serão descritos aspectos básicos de manutenção, confiabilidade e algoritmos genéticos. Também são descritos casos de aplicações práticas e adaptações dos modelos a certos tipos de problemas, visando a construção de uma metodologia adaptada ao problema em questão.

2.1 MANUTENÇÃO

Desde o momento em que ferramentas e equipamentos se tornaram importantes para a vida e sobrevivência do homem, surgiram atividades visando a conservação e recuperação destes itens para melhor desempenho de suas funções básicas (WYREBSKI, 1997). Tais atividades podem ser tanto de recuperação de uma condição de desgaste, reparos ou substituições completas, sendo formalmente definidas como atividades de manutenção (LUCATELLI, 2002). Inicialmente os próprios operadores realizavam todas as atividades de manutenção e, segundo Lucatelli (2002), foi a difusão de motores elétricos no chão de fábrica que exigiu serviços de conservação especializados e dedicados. Tais serviços surgiram na década de 1910 (WYREBSKI, 1997) e possuíam caráter puramente corretivo (XENOS, 1998).

Com o aumento da competição, em conjunto com maior complexidade de processos e equipamentos ao longo do século XX, surgiram novas demandas aos setores de manutenção, que se traduziram em diferentes políticas de manutenção. A primeira foi a manutenção

preventiva, objetivando a prevenção de falhas ou quebras, mediante a criação de programas de revisões ou restaurações preventivas (WYREBSKI, 1997). A determinação do intervalo programático era feito empiricamente, após observação de dados históricos.

Outra técnica surgida foi a manutenção preventiva baseada em condição, também chamada de manutenção preditiva, baseada no monitoramento de parâmetros de funcionamento vitais para a máquina. Tais parâmetros determinam a necessidade ou não de uma intervenção de manutenção preventiva (MIRSHAWKA, 1991).

Além das citadas, existe uma estratégia de manutenção surgida a partir da implantação dos preceitos de produção enxuta, chamada *Total Productive Maintenance* (TPM), ou Manutenção Produtiva Total (MPT). Tem como base atividades de manutenção preventiva pró-ativa associada a manutenções autônomas executadas pelos próprios operadores (NAKAJIMA apud CHAN et al, 2005). A Manutenção Produtiva Total utiliza como indicador de desempenho o Índice de Rendimento Operacional Global (IROG), que engloba 3 fatores: produtividade, qualidade e utilização (LABIB apud SPERANCETTA, 2005).

O uso de modelagens matemáticas e estatísticas mais sofisticadas na determinação de comportamento das taxas de falha de equipamentos, sistemas e componentes deu origem à Manutenção Centrada em Confiabilidade (MCC). A MCC pode ser entendida como uma ferramenta para otimização de planos de manutenção visando a conservação ou restauração da capacidade operacional plena de um sistema ou equipamento (DESPHANDE e MODAK, 2002). Complementarmente, a MCC visa decidir o que deve ser feito para que certa máquina continue realizando suas funções plenamente (MÁRQUEZ *et al.*, 2002). O desenvolvimento da MCC ocorreu principalmente nos setores aeroespaciais e de defesa, posteriormente sendo adaptado a setores civis com questões críticas de segurança, como usinas nucleares (DESPHANDE e MODAK, 2002). O cerne do funcionamento do MCC está no mapeamento do sistema a ser estudado, em conjunto com as funções de risco e confiabilidade, e parâmetros como tempo médio até falha (MTTF) e tempo médio entre falhas (MTBF). Tais entradas são utilizadas para planejar a manutenção visando algum objetivo, como minimização de custos, maximização de confiabilidade ou máxima segurança, entre outros (FOGLIATTO e RIBEIRO, 2009).

A otimização de programas de manutenção visando certo objetivo é tema recorrente na literatura, geralmente utilizando certa ferramenta ou combinando um conjunto de ferramentas para criar um método aplicável ao problema a ser resolvido. Vassiliadis e Pistikopoulos

(2000) utilizaram funções de disponibilidade combinadas com funções de custo de manutenção e funções de receita a fim de otimizar a rentabilidade de um processo produtivo da indústria química. Kaegi et al. (2009) propõem a adaptação do ABM – *Agent based modeling* – como alternativa para descrição e otimização de sistemas de componentes arranjados de maneira complexa. Apleland e Aven (2000) utilizaram o Teorema de Bayes aplicado à análise de risco como base de uma metodologia de otimização de manutenção baseada em risco. O algoritmo PSO (*Particle swarm optimization*) foi utilizado por Pereira et al. (2010) para otimização de manutenção de uma usina nuclear. Por fim, Mohanta et al. (2007) combinaram algoritmos genéticos com o algoritmo SA (*Simulated Annealing*) na otimização de confiabilidade e segurança de uma usina de força.

2.2 CONFIABILIDADE

Confiabilidade é a capacidade de um item de exercer suas funções projetadas dentro de condições declaradas e em um período de tempo especificado (FOGLIATTO e RIBEIRO, 2009). Tal capacidade pode ser descrita matematicamente através de funções, e o estudo das mesmas é chamada engenharia de confiabilidade (SALEH e MARAIS, 2006).

O crescimento dos estudos de confiabilidade se deu principalmente após a Segunda Guerra Mundial, concentrado principalmente nas áreas aeroespacial e militar. Nos mesmos setores, de maneira coincidente à aplicação da confiabilidade de maneira ampla, surgiu a MCC (FOGLIATTO e RIBEIRO, 2009 e DEPHANDE e MODAK, 2002).

A MCC é uma metodologia fundamentada em funções matemáticas e estatísticas. A função confiabilidade $R(t)$, também chamada de função de sobrevivência, de um certo componente ou sistema é a probabilidade de, decorrido o tempo t , tal sistema continuar operante, onde T é a variável aleatória tempo até falha.

$$R(t) = P(T > t)$$

Dado que a variável de tempo até falha segue uma função acumulada $F(t)$, pode-se representar a função de confiabilidade conforme abaixo, onde $f(u)$ é a densidade de probabilidade da distribuição $F(t)$.

$$R(t) = 1 - F(t) = \int_t^{+\infty} f(u) du$$

Outro conceito importante em confiabilidade é a taxa de falha, expressa pela função de risco $h(t)$, utilizada para modelar e calcular o comportamento de falhas ao longo da vida útil de um componente ou sistema de componentes (FOGLIATTO e RIBEIRO, 2009)

$$h(t) = \frac{f(t)}{R(t)}$$

sujeita a $t \geq 0$, $h(t) \geq 0$ e $\int_0^{+\infty} h(t)dt = +\infty \forall t \in [0, +\infty)$

A transformação de dados de falha nas funções descritas é passo fundamental no cálculo de otimizações de manutenções centradas em confiabilidade.

2.3 ALGORITMOS GENÉTICOS

A observação de funcionamento dos mecanismos da evolução biológica, principalmente no estudo de como a combinação de pressões seletivas com mecanismos de modificação (cruzamento, mutação) consegue resolver problemas complexos, deu origem à área de estudo denominada algoritmos genéticos, um ramo da computação evolucionária e da inteligência artificial.

Tanomaru (1995) define Algoritmos Genéticos (AG) como “métodos computacionais de busca baseados nos mecanismos de evolução natural e na genética. Em AGs, uma população de possíveis soluções para o problema em questão evolui de acordo com operadores probabilísticos concebidos a partir de metáforas biológicas assumindo que, na média, os indivíduos representem soluções cada vez melhores à medida que o processo evolutivo continua”.

Rusell e Norvig (2004) definem algoritmos genéticos como métodos estocásticos de busca formal e codificada de soluções quase-ótimas, e os estruturaram com base em 5 operadores lógicos genéticos:

1) **Função Fitness:** mede a adaptação de certa solução possível ao seu meio, ou seja, o índice de quão perto ela está da otimização desejada;

2) **Seleção:** seleciona soluções mais aptas para posteriores operações de formação da nova população, como clonagem e cruzamento – neste segundo caso a seleção ocorre aos pares. Os cromossomos não-selecionados são removidos da população de soluções por estarem menos aptos que as outras soluções.

3) **Cruzamento**: operação com objetivo de simular nos algoritmos genéticos as vantagens evolutivas trazidas pela reprodução sexuada presente na natureza.

4) **Mutação**: introduz um fator de aleatoriedade no algoritmo alterando cromossomos aleatoriamente.

5) **Clonagem**: é a duplicação direta de uma solução para a próxima geração, podendo ser explícita caso seja uma rotina declarada, ou implícita caso não existam restrições no programa que impeçam o cruzamento de pares idênticos.

Para melhor entender como os operadores genéticos se estruturam e quais seus encadeamentos lógicos, a Figura 1 apresenta o aspecto geral de um algoritmo genético genérico.

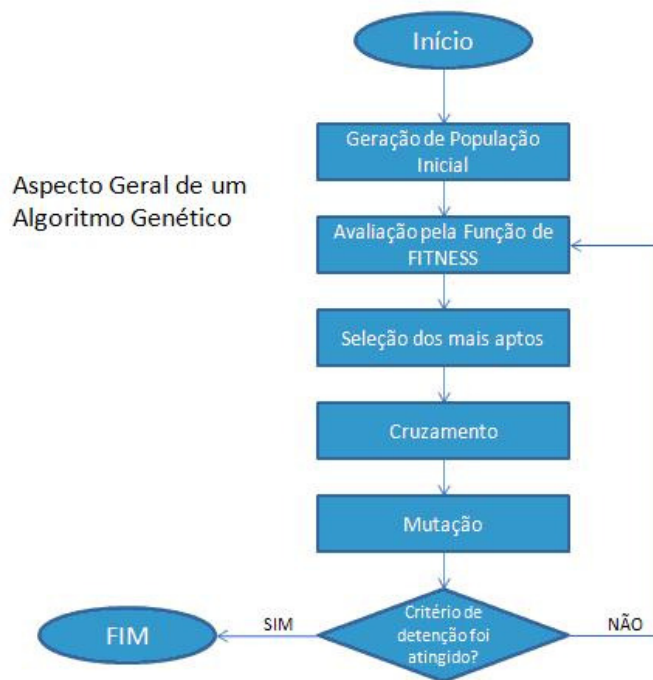


Figura 1 – Aspecto Geral de um Algoritmo Genético

Algoritmos genéticos em geral são muito flexíveis, possuem a maior base teórica de pesquisas no campo de computação evolutiva e não requerem uma quantidade grande de conhecimento teórico do pesquisador em inteligência artificial, sendo necessárias somente habilidades matemáticas e de programação (RUSSELL e NORVIG, 2004). Além disso, tais

métodos são robustos, ou seja, a população inicial não tem influência, na maior parte dos casos, para impedir a obtenção de um ótimo global.

Dentre os defeitos dos algoritmos genéticos, o principal deles é a não-garantia de encontro de ótimo global, ou seja, é possível que um algoritmo que aparentemente se comportou bem tenha atingido somente um ótimo local (GOSSELIN e POTVIN, 2009).

Os campos de aplicação de algoritmos genéticos são amplos, incluindo estudos na área de otimização de manutenção. Tanomaru (1995) lista aplicações em redes neurais, análise de aglomerados (*clustering*) de dados, otimizações de funções de um objetivo ou multi-objetivo, controle de processos, problemas de transporte, modelos ecológicos, modelos sociais, modelos econômicos, máquinas de estados finitos e robótica. Carrijo *et al.* (2003) aplicou a técnica na definição de regras de operação de sistemas urbanos de distribuição de água. Gosselin e Potvin (2009) revisaram aplicações de AGs em problemas de transferência de massa e calor. Okasha e Frangopol (2009) utilizaram AGs em um problema de manutenção em sistemas estruturais, utilizando otimização multi-objetivo considerando confiabilidade, redundância e custo. Wang e Handschin (2000) propõem um novo tipo de algoritmo genético inteiro com melhor eficiência que os AGs binários na resolução de problemas de manutenção de usinas de força, enquanto que Lapa *et al.* (2006) apresentam um modelo de plano de manutenção utilizando AGs na minimização da função de não-confiabilidade (*unreliability function*). Tsai *et al.* (2001) utilizou algoritmos genéticos na otimização de manutenção de componentes mecânicos com partes elétricas e comparou o uso de AGs com o cálculo de todas as soluções, obtendo uma redução de 480 minutos para 5 minutos de cálculo em um mesmo computador. Como é possível inferir, demanda computacional também constitui-se em interesse ao utilizar-se AG.

3. METODOLOGIA

O método proposto parte de modificações na abordagem sugerida por Tsai *et al.* (2001), dado que o tipo de máquina analisado é semelhante: predominantemente mecânico com sistemas elétrico-eletrônicos secundários. O método adaptado é composto pelas seguintes etapas: (i) determinação e coleta de dados necessários e modelagem de confiabilidade utilizando aplicativo estatístico, (ii) determinação, junto à empresa, da confiabilidade mínima aconselhada para bom funcionamento do equipamento, (iii) determinação, junto a técnicos no

processo, dos ganhos das manutenções preventivas, (iv) levantamento de custos associados às manutenções corretivas e preventivas, (v) modelagem final da função-objetivo, e (vi) otimização da função objetivo via algoritmos genéticos.

A primeira etapa consiste na coleta dos tempos de falha das máquinas analisadas. Utilizam-se dados de ordens de manutenção, cruzadas com dados de paradas de máquina, geradas pelo ERP (*Enterprise Resource Planning*) da empresa. Tal entrada de informações permite calcular o tempo até falha de cada sistema em operação normal, bem como o tipo de manutenção (mecânica ou elétrica/eletrônica) para os anos de 2009 e 2010, a fim de mapear a confiabilidade. Os dados são então modelados para definir a distribuição probabilística que mais se ajusta aos mesmos, valendo-se do software Proconf. São testadas as distribuições Exponencial, Weibull, Normal e Lognormal.

A etapa seguinte consiste na avaliação da eficácia de duas sistemáticas de manutenção preventiva: (i) manutenção preventiva imperfeita e (ii) manutenção preventiva perfeita.

Para a manutenção do tipo (i), gera-se uma tabela de manutenção do tipo de atividade (X_i) versus sistema da máquina (Tabela 1), adaptado do modelo proposto por Tsai et al. (2001). Tal sistemática avalia o incremento de confiabilidade gerado por uma manutenção preventiva imperfeita, através da avaliação do impacto de seis atividades genéricas sobre os sistemas avaliados: lubrificar (1), limpar (2), ajustar/calibrar (3), apertar (4), suprir (5) e reparo simples (6). Cada atividade é então multiplicada pelo peso proporcional de tal sistema da máquina em relação as suas paradas totais.

SISTEMAS	ATIVIDADES - 1 a 6						FATOR
	X1	X2	X3	X4	X5	X6	
Alimentação	p_{11}	p_{12}	p_{13}	p_{14}	p_{15}	p_{16}	d_1
Formação	p_{21}	p_{22}	p_{23}	p_{24}	p_{25}	p_{26}	d_2
Solda	p_{31}	p_{32}	p_{33}	p_{34}	p_{35}	p_{36}	d_3
Resfriamento	p_{41}	p_{42}	p_{43}	p_{44}	p_{45}	p_{46}	d_4
Calibração	p_{51}	p_{52}	p_{53}	p_{54}	p_{55}	p_{56}	d_5
Serra	p_{61}	p_{62}	p_{63}	p_{64}	p_{65}	p_{66}	d_6
Mesa embalagem	p_{71}	p_{72}	p_{73}	p_{74}	p_{75}	p_{76}	d_7

Tabela 1 – Sistemas versus Atividades de manutenção preventiva

O cálculo do fator de melhoria m de uma manutenção preventiva imperfeita se dá através da equação (1), onde p_{ij} é o fator de melhoria resultante da j -ésima atividade no i -

ésimo sistema em uma manutenção preventiva, e d_i é o fator de criticidade calculado em função do % de horas paradas da máquina que se deve a falhas no sistema j .

$$m = \sum_{i=1}^6 \frac{\sum_{j=1}^6 p_{ij}}{d_i} \quad (1)$$

A manutenção preventiva do tipo (ii) consiste na substituição completa do componente antes de uma quebra. Como o caso estudado trata de sistemas e não componentes, a substituição preventiva será considerada como o *overhaul* de equipamento, consistindo na plena inspeção e revisão do sistema, com substituição de todos componentes desgastados e execução de reparos necessários. Na empresa estudada, tal atividade é estritamente realizada aos sábados, durante a parada de planta. Para esse tipo de intervenção, especialistas de engenharia e manutenção da empresa-foco arbitraram um fator de melhoria $m_i = 0,98$, visto que trata-se de uma renovação geral no sistema.

O próximo passo é a determinação da confiabilidade mínima do equipamento com base no conhecimento de especialistas de processo, levando em conta fatores de segurança e desempenho esperado. Tal confiabilidade serve como restrição à otimização.

A influência dos fatores de melhoria pode ser entendida como uma diminuição do tempo de uso sujeito ao desgaste do equipamento, dentro de intervalos fixos e constantes de tempo. Considere T como o intervalo padrão de manutenção. Se no intervalo T não for feita nenhuma manutenção, a curva de confiabilidade avançará T horas. Caso ocorra uma manutenção preventiva com efeito m , tem-se que o tempo transcorrido desde o tempo inicial até o intervalo considerado retrocederá $m\%$. Portanto, uma melhoria $m=1$ representaria a reposição do nível de confiabilidade verificada T unidades de tempo atrás. Uma relação genérica para a determinação do tempo referente à reposição do nível de confiabilidade, ou tempo de desgaste efetivo (t_{ik}), é dada pela equação (2) para o i -ésimo componente ou subsistema ao final do k -ésimo intervalo, sujeito à j -ésima manutenção:

$$t_{ik} = t_{ik-1} + T - m_{ij}(t_{ik-1} + T) \quad (2)$$

onde a j -ésima manutenção pode assumir 3 níveis: 0 se uma manutenção não é necessária, 1 se uma manutenção preventiva imperfeita será efetivada, e 2 se uma manutenção do tipo *overhaul* (preventiva perfeita) será efetivada. Portanto, dada a função de confiabilidade do sistema da máquina $R(t)$, a confiabilidade ao final do k -ésimo intervalo será $R(t_{ik})$, que

equivale à $R(kT)$ para ausência completa de manutenção. Tal conceito pode ser visualizado na Figura 2.

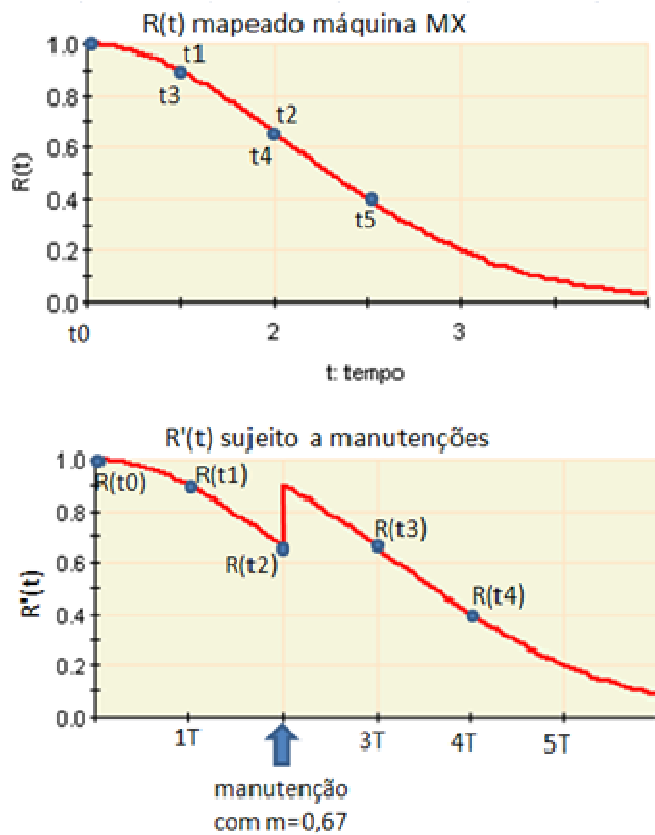


Figura 2 – Confiabilidade mapeada *versus* confiabilidade sujeita a manutenções

Na sequência, calcula-se o custo de manutenções corretivas do sistema ao final do k -ésimo intervalo através da equação (3). Para tanto, levantam-se os custos de cada tipo de atividade, bem como os custos gerados por possíveis falhas do equipamento. Também são necessários dados de velocidade de máquina (provenientes de dados históricos) para cruzamento com as bases de dados de manutenção, a fim de testar a hipótese de influência dos *overhauls* no ritmo produtivo.

$$CMC_k = \sum_{i=1}^n \sum_{p=1}^4 S_{pi} \int_{t_{ik-1}}^{t_{ik}} h'_i(t) dt \quad (3)$$

onde S é o custo de manutenção corretiva do i -ésimo componente considerando p -ésimos fatores (1: custo de parada da máquina, 2: custo de componentes substituídos, 3: custo de insumos consumidos, 4: custo hora-homem de técnicos).

Ao final das modelagens, é possível determinar uma função objetivo (expressa em unidades monetárias) que relacione os diferentes custos de manutenção visando sua minimização:

$$\text{MIN } F(X_1, X_2, \dots, X_N) = \text{CMC}_k + \text{CMP}$$

Sujeito a

$$R(t) \geq R_{\min} \quad \forall t \in (0, t_N)$$

onde CMP é o custo de manutenção preventiva determinado pela soma dos custos de homem-hora e insumos consumidos por atividade, e CMC_k são os custos decorrentes de uma falha. Custos de equipamento parado não são contabilizados no custo das manutenções preventivas, pois as mesmas são realizadas em momentos nos quais as máquinas estão ociosas, aos sábados.

Tal função objetivo será otimizada através de algoritmos genéticos. O resultado do método sugerido consistirá em um cronograma de manutenção relacionando o tipo de manutenção a ser efetuada (preventiva imperfeita (1), *overhaul* (2) ou sem manutenção (0)) em uma linha de tempo pré-definida frente ao menor custo de manutenção no período. O algoritmo genético a ser utilizado será uma adaptação do modelo proposto por Wang e Handschin (2000), com a substituição dos cromossomos binários tradicionais por valores inteiros positivos, simplificação que economiza tempo computacional. Mais especificamente, cada cromossomo-solução terá o aspecto abaixo, sendo X_N o tipo de manutenção realizada na semana n :

$$CS = [X_1, X_2, \dots, X_N]$$

sujeito a $X_n \in \{0; 1; 2\}$.

4. RESULTADOS

Foi escolhida, dentre as máquinas formadoras da empresa-alvo, a formadora de tubos de aço carbono de grande bitola e espessura, com base na análise do indicador de utilização. Foram coletados dados de falhas operacionais de janeiro a maio de 2010, período no qual a máquina operou sem qualquer tipo de manutenção preventiva. Foram coletados também

dados de custos mensais médios do centro de custos individual da máquina e custos de manutenção.

Os ganhos de manutenções preventivas imperfeitas foram levantadas junto aos especialistas, bem como o tempo médio de parada de máquina para a execução de tais manutenções. Os resultados geraram um fator de melhoria $m= 0,2371$ [calculado de acordo com a equação (1)] e 3,5 horas de máquina parada, contando com o trabalho de dois técnicos.

Os dados de falha foram modelados através do software Proconf. A distribuição que melhor se ajusta aos dados é a normal, com papel de probabilidade e intervalo de confiança dos parâmetros apresentada na Figura 3.

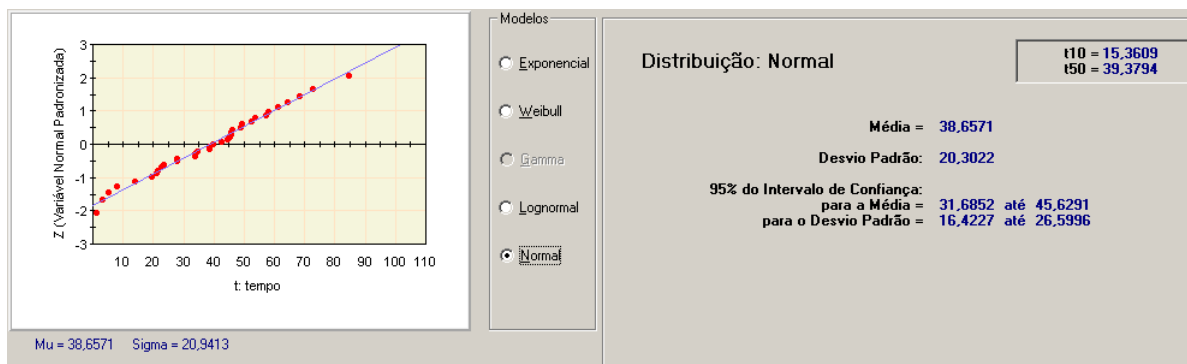


Figura 3 – Papel de probabilidade e intervalo de confiança

O próximo passo foi a montagem da função objetivo, consistindo basicamente na sua alimentação com os dados reais do problema, tanto de confiabilidade quanto de custos. Para o problema de manutenção de 6 meses, dividido em 28 semanas, a configuração da função de custo total é apresentada abaixo, considerando a k -ésima semana na qual foi realizada a j -ésima manutenção e na qual a máquina esteve sujeita aos p -ésimos tipos de custos preventivos e corretivos:

$$F(X_1, X_2, \dots, X_{28}) = \sum_{k=1}^{28} \sum_{p=1}^4 \left(CM_{kp} \int_{t_{jk-2}+T-m_{ij}(t_{jk-2}+T)}^{t_{jk-1}+T-m_{ij}(t_{jk-1}+T)} \frac{\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(t-\mu)^2}{2\sigma^2}}}{1 - \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^t e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt} dt + CP_{kp} \right)$$

Importante notar que a função taxa de falha não é integrável por método analítico, sendo necessária sua integração por métodos numéricos; utilizou-se, para isso, a quadratura adaptativa de Simpson.

A programação do algoritmo genético no MATLAB foi realizada utilizando-se a função de algoritmos genéticos já presente no programa. A mesma foi modificada, tendo as funções de criação e mutação da população customizadas para permitir o trabalho com soluções inteiras limitadas, ao invés do uso de variáveis *double*, de ponto flutuante. Outra alteração foi a função taxa de falha, que, pela necessidade de resolução de integrais definidas por métodos numéricos, foi programada como função separada em módulo à parte. Após montado o algoritmo completo, sua eficácia foi testada para um problema piloto, cuja resolução por algoritmos genéticos levou, em testes repetidos, entre 8,2 e 9,8 segundos, enquanto o método da enumeração por força bruta computacional precisou de 1212 a 1299 segundos. O algoritmo completo utilizado pode ser visto nos apêndices 1 a 5.

O algoritmo foi rodado com parâmetro de 250 gerações, população de 20 cromossomos e tolerância de 10^{-6} . A otimização foi finalizada em 151 gerações, quando a mudança média na função *fitness* ficou abaixo da tolerância. A solução ótima encontrada, chamada cromossomo-solução, para o problema de 28 semanas (6 meses) de programação de manutenções foi:

$$CS = [0\ 0\ 0\ 0\ 0\ 0\ 1\ 1\ 1\ 1\ 0\ 1\ 0\ 1\ 1\ 1\ 0\ 1\ 1\ 0\ 1\ 0\ 1\ 1\ 1\ 1\ 1\ 1\ 1]$$

Tal solução apresenta o valor ótimo da função objetivo de R\$187.511,57, no qual já estão incluídas as perdas relativas às falhas esperadas para cada período, calculadas através da integral da taxa de falha sujeita à manutenções, conforme equações básicas e metodologia proposta. Através da análise da evolução dos valores da função objetivo, conforme Figura 4, percebe-se que a convergência para a solução foi rápida ao longo das gerações.

Verifica-se que a solução ótima não inclui manutenções do tipo preventiva completa (*overhaul*). Isso se dá por conta do curto horizonte de 6 meses, o qual, segundo especialistas, é pequeno demais para a recomendação de tal procedimento. Tal manutenção seria provavelmente recomendada para programações de longo prazo, com mais de 1 ano de agendamento de manutenções (esse teste não é feito neste estudo).




Figura 4 – Evolução gráfica da função objetivo e solução ótima

Importante também notar que a sequência de manutenções preventivas só é ótima após correr um tempo de 6 semanas de uso da máquina e consequente degradação de seu estado. Manutenções antes de tal período não se pagariam, do ponto de vista de custos, pois haveria poucos componentes suficientemente desgastados para revisão e reparo/substituição.

Apesar da impossibilidade do método de algoritmos genéticos de garantir formal e matematicamente que a solução encontrada é um ótimo global do espaço de soluções, o fato de a solução, em conjunto com o valor médio populacional da função objetivo, mostrar-se estável entre a geração 50 e 150 permite ter bom nível de confiança em sua acuracidade. Infelizmente não é possível testar a resposta por enumeração, pois o tempo computacional seria de aproximadamente 61 mil anos.

Financeiramente, o resultado também é relevante, gerando um retorno, para o período considerado, de R\$45.221,55. O custo de manutenção esperado para o programa de manutenções sugerido, de R\$187.511,57, é inferior ao custo, no período, de quebras e manutenções corretivas para o caso de nenhuma manutenção preventiva ser efetuada, que se soma em R\$232.733,12.

5. CONCLUSÃO

O primeiro resultado importante do presente estudo é o reforço das evidências de eficiência do uso de algoritmos genéticos em problemas de pesquisa operacional relacionada a agendas de manutenção baseada em confiabilidade. Tal resultado, esperado e presente na literatura, torna possível a resolução de um problema de otimização no qual o uso da técnica de enumeração seria ineficiente o suficiente para tornar inviável a obtenção de uma solução ótima.

A baixa necessidade de tempo computacional para realizar a programação de manutenções, mesmo utilizando-se um equipamento de uso pessoal, torna viável seu uso cotidiano na empresa para determinação de manutenções das principais máquinas. É possível, inclusive, desenvolver um aplicativo que automatize a coleta de dados de falha no ERP da organização, o mapeamento da distribuição estatística e seus parâmetros, e o cálculo e determinação de agenda de manutenção via algoritmos genéticos. Tal ferramenta torna possível o uso de MCC mesmo em empresas que não disponham dos especialistas necessários para executar os passos de maneira manual.

Dado que os recursos em horas-homem de manutenção preventiva de uma empresa geralmente são escassos, uma sugestão de futura pesquisa seria um estudo de pesquisa operacional de otimização, usando algoritmos genéticos, para uma planta completa. Tal estudo deveria levar em conta escassez de homens-hora de manutenção para um planejamento de curto prazo, para o qual haveria dificuldades de contratação e treinamento de novos técnicos, e ao mesmo tempo dimensionar equipes de manutenção de tamanho ótimo para médio e longo prazo.

Por fim, na empresa estudada há fortes evidências empíricas de correlação entre velocidade ou ritmo de máquina e também de indicadores de qualidade com a confiabilidade do equipamento. A partir disso se pode notar que a influência de um bom plano de manutenções na eficiência global da máquina, medida pelo IROG, vai além da simples diminuição do tempo parado e conseqüente melhoria no índice de utilização. Dado o exposto, uma pesquisa futura envolveria a modelagem de uma função que correlacione a função confiabilidade com o IROG.

6. REFERÊNCIAS

APLELAND, S., AVEN, T. Risk based maintenance optimization: foundational issues. **Reliability Engineering & System Safety**, v.67, n.3, p.285-292, mar. 2000

CAMPOS, V.F. O Significado dos Indicadores. **INDG**, Nova Lima, Out. 2006. Disponível em <http://www.indg.com.br/institucional/falconi/request_id.asp?id=132>. Acesso em 20 jun. 2010.

CARRIJO, I. B. et al. Otimização da operação de sistemas de distribuição de água utilizando algoritmos genéticos multiobjetivo. In: Anais do XV Simpósio Brasileiro de Recursos Hídricos, 15., 2003, Curitiba. **Anais...** Porto Alegre: ABRH, 2003

CHAN, F. T. S., LAU, H. C. W., IP, R. W. L. Implementation of total productive maintenance: A case study. **International Journal of Production Economics**, v.95, n.1, p.71-94, jan. 2005

COULIBALY, A., HOUSSIN, R., MUTEL, B. Maintainability and safety indicators at design stage for mechanical products. **Computers in Industry**, v.59, n.5, p.438-449, maio 2008

DESPHANDE, V.S., MODAK, J.P. Application of RCM for safety considerations in a steel plant. **Reliability Engineering & System Safety**, v.78, n.3, p.325-334, dez. 2002

FOGLIATTO, F.S., RIBEIRO, J.L.D. **Confiabilidade e Manutenção Industrial**. Rio de Janeiro: Elsevier, 2009.

GOSSELIN, M.T., POTVIN, F.M. Review of utilization of genetic algorithms in heat transfer problems. **International Journal of Heat and Mass Transfer**, v.52, n.9-10, p.2169-2188, abr. 2009

KAEGI, M., MOCK, R., KRÖGER, W. Analyzing maintenance strategies by agent-based simulations: A feasibility study. **Reliability Engineering & System Safety**, v.94, n.9, p.1416-1421, set. 2009

LAPA, C.M.F.; PEREIRA, C.M.; BARROS, M.P. A model for preventive maintenance planning by genetic algorithms based in cost and reliability. **Reliability Engineering & System Safety**, v.91, n.2, p.233-240, fev. 2006

LUCATELLI, M. V. Proposta de aplicação de manutenção centrada em confiabilidade em equipamentos médico-hospitalares. **Tese de Doutorado** em Sistemas de Informação – Programa de Pós-Graduação em Engenharia Elétrica Universidade Federal de Santa Catarina, 2002

MIRSHAWKA, V. **Manutenção Preditiva**. São Paulo: Markon Books do Brasil, 1991

MOHANTA, D.K., SADHU, P.K., CHAKRABARTI, R. Deterministic and stochastic approach for safety and reliability optimization of captive power plant maintenance scheduling using GA/SA-based hybrid techniques: A comparison of results. **Reliability Engineering & System Safety**, v.92, n.2, p. 87-199, fev. 2007

OKASHA, N.M., FRANGOPOL, D.M. Lifetime-oriented multi-objective optimization of structural maintenance considering system reliability, redundancy and life-cycle cost using GA. **Structural Safety**, n.31, p.460-474, 2009

PEREIRA, M.N.A et al. A Particle Swarm Optimization (PSO) approach for non-periodic preventive maintenance scheduling programming. **Progress in Nuclear Energy**, v.52, n.8, p.710-714, nov. 2010

PINJALA, S.K., PINTELON, L., VEREECKE, A. An empirical investigation on the relationship between business and maintenance strategies. **International Journal of Production Economics**, v.104, n.1, p.214-229, nov. 2006

RUSSEL, S.; NORVIG, P. (2004). **Inteligência Artificial**. Rio de Janeiro: Elsevier, 2004

SALEH, J.H.; MARAIS, K. Highlights from the early (and pre-) history of reliability engineering **Reliability Engineering & System Safety**, v.91, n.2, p.249-256, fev 2006

SPERANCETTA, A. **O Impacto da Implantação do TPM nos Indicadores de Manutenção. Dissertação de Mestrado** Profissionalizante em Engenharia – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2005.

SUPPEN, N., CARRANZA, M., HUERTA, M., HERNANDEZ, M.A. Environmental management and life cycle approaches in the Mexican mining industry. **Journal of Cleaner Production**, v.14, n.12-13, p.1101-1115, 2006

SWANSON, L. Linking maintenance strategies to performance. **International Journal of Production Economics**, v.70, n.3, p.237-244, abr. 2001

TANOMARU, J. Motivação, fundamentos e aplicações de Algoritmos Genéticos. In: Congresso Brasileiro de Redes Neurais, 2., 1995, Curitiba. **Anais...** Curitiba: CNRN/Copel, 1995. p.373-403.

TSAI, Y.T., WANG, K.S.; TENG, H.Y. Optimizing preventive maintenance for mechanical components using genetic algorithms. **Reliability Engineering & System Safety**, v.74, n.1, p.89-97, Oct 2001

VASSILIADIS, C.G.; PISTIKOPOULOS, E.N. Maintenance scheduling and process optimization under uncertainty. **Computers & Chemical Engineering**. v.25, n.2-3, p.217-236, mar. 2001

WANG, Y.; HANDSCHIN, E. A new genetic algorithm for preventive unit maintenance scheduling of power systems. **International Journal of Electrical Power & Energy Systems**. v.22, n.5, p.343-348, jun. 2000

WYREBSKI, J. Manutenção Produtiva Total – Um Modelo Adaptado. **Dissertação de Mestrado** em Engenharia de Produção e Sistemas. Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 1997

XENOS, H.G.D. **Gerenciando a Manutenção Produtiva**. Belo Horizonte: FDG, 1998

7. APÊNDICES

APENDICE 1 – FUNÇÃO TAXA DE FALHA

```
function [valor] = h_normal(t)
```

```
%PARAMETROS PARA A MAQUINA
```

```
mi = 38.6571
```

```
var = 20.3022
```

```
%CONFIABILIDADE
```

```
Rt = 1 - cdf('norm',t,mi,var)
```

```
%DENSIDADE
```

```
ft = pdf('norm',t,mi,var)
```



```

%atribui o valor correto de fator de melhoria e custo
switch manut8(s)
    case 0
        m(s) = 0
        Cprev(s) = 0
    case 1
        m(s) = 0.2371
        Cprev(s) = A-CONSTANTE_NUMÉRICA_CONFIDENCIAL
    case 2
        m(s) = 0.98
        Cprev(s) = B-CONSTANTE_NUMÉRICA_CONFIDENCIAL
end

%aplica o fator de melhoria de acordo com semana
if s>1
    anterior = s-1
    tmen = t(anterior)
    t(s)=tmen+Tsem - m(s)*(tmen+Tsem)
    inicial = tmen
else
    t(s)=Tsem - m(s)*Tsem
    inicial = 0
end

final = t(s)

%calcula o número de falhas esperadas no período
falhas(s) = quad(@h_normal,inicial,final)

%calcula o custo das falhas
Cfalhas(s) = falhas(s) * C-CONSTANTE_NUMÉRICA_CONFIDENCIAL

%calcula o custo total da semana das preventivas
custo_semana(s) = Cfalhas(s)+Cprev(s)
custo_intermed = custo_intermed + custo_semana(s)
s = s + 1
end

%calcula o custo total
custo = custo_intermed

end

```

APENDICE 5 – CONFIGURAÇÕES DO GATOOOL

```

function [x,fval,exitflag,output,population,score] =
problema_E2(nvars,PopInitRange_Data,Generations_Data,StallGenLimit_Data)
% This is an auto generated M-file from Optimization Tool.

% Start with the default options
options = gaoptimset;
% Modify options setting
options = gaoptimset(options,'PopulationType', 'custom');
options = gaoptimset(options,'PopInitRange', PopInitRange_Data);
options = gaoptimset(options,'Generations', Generations_Data);
options = gaoptimset(options,'StallGenLimit', StallGenLimit_Data);
options = gaoptimset(options,'CreationFcn', @int_pop);
options = gaoptimset(options,'MutationFcn', @int_mutation);
options = gaoptimset(options,'Display', 'off');

```

```
options = gaoptimset(options, 'PlotFcns', { @gaplotbestf @gaplotbestindiv
@gaplotscores @gaplotstopping });
[x, fval, exitflag, output, population, score] = ...
ga(@confiabilidade, nvars, [], [], [], [], [], [], [], [], options);
```