



**XXII SNTPEE
SEMINÁRIO NACIONAL
DE PRODUÇÃO E
TRANSMISSÃO DE
ENERGIA ELÉTRICA**

BR/GMI/09
13 a 16 de Outubro de 2013
Brasília - DF

GRUPO - XII

GRUPO DE ESTUDO DE ASPECTOS TÉCNICOS E GERENCIAIS DA MANUTENÇÃO – GMI

GESTÃO DA MANUTENÇÃO DE EQUIPAMENTOS DE GERAÇÃO DE ENERGIA ELÉTRICA UTILIZANDO O ALGORITMO METROPOLIS-HASTINGS

**Raimundo C. GhizoniTeive(*)C. Celso de BrasilCamargoThales Lange
FEESC/UFSCFEESC/UFSCSEENERGIA**

**Everton T. SicaJorge Coelho Marcus V. Santana Augusto C. M. Gregatti
IFSCUFSCBAESA/ENERCAN**

RESUMO

A caracterizaçãooperativa de grandes equipamentos de usinas geradoras, visando a definição do plano de manutenção ótimo e a consequentemaximização da disponibilidade dos ativos de geração, é fundamental para o agente gerador, considerando aspectos de operação e financeiros, contribuindo também com a redução da probabilidade de déficit de energia elétrica no Sistema Interligado Nacional.Neste trabalho, é proposto a aplicação do algoritmo para inferência bayesiana Metropolis-Hastingspara combinar as funções de distribuição de probabilidade (FDP), baseada em dados históricos, chamada deFDP *a priori* do Tempo Médio entre Falhas (MTBF),o qual é geralmente usado como medida de indisponibilidade de um sistema reparável, com possíveis evidências de desligamentos forçados; com vistas a estimar o MTBF dos principais equipamentos de geração, a partir da FDP *a posteriori*. A metodologia é testada com dados típicos do setor elétrico.

PALAVRAS-CHAVE

Gestão da Manutenção,Inferência Bayesiana, Algoritmo Metropolis-Hastings

1.0 - INTRODUÇÃO

Não há dúvidas que o setor de energia elétrica é estratégico para um país e para as sociedades modernas. Entretanto, o que pode ser novidade para muitos é que a área de manutenção, dentro do setor elétrico em especial, também é estratégica, pois através de uma manutenção sistemática e executada de forma eficaz, as falhas potenciais podem ser evitadas, ou mesmo controladas para que a intervenção do equipamento ocorra no momento mais oportuno e com um mínimo de indisponibilidade dos serviços.

A caracterização operativa de grandes equipamentos de usinas geradoras, visando a definição de um plano de manutenção ótimo e a consequente maximização da disponibilidade dos ativos de geração, é fundamental para o agente gerador,considerando aspectos de operação e financeiro, contribuindo também com a redução da probabilidade de déficit de energia elétrica no Sistema Interligado Nacional.

Na análise de indisponibilidade operativa, o Tempo Médio entre Falhas (MTBF) é, geralmente, usado como medida da indisponibilidade de um sistema reparável e predizê-lo é um importante aspecto no desenvolvimento da metodologia. Entretanto, quando o ativo possui um histórico reduzido de dados operativos e de manutenção, os valores de MTBF calculados não são representativos.

Nesse sentido, as técnicas bayesianas do tipo Markov Chain Monte Carlo (MCMC) proporcionam uma estrutura de modelagem adequada para aplicações em confiabilidade de sistemas, mesmo sob escassez de dados, que permite determinar o MTBF e, quando aliado a uma metodologia de otimização auxilia a tomada de decisão para definição do plano de manutenção ótimo.

O algoritmo proposto para obter o MTBF incorpora a duração dos reparos após as falhas, sendo que para equipamentos com pouco tempo de operação, as técnicas Bayesianas permitem corrigir as informações disponíveis no banco de dados a cada novo evento, atualizando a distribuição de probabilidades de falhas disponível sobre os equipamentos.

O uso dos dados históricos de falhas de máquinas geradoras de porte similar, nacionais ou internacionais, permite obter a função de distribuição *a priori* do MTBF. A combinação desta distribuição com os dados obtidos a partir do histórico de manutenção de unidades geradoras específicas, envolvendo desligamentos ocorridos durante os últimos seis anos, permite a obtenção de uma nova função distribuição de probabilidade do MTBF, chamada de função distribuição *a posteriori*, ou seja, com este procedimento é possível estimar uma distribuição de probabilidades para uma unidade geradora específica a partir da obtenção de evidências sobre desligamentos forçados de unidades geradoras. Isto é possível com a implementação do algoritmo Metropolis-Hastings, o qual representa um dos mais populares métodos para implementar MCMC para inferência Bayesiana.

A análise do estado-da-arte permite afirmar que os resultados obtidos por meio de dados reais, advindos da análise de relatórios do setor elétrico (2), tem comprovado a viabilidade da metodologia implementada, baseada em estatística Bayesiana; além da utilização do MTBF como parâmetro para indicação de envelhecimento ou deterioração de componentes pertencentes a uma usina de geração.

Desta forma, o algoritmo proposto busca facilitar a gestão da manutenção de equipamentos, tais como: geradores e transformadores, pertencentes a uma subestação geradora; auxiliando assim na reprogramação das datas de manutenção programada, visando a otimização do trabalho das equipes de manutenção e redução da indisponibilidade, baseado na distribuições das taxas MTBF, estimados por métodos estatísticos Bayesianas do tipo MCMC, como o algoritmo Metropolis-Hastings. É importante enfatizar que nesta proposição há a atualização automática dos valores estimados do MTBF, quando novas evidências são inseridas no algoritmo, como por exemplo, a obtenção de novos tempos de desligamentos ocorridos na usina de geração de energia elétrica.

2.0 - O PROBLEMA DA GESTÃO DA MANUTENÇÃO

Para auxiliar à elaboração de um plano de manutenção ótimo, a engenharia de manutenção deve dispor de indicadores de desempenho dos equipamentos mais importantes, como por exemplo taxas de falhas ou o tempo médio entre falhas, ambos obtidos a partir de dados históricos. A disponibilidade de um equipamento, pode ser obtida pela razão entre o tempo médio de operação e o tempo médio de operação mais o de reparo. O tempo MTBF é, geralmente, usado como medida da indisponibilidade de um sistema reparável e prevê-lo constitui-se em um importante aspecto para gestão da manutenção e consequente redução da indisponibilidade operativa.

Dessa forma, o monitoramento da disponibilidade operativa das unidades geradoras tem como principal variável de decisão (para a modelagem matemática) o histórico das falhas dos equipamentos que levaram a interrupção do suprimento de energia elétrica. A análise estatística dos índices de confiabilidade, tais como o MTBF e o MTTF (tempo médio para a falha), organizados por meio de banco de dados, fornecem importantes subsídios que orientam o planejamento e a operação das empresas geradoras, bem como a gestão da manutenção dos seus ativos de geração.

Uma das metodologias mais usadas para a análise das falhas (1) é o FMEA (*Failure modes and Effect Analysis*), que junto com a Análise de Críticidade, formam o FMECA (*Failure Modes, Effect Analysis and Criticality*). Outra metodologia para análise das taxas de falha e de reparo é a aplicação de testes de aderência, que permitem identificar o tipo de distribuição das probabilidades de falhas e a partir daí determinar a função densidade de probabilidade dessas falhas.

Entretanto, quando o histórico de desligamentos é pequeno, ou mesmo o tempo de operação da usina é curto, os valores de MTBF calculados tendem a não ser representativos; necessitando-se assim de técnicas que possam extrapolar os valores do MTBF, a partir de uma distribuição de probabilidade *a posteriori*.

Neste sentido, a utilização de técnicas bayesianas e dos métodos computacionais de apoio (algoritmos MCM), os quais proporcionam uma estrutura de modelagem adequada para aplicações em confiabilidade de sistemas, mesmo sob escassez de dados, são importantes para possibilitar uma estimativa confiável do MTBF futuro de um equipamento, ou conjunto de equipamentos, dado algumas evidências observadas nos estados dos equipamentos atuais. Esta metodologia permite assim interagir com as informações disponíveis no banco de dados a cada novo evento ocorrido, atualizando a distribuição de probabilidades de falhas disponível sobre os equipamentos.

A partir da análise dos equipamentos de geração de energia elétrica por meio dos relatórios da ABRAGE (2), a gestão da manutenção tem como os equipamentos mais críticos: o regulador de velocidade e o sistema de excitação, no âmbito dos indicadores de confiabilidade. Neste sentido, pode-se observar a partir da análise dos dados obtidos de (2) que menos de 20% dos equipamentos de geração são responsáveis por mais de 80% das falhas ocorridas, considerando-se dados de 2001 a 2011. Assim, como apresentado na Figura 1, sete equipamentos relativos ao sistema de geração têm as maiores taxas de falhas (ocorrências /ano), com destaque para os reguladores de velocidade, geradores e sistemas de excitação. Os valores médios para taxa de falhas para estes equipamentos são de 0,66, 0,47 e 0,42 ocorrências /ano, respectivamente.




Figura 1 – Evolução da taxa de falhas de Equipamentos que mais falham (2)

Ainda com relação aos dados analisados da ABRAGE (2), pode-se inferir que os geradores têm também uma contribuição importante para o aumento dos tempos de reparo na manutenção (MTTR). Entretanto, neste quesito os transformadores são os equipamentos que apresentam os maiores tempos médios de reparo, seguidos dos gerados, conforme pode ser observado na Figura 2, onde os tempos médios de reparo estão em horas. Neste caso, os valores médios de MTTR para estes equipamentos são de 145,99 h e 114,92 h, respectivamente. Na Figura 2, os sete equipamentos listados contribuem com 86% do total do tempo médio de reparo da usina, considerando os dados de 2001 a 2011.




Figura 2 - Equipamentos com maiores tempos de reparo (2)

Os dados apresentados nas figuras 1 e 2 são importantes para embasar os planos de manutenção das empresas de geração, de forma a aplicar novas metodologias que possam balizar o acompanhamento do estado dos equipamentos, a partir da utilização de índices de confiabilidade adequados; focando esta análise nos equipamentos considerados mais críticos, no âmbito da confiabilidade.

Neste sentido, os algoritmos de inferência bayesianas podem ser aplicados, para estimar valores de MTBF de equipamentos como reguladores de velocidade, transformadores ou geradores; sinalizando para uma eventual necessidade de manutenção preventiva, ou mesmo para servir como um parâmetro indicativo do estado operativo destes equipamentos.

3.0 - MODELO PARA INFERÊNCIA BAYESIANA EM ESTUDOS DE CONFIABILIDADE

3.1 Cadeias Markov – Monte Carlo

De forma geral, como observado por Zio(3), os algoritmos MCMC oferecem uma maneira efetiva para executar a amostragem de funções de distribuição de probabilidade complexas em espaços de alta dimensão. Nestes casos, o cálculo do valor esperado destas funções é inviável por integração direta, tanto de forma analítica, quanto por meio de métodos numéricos. Assim, os algoritmos MCMC fornecem uma maneira alternativa para realizar a amostragem da função densidade de probabilidade, sendo esta abordagem baseada na construção da cadeia de Markov no espaço do problema desejado, cuja distribuição estacionária é a função densidade.

Assim, para esta metodologia ser válida supõe-se que as mudanças de estados são causadas por processos ditos estacionários, ou seja, as mudanças são governadas por leis que não se alteram ao longo do tempo. Ou seja, denomina-se de cobertura de Markov quando um nó é condicionalmente independente de todos outros nós da rede, dados seus pais, filhos e pais dos filhos.

Para evitar a manipulação de um número infinito de pais, conforme observado por Russel e Norvig(4), considera-se a hipótese de Markov, isto é, o estado atual depende apenas do histórico finito de estados anteriores., representando um processo de Markov ou cadeia de Markov. O processo mais simples é chamado de Processo de Markov de primeira ordem, em que o estado atual depende apenas do estado anterior e não de quaisquer estados antigos. Em outras palavras, um estado consiste nas informações que você precisa para tornar o futuro independente do passado, dado o estado. Pode-se escrever isto da seguinte forma:

$$P(X_t | X_{0:t-1}) = P(X_t | X_{t-1}) \quad (1)$$

Consequentemente, em um processo de Markov de primeira ordem, as leis que descrevem como o estado evolui ao longo do tempo estão inteiramente contidas na distribuição condicional $P(X_t | X_{t-1})$, que denominamos de modelo de transição para o processo de primeira ordem. Para um processo de Markov de segunda ordem, o modelo de transição é dado pela distribuição condicional $P(X_t | X_{t-2}, X_{t-1})$.

O processo de amostragem se fundamenta em um “equilíbrio dinâmico” no qual a fração a longo prazo do tempo gasto em cada estado é exatamente proporcional à sua probabilidade posterior. Esta notável propriedade decorre da probabilidade de transição específica com que o processo passa de um estado para outro, definida pela distribuição condicional dada pela cobertura de Markov da variável cuja amostra está sendo coletada.

Segundo Russel e Norvig(4), esta probabilidade de transição define o que se denomina cadeia de Markov sobre o espaço de estados. Esta probabilidade de transição pode ser calculada por métodos de simulação MCMC, tais como o algoritmo de Amostragem de Gibbs ou o clássico algoritmo de Metropolis-Hastings (MH); sendo poderosos métodos para computação com modelos de probabilidade. Neste trabalho, adotou-se como método para inferência bayesiana aplicado a estudos de confiabilidade, o algoritmo de MH, o qual será descrito a seguir.

3.2 Modelagem MCMC Proposta

A aplicação do algoritmo de MH para o problema de gestão da manutenção de equipamentos de geração, considerando uma abordagem MCMC, passa inicialmente por uma modelagem do problema através de uma cadeia de Markov. Na Figura 3 é apresentada a cadeia de Markov três estados, proposta para este problema.




Figura 3 – Cadeia de Markov Três Estados

Conforme apresentado na Figura 3, considera-se neste trabalho 3 estados possíveis para a unidade geradora:

- o estado disponível **A** (disponível para o ONS produzindo [MW]ou [MVar]). Neste caso, o estado disponível representa as situações em que a máquina está disponível para o ONS, podendo operar como gerador ou como compensador síncrono;

- o estado em manutenção **U**; e
- o estado gerando com potência reduzida (abaixo da nominal) **OR**, ou seja, por alguma limitação técnica a máquina está gerando abaixo do que foi solicitado pelo ONS.

A partir da definição da cadeia de Markov para modelagem dos estados possíveis para o problema de gestão da manutenção (Fig. 3), o algoritmo de MH foi implementado, considerando-se inicialmente apenas dois estados: disponível e indisponível. O estado de potência reduzida não foi considerado neste momento no algoritmo, em função da falta de dados históricos.

Desta forma, o algoritmo que representa o modelo bayesiano para uma unidade geradora de uma usina hidrelétrica é composto pelos estados, ϕ_i , de disponibilidade, $\phi_i = A$, e indisponibilidade, $\phi_i = U$. O estado de indisponibilidade indica que ao menos um dos equipamentos de controle e proteção atuam ($E_\psi = U$), colocando a máquina fora de operação (indisponível). A Figura 4 representa este modelo bayesiano.

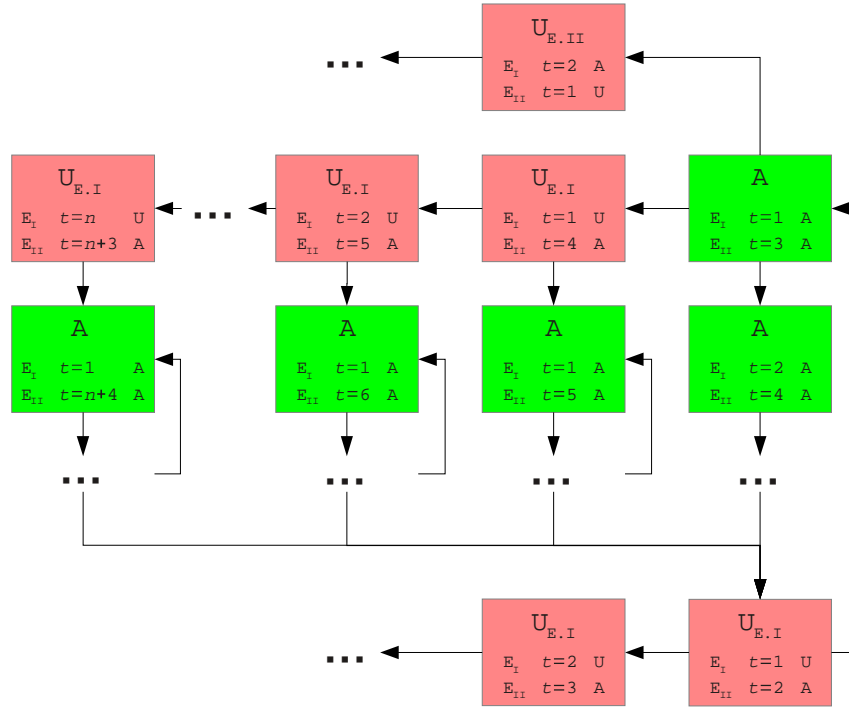


Figura 4 – Modelo Bayesiano Proposto para Dois Estados

Na figura 4 foi apresentado um modelo Bayesiano para dois estados com a finalidade de prezar pela nitidez e organização das informações que devem estar contidas na figura, dado que o modelo implementado neste trabalho correspondente ao apresentado na figura 3. Além disto, o modelo Bayesiano para três estados é uma extrapolação do modelo da figura 4, considerando um estado a mais (potência reduzida) e as correspondentes novas taxas.

Em que:

A é o conjunto de estados para disponibilidade;

U é o conjunto de estados para indisponibilidade;

E_ψ é o equipamento ψ , onde $\psi \in \Psi \{I, II, III, \dots\}$;

t é o tempo desde a última transição de estado do E_ψ , onde $(0 < t < \infty)$; e

n é o tempo máximo para E_ψ sair do estado de falha.

Os equipamentos de proteção, E_ψ , formam um sistema, ϕ , série, sendo a confiabilidade do sistema uma função tal que:

$$R_\phi(t) = \prod_{\psi \in \Psi} P(E_\psi(t, \mu) = A) = \prod_{\psi \in \Psi} R_\psi(t, \mu) \quad (2)$$

sendo $R_\phi(t) \leq \min_{\psi} R_\psi(t, \mu)$

A probabilidade de transição entre os estados, $\phi_i \rightarrow \phi_j$, sempre será positiva e aperiódica. A taxa de falha (λ_ψ) e a taxa de reparo (μ_ψ) de cada equipamento de controle e proteção é constante e obtida por uma distribuição a priori.

As falhas e os reparos são considerados mutuamente exclusivos. O comportamento probabilístico de cada equipamento depende unicamente do seu estado anterior.

Definições do modelo:

Df₁: $\forall (\phi_i \rightarrow \phi_j : \text{as falhas são consideradas mutuamente exclusivas})$

Df₂: $\forall (\phi_i \in A : |t_{\psi_1} - t_{\psi_2}| \geq 2)$

Df₃: $\forall (\phi_i \in U : |t_{\psi_1} - t_{\psi_2}| \geq 1)$

Df₄: $\forall (\phi_i \rightarrow \phi_j) \text{ se } \begin{cases} E_{\psi} = A \rightarrow E_{\psi} = U \therefore t_{\psi} = 1 \\ E_{\psi} = U \rightarrow E_{\psi} = A \therefore t_{\psi} = 1 \\ \text{senão} \therefore t_{\psi} = t_{\psi} + 1 \end{cases}$

Em que:

ϕ_i e ϕ_j representam os estados i e j do sistema ϕ que pode estar disponível (A) ou indisponível (U), mutuamente exclusivos;

ψ_1 e ψ_2 representam os equipamentos em série contido no sistema ϕ ;

$t \forall (\phi_i = A)$ representa o tempo de disponibilidade; e

$t \forall (\phi_i = U)$ representa o tempo de indisponibilidade.

Desse modo, para o modelo de três estados implementado e apresentado nas Figura 3 e na Figura 5, tem-se as seguintes equações de transição:

$$P(\phi_z(E_{\psi,t}) | \phi_x(E_{\psi,t=0})) = 1 - P(\phi_y(E_{\psi,t}) | \phi_x(E_{\psi,t=0})) \quad (3)$$

$$P(\phi_y(E_{\psi,t}) | \phi_x(E_{\psi,t=0})) = \frac{\lambda_{ij,\psi} e^{-\lambda_{ij,\psi} t}}{\lambda_{ij,\psi} e^{-\lambda_{ij,\psi} (t=0)}} = e^{-\lambda_{ij,\psi} t} \quad (4)$$

Em que, conforme as taxas de transição

ϕ_x representa o estado atual do sistema;

ϕ_y representa o estado futuro do sistema (aceitação);

ϕ_z representa o estado atual do sistema (rejeição); e

$\lambda_{ij,\psi}$ representa a taxa de transição (reparo ou falha) do estado i para o estado j do equipamento ψ , Figura 3

Diante disso, por exemplo, pode-se definir a probabilidade de transição para dois estados, em que a disponibilidade é calculada segundo as equações abaixo:

$$P(A_{t+1} | A_t) = 1 - \sum_{\psi_1 = \min(\psi)}^{\max(\psi)} P(E_{\psi_1,t+1} = U | E_{\psi_1,t} = A) \quad (5)$$

$$P(E_{\psi_1,t+1} = U | E_{\psi_1,t} = A) = \frac{\lambda_{\psi_1} e^{-\lambda_{\psi_1} t}}{\lambda_{\psi_1} e^{-\lambda_{\psi_1} (t=0)}} = e^{-\lambda_{\psi_1} t} \quad (6)$$

A probabilidade de transição para os estados de indisponibilidade é calculada segundo as equações abaixo:

$$P(E_{\psi_1,t+1} = U | E_{\psi_1,t} = U) = 1 - P(E_{\psi_1,t+1} = A | E_{\psi_1,t} = U) \quad (7)$$

$$P(E_{\psi_1,t+1} = A | E_{\psi_1,t} = U) = \frac{\mu_{\psi_1} e^{-\mu_{\psi_1} t}}{\mu_{\psi_1} e^{-\mu_{\psi_1} (t=0)}} = e^{-\mu_{\psi_1} t} \quad (8)$$

4.0 - RESULTADOS

4.1 Estudo de caso premissas

Para aplicação do algoritmo, considera-se um sistema composto de dois componentes, os quais pertencem a um mesmo módulo de desligamento (por exemplo, regulador de velocidade e sistema de excitação), onde o desligamento forçado de um componente acarreta o desligamento forçado do sistema composto (exemplo, sistema de geração). Na Figura 5 é representada a operação dos dois componentes, considerando três estados de operação (Figura 3), sendo que no diagrama de estados as arestas tracejadas representam as transições quando a proposta é rejeitada. Da mesma forma, a unidade geração, que é o sistema resultante, terá uma operação que é resultante da operação dos equipamentos individuais.

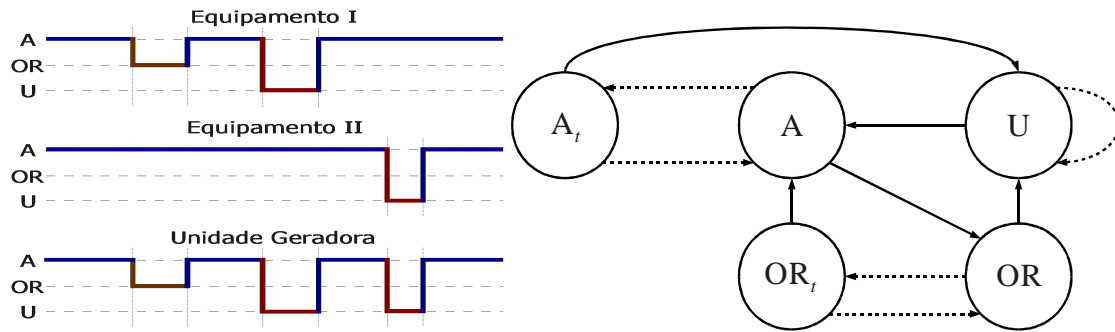


Figura 5 - Exemplo de Sistema Composto de Dois Equipamentos

4.2 Resultados Preliminares

Para exemplificação da metodologia MCMC, discutida nas seções anteriores, assume-se que um sistema mecânico/elétrico (por exemplo, sistema de geração) é composto por dois equipamentos, e se um desses equipamentos falha, a operação de todo o sistema é comprometida (corte mínimo de 1ª. ordem) (5). Estes equipamentos constituem um mesmo módulo de desligamento. Numa análise de confiabilidade esse sistema seria classificado como serial (5). Com objetivo de facilitar a validação da parametrização da confiabilidade desses equipamentos, optou-se por dois equipamentos com taxas de transições idênticas.

Na Tabela 1 são apresentadas as taxas de transição para os cinco estados do sistema. Na coluna “referência”, estão descritas as taxas de falha do sistema quando ambos equipamentos têm exatamente as mesmas taxas de transição. Na coluna “melhoria”, novamente são apresentadas as taxas de transição do sistema, entretanto, nessa simulação, as taxas de transição de um equipamento foi aprimorada em 20%, logo esse equipamento permanece 20% mais tempo disponível e os reparos são 20% mais rápidos. Ao comparar os resultados de ambas as simulações, percebe-se que a melhoria de 20% nas taxas de transição de um equipamento representou uma melhoria média de 11% na confiabilidade do sistema.

Tabela 1 – Resultado da Aplicação do Algoritmo MCMC ao Exemplo da Figura 5

Transição	Unidade	Taxas (a posteriori)		Melhoria (%)
		Referência	Com Melhoria	
$A \rightarrow U$	(oc/ano)	0,336814	0,299688	11,023
$A \rightarrow OR$	(oc/ano)	0,340486	0,301173	11,546
$OR \rightarrow U$	(oc/ano)	0,171255	0,150020	12,399
$OR \rightarrow A$	(reparos/hora)	0,135018	0,149177	10,487
$U \rightarrow A$	(reparos/hora)	0,034183	0,037939	10,991

5.0 - CONCLUSÕES

O presente trabalho insere-se num projeto de Pesquisa e Desenvolvimento da ANEEL e busca aplicar técnicas de inferência Bayesiana para nortear os planos de manutenção das empresas de geração de energia elétrica, de forma a aplicar novas metodologias que possam balizar o acompanhamento do estado dos equipamentos, a partir da utilização de índices de confiabilidade adequados, focando esta análise nos equipamentos considerados mais críticos, no âmbito dos indicadores de confiabilidade.

Neste sentido, mesmo sob escassez de dados operativos, os algoritmos de inferência Bayesiana podem ser aplicados, para estimar valores de MTBF (tempo médio entre falhas) de equipamentos como reguladores de velocidade, transformadores ou geradores; sinalizando para uma eventual necessidade de manutenção preventiva,

atenção especial a um determinado equipamento, ou mesmo para servir como um parâmetro indicativo do estado operativo destes equipamentos.

A complexidade inerente ao tratamento matemático deste tipo de desenvolvimento, leva ao aproveitamento de técnicas de simulação para a resolução do problema, no caso em tela, o uso do Algoritmo de Metropolis-Hastings para avaliar as condições operativas futuras dos equipamentos sendo estudados. O desenvolvimento e o consequentemente aperfeiçoamento destes algoritmos seguem sendo objeto de estudo no andamento do projeto.

6.0 - AGRADECIMENTOS

Este artigo é parte de um projeto de P&D financiado pelas empresas Energética Barra Grande (BAESA) e Campos Novos Energia (ENERCAN). O projeto faz parte do Programa de P&D da Agência Nacional de Energia Elétrica brasileira (ANEEL).

7.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) W. P. P. Araujo, *et al.*, "Aplicação da Metodologia FMEA e Lógica Fuzzy a Indicadores de Continuidade Individuais em Sistemas de Distribuição," Artigo apresentado no CLADE 2008 - Congresso Latinoamericano de Distribución Eléctrica, Mar del Plata, 2008.
- (2) ABRAGE2005 a 2011 .Relatório Técnico – Análise Estatística de Desempenho Unidades Geradoras Hidráulicas e Térmicas e Equipamentos sob Responsabilidade da Geração. Grupo Técnico de Manutenção de Usinas Hidráulicas – GTMN. 2011. Associação Brasileira das Empresas Geradoras de Energia Elétrica.
- (3) Zio, E. Computational Methods for Reliability and Risk Analysis. World Scientific Publishing Co. Singapore. 2009.
- (4) Russel, S. ; Norvig, P. Inteligência Artificial. Elsevier: RJ. 2004.
- (5) Camargo, C.C.B. Confiabilidade Aplicada a Sistemas Elétricos de Potência. RJ, Ed. LTDA, 1981.

8.0 - DADOS BIOGRÁFICOS

Raimundo C. GhizoniTeive - engenheiro eletricitista formado pela UFSC, com mestrado e doutorado pela própria UFSC, em 2001 e 2007, respectivamente. É professor titular na Universidade do Vale do Itajaí e pesquisador participante do programa de pós-graduação em engenharia elétrica da UFSC, onde atua principalmente nas áreas de planejamento da transmissão e distribuição, manutenção de sistemas elétricos e comercialização de energia.

C. Celso B. Camargo - engenheiro eletricitista pela UFJF e mestrado em engenharia elétrica pela COPPE em 1977. Doutor em Engenharia de Produção pela UFSC em 1996. Coordenador e pesquisador de P&D com várias empresas e professor aposentado da UFSC. Tem experiência na área de Confiabilidade, GLD, aplicação de Métodos Probabilísticos em Sistemas de Energia Elétrica. Possui 05 livros publicados.

Thales Lange –engenheiro de computação formado pela Universidade do Vale do Itajaí (Univali), com mestrado pela própria Univali em 2011. Atua como programador no desenvolvimento de software científicos multi-plataformas, com experiência em Banco de Dados, linguagens C/C++ e framework QT.

Everthon Taghori Sica, Engenheiro Industrial Eletrotécnico, pelo CEFET-PR(2000). Mestre (2003) e doutor (2009) em Engenharia Elétrica (Sistemas de Energia Elétrica) pela UFSC. Professor do curso de Engenharia Elétrica e do curso superior em Tecnologia de Sistemas de Energia do IF-SC, consultor ad hoc de P&D da ANEEL e Pesquisador Associado do Laboratório de Planejamento de Sistemas de Energia Elétrica (LabPlan) da UFSC.

Jorge Coelho - graduação e mestrado pela UFSC em 1977 e 1980, respectivamente, doutorado pela PUC_RJ em 1990. Coordenador e pesquisador de P&D com várias empresas e professor titular da UFSC. Tem experiência na área de Confiabilidade, Qualidade de Energia, Proteção, Modelagem de Incertezas, Sistemas de Grande Porte.

Marcus V. F. Santana - graduação em Ciências Econômicas pela UFSC (2006) e MBA em Gerenciamento de projetos pelo Centro Internacional de Estudos do Cone Sul. É analista de P&D da CSC Energia e trabalha na Gestão do Programa da P&D das empresas BAESA - Energética Barra Grande S.A, ENERCAN - Campos Novos Energia S.A e CESAP - Consórcio Empresarial Salto Pilão S.A

Augusto C. M. Gregatti, - engenheiro mecânico pela Faculdade de Engenharia de Varginha - MG em 1990. MBA em gestão empresarial pela FGV. É superintendente de O&M das empresas Energética Barra Grande S/A e Campos Novos Energia S/A. Tem 19 anos de atuação no setor elétrico, sendo 4,5 anos como consultor e gerente de O&M de Usina hidroelétrica de Capanda em Angola e 14,5 anos atuando no SIN.