

MODELO HÍBRIDO PARA GERAÇÃO DE ÁRVORES DE CENÁRIOS APLICADO AO PLANEJAMENTO DO DESPACHO HIDROTÉRMICO BRASILEIRO

Fernando Luiz Cyrino Oliveira

Pontifícia Universidade Católica do Rio de Janeiro - Departamento de Engenharia Elétrica
Rua Marquês de São Vicente, 225, Gávea, Rio de Janeiro, RJ
f Cyrino@ele.puc-rio.br

Pedro Guilherme Costa Ferreira

Pontifícia Universidade Católica do Rio de Janeiro - Departamento de Engenharia Elétrica
Rua Marquês de São Vicente, 225, Gávea, Rio de Janeiro, RJ
ferreira@ele.puc-rio.br

Reinaldo Castro Souza

Pontifícia Universidade Católica do Rio de Janeiro - Departamento de Engenharia Elétrica
Rua Marquês de São Vicente, 225, Gávea, Rio de Janeiro, RJ
reinaldo@ele.puc-rio.br

RESUMO

Em função da dependência dos regimes hidrológicos, a incerteza associada ao planejamento energético no Brasil exige a modelagem estocástica das séries hidrológicas de maneira adequada e coerente. Percebe-se, portanto, a importância dos modelos de geração de árvores de cenários hidrológicos com vistas à otimização do desempenho das operações do sistema, com consequente aumento de benefícios e confiabilidade e, sobretudo, redução de custos. Este trabalho insere-se neste contexto propondo uma metodologia para geração de árvores de cenários empregadas no despacho hidrotérmico brasileiro. A proposta desenvolvida é uma alternativa ao modelo vigente e aplica-se às recursões *Forward* e *Backward*, empregadas na fase de otimização por meio da técnica de Programação Dinâmica Dual Estocástica. A metodologia desenvolvida utiliza técnicas não paramétricas e de simulação de Monte Carlo e os resultados obtidos com relação à qualidade dos cenários, no que tange à reprodução das séries históricas, mostraram a adequabilidade do modelo proposto.

PALAVRAS CHAVE. *Árvore de Cenários, Despacho Hidrotérmico, PDDE.*

ABSTRACT

The uncertainty associated with energetic planning in Brazil, due to the strong dependency on the hydrologic regimes, requires adequate and coherent stochastic models of the corresponding hydro series. Therefore, the generation of scenario trees aiming the optimal performance of the system operation tend to improve on the benefits and the reliability of the system, as well as producing a reduction of the operational costs. This paper deals with this problem, by proposing a new approach to generate scenario trees to be used in the brazilian hydrothermal dispatch. The proposal method is an alternative to the current model and is applied to the Forward and Backward recursions of the Stochastic Dual Dynamic Programming which is used to find the optimal operations costs. The proposed approach used non-parametric statistical tools, as well as Monte Carlos simulations. The results produced are quite consistent and should be considered an improvement on the current approach.

KEYWORDS. *Scenarios tree, Hydro-thermal dispatch, Dual Stochastic Dyanamic Programming*

1. Introdução

O sistema de produção e transmissão de energia elétrica do Brasil apresenta dimensão e características que permitem classificá-lo como único em âmbito global. Trata-se de um sistema hidrotérmico de grande porte, com forte predominância de usinas hidrelétricas e com múltiplos proprietários. O Sistema Interligado Nacional (SIN) é formado pelas empresas das regiões Sul, Sudeste, Centro-Oeste, Nordeste e parte da região Norte. Apenas 3,4% da capacidade de produção de eletricidade do país encontram-se fora do SIN, em pequenos sistemas isolados localizados principalmente na região amazônica (ONS, 2013).

Sabe-se que uma das principais características dos sistemas de geração com predominância hidráulica é a forte dependência dos regimes hidrológicos. Assim, o planejamento da operação energética consiste em determinar metas de geração para as usinas hidrelétricas e termelétricas para cada estágio ao longo do horizonte de estudo, atendendo à demanda de energia elétrica, às restrições operativas das usinas e às restrições elétricas do sistema (Pereira, 1989).

Em função da dependência dos regimes hidrológicos, a incerteza associada ao planejamento energético no Brasil exige a modelagem estocástica das séries hidrológicas de maneira adequada e coerente. Percebe-se, portanto, a importância dos modelos de geração de árvores de cenários hidrológicos com vistas à otimização do desempenho das operações do sistema, com consequente aumento de benefícios e confiabilidade e, sobretudo, redução de custos (Oliveira, 2010).

O modelo empregado no planejamento da operação energética de médio prazo é o NEWAVE, (Cepel, 2001). Este define, para cada mês do período de planejamento, que pode variar de 5 a 10 anos, a alocação ótima dos recursos hídricos e térmicos de forma a minimizar o valor esperado do custo de operação. O parque hidrelétrico é representado de forma agregada e o cálculo da política de operação é baseado na Programação Dinâmica Dual Estocástica (PDDE), (Marcato, 2002).

O modelo NEWAVE considera diversos cenários de energias afluentes, obtidos por meio de simulações estocásticas empregando modelos autorregressivos periódicos, $PAR(p)$, (Thomas & Fiering, 1962). No modelo NEWAVE, a formulação do problema é baseada em sistemas equivalentes de energia, com base nos quatro subsistemas que compõem o SIN. Nesta formulação, as séries hidrológicas são transformadas em Energia Natural Afluente (ENA) (Oliveira, 2010).

A modelagem estocástica da ENA é realizada pelo $PAR(p)$, que ajusta um modelo autorregressivo de ordem p para cada um dos estágios das séries hidrológicas históricas que compõem as configurações do sistema. Nas simulações de cenários, a versão vigente do NEWAVE emprega uma transformação Lognormal para a geração das séries sintéticas, o que, de acordo com (Oliveira, 2010), pode gerar uma não convexidade no modelo empregado na PDDE. A utilização da Distribuição Lognormal no contexto da simulação de cenários hidrológicos se dá em função da garantia de geração de valores não negativos para qualquer realização da variável estocástica.

Na literatura recente estão disponíveis alguns modelos alternativos ao vigente aplicados ao contexto do planejamento da operação de médio prazo. Em (Souza, et al., 2012), os autores propõem nova abordagem que utiliza a técnica de *Bootstrap*, (Efron & Tibishirani, 1993) e de PDE-Convex Hull (Dias, et al., 2010). Em (Castro, 2012) é apresentada uma alternativa que conjuga a o modelo proposto por (Oliveira, 2010) e a técnica de PDDE.

O objetivo deste trabalho é propor uma nova abordagem metodológica para a geração de séries sintéticas que compõem árvores de cenários utilizadas em modelos de otimização estocástica. Particularmente, a aplicação do modelo proposto se dá no planejamento da operação energética de médio prazo do Brasil, através da PDDE. Neste contexto, em trabalhos disponíveis na literatura, os mecanismos de simulação das realizações da variável estocástica em questão causam uma estrutura não linear no modelo gerador, o que pode ocasionar não convexidade indesejável na construção da função objetivo do processo de otimização estocástica. Neste trabalho, a construção da árvore de cenários é realizada de forma diferente nos passos *Forward* e

Backward, por meio da técnica não paramétrica *Bootstrap* e o método de simulação de Monte Carlo.

Este trabalho está organizado da seguinte forma: a seção 2 é dedicada à revisão bibliográfica acerca da modelagem da árvore de cenários e a apresentação do modelo proposto. A seção 3 descreve os resultados obtidos e, finalmente, na seção 4 estão expostas as considerações finais.

2. Modelagem da Árvore de Cenários

Conforme descrito, por meio da representação de um problema de programação estocástica multiestágios, resolvido pela técnica de PDDE, o planejamento da operação de médio prazo é realizado pelo modelo NEWAVE. No contexto do planejamento energético, esta metodologia foi proposta no Brasil por (Pereira & Pinto, 1991). A mesma técnica pode ser usada na gestão de portfólios de finanças, como em (Consigli & Dempster, 1998).

A representação dos vários estágios e da estocasticidade do problema é realizada por meio da construção de uma árvore de cenários considerando as variáveis de estado do problema, via modelos $PAR(p)$. Cada caminho da árvore é chamado de "cenário" e cada nó representa a realização da variável estocástica considerada. A cardinalidade da árvore é função do número de nós e ramos. Do ponto de vista computacional, a resolução de problemas de otimização para cada um dos nós, percorrendo todos os caminhos possíveis da árvore, é extremamente custoso e o tempo de processamento não é factível. Em (Chrralaksanakul, 2003), o autor propõe alguns métodos para atacar situações deste tipo, cuja solução computacional é complexa.

No modelo vigente, para a construção da árvore são realizados sorteios aleatórios de ruídos a partir de uma distribuição Lognormal multivariada. De posse desses e a partir da estimação de um modelo paramétrico, é possível construir a árvore de cenários de afluições.

A solução do problema de planejamento associado à árvore de cenários completa, em princípio, exigiria a solução de um problema para cada nó. Supondo a árvore completa com três aberturas, sua cardinalidade da árvore é igual a 3^3 . No caso do problema real, considera-se 20 aberturas e 60 períodos de simulações.

Para o detalhamento da construção da árvore de cenários, a partir deste ponto, com vistas à simplificação da visualização e facilidade de entendimento, serão exibidas nas próximas figuras somente nove das 27 possibilidades do terceiro estágio. Por conseguinte, a partir de um conjunto de variáveis que seguem uma distribuição de probabilidade definida, considere a seguinte árvore:




Figura 1 - Elementos para Construção da Árvore de Cenários

Na Figura 1 o espaço amostral para um estágio t é definido como Ω_t e um cenário nesse espaço pode ser definido como ω_t . A realização desse cenário é representada pelos elementos $A_t^{\omega_t}$. Segundo (Matos, 2008), o primeiro estágio é considerado determinístico, tendo valor previamente conhecido. No caso do modelo NEWAVE, é usada a tendência hidrológica ou a média de longo termo (MLT), (Penna, 2009). Cada nó do estágio $t \geq 1$, $A_t^{\omega_t}$, possui apenas um nó antecessor, denominado $a(\omega_t)$. Por sua vez, cada nó do estágio $t < T$, em que T é o número total de estágios, tem um conjunto de nós sucessores, definido como $\Delta(\omega_t)$. Dessa forma, os nós formam uma árvore de cenários, conforme ilustrado pela Figura 1.

As realizações que formam os nós sucessores, $\Delta(\omega_t)$, são as mesmas para qualquer cenário do estágio t , isto é, por exemplo, $A_3^1 = A_3^4 = A_3^7 = A_3^a$, $A_3^2 = A_3^5 = A_3^8 = A_3^b$ e $A_3^3 = A_3^6 = A_3^9 = A_3^c$.

Assim, o elemento 9 do segundo estágio, ilustrado na Figura 1, é constituído pela realização A_3^c quando os nós antecessores forem $[A_1, A_2^c]$. Pode-se, então, definir $\omega_2 = 9 = [A_1, A_2^c, A_3^c]$. O nó antecessor a $\omega_2 = 9$, $a(\omega_2)$, é dado pelo último nó do cenário $\omega_1 = 3$, e o conjunto de nós sucessores, $\Delta(\omega_2)$, formam os elementos $\omega_2 = 25, 26, 27$.

Em geral, se dois cenários têm a mesma sequência de nós entre o primeiro e o k -ésimo estágios, têm a mesma parcela de informações durante estes períodos. Consequentemente, decisões associadas a tais cenários devem ser idênticas até o k -ésimo período. Este requerimento é chamado de Condição de Implementabilidade, (Oliveira, 2007).

No caso de processos estocásticos de fenômenos naturais, de acordo com (Salas, et al., 1982), estes naturais são, em geral, estacionários em sentido lato, isto é, os momentos de primeira e segunda ordem da distribuição de probabilidades não são afetados por variações devido à escolha da origem dos tempos, um dos pressupostos para a aplicação da metodologia Box & Jenkins (Box, et al., 2008). Para a modelagem destas séries, a literatura recomenda o emprego de processos periódicos, que surgiram a partir do trabalho de (Gladysev, 1961) e a partir de então inúmeros trabalhos nas áreas de hidrologia e econometria surgiram.

Na classe de modelos periódicos, dois modelos se destacam: PAR (*periodic autoregressive*) e PARMA (*periodic ARMA*). O modelo PAR(p) ajusta, para cada período da série, uma estrutura autorregressiva. Em hidrologia, a modelagem PAR(p) foi originalmente proposta por (Thomas & Fiering, 1962) e pormenorizada em (Pagano, 1978), apresentando as propriedades assintóticas destes modelos assumindo normalidade do processo estocástico gerador. No trabalho de (Troutman, 1979), o autor apresenta as condições necessárias e suficientes para estacionariedade periódica.

Uma série de outros trabalhos utilizando modelos periódicos para dados hidrológicos está disponível na literatura. Algumas referências, em ordem cronológica, são: (Parzen & Pagano, 1979), (Obeysekera & Salas, 1982), (Vechia, 1985), (Bartolini, et al., 1988), (Shahjajan Mondal, 2006), (Lund, et al., 2006), (Oliveira & Souza, 2011) e (Souza, et al., 2012)

No caso de um modelo PAR(p), considere a série temporal periódica Z_t , $t = 1, \dots, N$, sendo N o número de observações da série com período S . Para simplificar, assumamos que $N/S = n$ é um número inteiro. Em outras palavras, n é o número de anos disponível na base de dados. O índice t pode ser escrito como $t = t(r, m) = (r-1)S + m$, em que $r = 1, \dots, n$ e $m = 1, \dots, S$. No caso de séries mensais, $S = 12$ e r e m denotam o ano e mês, respectivamente. Nos casos em que:

$$\mu_m = E[Z_{t(r,m)}] \quad (1)$$

$$\gamma_{k,m} = Cov(Z_{t(r,m)}, Z_{t(r,m)-k}) \quad (2)$$

existem e dependem somente de k e m , Z_t é dita periodicamente correlacionada ou estacionária periódica (Gladyshev, 1961).

Deste modo, o modelo PAR de ordem (p_1, p_2, \dots, p_S) é dado, na sua forma padronizada, por:

$$\left(\frac{Z_{t(r,m)} - \mu_m}{\sigma_m} \right) = \sum_{i=1}^{p_m} \varphi_{i,m} \left(\frac{Z_{t(r,m)-i} - \mu_{m-i}}{\sigma_{m-i}} \right) + a_{t(r,m)} \quad (3)$$

com $p_m < S$ e $a_{t(r,m)}$ é um processo $NID(0, \sigma_{m(a)}^2)$, (McLeod, 1994).

De acordo com (Cepel, 2001), uma vez que as séries sintéticas que serão geradas pelo modelo PAR serão utilizadas em modelos que calculam as estratégias ótimas de operação de sistemas multireservatórios, baseados na PDDE, o modelo de geração de cenários deve ser aplicado diretamente aos dados de ENA originais, isto é, sem quaisquer transformações estatísticas, e deve ser capaz de lidar com resíduos que apresentam forte coeficiente de assimetria, que é o caso das séries de ENA no contexto do Sistema Elétrico Brasileiro.

Por conseguinte, a solução adotada pelo para lidar com o problema citado anteriormente foi ajustar uma distribuição Lognormal com três parâmetros aos resíduos mensais. Essa distribuição, aplicada a dados hidrológicos, foi originalmente proposta por (Charbeneau, 1978). De acordo com o autor, a distribuição Lognormal com três parâmetros só é aplicável a distribuições com coeficiente de assimetria positivo.

Os detalhes matemáticos serão omitidos e, de acordo com (Castro, 2012), a partir da utilização da distribuição Lognormal para simulação das realizações estocásticas da variável de estado, o modelo gerador assume a seguinte estrutura:

$$C_t = \sigma_m \left[e^{b_t \sigma_{\xi_t} + \mu_{\xi_t}} \right] \quad (4)$$

Em que C_t representa o valor simulado de ENA em um dado instante t , b_t é um vetor de $b_t \sim N_4(0, I)$ amostrado via método de Monte Carlo e μ_{ξ_t} e σ_{ξ_t} são os dois primeiros momentos de uma distribuição Lognormal de três parâmetros.

No caso da PDDE, a Função Objetivo a ser minimizada (Função de Custo Futuro – FCF) é um poliedro convexo que pode ser aproximado por uma função linear por partes, através dos Cortes de Benders. A forma da equação linear por partes, que representa a aproximação do valor esperado da FCF, depende da hipótese assumida sobre a estocasticidade das afluências ao sistema de reservatórios equivalentes. Esta hipótese é de que a variável aleatória segue um modelo baseado em uma estrutura autorregressiva linear. A equação (4) mostra que em função do uso da distribuição Lognormal de três parâmetros para o processo de simulação estocástica, o modelo adquire uma estrutura não linear.

Isto posto, este trabalho insere-se neste contexto com vistas à proposição de um modelo alternativo para geração das realizações estocásticas da variável de estado que compõem a árvore de cenários utilizada nos modelos de otimização. Essas realizações devem atender de maneira satisfatória os pressupostos necessários para o sucesso das simulações *Forward* e *Backward*, evitando a não convexidade da FCF.

Considerando um conjunto contínuo de possíveis realizações do processo estocástico, para efeito de convergência é de se supor que os cenários visitados nos passos *Forward* e *Backward* não precisam ser necessariamente os mesmos, mas sim que devam visitar as mesmas regiões da distribuição de probabilidades do processo estocástico. Esta premissa conduz à proposta descrita neste trabalho. Outros trabalhos utilizam amostras diferentes para as referidas recursões, mas de maneira diferente da apresentada aqui, (Penna, 2009).

O modelo desenvolvido neste trabalho trata a construção da árvore de cenários em dois níveis distintos, com diferentes amostras de ruídos para as recursões do processo de otimização.

Para o passo *Forward* são utilizados os resíduos do próprio modelo estocástico $PAR(p)$ ajustado aos dados, que são amostrados com reposição, por meio da técnica não paramétrica de computação intensiva de *Bootstrap*. As séries sintéticas geradas servem como base para o modelo autorregressivo empregado na recursão *Backward*, que, por sua vez, realiza as simulações estocásticas via método de Monte Carlo a partir da distribuição de probabilidade mais aderente a cada vetor de resíduos do próprio modelo $PAR(p)$ estimado para cada período m .

A proposta de associação das duas técnicas de simulação para as recursões *Forward* e *Backward* a partir de diferentes amostras de ruídos tem sua motivação na preservação das características das séries históricas de ENA. No contexto do SIN, uma das características desejáveis dos cenários simulados é a preservação da correlação entre os valores de ENA dos subsistemas, haja vista a dependência espacial dos mesmos. No caso do modelo que emprega a estrutura Lognormal, a preservação desta característica se dá em função do uso da matriz de carga, (Oliveira, 2010). No caso da utilização do *Bootstrap* na geração dos caminhos *Forward*, a alternativa proposta foi o sorteio, no vetor de resíduos de cada estágio, daqueles de mesma posição para todos os subsistemas. Esta alternativa mostrou-se eficiente na geração dos cenários *Forward* para a maior parte dos casos.

A justificativa para o não emprego do *Bootstrap* na fase *Backward* já foi apresentada anteriormente. Por sua vez, a simples amostragem de ruídos, via Monte Carlo, em ambas as recursões, não seria capaz de preservar a correlação espacial entre os valores de ENA dos quatro subsistemas. Haja vista que no passo *Backward* são usados os valores passados da variável simulada na fase *Forward*, com a correlação preservada, espera-se que na recursão inversa o mesmo aconteça. Desta maneira, em função da especificidade do problema, a conjugação das técnicas de simulação propostas está, portanto, fundamentada. A seguir o detalhamento da construção das árvores de cenários nos passos *Forward* e *Backward*.

a. Passo Forward:

- a.1. Amostrar, através da técnica não paramétrica *Bootstrap*, resíduos dos modelos estocásticos definidos para cada um dos períodos do horizonte de planejamento. Nesta amostragem, a posição do resíduo sorteado, no período em questão, deve ser a mesma para todos os subsistemas, com vistas à preservação da correlação entre os mesmos.
- a.2. Compor, a partir dos resíduos sorteados, os caminhos *Forward*, respeitando a restrição de que os valores de ENA, obtidos a partir do modelo estocástico, sejam positivos.
- a.3. Verificar que, em caso de valores de ENA simulados negativos, tais elementos devem ser descartados (para todos os subsistemas) e novos sorteios devem ser realizados.
- a.4. Selecionar os N caminhos *Forward*, simulados dos períodos $(t = 1, 2, \dots, T)$.

b. Passo Backward:

- b.1. Ajustar a matriz de resíduos mensais gerados pelo modelo PAR para cada período do horizonte de planejamento às distribuições de probabilidade selecionadas.
- b.2. *Rankear* as famílias de distribuições de probabilidade.
- b.3. Estimar os parâmetros da distribuição de probabilidade identificada como a mais aderente no *ranking* do item anterior.
- b.4. Iniciar o processo do passo *Backward*, com início em $(t = T, T - 1, \dots, 1)$, simulando, via método de Monte Carlo. Descartar valores de ENA negativos e reamostrar da distribuição de probabilidade identificada.
- b.5. Para a determinação dos valores passados dos cenários, utilizar a matriz de ENAs simuladas no passo *Forward*.

Na próxima seção são apresentados os resultados do modelo proposto quanto à simulação da árvore de cenários e à otimização do planejamento da operação.

3. Resultados

Nesta seção são apresentados os resultados da metodologia proposta aplicada ao caso do despacho hidrotérmico. A mesma tem impacto tanto na parte estocástica, no que tange à construção da árvore de cenários, quanto na etapa de otimização do despacho hidrotérmico e por isso precisa ser tratada de forma que ambas as fases sejam "atendidas", do ponto de vista da qualidade dos cenários estocásticos gerados e da política ótima de planejamento e operação do sistema.

Neste estudo será considerada a base de dados do Programa Mensal da Operação (PMO) de janeiro/2011 e os resultados apresentados são o do subsistema Sul, em função deste apresentar séries de ENA com maior dificuldade de modelagem. A análise e interpretação dos demais subsistemas é análoga. Os modelos $PAR(p)$ foram ajustados aos dados de ENA, cujo histórico disponível era de janeiro de 1931 a dezembro de 2009, para cada um dos períodos do horizonte de planejamento, que foi definido em 120 meses, isto é, 10 anos.

Para diagnóstico da modelagem, foram aplicados testes de média, variância e homoscedasticidade aos resíduos. Todos indicaram média nula, e ausência de dependência linear e homoscedasticidade condicional. O ajuste de distribuições de probabilidade aos resíduos de cada um dos períodos indicou que todos são aderentes à distribuição Generalizada de Valores Extremos (GEV). A GEV é uma distribuição que engloba as Distribuições de Extremos do Tipo I (Gumbel), Tipo II (Fréchet) e Tipo III (Weibull). Estas distribuições são bastante adequadas para dados com forte coeficiente de assimetria. Em estudos recentes, como (Katz, 1999), (Martins & Stedinger, 2000), (Gellens, 2002), (Katz, et al., 2002), (Morrison & Smith, 2002), (Ramesh & Davison, 2002) e (Quadros, et al., 2011), a GEV apresenta desempenho satisfatório na descrição de eventos máximos naturais. Os referidos trabalhos mostram, em geral, que a distribuição ajusta-se bem a estes tipos de dados, sendo útil no planejamento de atividades que são influenciadas pela intensidade de chuvas, vazões e enchentes.

Isto posto, uma vez obtidos modelos adequados, com ruídos brancos e distribuições parametrizadas, é possível iniciar o processo de construção da árvore de cenários estocásticos para as recursões *Forward* e *Backward*, conforme descrito anteriormente: a primeira será realizada com utilizando a técnica de *Bootsrap* e a segunda com base na simulação de Monte Carlo a partir da distribuição GEV.

A seguir são apresentados os resultados da geração de cenários e o desempenho dos mesmos no modelo de otimização empregado no planejamento da operação do despacho hidrotérmico no contexto do Setor Elétrico Brasileiro (SEB).

As análises dos cenários no que tange à conservação das características das séries históricas originais permite concluir, com base nas Figuras 2 a 5, que o modelo de geração da árvore de cenários mostrou-se adequado.

No que tange à conservação das médias históricas, Figura 3, foi aplicado um Teste t para testar a hipótese nula de que diferença entre a média dos valores históricos e simulados seja igual a zero, (Casela & Berger, 2001). Para variância, Figura 4, realizou-se, a cada período, o Teste de Levene, que testa a hipótese de que diferença entre a variância dos valores históricos e simulados é igual a zero, (Almeira, et al., 2008). O teste de Kolmogorov-Smirnof (K-S), Figura 5, avalia se há diferença entre as distribuições de probabilidade dos valores históricos e simulados, (Gibbons & Chakraborti, 2003). Finalmente, na Figura 6, são apresentados gráficos do tipo Box Plot para comparação dos valores obtidos de correlação entre os cenários simulados e o valor histórico.

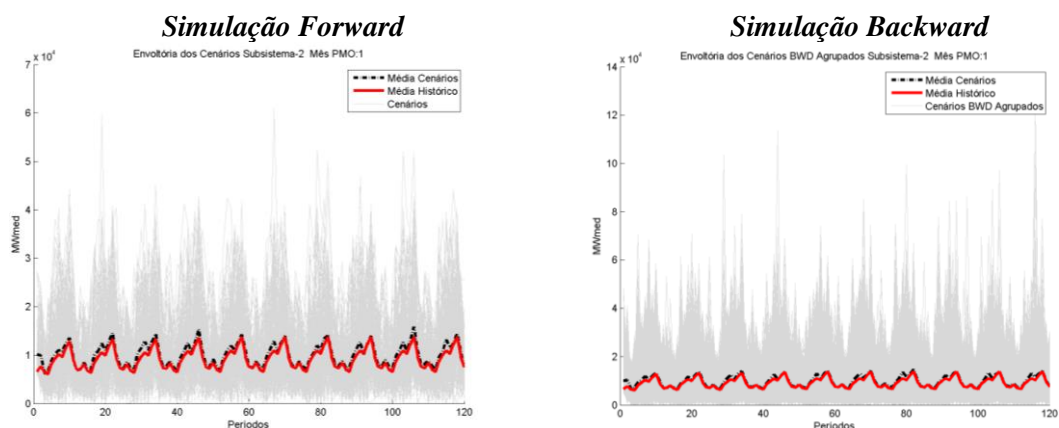


Figura 2 - Envoltória (cinza), média dos cenários (linha vermelha) e histórica (linha descontínua preta)

Nas figuras a seguir, o p-value do teste de hipótese realizado, com nível de significância de 5%, para cada período do horizonte de simulação está representado pelas barras verticais. O limite inferior para não rejeição da hipótese nula está destacado pela linha horizontal contínua preta. Nota-se que para todos os testes realizados, para os cenários das recursões *Forward* e *Backward*, a proporção de aceitação no mínimo de 95% para análise de média e variância. No caso do teste K-S, 80% e 64%, respectivamente para as simulações *Forward* e *Backward*.

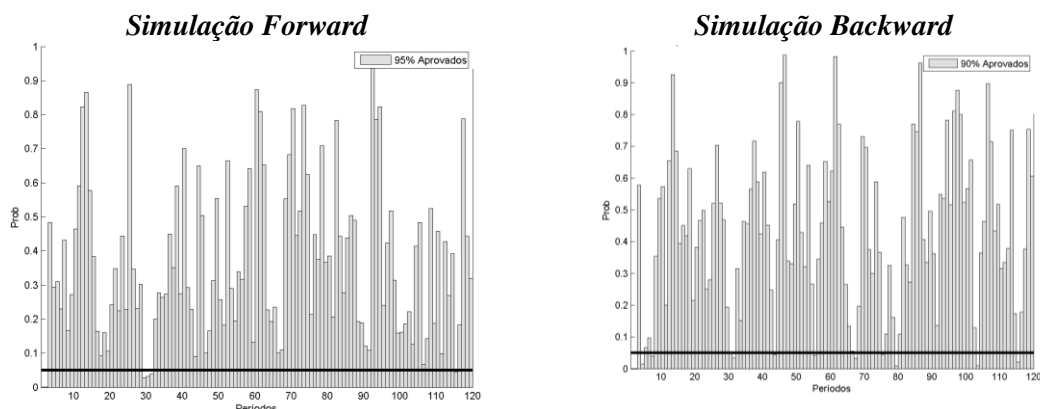


Figura 3 – p-valores dos testes de média para todos os períodos

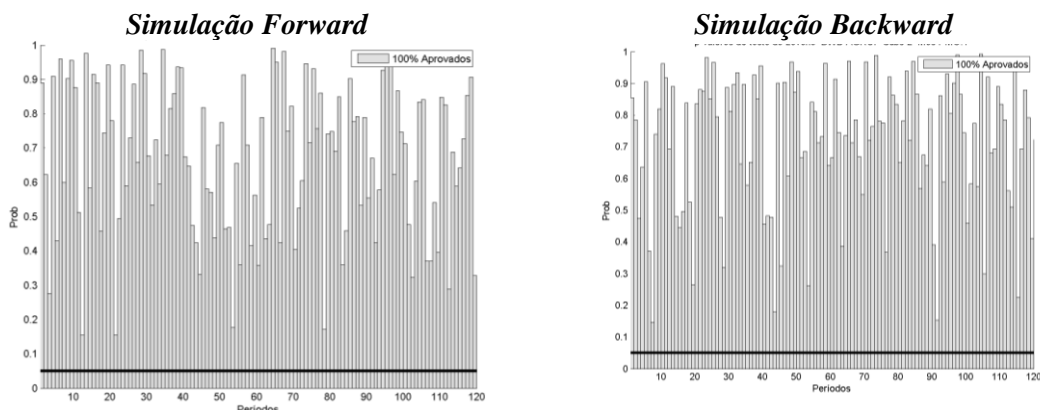


Figura 4 - p-valores dos testes de variância para todos os períodos simulados

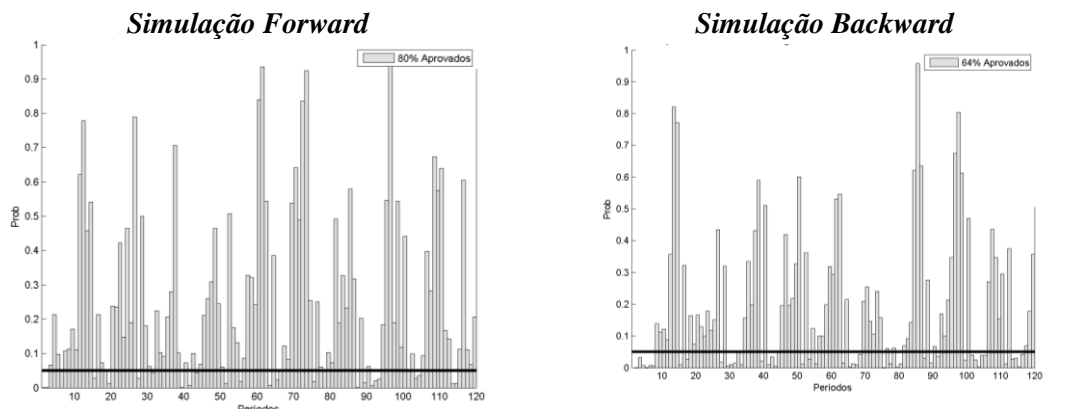


Figura 5 - p-valores dos testes de KS para todos os períodos simulados

No caso da análise de correlação, com exceção do par SulxSudeste/Centro-Oeste, o valor da mediana obtida no Box Plot é bastante próximo do valor histórico.

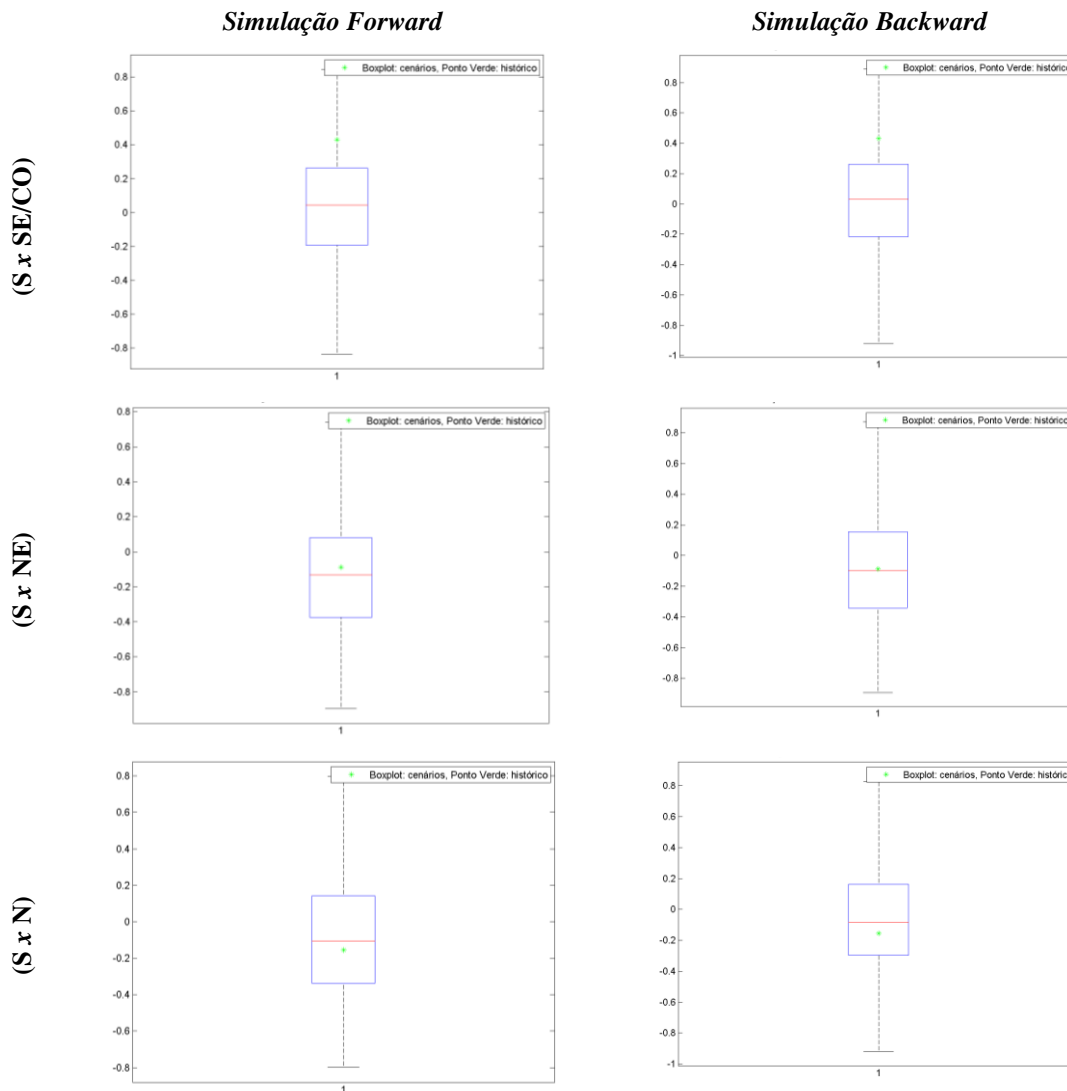


Figura 6 – Correlação cruzada

Com base nos resultados apresentados, é possível considerar o modelo estocástico para construção das árvores de cenários para as recursões *Forward* e *Backward* adequado, haja vista o desempenho do mesmo no que tange à qualidade das séries simuladas, embora ainda sejam possíveis novas investigações acerca da maior aderência entre as distribuições e com relação à conservação da correlação com o subsistema Sudeste/Centro-Oeste. Na próxima seção são apresentadas as considerações finais acerca do modelo proposto.

4. Considerações Finais

A partir da análise dos resultados obtidos no que tange à qualidade dos cenários gerados em relação à reprodução das características do histórico, é possível concluir que a modelagem proposta neste trabalho mostrou-se adequada à fase estocástica do planejamento da operação do despacho hidrotérmico de médio prazo no contexto do SEB. As simulações *Forward* e *Backward* foram avaliadas a partir de vários testes e, para a maioria dos períodos, não foi possível rejeitar as hipóteses nulas dos testes especificados, indicando a reprodução adequada do histórico do PMO considerado.

A partir dos resultados obtidos, os avanços na metodologia proposta relacionam-se à aplicação da mesma no modelo de otimização que emprega a técnica de PDDE com vistas à avaliação do desempenho do modelo no planejamento da operação com relação, por exemplo, aos custos total e marginal da operação, geração hidráulica e térmica, déficit futuro, energia armazenada final, dentre outros.

5. Referências

- Almeira, A., Ellian, S. & Nobre, J.** (2008). Modificações e Alternativas aos Testes de Levene e de Brown e Forsythe para Igualdade de Variâncias e Médias. *Revista Colombiana Estadística*, 31(2), pp. 241-260.
- Bartolini, P., Sakas, J. & Obeysekera, J. T. B.** (1988). Multivariate periodic ARMA(1,1) process. *Water Resources Research*, 25(8), pp. 1237-1246.
- Box, G. E. P., Jenkins, G. M. & Reinsel, G. C.** (2008). *Time Series analysis: forecasting and control*. s.l.:Wiley.
- Casela, G. & Berger, R. L.** (2001). *Statistical Inference*. 2nd ed. s.l.:Duxbury Press.
- Castro, C. M. B.** (2012). *Planejamento Energético da Operação de Médio Prazo Conjugando as Técnicas de PDDE, PAR(p) e Bootstrap*. Juiz de Fora: Tese de Doutorado em Engenharia Elétrica, Universidade Federal de Juiz de Fora.
- Cepel**, (2001). Manual de referência do Modelo NEWAVE, Rio de Janeiro: s.n.
- Charbeneau, R. J.** (1978). Comparison of the Two and Three-Parameter Log Normal Distributions Used in Streamflow Synthesis. *Water Resources Research*, 14(1), pp. 149-150.
- Chrralaksanakul, A.** (2003). *Monte Carlo Methods for Multi-stage Stochastic Programs*. Austin(Texas): PhD Dissertation, The University of Texas at Austin.
- Consigli, G. & Dempster, M. A. H.** (1998). Dynamic stochastic programming for asset-liability management. *Annals of Operations Research*, Volume 81, pp. 131-161.
- Dias, B. H. et al.** (2010). Stochastic Dynamic Programming Applied to Hydrothermal Power Systems Operation Planning Based on the Convex Hull Algorithm. *Mathematical Problems in Engineering*, Volume 2010, pp. 1-21.
- Efron, B. & Tibishirani, R. J.** (1993). *An Introduction to the Bootstrap*. New York: Chapman & Hall.
- Gellens, D.** (2002). Combining regional approach and data extension procedure for assessing GEV distribution of extreme precipitation in Belgium. *Journal of Hydrology*, Volume 268, pp. 113-126.
- Gibbons, J. D. & Chakraborti, S.** (2003). *Non Parametric Statistical Inference*. Fourth Edition ed. New York: Taylor & Francis.

- Gladyshev, E. G.** (1961). Periodically correlated random sequences. *Sov. Math. Dokl.*, Volume 2, pp. 385-388.
- Katz, R. W.** (1999). Extreme value theory for precipitation. *Advances in Water Resources*, Volume 23, pp. 133-139.
- Katz, R. W., Parlange, M. B. & Naveau, P.** (2002). Statistics of extremes in hydrology. *Advances in Water Resources*, Volume 25, pp. 1287-1304.
- Lund, R., Shao, Q. & Basawa, I.** (2006). Parsimonious Periodic Time Series Modeling. *Australian & New Zealand Journal of Statistics*, Volume 48, pp. 33-47.
- Marcato, A. L. M.** (2002). Representação híbrida de sistemas equivalentes e individualizados para o planejamento da operação a médio prazo de sistemas de potência de grande porte. Rio de Janeiro: Tese de Doutorado, DEE, PUC-Rio.
- Martins, E. S. & Stedinger, J. R.** (2000). Generalized maximum-likelihood generalized extreme-value quantile estimators for hydrologic data. *Water Resources Research*, 36(3), pp. 737-744.
- Matos, V. L.** (2008). Análise comparativa entre as modelagens de reservatório equivalente de energia agregado por Subsistema e por cascata no problema do Planejamento anual da operação energética. s.l.:Dissertação de Mestrado, Departamento de Engenharia Elétrica, UFSC.
- McLeod, A. I.** (1994). Diagnostic checking of periodic autoregression models with application. *Journal of Time Series Analysis*, 15(2), pp. 221-233.
- Morrison, J. & Smith, J. A.** (2002). Stochastic modeling of flood peaks using the generalized extreme value distribution. *Water Resources Research*, 38(12), pp. 1-12.
- Obeysekera, J. T. B. & Salas, J. D.** (1982). ARMA model identification of hydrologic time series. *Water Resources Research*, 18(4), pp. 1001-1021.
- Oliveira, F. L. C.** (2010). Nova abordagem para geração de cenários de aflúências no planejamento da operação energética de médio prazo. Rio de Janeiro: Dissertação de Mestrado, DEE, PUC-Rio.
- Oliveira, F. L. C. & Souza, R. C.** (2011). A new approach to identify the structural order of par (p) models. *Pesquisa Operacional*, 31(3), pp. 487-498.
- Oliveira, W. L.** (2007). Redução ótima de cenários em programação estocástica. Aplicação às vazões afluentes aos aproveitamentos hidroelétricos. s.l.:Dissertação de Mestrado, IMPA.
- ONS**, (2013). www.ons.org.br. [Online] [Acesso em Fevereiro 2013].
- Pagano, M.** (1978). On periodic and multiple autorregressions. *The Annals of Statistics*, 6(6), pp. 1310-1317.
- Parzen, E. & Pagano, M.** (1979). A approach to modeling seasonally stationary time series. *Journal of Econometrics*, Volume 9, pp. 137-153.
- Penna, D. D. J.** (2009). Definição da árvore de cenários de aflúências para o planejamento da operação energética de médio prazo. Rio de Janeiro: Tese de Doutorado, DEE, PUC-Rio.
- Pereira, M. V. F.** (1989). Optimal stochastic operations scheduling of large hydroelectric systems. *International Journal of Electric Power and Energy Systems*, 11(3), pp. 161-169.
- Pereira, M. V. F. & Pinto, L. M. V. G.** (1991). Multi-Stage Stochastic Optimization Applied to Energy Planning. *Mathematical Programming*, 52(3), pp. 359-375.
- Quadros, L. E., Queiroz, M. M. F. & Vilas Boas, M. A.** (2011). Distribuição de frequência e temporal de chuvas intensas. *Acta Sci., Agron. (Online)*, 33(3), pp. 401-410.
- Ramesh, N. I. & Davison, A. C.** (2002). Local models for exploratory analysis of hydrological extremes. *Journal of Hydrology*, Volume 256, pp. 106-119.
- Salas, J. D., Boes, D. C. & Smith, R. A.** (1982). Estimation of ARMA models with seasonal parameters. *Water Resources Research*, 18(4), pp. 1006-1010.
- Shahjajan Mondal, M. W. S. A.** (2006). Generating and forecasting monthly flows of the Ganges river with PAR model. *Journal of Hydrology*, Volume 323, pp. 41-46.
- Souza, R. C., Marcato, A. L. M., Dias, B. H. & Oliveira, F. L. C.** (2012). Optimal Operation of Hydrothermal Systems with Hydrological Scenario Generation through Bootstrap and Periodic Autoregressive Models. *European Journal of Operational Research*, 222(3), pp. 606-615.

- Thomas, H. A. & Fiering, M. B.** (1962). Mathematical synthesis of streamflow sequences for the analysis of river basins by simulation. *Design of Water Resource Systems*, pp. 459-463.
- Troutman, B. M.** (1979). Some results in periodic autorregression. *Biometrika*, Volume 66, pp. 219-228.
- Vechia, A. V.** (1985). Periodic autoregressive moving average (PARMA) modeling with application to water resources. *Water Resources Bulletin*, Volume 21, pp. 721-730.