



Influência de fenômenos climáticos na geração de cenários de Energia Natural Afluente: um caso de estudo para o subsistema Sul e o índice SOI

Paula Medina Maçaira

PUC-Rio/Departamento de Eng. Industrial
Rua Marquês de São Vicente, 225, Gávea - Rio de Janeiro, RJ
paulamacaira@aluno.puc-rio.br

Fernando Luiz Cyrino Oliveira

PUC-Rio/Departamento de Eng. Industrial
Rua Marquês de São Vicente, 225, Gávea - Rio de Janeiro, RJ
cyrino@puc-rio.br

Reinaldo Castro Souza

PUC-Rio/Departamento de Eng. Elétrica
Rua Marquês de São Vicente, 225, Gávea - Rio de Janeiro, RJ
reinaldo@ele.puc-rio.br

RESUMO

A matriz energética brasileira é formada essencialmente por fontes hidráulicas, que atualmente representam 70% da capacidade instalada, tendo como principal característica uma forte dependência dos regimes de afluições. O Setor Elétrico Brasileiro utiliza um modelo linear autorregressivo para modelagem e simulação de cenários sintéticos de afluições, não considerando qualquer informação exógena que possa afetar os regimes hidrológicos. O objetivo principal deste trabalho é inferir sobre a influência dos fenômenos El Niño nas afluições, como forma de melhorar o desempenho do modelo. Para tanto, foi aplicado um Modelo Aditivo Generalizado, considerando como variável exógena o Southern Oscillation Index (SOI), um índice padronizado que indica o desenvolvimento e intensidade de El Niño no Oceano Pacífico, para gerar cenários para o subsistema Sul. Os resultados indicam que a inclusão de variáveis climáticas neste contexto é um campo de pesquisa promissor, considerando a importância da precisão dos cenários no planejamento energético de longo prazo.

PALAVRAS CHAVE. ENA, SOI, Modelos Aditivos Generalizados.

Tópicos: EN, SIM.

ABSTRACT

The Brazilian electrical energy matrix is essentially formed by hydraulic sources, which currently account for 70% of the installed capacity, with main characteristic the strong dependence on the streamflow regimes. The Brazilian Electrical System uses a linear autoregressive model to modelling and simulate synthetic scenarios for hydrological streamflow, not considering any exogenous information that may affect the hydrological regimes. The main objective of this paper is to infer on the influence of El Niño phenomena into the streamflow process as a way to improve the model's performance. To do so, it was applied a Generalized Additive Model considering, as an exogenous variable, the Southern Oscillation Index (SOI), a standardized index that gives an indication of the development and intensity of El Niño events in the Pacific Ocean, to generate scenarios for the South subsystem. The results indicate that the inclusion of climate variables in this context is a promising research field, considering the importance of the scenarios accuracy in the long term energy planning.

KEYWORDS. Inflow, SOI, Generalized Additive Models.

Paper topics: EN, SIM.



1. Introdução

A geração de eletricidade brasileira é composta basicamente por usinas hidroelétricas pertencentes a múltiplos proprietários; o Sistema Interligado Nacional (SIN) integra a potência produzida e as linhas de transmissão do Sul, Sudeste, Centro-Oeste, Nordeste e parte da região Norte. Apenas 1.7% da capacidade produzida de eletricidade do país encontra-se fora do SIN, em pequenos sistemas isolados localizados principalmente na região amazônica [ONS, 2014].

Planejar o setor energético brasileiro significa, basicamente, tomar decisões sobre o despacho de usinas hidrelétricas e termoeleétricas, com o risco de perdas financeiras ou racionamento de energia, como aconteceu em 2001, afetando quase todas as regiões brasileiras [Pinguelli et al., 2013].

Uma das principais características do sistema de geração hidráulica é a sua forte dependência dos regimes hidrológicos. Assim, o planejamento da operação de despacho tem que definir metas de geração para as usinas hidrelétricas e térmicas ao longo do horizonte do estudo, considerando a demanda de eletricidade, as plantas e as restrições operacionais elétricas [Pereira, 1989].

Considerando a dependência dos regimes hidrológicos, a incerteza existente no planejamento energético brasileiro requer uma modelagem estocástica adequada e consistente das séries hidrológicas. Portanto, é possível identificar a importância de construir modelos para gerar cenários hidrológicos, a fim de otimizar o desempenho da operação do sistema, agregando confiabilidade ao sistema e reduzindo seus custos [Oliveira, 2010]. Este processo de otimização tem uma variável estocástica: Energia Natural Afluente (ENA).

Existem, basicamente, duas abordagens para prever as afluências: modelos físicos e estatísticos, onde o primeiro inclui o modelo hidrológico chuva-escoamento e o segundo aborda métodos baseados em dados, como séries temporais. Para realizar previsões e simulação mensais, o modelo clássico Autoregressivo Periódico (p) [Terry et al., 1986], tem sido amplamente utilizado. Este tipo de modelo ajusta a série usando os parâmetros estimados dos dados históricos [Maceira e Damázio, 2006], e não considera qualquer informação exógena que possa afetar os regimes hidrológicos e, conseqüentemente, a geração de eletricidade. Vários exemplos da aplicação do PAR(p) podem ser encontrados na literatura, veja por exemplo Mondal e Wasimi [2006] que gera e prevê entradas mensais do rio Ganges com o modelo PAR. Uma pesquisa rápida de literatura também retorna um extenso conjunto de modelos univariados aplicados as afluência de reservatórios (por exemplo, Ravines et al. [2008]).

Entretanto, modelos que incorporam variáveis explicativas, especificamente climáticas, têm sido desenvolvidos recentemente. Alguns exemplos destes trabalhos em ordem cronológica são: Uvo e Graham [1998] estudou a relação entre o padrão da temperatura da superfície do mar (SST) sobre os oceanos Atlântico e Pacífico e a variabilidade da disponibilidade de água na Bacia Amazônica; Kelman et al. [2000] introduziu um procedimento para condicionar ainda mais as distribuições de probabilidade de afluência, considerando as recentes medições de variáveis climáticas, Souza Filho e Lall [2003] desenvolveu uma abordagem semiparamétrica para prever a afluência em múltiplos locais de medição em precursores climáticos; Maity e Kumar [2008] aplicou Redes Neurais Artificiais para modelar a complexa relação entre afluência e fenômeno climático; Kumar e Maity [2008] investigou o potencial da abordagem de modelagem dinâmica Bayesiana para prever uma série temporal hidrológica usando informações relevantes do índice climático; Lima e Lall [2010] incluiu informações climáticas em um modelo auto-regressivo periódico, a fim de fornecer previsões mensais de vazão para 54 hidrelétricas no Brasil; e Lima et al. [2014] aplicou Modelos Dinâmicos Bayesianos para modelar e prever a vazão dos reservatórios hidrelétricos brasileiros, concluindo que a incorporação de variáveis climáticas como precipitação pluviométrica e variáveis El Niño aumentaram a precisão tanto da modelagem quanto da previsão.

Considerando o contexto e a relevância do assunto, este trabalho tem como objetivo investigar e propor avanços metodológicos na modelagem de séries temporais e simulação estocástica



para gerar cenários hidrológicos sintéticos para modelar o despacho hidrotérmico brasileiro.

O método proposto, pretende incluir através de modelos aditivos generalizados, a influência dos fenômenos climáticos El Niño e La Niña medidos pelo Southern Oscillation Index (SOI) na geração de cenários de Energia Natural Afluente.

O artigo está organizado da seguinte forma: a seção 2 apresenta o contexto teórico, com uma breve descrição do Modelo Aditivo Generalizado e uma breve descrição da técnica de Bootstrap, utilizada para gerar os cenários sintéticos. A seção 3 apresenta uma análise exploratória das variáveis disponíveis, seguido dos resultados obtidos e a seção 4 resume o trabalho com as conclusões e observações finais.

2. Referencial Teórico

2.1. Modelos Aditivos Generalizados

Os modelos aditivos generalizados (MAG) podem ser considerados uma generalização dos modelos lineares generalizados (MLG) introduzidos por Nelder e Wedderburn [1972]. Os MLG's são da forma:

$$g[E(Y|X_1, \dots, X_p)] = \alpha + \beta_1 X_1 + \dots + \beta_p X_p, \quad (1)$$

onde Y é uma variável resposta, X_1, \dots, X_p são variáveis preditoras, $g(\cdot)$ é a função de ligação que relaciona a média da resposta com as variáveis preditoras e $\alpha, \beta_1, \dots, \beta_p$ são parâmetros a serem estimados.

Uma característica dos MLG's é que a forma da relação funcional entre a média da variável resposta e as variáveis preditoras é completamente especificada por termos paramétricos $\beta_1 X_1, \dots, \beta_p X_p$. Um procedimento alternativo é adotar um modelo não paramétrico no qual a relação entre a resposta e cada uma das variáveis preditoras é ditada pelos próprios dados. Modelos assim definidos constituem os modelos aditivos generalizados descritos por Hastie e Tibshirani [1990], cuja forma geral é:

$$g[E(Y|X_1, \dots, X_p)] = \alpha + f_1(X_1) + \dots + f_p(X_p), \quad (2)$$

onde $g(\cdot)$ continua sendo a função de ligação que relaciona a média da resposta com as variáveis preditoras, α é um parâmetro a ser estimado e f_1, \dots, f_p são funções arbitrárias não especificadas. A única restrição sobre essas p funções é que sejam suaves. O termo "aditivo" deve-se ao fato do modelo ser constituído pela soma de funções das variáveis preditoras, o que permite avaliar o efeito de cada uma delas na variável resposta, condicionalmente à presença das outras covariáveis no modelo.

Dentre as vantagens dos MAG's, citam-se: a possibilidade de modelar relações não lineares utilizando funções para cada covariável de forma a obter predições mais precisas, e a manutenção da capacidade interpretativa do modelo devido a sua natureza aditiva, onde é possível interpretar o efeito individual de cada covariável na variável resposta.

2.2. Geração de cenários sintéticos

Para simular cenários sintéticos da variável ENA a técnica conhecida como Bootstrap é aplicada. Esta técnica, desenvolvida por Efron [1979], é um método de amostragem com reposição das observações de uma amostra aleatória que permite a avaliação da variabilidade de um estimador. Essa técnica gera tantas amostras novas quanto se deseja, chamadas de "amostra Bootstrap", geralmente com o mesmo tamanho da amostra original. No contexto de séries temporais, existem basicamente duas maneiras de aplicar esta técnica: Bootstrap nos resíduos e o método chamado Bootstrap Moving Blocks [Kunsch, 1989].

Neste trabalho, o Bootstrap é aplicado nos resíduos, pelo fato de que para a série estudada é possível extrair resíduos do tipo ruído branco, assegurando assim as hipóteses de uma amostra aleatória (isto é, observações independentes e identicamente distribuídas) uma condição necessária para aplicar Bootstrap nos resíduos.



Uma descrição formal do método é: considere R_1, \dots, R_N a amostra aleatória e B o número de séries de resíduos a serem geradas. B séries residuais são construídas com reposição da amostra original, gerando B séries de resíduos Bootstrap de tamanho N cada: r^1, \dots, r^B , onde $r^i = r_1^i, \dots, r_N^i, i = 1, \dots, B$.

A seguir o passo a passo para geração dos cenários Energia Natural Afluente, segundo Cyrino Olivera et al. [2013]:

1. Amostrar, através da técnica não paramétrica Bootstrap, resíduos dos modelos estocásticos definidos para cada um dos períodos do horizonte de planejamento.
2. Selecionar os N caminhos simulados dos períodos.
3. Compor, a partir dos resíduos sorteados, os caminhos, respeitando a restrição de que os valores de ENA, obtidos a partir do modelo estocástico, sejam positivos.
4. Verificar que, em caso de valores de ENA simulados negativos, tais elementos devem ser descartados e novos sorteios devem ser realizados.

Anderson et al. [2012] calculou intervalos de confiança Gaussianos para os parâmetros estimados de um modelo média móvel autorregressivo periódico (PARMA). No presente estudo, o intervalo de confiança de 5% é construído a partir das séries simuladas calculando os quantis 2.5% e 97.5%.

3. Resultados

3.1. Análise Exploratória

A Energia Natural Afluente é a média da vazão recebida por unidade de tempo no reservatório de cada gerador. O dado histórico disponível data de janeiro de 1931 até dois anos antes do mês corrente em base mensal e medida em megawatt médio.

O Southern Oscillation Index (SOI) é calculado com base na diferença entre a pressão atmosférica ao nível do mar nas regiões de Tahiti (no Pacífico Ocidental) e Darwin (Austrália, Pacífico Ocidental). Períodos consecutivos de valores negativos indicam ocorrência do fenômeno El Niño; entretanto, valores consecutivos positivos denotam a presença de La Niña e valores próximos a zero indicam uma situação normal, onde nenhum dos dois fenômenos ocorre. A série mensal histórica oficial deste índice é fornecida pela National Oceanic and Atmospheric Administration (NOAA) [NOAA, 2016] e datam de 1951 até o mês corrente.

Para melhor compreensão das séries utilizadas nesta pesquisa, esta seção apresenta uma análise exploratória que inclui: evolução da série através do tempo utilizando o gráfico da linha; distribuição de probabilidade das variáveis usando o histograma; características mensais das séries; e estatística descritiva da ENA e do SOI.

As estatísticas descritivas de cada uma das séries são apresentadas na Tabela 1, mostrando que a série SOI é extremamente volátil e possui média próxima a 0 e desvio padrão próximo a 1, enquanto a série de ENA apresenta valor baixo de coeficiente de variação, porém uma grande diferença entre os valores mínimo e máximo. Os coeficientes de assimetria e curtose são indicativos do formato da distribuição dos dados e seu deslocamento em relação a 0. Valores de assimetria maiores do que 0 apontam para dados com alta concentração em valores pequenos e curtose próxima a 3 indica uma distribuição do tipo sino. Segundo a Tabela 1 a ENA possui concentração dos dados a esquerda (assimetria negativa) e um formato leptocúrtico (curtose maior que 3), enquanto que a série SOI possui um formato muito próximo a Normal padrão, pois apresenta assimetria aproximadamente 0 e curtose aproximadamente 3.



Tabela 1: Estatísticas descritivas ENA e SOI

| Estatística | ENA (MWmed) | SOI |
|--------------------------|-------------|--------|
| Média | 10840.711 | 0.024 |
| Mediana | 8620.500 | 0.000 |
| Desvio Padrão | 7614.050 | 0.989 |
| Coefficiente de Variação | 0.702 | 41.027 |
| Assimetria | 2.324 | -0.315 |
| Curtose | 13.539 | 3.705 |
| Mínimo | 1442.000 | -3.600 |
| Máximo | 69521.000 | 2.900 |

As características de assimetria e curtose inferidas sobre as distribuições das séries de ENA e SOI podem ser confirmadas através dos histogramas dispostos nas Figuras 1 e 2, note a alta concentração em valores pequenos da série de ENA e o formato próximo de sino para a série SOI. Ainda na Figura 1, a evolução temporal da série de ENA do subsistema Sul mostra a presença de diversos outliers enquanto que o monthplot apresenta a ausência de uma definição periódica entre meses ditos úmidos e secos, característica comum para séries hidrológicas. Essa ausência de sazonalidade é a principal dificuldade para um ajuste preciso da série e o motivador para a busca de informações exógenas que auxiliem na explicação de comportamento tão anormal.

Na Figura 2 pode-se observar além do histograma, a evolução temporal da série SOI conjuntamente com a identificação da ocorrência dos eventos El Niño e La Niña. Como explicado anteriormente, uma sequência de valores negativos indica a ocorrência de El Niño enquanto uma sequência de valores positivos indica a ocorrência de La Niña. O critério comumente utilizado para identificar tais fenômenos consiste em cinco valores seguidos acima de $+0.5^\circ$ ou abaixo de -0.5° , isto é, assume-se que no quinto mês seguido de valores acima de $+0.5^\circ$ é caracterizado o evento La Niña e no quinto mês seguido de valores abaixo de -0.5° caracteriza-se o El Niño. Aplicando tal critério a série de SOI de 1983 até 2010, observa-se a ocorrência de 8 eventos El Niño e 7 eventos La Niña, onde o mais profundo El Niño ocorreu no início de 1992 e em dezembro de 2010 mediu-se o início de um evento La Niña.

Figura 1: Série de tempo, monthplot e histograma - Energia Natural Afluyente

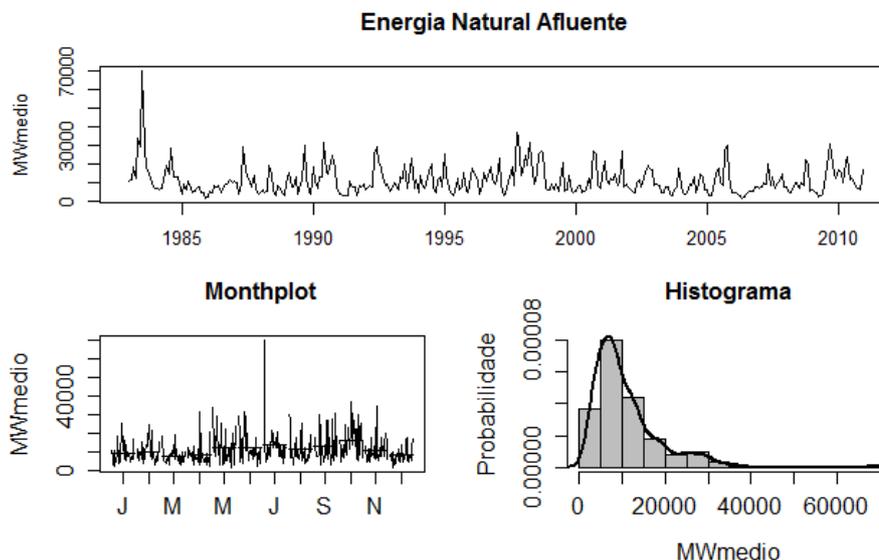
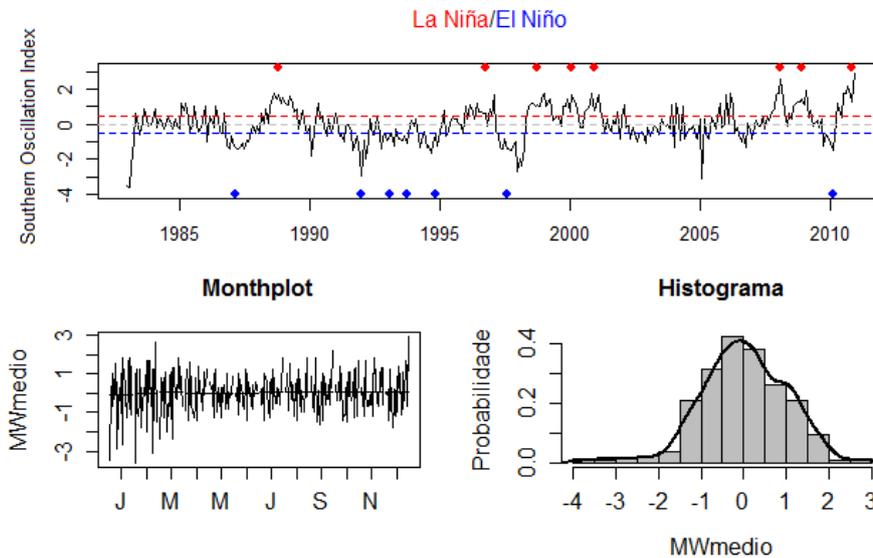




Figura 2: Série de tempo, monthplot e histograma - Southern Oscillation Index



3.2. Ajuste do Modelo Aditivo GAM

O procedimento inicial para geração de cenários de energia natural afluyente com o modelo aditivo generalizado consiste no ajuste de um modelo ao histórico disponível. Para encontrar a melhor equação de MAG que ajuste o histórico de ENA, ou seja, para definir a melhor combinação de variáveis predictoras que reproduzissem o histórico de ENA, uma variedade de modelos foi testada afim de encontrar a combinação que produzisse melhores métricas de ajuste: raiz do erro quadrático médio (RMSE), erro médio absoluto (MAE) e erro médio percentual absoluto (MAPE). Nesse passo foi definido que a melhor combinação de variáveis que descreve o histórico de ENA consiste na: ENA defasada em um mês, SOI no mês corrente, defasada em dois meses, seis meses, nove meses e onze meses, além de uma dummy para identificação do mês de ajuste. A equação pode ser vista na Equação 3 onde a função de ligação é do tipo Gaussiana.

$$MAG_{SOI} : ENA_t = ENA_{t-1} + SOI_t + SOI_{t-2} + SOI_{t-6} + SOI_{t-9} + SOI_{t-11} + dummy_{mes} \quad (3)$$

Para critério de comparação, foi definido que dois outros modelos devem ser ajustados a série de ENA: o PAR(p) e um MAG com ausência da variável SOI entre as variáveis predictoras. O modelo PAR(p) é o atualmente empregado pelo Setor Elétrico Brasileiro e seus parâmetros foram definidos através do critério de informação AIC [Akaike, 1974]. Já o MAG estimado através da combinação somente da série ENA defasada é chamado de Benchmark, onde a melhor combinação de defasagens também foi definida com auxílio do critério AIC. Na Equação 4 é possível observar que o melhor PAR(p) encontrado possui ordens $p = (1, 1, 4, 2, 1, 1, 2, 1, 1, 1, 1)$, onde o mês de março foi o que obteve maior ordem autoregressiva. A Equação 5 mostra que a melhor combinação de variáveis predictoras segundo o critério AIC consiste na ENA defasada em um e quatro meses, além de uma dummy para identificar o mês de ajuste.



$$\begin{aligned}
 PAR(p) = & \phi_1^{Jan} ENA_{t-1} + \phi_1^{Fev} ENA_{t-1} + \phi_1^{Mar} ENA_{t-1} \\
 & + \phi_2^{Mar} ENA_{t-2} + \phi_3^{Mar} ENA_{t-3} + \phi_4^{Mar} ENA_{t-4} \\
 & + \phi_1^{Abr} ENA_{t-1} + \phi_2^{Abr} ENA_{t-2} + \phi_1^{Mai} ENA_{t-1} \\
 & + \phi_1^{Jun} ENA_{t-1} + \phi_1^{Jul} ENA_{t-1} + \phi_2^{Jul} ENA_{t-2} \\
 & + \phi_1^{Ago} ENA_{t-1} + \phi_1^{Set} ENA_{t-1} + \phi_1^{Out} ENA_{t-1} \\
 & + \phi_1^{Nov} ENA_{t-1} + \phi_1^{Dez} ENA_{t-1} \quad (4)
 \end{aligned}$$

$$MAG_{Benchmark} : ENA_t = ENA_{t-1} + ENA_{t-4} + dummy_{mes} \quad (5)$$

As métricas de ajuste computadas para cada um dos três modelos podem ser vistas na Tabela 2. Observe que para as três métricas os modelos do tipo MAG foram melhores do que o PAR(p), mesmo o que não inclui a variável SOI, porém o melhor modelo no ajuste é o que considera os fenômenos El Niño, alcançando uma redução de aproximadamente 13% nas métricas avaliadas, em relação ao PAR(p).

Tabela 2: Métricas de ajuste

| Modelo | RMSE | MAE | MAPE |
|--------------------------|------|------|------|
| PAR(p) | 5923 | 4207 | 51.0 |
| MAG _{Benchmark} | 6059 | 4156 | 49.1 |
| MAG _{SOI} | 4983 | 3633 | 44.3 |

Além da comparação entre as medidas de erro foi realizado o teste de Diebold-Mariano [Diebold e Mariano, 1995] que consiste na hipótese alternativa de que o modelo MAG_{SOI} possui maior precisão do que o modelo PAR(p) para ajuste da série de energia natural afluyente. Tal teste apresentou um p-valor de 0.008, confirmando a rejeição da hipótese nula de que os modelos possuem a mesma precisão e reafirmando a importância da inserção da variável SOI na modelagem da série de ENA do subsistema Sul. Verifique na Figura 3 o histórico da variável ENA e os valores ajustados pelo modelo MAG.

Após a definição de qual o melhor modelo para gerar os cenários sintéticos de ENA, através da comparação das performances dos modelos no ajuste, deve-se verificar se os resíduos gerados possuem comportamento semelhante a um ruído branco. Uma série ruído branco tem como características a média igual a zero, variância homocedástica e não correlação temporal. Note na Figura 4 que a média dos resíduos está distribuída em torno de zero, com confirmação através da não rejeição da hipótese nula do teste T-Student de que a média dos resíduos é significativamente igual a zero. Também na Figura 4 é possível verificar que os gráficos de Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACP) não apresentam qualquer Lag significativo, confirmando a não correlação temporal. Após essas verificações confirma-se que os resíduos gerados pelo modelo MAG possuem comportamento de ruído branco, portanto os cenários a serem gerados podem ser feitos através da técnica não paramétrica Bootstrap aplicada diretamente aos resíduos.



Figura 3: Histórico da ENA e ajuste pelo modelo MAG

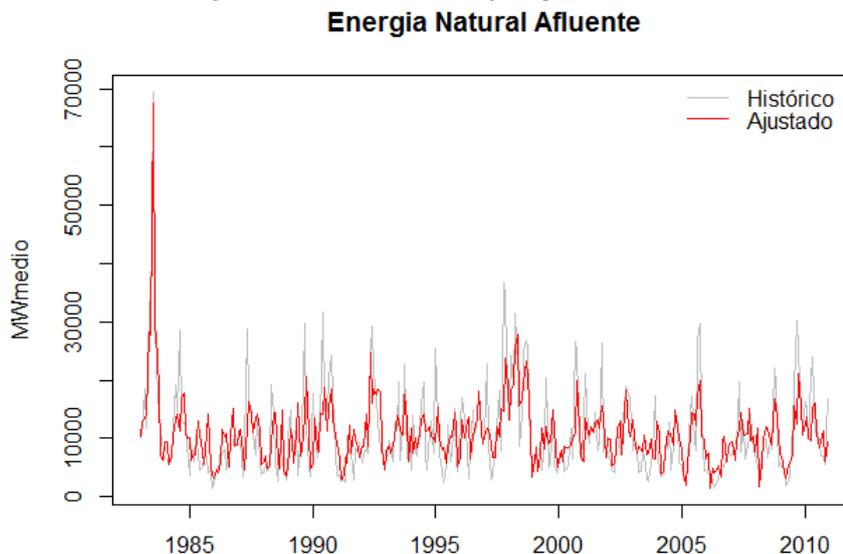
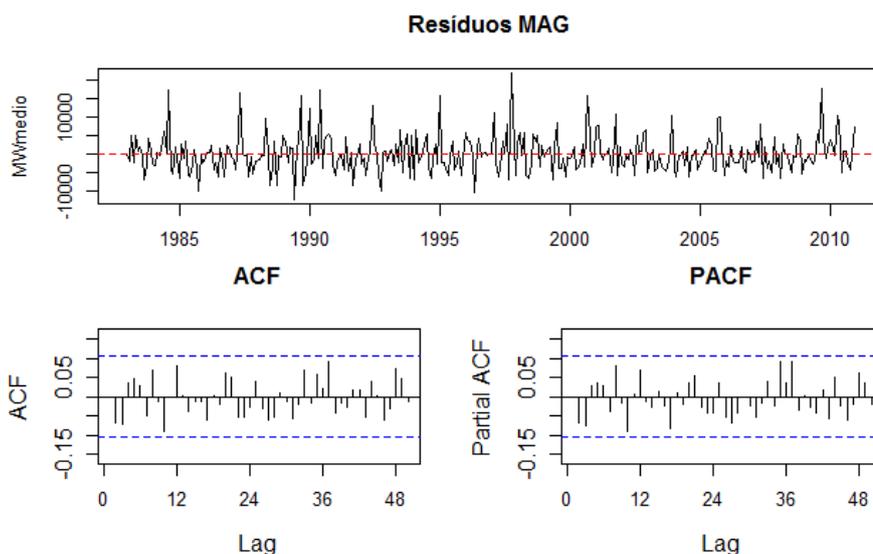


Figura 4: Resíduos Modelo Aditivo Generalizado

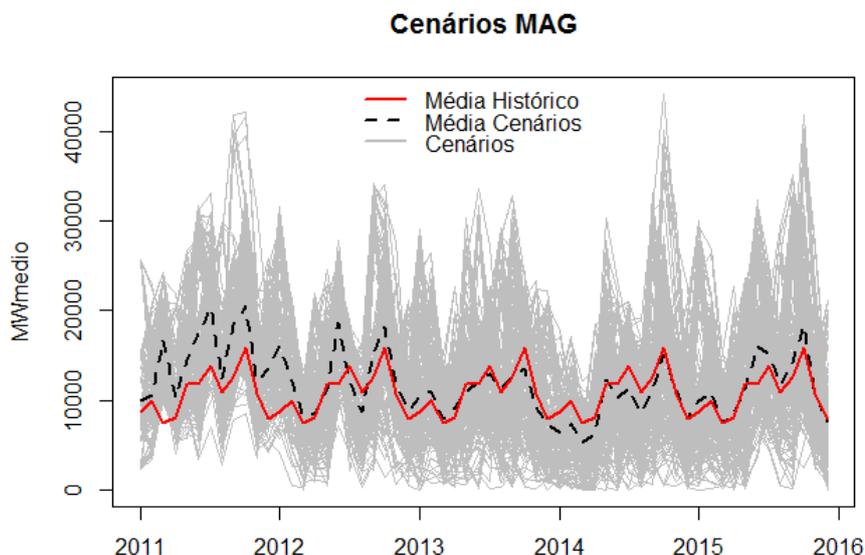


Os cenários sintéticos da ENA do subsistema Sul foram gerados seguindo o passo a passo descrito no Referencial Teórico para um período de 60 meses a frente. Na Figura 5 são apresentados os 200 cenários gerados em cinza, a média dos cenários gerados com a linha pontilhada e a média do histórico de ENA em vermelho. Observa-se que para os dois primeiros anos da simulação existe uma diferença significativa entre a média dos cenários e a do histórico, geradas pela previsão de ocorrência de eventos extremos de La Niña. Para os demais períodos de simulação observa-se uma maior aderência entre a média histórica e a dos cenários.

Mais do que comparar com a média do histórico da série de ENA, esse trabalho também analisou a cobertura do intervalo de confiança dos cenários gerados em relação a ENA verificada no período, isto é, entre janeiro de 2011 e dezembro de 2015. Veja na Figura 6 o intervalo de confiança de 95% em preto e a ENA verificada no período em linhas pontilhadas e pontos vermelhos. Com essa análise mostra-se que 54 observações da ENA verificada encontram-se dentro do intervalo de confiança construído a partir dos cenários gerados (90%), e no caso das afluências mais

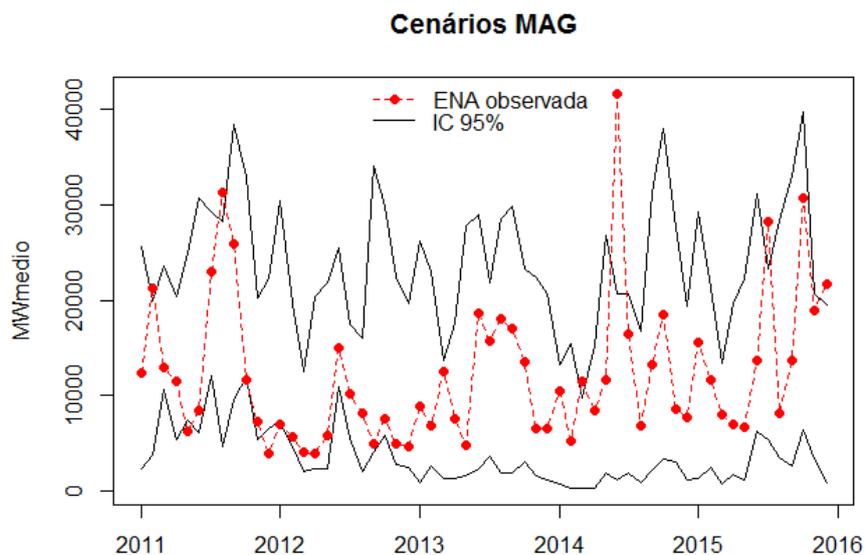


Figura 5: Cenários Modelo Aditivo Generalizado



desfavoráveis, apenas 2 valores foram observados abaixo do intervalo de 2.5%.

Figura 6: Comparação entre a ENA verificada e o intervalo de confiança



4. Conclusão

Atualmente, o Setor Elétrico Brasileiro utiliza um modelo linear autorregressivo para modelagem e simulação de cenários sintéticos de afluências, não considerando qualquer informação exógena que possa afetar os regimes hidrológicos. O objetivo principal deste trabalho foi inferir sobre a influência dos fenômenos El Niño e La Niña nas afluências, como forma de melhorar o desempenho do modelo. Para alcançar tal objetivo foi desenvolvido e aplicado um Modelo Aditivo Generalizado no âmbito da modelagem e simulação da variável de Energia Natural Afluenta para o subsistema Sul com a variável climática SOI, um índice de duração e profundidade dos eventos El Niño e La Niña.

No processo de identificação da melhor combinação de covariáveis que ajustasse a série ENA concluiu-se que a própria ENA defasada em um mês era suficiente em conjunto com a



variável SOI em tempos correntes e defasada em dois, seis, nove e onze meses, segundo critério de informação Akaike. Comparou-se através de métricas de erro o modelo obtido com dois outros: o PAR(p), atualmente aplicado pelo Setor Elétrico; e um MAG somente com variáveis defasadas de ENA. Essa comparação mostrou resultados favoráveis para o modelo com inserção do SOI, mostrando que somente a variável ENA não é suficiente para a explicação da variância total da série.

Já no processo de geração de cenários utilizou-se a técnica de Bootstrap diretamente nos resíduos, pois após diferentes testes provou-se que os resíduos gerados tem o comportamento de um ruído branco, condição necessária para aplicação da técnica não-paramétrica. Como resultado, obtiveram-se 200 cenários sintéticos para 60 períodos a frente, onde a média dos cenários nos dois primeiros anos de simulação não foram aderentes a média histórica da ENA em função da previsão de ocorrência de um evento La Niña. Comparou-se também a média e o intervalo de confiança dos cenários gerados com os valores observados de ENA para o período de simulação (janeiro de 2011 a dezembro de 2015) concluindo que nos casos mais desfavoráveis de ENA, apenas duas observações encontraram-se fora do intervalo de confiança.

A importância deste trabalho se deve a aplicação de Modelos Aditivos Generalizados no contexto das séries de Energia Natural Afluente e a inclusão de fenômenos climáticos para ajuste e geração de cenários sintéticos de ENA. Como diretrizes futuras analisa-se a possibilidade da inclusão de diferentes eventos climáticos e demais variáveis meteorológicas para maior explicação da variabilidade das séries de ENA e aplicação do modelo desenvolvido para os demais subsistemas (Nordeste, Norte e Sudeste/Centro-Oeste). Também verifica-se como oportunidade futura o desenvolvimento de um modelo aditivo generalizado com características periódicas, pois após exaustivos testes notou-se que a característica periódica das séries de afluência devem ser levadas em consideração.

Referências

- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6):716–723.
- Anderson, P. L., Meerschaert, M. M., e Zhang, K. (2012). Forecasting with prediction intervals for periodic autoregressive moving average models. *Journal of Time Series Analysis*, 34:187–193.
- Cyrino Olivera, F., Ferreira, P., e Souza, R. C. (2013). Modelo híbrido para geração de árvores de cenários aplicado ao planejamento do despacho hidrotérmico brasileiro. *Simpósio Brasileiro de Pesquisa Operacional*, p. 997–1008.
- Diebold, F. e Mariano, R. (1995). Comparing predictive accuracy. *Journal of Business and Economic Statistics*, 13:253–63.
- Efron, B. (1979). Bootstrap methods: Another look at the jackknife. *The Annals of Statistics*, 7: 1–26.
- Hastie, T. e Tibshirani, R. (1990). *Generalized Additive Models*. Chapman and Hall/CRC.
- Kelman, J., Vieira, A. M., e Rodriguez-Amaya, J. E. (2000). El niño influence on streamflow forecasting. *Stochastic Environmental Research and Risk Assessment*, 14:123–138.
- Kuensch, H. R. (1989). The jackknife and the bootstrap for general stationary observations. *The Annals of Statistics*, 17:1217–1241.
- Kumar, D. N. e Maity, R. (2008). Bayesian dynamic modelling for nonstationary hydroclimatic time series forecasting along with uncertainty quantification. *Hydrological Processes*, 22:3488–3499.
- Lima, C. H. e Lall, U. (2010). Climate informed monthly streamflow forecasts for the brazilian hydropower network using a periodic ridge regression model. *Journal of Hydrology*, 380:438–449.



- Lima, M., Popova, E., e Damien, P. (2014). Modeling and forecasting of brazilian reservoir inflows via dynamic linear models. *International Journal Forecasting*, 30:464–474.
- Maceira, M. e Damázio, J. (2006). Use of the par(p) model in the stochastic dual dynamic programming optimization scheme used in the operation planning of the brazilian hydropower system. *Probability in the Engineering and Informational Sciences*, 20:143–156.
- Maity, R. e Kumar, D. N. (2008). Basin-scale stream-flow forecasting using the information of large-scale atmospheric circulation phenomena. *Hydrological Processes*, 22:643–650.
- Mondal, M. S. e Wasimi, S. A. (2006). Generating and forecasting monthly flows of the ganges river with par model. *Journal of Hydrology*, 323:41–56.
- Nelder, J. A. e Wedderburn, R. W. M. (1972). Generalized linear models. *Journal of the Royal Statistical Society*, 135(3):370–384.
- NOAA (2016). Climate prediction center. URL www.cpc.ncep.noaa.gov/data/indices/.
- Oliveira, F. L. C. (2010). Nova abordagem para geração de cenários de aflúências no planejamento da operação energética de médio prazo. Master's thesis, Pontifícia Universidade Católica do Rio de Janeiro.
- ONS (2014). Operador nacional do sistema elétrico. URL www.ons.com.br.
- Pereira, M. (1989). Optimal stochastic operations scheduling of large hydroelectric systems. *International Journal of Electric Power and Energy Systems*, 11:161–169.
- Pinguelli, L. R., Fidelis, N. S., Giannini, M. P., e Dias, L. L. (2013). *Evolution of Global Electricity Markets: New Paradigms, New Challenges, New Approaches*. Academic Press.
- Ravines, R. R., Schmidt, A. M., Migon, H. S., e Renno, C. D. (2008). A joint model for rainfall-runoff: the case of rio grande basin. *Journal of Hydrology*, 353:189–200.
- Souza Filho, F. A. e Lall (2003). Seasonal to interannual ensemble streamflow forecasts for ceara, brazil: applications of a multivariate, semiparametric algorithm. *Water Resources Research*, 39 (11).
- Terry, L., Pereira, M., Neto, T. A., Silva, L., e Sales, P. (1986). Coordinating the energy generation of the brazilian national hydrothermal electrical generating system. *Interfaces*, 16:16.
- Uvo, C. B. e Graham, N. E. (1998). Seasonal runoff forecast for northern south america: a statistical model. *Water Resources Research*, 34(12):3515–3524.