

# MODELO PARA GERAÇÃO DE SÉRIES SINTÉTICAS MENSAIS USADAS NO PLANEJAMENTO E OPERAÇÃO DE SISTEMAS HIDROTÉRMICOS

*Ricardo Luis dos Reis*<sup>1</sup>; *Marinho G. Andrade*<sup>1</sup>; *Secundino Soares*<sup>2</sup>; *Donato da Silva Filho*<sup>3</sup>

**Resumo** – Este trabalho apresenta um modelo para geração de séries sintéticas mensais. Neste estudo, considera-se para a série mensal os modelos auto-regressivos periódicos  $PAR(1)$  e  $PAR(p_m)$  com a ordem  $p_m$  selecionada segundo a análise da função de autocorrelação parcial. Os modelos são ajustados considerando-se as equações de *Yule-Walker* periódicas, em que para o ruído dos modelos foi adotada uma distribuição Log-Normal com três parâmetros. O modelo mostra-se eficiente, prático e conduz a séries sintéticas com características estocásticas semelhantes à série observada.

**Abstract** – This paper presents a model for generation of monthly synthetic series. In this study, it is considered for the monthly series periodic autoregressive models,  $PAR(1)$  and  $PAR(p_m)$ , with the order  $p_m$  selected according to the analysis of the partial autocorrelation function. The models are adjusted considering the periodic Yule-Walker equations, that for noise models was used a Log-Normal distribution with three parameters. The model proves efficient, practical and leads to synthetic series with stochastic features similar to the observed series.

**Palavras-Chave** – Geração de vazões médias mensais, modelos auto-regressivos periódicos.

---

<sup>1</sup> Departamento de Matemática Aplicada e Estatística - ICMC - USP, São Carlos-SP, [rreis@icmc.usp.br](mailto:rreis@icmc.usp.br), [marinho@icmc.usp.br](mailto:marinho@icmc.usp.br)

<sup>2</sup> Departamento de Engenharia de Sistemas - FEEC - UNICAMP, Campinas-SP

<sup>3</sup> Energias do Brasil - EDP - São Paulo-SP

# 1 INTRODUÇÃO

Modelos para geração de vazões tornaram-se uma ferramenta muito útil no desenvolvimento dos recursos hídricos. Atualmente, são amplamente utilizados em simulações e técnicas de otimização, tentando-se produzir resultados comparáveis para as várias alternativas de planejamento, projeto ou operação desses recursos hídricos. Nestas áreas, apesar da disponibilidade de longos históricos de vazões, um grande número de sequências, que se assemelhe aos dados históricos em termos de vários parâmetros especificados, são necessários para que se possam conseguir resultados confiáveis.

Os modelos para séries de vazões mensais apresentam sazonalidade na média e no desvio-padrão de cada mês. Além disso, as séries mensais apresentam uma função de autocorrelação que varia de forma periódica, ou seja, a correlação entre as observações dos meses de janeiro e fevereiro geralmente é diferente da correlação entre as observações dos meses de junho e julho. Outra característica importante das séries mensais, que deve ser considerada nos modelos, são os coeficientes de assimetria das distribuições de probabilidade das vazões de cada mês. Vários modelos estocásticos têm sido propostos para séries de vazões mensais, em que destacam-se os trabalhos de Thomas e Fiering (1962), Todorovic e Zelenhasic (1970), Vicens *et al.* (1975), Lawrence e Kottegoda (1977), Hippel *et al.* (1979), Stedinger e Taylor (1982), Pereira *et al.* (1984), Jardim *et al.* (2001), Mondal e Wasimib (2006) e Salas *et al.* (2006).

O desenvolvimento e uso de modelos estocásticos de vazões devem envolver as seguintes etapas:

1. Obter dados de vazões e outras informações;
2. Selecionar a distribuição de probabilidade da vazão de cada mês;
3. Selecionar o modelo para descrever as dependências temporais das vazões;
4. Desenvolver métodos para estimar os parâmetros destes modelos;
5. Verificar se a implementação computacional deste modelo tem o desempenho como especificado;
6. Usar o modelo.

As etapas de 1 a 4 são de desenvolvimento e consiste de um conjunto de equações e relações lógicas usadas para construir um modelo que deve descrever algum sistema do mundo real. As etapas 5 e 6 são, respectivamente, de verificação e validação dos modelos. Na etapa de verificação, deve ser demonstrado que o modelo idealizado foi implementado corretamente e tem o desempenho teoricamente ou conceitualmente esperado. Na etapa de validação, os dados simulados e reais são interpretados e o modelo é validado se os dados simulados apresentarem uma aproximação razoável

dos dados reais. Nesta etapa várias medidas de comparação são adotadas, como pode ser visto em Stedinger e Taylor (1982).

Uma característica que deve ser destacada nos modelos estocásticos das vazões mensais, com a mesma importância da sazonalidade, é a assimetria das distribuições de probabilidade das vazões de cada mês. Para modelar a assimetria das distribuições de probabilidade das séries de vazões mensais padronizadas, alguns modelos fazem uso da transformação logarítmica ou das transformações propostas por Box e Cox (1964).

No trabalho de Hipel e Meeleod (1994) são apresentados alguns modelos que podem ser utilizados para o caso de vazões médias mensais, sendo que o modelo selecionado para este estudo foi o auto-regressivo periódico ou *PAR*. Esta metodologia foi escolhida visto que é utilizada no Setor Elétrico Brasileiro (SEB) e que, segundo Noakes (1985) é o melhor modelo para descrever séries de vazões mensais.

Portanto, este artigo apresenta um modelo para geração de séries de vazões médias mensais utilizando os modelos *PAR*(1) e *PAR*( $p_m$ ). Algumas estatísticas, tais como a média, o desvio-padrão, o coeficiente de assimetria e o coeficiente de curtose, entre a série histórica e a sintética, são realizados no intuito de validar o modelo de geração de séries sintéticas.

## 2 MODELO AUTO-REGRESSIVO PERIÓDICO

Segundo Salas *et al.* (2006), os processos estocásticos naturais são, em geral, estacionários em sentido fraco, isto é, os momentos de primeira e segunda ordem não são afetados por variações devido à escolha em relação à origem dos tempos. Algumas séries hidrológicas sazonais apresentam uma estrutura de autocorrelação que não depende apenas do intervalo de tempo entre as observações, mas também do período observado, de acordo com Hipel e Meeleod (1994).

Na classe dos modelos periódicos, um modelo que se destaca é o *PAR* (*periodic autoregressive*). Dentro da área hidrológica, a modelagem *PAR* surgiu através dos trabalhos desenvolvidos por Thomas e Fiering (1962). Neste trabalho, os autores ajustaram um modelo *PAR*(1) para vazões mensais, ou seja, para cada mês foi identificado um modelo *AR*(1).

As séries hidrológicas mensais apresentam como característica um comportamento periódico de suas propriedades probabilísticas, tais como a média, a variância, a assimetria e a estrutura de autocorrelação. Sendo assim, a análise deste tipo de série pode ser realizada com modelos que apresentam um comportamento periódico para os seus parâmetros. A esta classe, denomina-se modelos auto-regressivos periódicos, *PAR*( $p_m$ ), em que  $p_m$  representa o número de termos auto-regressivos para cada mês  $m$ .

O modelo  $PAR(p_m)$  é descrito matematicamente por:

$$\left( \frac{q_{t(r,m)} - \mu_m}{\sigma_m} \right) = \sum_{j=1}^{p_m} \phi_{j,m} \left( \frac{q_{t(r,m)-j} - \mu_{m-j}}{\sigma_{m-j}} \right) + a_{t(r,m)}, \quad (1)$$

em que  $q_{t(r,m)}$  é a vazão média mensal para o ano  $r$  e o mês  $m$ ,  $\mu_m$  é a média do mês  $m$ ,  $\sigma_m$  é o desvio-padrão do mês  $m$ ,  $\phi_{1,m}, \dots, \phi_{p_m,m}$  são os coeficientes do modelo auto-regressivo para cada mês  $m$  e  $a_{t(r,m)}$  é o ruído não correlacionado para o ano  $r$  e o mês  $m$ , com  $E(a_{t(r,m)}) = 0$ ,  $Var(a_{t(r,m)}) = \sigma_m^{(a)2}$  dada por:

$$\sigma_m^{(a)2} = \sigma_m^2 \left( 1 + \sum_{j=1}^{p_m} \rho_j^m \right), \quad (2)$$

em que  $\rho_j^m$  é a autocorrelação entre  $q_{t(r,m)}$  e  $q_{t(r,m)-j}$ , dada por:

$$\rho_j^m = E \left\{ \left( \frac{q_{t(r,m)} - \mu_m}{\sigma_m} \right) \left( \frac{q_{t(r,m)-j} - \mu_{m-j}}{\sigma_{m-j}} \right) \right\} \quad (3)$$

## 2.1 Estimação dos parâmetros do modelo $PAR(p_m)$

Segundo Stedinger e Taylor (1982), a identificação do ordem  $p_m$  para o modelo  $PAR(p_m)$  é realizada por meio das análises da função de autocorrelação (FAC) e da função de autocorrelação parcial (FACP) da série.

Considerando o modelo  $PAR(p_m)$ , tem-se que:

$$\rho_k^m = \phi_{1,m} E[z_{t(r,m)-1} z_{t(r,m)-k}] + \dots + \phi_{p_m,m} E[z_{t(r,m)-p_m} z_{t(r,m)-k}], \quad k \geq 1, \quad (4)$$

em que  $\rho_0^m = 1$ .

Fixando-se o mês  $m$  e variando  $k$  de 1 até  $p_m$  em (4) encontra-se para cada mês  $m$ , um conjunto de equações lineares, comumente denominadas de equações de *Yule-Walker*. Para um mês  $m$  qualquer, as equações de *Yule-Walker* são dadas por:

$$\begin{bmatrix} r_1^m \\ r_2^m \\ \vdots \\ r_{p_m}^m \end{bmatrix} = \begin{bmatrix} 1 & r_1^{m-1} & \dots & r_{p_m-1}^{m-1} \\ r_1^{m-1} & 1 & \dots & r_{p_m-2}^{m-2} \\ \vdots & \vdots & \ddots & \vdots \\ r_{p_m-1}^{m-1} & r_{p_m-2}^{m-2} & \dots & 1 \end{bmatrix} \begin{bmatrix} \hat{\phi}_{1,m} \\ \hat{\phi}_{2,m} \\ \vdots \\ \hat{\phi}_{p_m,m} \end{bmatrix} \quad (5)$$

Denotando por  $\phi_{kj}^m$ , o  $j$ -ésimo parâmetro auto-regressivo de um processo PAR de ordem  $k$  em que  $\phi_{kk}^m$  é o último parâmetro deste processo, as equações de *Yule-Walker* para cada período  $m$  podem ser reescritas da seguinte forma:

$$\begin{bmatrix} r_1^m \\ r_2^m \\ \vdots \\ r_{p_m}^m \end{bmatrix} = \begin{bmatrix} 1 & r_1^{m-1} & \cdots & r_{p_m-1}^{m-1} \\ r_1^{m-1} & 1 & \cdots & r_{p_m-2}^{m-2} \\ \vdots & \vdots & \ddots & \vdots \\ r_{p_m-1}^{m-1} & r_{p_m-2}^{m-2} & \cdots & 1 \end{bmatrix} \begin{bmatrix} \hat{\phi}_{k1}^m \\ \hat{\phi}_{k2}^m \\ \vdots \\ \hat{\phi}_{kk}^m \end{bmatrix} \quad (6)$$

Os valores dos parâmetros  $\{\phi_{kk}^m, k=1,2,\dots\}$  correspondem a função de autocorrelação parcial do processo PAR, no mês  $m$ . Esta função representa também a estrutura de dependência do processo estocástico ao longo do tempo. Em um processo periódico auto-regressivo de ordem  $p_m$ , a função de autocorrelação parcial é valor do último parâmetro  $\phi_{kk}^m$  e será diferente de zero para  $k$  menor ou igual a  $p_m$  e zero para  $k$  maior que  $p_m$ .

Portanto, a identificação de um modelo  $PAR(p_m)$  consiste em determinar as ordens,  $p_m$ , mais apropriadas dos operadores auto-regressivos de cada mês,  $m=1,\dots,12$ . Isto pode ser feito obtendo-se estimativas de  $\hat{\phi}_{kk}^m$ ,  $k=1,2,\dots$ . Para testar a hipótese nula  $H_0: \phi_{kk}^m=0$  para todos os valores de  $k=1,2,\dots$ , utiliza-se o resultado assintótico o qual afirma que, se a ordem do operador auto-regressivo de um mês  $m$  qualquer é  $p_m$ , então o estimador  $\hat{\phi}_{kk}^m$  de  $\phi_{kk}^m$ , para  $k > p_m$  tem distribuição aproximadamente Normal de média zero e variância  $1/n$ . Portanto não se rejeita  $H_0$  com nível de significância  $\alpha < 5\%$  se o zero está contido no intervalo  $\hat{\phi}_{kk}^m \pm 2/\sqrt{n}$ . Neste caso se diz que a estimativa  $\hat{\phi}_{kk}^m$  é não significativa. Um procedimento de identificação da ordem  $p_m$ , consiste em procurar, para cada mês  $m$ , a maior ordem  $p_m$  tal que todas as estimativas  $\hat{\phi}_{kk}^m$  para  $k > p_m$  não sejam mais significativas.

Este procedimento clássico de identificação da ordem dos modelos  $PAR(p_m)$  pode levar a aceitação de processos como sendo ruídos brancos, quando, na verdade, trata-se de modelos que possuem baixos valores de  $\rho_k^m$  e  $\phi_{kk}^m$ . Valores intermediários baixos de  $\phi_{jj}^m$  para  $j < p_m$  também pode ser considerados não significativos e isso leva a identificação de modelos com parâmetros intermediários nulos,  $\phi_{kj} = 0$ , para alguns  $j < p_m$ .

Stedinger (2001) afirma que uma modelagem que considera individualmente cada mês não pode produzir o conjunto de modelos mais adequado. Sem maiores detalhes matemáticos e somente considerando a natureza dos fenômenos naturais envolvidos, o autor argumenta que não faria

sentido considerar que a vazão de determinado mês  $m$  dependa de vários meses anteriores, ou seja, o modelo  $PAR(p_m)$  tem ordem  $p_m$  elevada ( $p_m = 6$ ) e para o mês seguinte,  $m+1$ , a ordem seja pequena ( $p_{m+1} = 1$ ). Assim como também não é razoável supor que, devido a parâmetros intermediários nulos, a vazão de um mês  $m$  dependa da vazão do mês  $m-2$  e não do mês  $m-1$ . Estes resultados corroboram a idéia de que a forma clássica de identificação das ordens  $p_m$  pode não ser a mais adequada. Stedinger (2001) propõe como critério para a seleção das defasagens  $j$  significantes, que para cada período  $m$ , encontre-se a maior ordem  $j$  tal que todas as estimativas  $\hat{\phi}_{kk}^m$  para  $k < j$  sejam significativas. Este critério não admite valores intermediários de  $\hat{\phi}_{kk}^m$  não significativos, o que ocorre na forma clássica. Após a etapa de identificação da ordem  $p_m$ , estima-se os parâmetros do modelo  $PAR(p_m)$  utilizando as equações de *Yule-Walker*.

### 3 PROCEDIMENTOS PARA GERAÇÃO DE VAZÕES MÉDIAS MENS AIS

O histórico de vazões disponível para ajuste dos modelos consiste em uma das possíveis realizações do processo estocástico gerador da série. O procedimento para geração de séries sintéticas é realizado a partir de um modelo ajustado à série histórica e, após, sinteticamente gerar tantas séries temporais quanto se necessite. Portanto a elaboração do modelo estocástico para a série de vazões é um passo fundamental para a geração de séries sintéticas de vazões.

Neste trabalho vamos considerar, para modelar as vazões mensais, os modelos  $PAR(p_m)$  dados por:

$$\left( \frac{q_{t(r,m)} - \mu_m}{\sigma_m} \right) = \sum_{j=1}^{p_m} \phi_{j,m} \left( \frac{q_{t(r,m)-j} - \mu_{m-j}}{\sigma_{m-j}} \right) + a_{t(r,m)} \quad (7)$$

Um restrição adotada ao uso dos modelos (7), para geração de séries de vazões mensais é que deve-se ter  $q_{t(r,m)} > q_{\min}^{(m)}$ , em que  $q_{\min}^{(m)}$  representa o valor mínimo para cada mês. Para atender esta restrição, os ruídos  $a_{t(r,m)}$  devem satisfazer a condição:

$$a_{t(r,m)} > - \left( \frac{\mu_m - q_{\min}^{(m)}}{\sigma_m} \right) - \left[ \sum_{j=1}^{p_m} \phi_{j,m} \left( \frac{q_{t(r,m)-j} - \mu_{m-j}}{\sigma_{m-j}} \right) \right] \quad (8)$$

O modelo para geração de séries sintéticas deve ser aplicado diretamente à série temporal original e deve ser capaz de lidar com ruídos que apresentam um forte coeficiente de assimetria. Além disso, é necessário que a distribuição dos ruídos  $a_{t(r,m)}$  seja adequadamente definida para que a restrição imposta pela equação (8) seja satisfeita. A solução adotada, segundo Stedinger e Taylor (1982) e Pereira *et al.* (1984) foi ajustar uma distribuição Log-normal com três parâmetros para os

ruídos  $a_{t(r,m)}$ . Portanto, vamos supor que  $a_{t(r,m)}$  tem uma distribuição Log-Normal com três parâmetros, tal que pode-se definir um processo aleatório  $\xi_{t(r,m)}$ , com distribuição Normal  $N(\mu_m^\xi, \sigma_m^{(\xi)2})$ , que está relacionado ao processo  $a_{t(r,m)}$  pela equação:

$$\xi_{t(r,m)} = \ln(a_{t(r,m)} + \tau_m) \quad (9)$$

A equação (9) impõe uma nova restrição para  $a_{t(r,m)}$ , ou seja,  $a_{t(r,m)} > -\tau_m$ . Portanto, comparando-se as equações (8) e (9), tem-se uma possível definição para o parâmetro  $\tau_m$  dada por:

$$\tau_m = \left( \frac{\mu_m - q_{\min}^{(m)}}{\sigma_m} \right) + \sum_{j=1}^{p_m} \phi_{j,m} \left( \frac{q_{t(r,m)-j} - \mu_{m-j}}{\sigma_{m-j}} \right) \quad (10)$$

Os parâmetros  $\mu_m^\xi$  e  $\sigma_m^{(\xi)2}$  devem ser calculados de forma a preservar os dois primeiros momentos do ruído  $a_{t(r,m)}$ , denotados por  $E(a_{t(r,m)}) = \mu_m^{(a)}$  e  $Var(a_{t(r,m)}) = \sigma_m^{(a)2}$ . Isto é feito usando-se as relações entre os parâmetros da distribuição Normal  $N(\mu_m^\xi, \sigma_m^{(\xi)2})$  e os da distribuição Log-Normal com três parâmetros  $LN(\mu_m^{(a)}, \sigma_m^{(a)2}, \tau_m)$ , dadas por:

$$\mu_m^{(\xi)} = \frac{1}{2} \ln \left( \frac{\sigma_m^{(a)2}}{\theta_m^2 - \theta_m} \right), \quad (11)$$

$$\sigma_m^{(\xi)2} = \ln(\theta_m), \quad (12)$$

em que  $\theta_m$  é definido por:

$$\theta_m = 1 + \frac{\sigma_m^{(a)2}}{(\mu_m^{(a)} - \tau_m)^2} \quad (13)$$

Portanto após a identificação da ordem  $p_m$  e o ajuste dos modelos  $PAR(p_m)$ , estima-se  $\sigma_m^{(a)2}$  e  $\tau_m$  com as equações (2) e (10) e os parâmetros  $\mu_m^{(\xi)}$  e  $\sigma_m^{(\xi)2}$  são estimados com as equações (11) - (13).

Um modelo para geração de uma série sintética de vazões mensais pode ser encontrado substituindo-se na equação (7), o valor do ruído  $a_{t(r,m)}$  retirado da equação (9), ou seja,  $a_{t(r,m)} = \exp(\xi_{t(r,m)}) - \tau_m$  e a expressão de  $\tau_m$  dada em (10). Após algumas manipulações matemáticas obtém-se uma equação final para a geração de uma série sintética no ano  $r$  para o mês  $m$ . Esta equação final é dada por:

$$q_{t(r,m)} = q_{\min}^{(m)} + \sigma_m \exp(\xi_{t(r,m)}) \quad (14)$$

Portanto gerando-se o processo  $\xi_{t(r,m)} \sim N(\mu_m^\xi, \sigma_m^{(\xi)2})$  e substituindo-se na equação (14), pode ser gerada uma vazão  $q_{t(r,m)}$ , repetindo-se este procedimento recursivamente, em que o resultado é a

geração de uma série sintética de vazões mensais. Observa-se que dependência entre as vazões  $q_{t(r,m)}$  e  $q_{t(r,m)-j}$  são consideradas no modelo de geração devido a presença do parâmetro  $\tau_m$  introduzido no cálculo dos parâmetros  $\mu_m^{(\xi)}$  e  $\sigma_m^{(\xi)^2}$ . Estes procedimentos foram implementados utilizando o software livre R, desenvolvido por R Development Core Team (2010).

#### 4 RESULTADOS E DISCUSSÃO

Neste trabalho foram adotados os modelos  $PAR(1)$ , ou seja, para cada mês  $m$  foi considerado um  $AR(1)$  e  $PAR(p_m)$ , ou seja, para cada mês  $m$  foi considerado um modelo  $AR(p)$ , em que  $p$  não é fixo. Foram geradas séries de tamanho  $n = 2000$  anos.

A Figura 1 apresenta a série histórica de vazões médias mensais do reservatório de Furnas, no período de 1931 a 2005 (75 anos) e os primeiros 75 anos para a série sintética gerada a partir dos modelos  $PAR(1)$  e  $PAR(p_m)$ . Pode-se observar que as séries apresentam um comportamento semelhante entre si.




Figura 1 – Série histórica, sintética  $PAR(1)$  e sintética  $PAR(p_m)$  para Furnas.

A Figura 2 apresenta o gráfico  $q-q$  plot e o histograma entre a série histórica e a série sintética  $PAR(p_m)$  e a função de autocorrelação para a série histórica e para a série sintética  $PAR(p_m)$ . Esses gráficos realçam a similaridade entre estas séries.



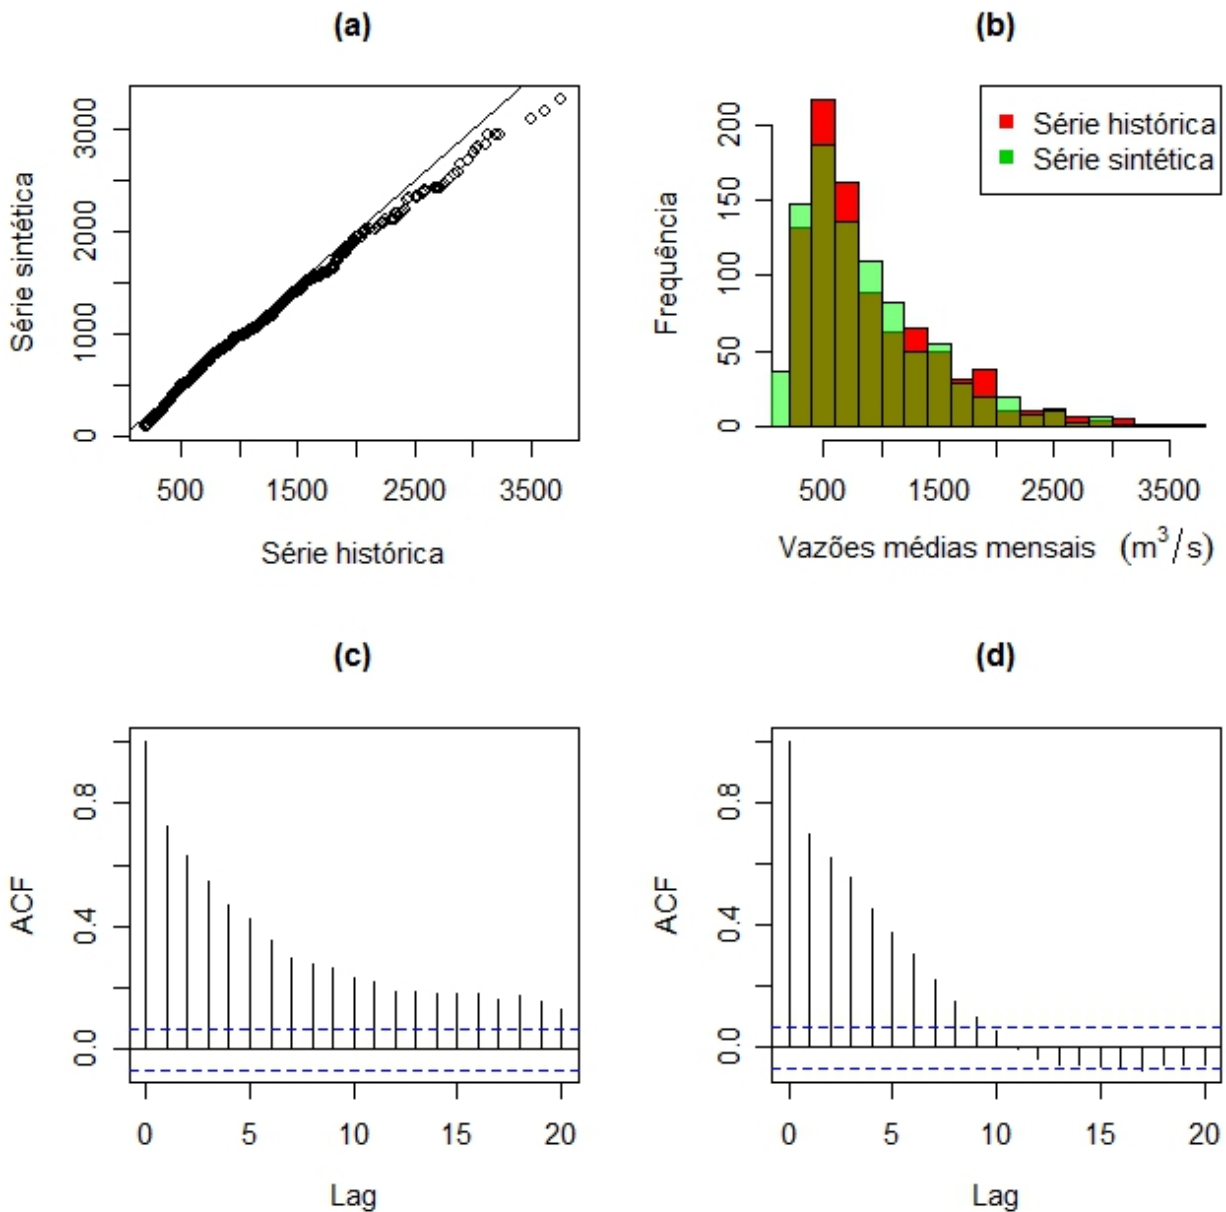


Figura 2 – (a)  $Q-Q$  plot, (b) Histograma, (c) Função de autocorrelação para série histórica e (d) Função de autocorrelação para série sintética  $PAR(p_m)$ .

As Tabelas 1, 2, 3 e 4 apresentam as estatísticas, tais como a média, o desvio-padrão, o coeficiente de assimetria e o coeficiente de curtose, para a série histórica e para as séries sintéticas geradas a partir dos modelos  $PAR(1)$  e  $PAR(p_m)$ . Vale ressaltar que as estatísticas média e desvio-padrão apresentam valores bem próximos entre si e o coeficiente de assimetria e curtose apresentam, para alguns meses, valores bem discrepantes.

Tabela 1 – Média para a série histórica e as séries sintéticas  $PAR(1)$  e  $PAR(p_m)$ .

	Histórico	Sintética $PAR(1)$	Sintética $PAR(p_m)$
Janeiro	1747,56	1735,94	1647,73
Fevereiro	1662,64	1744,25	1566,52
Março	1479,58	1566,67	1380,44
Abril	1010,13	1079,03	953,45
Maio	746,7	788,39	710,77
Junho	618,12	646,29	559,78
Julho	508,8	512,29	476,57
Agosto	420,29	418,66	398,47
Setembro	441,24	445,67	400,82
Outubro	515,62	511,77	469,76
Novembro	729,88	738,6	656,54
Dezembro	1239,56	1225,35	1138,93

Tabela 2 – Desvio-padrão para a série histórica e as séries sintéticas  $PAR(1)$  e  $PAR(p_m)$ .

	Histórico	Sintética $PAR(1)$	Sintética $PAR(p_m)$
Janeiro	677,64	606,12	602,1
Fevereiro	628,75	824,06	601,77
Março	597,72	661,17	509,54
Abril	344,34	373,05	320,76
Maio	231,64	252,82	233,3
Junho	247,52	238,9	239,96
Julho	154,4	154,27	152,82
Agosto	121,53	117,76	130,86
Setembro	227,97	243,2	253,88
Outubro	223,31	209,57	210,97
Novembro	311,62	300,23	292,31
Dezembro	460,91	436,9	441,82

Tabela 3 – Assimetria para a série histórica e as séries sintéticas  $PAR(1)$  e  $PAR(p_m)$ .

	Histórico	Sintética $PAR(1)$	Sintética $PAR(p_m)$
Janeiro	0,69	0,06	0,66
Fevereiro	0,3	1,64	0,59
Março	1,3	0,68	0,55
Abril	1,15	0,41	0,2
Mai	0,91	0,51	0,34
Junho	4,24	0,09	0,23
Julho	2,06	0,23	0,16
Agosto	1,29	0,12	0,37
Setembro	3,78	0,75	1,27
Outubro	2,9	0,46	0,15
Novembro	1,35	0,93	0,61
Dezembro	1,12	0,36	0,52

Tabela 4 – Curtose para a série histórica e as séries sintéticas  $PAR(1)$  e  $PAR(p_m)$ .

	Histórico	Sintética $PAR(1)$	Sintética $PAR(p_m)$
Janeiro	3,14	2,16	3,07
Fevereiro	2,83	7,43	2,82
Março	5,18	2,99	2,87
Abril	5	2,88	2,34
Mai	4,77	3,48	2,69
Junho	29,83	2,58	2,16
Julho	11,55	2,64	2,42
Agosto	6,57	2,58	2,85
Setembro	23,37	3,36	4,79
Outubro	16,89	2,98	2,38
Novembro	5,46	3,95	2,89
Dezembro	5,72	3,11	3,15

## 5 CONCLUSÃO

O modelo de geração de séries sintéticas é de fundamental importância nos estudos do planejamento da operação energética, visto que as políticas operativas serão definidas com base na

previsão de vazões determinadas por este modelo. Nesse sentido, este trabalho apresentou os modelos  $PAR(1)$  e  $PAR(p_m)$ , em que os resultados obtidos indicam que a série sintética apresenta características semelhantes à série histórica, viabilizando o uso desses modelos de geração de vazões como uma ferramenta importante para o planejamento de uso dos recursos hídricos renováveis.

## AGRADECIMENTOS

Este trabalho foi financiado pelo projeto estratégico de P&D da ANEEL denominado ODIN - Otimização do Despacho Interligado Nacional - com apoio de 18 concessionárias lideradas pela Bandeirante Energia S.A. do grupo EDP e pelas agências de financiamento à pesquisa CNPq e FAPESP.

## BIBLIOGRAFIA

- BOX, G.; COX, D. (1964). “*An analysis of transformations*”. J. R. Statis. Soc. Serie B, pp. 211–252.
- HIPPEL, K. W.; MCBEAN, A.; MECLEOD, A. I. (1979). “*Hydrologic generating model selection*”. J. Water Resour. Plann. Manag. Div. Am. Soc. Civ. Eng. 105(WR2), pp. 223–242.
- HIPPEL, K. W.; MECLEOD, A. I. (1994). “*Time series modelling of water resources and environmental systems*”. Amsterdam: Elsevier Science B.V., 690 p.
- JARDIM, D. L. D. D.; MACEIRA, M. E. P.; FALCÃO, D. M. (2001). “*Stochastic streamflow model for hydroelectric systems using clustering techniques*”, in IEEE Porto Power Tech Conference, IEEE, Porto, Portugal, pp. 1–6.
- LAWRENCE, A. J.; KOTTEGODA, N. T. (1977). “*Stochastic modelling of riverflow time series*”, J.R. Statist. Soc. Serie A 150(Part 1), pp. 1–47.
- MONDAL, M. S.; WASIMIB, S. A. (2006). “*Generating and forecasting monthly flows of the ganges river with par model*”. Journal of Hydrology, pp. 41–56.
- NOAKES, D.; MECLEOD, A.; HIPPEL, K. (1985). “*Forecasting monthly riverflow time series*”, International Journal of Forecasting, pp. 179–190.
- PEREIRA, M. V. F.; OLIVEIRA, G. C.; COSTA, C. C. G.; KELMAN, J. (1984). “*Stochastic streamflow models for hydroelectric systems (brazil)*”, Water Resources Research, pp. 379–390.

- R DEVELOPMENT CORE TEAM. (2010). “*R: a language and environment for statistical computing*”. Vienna, Austria. R Foundation for Statistical Computing. Disponível em: <http://www.R-project.org>. Acesso em: 10 jan. 2010.
- SALAS, J. D.; SVEINSSON, O. G.; LANE, W. L.; FREVERT, D. K. (2006). “*Stochastic streamflow simulation using SAMS-2003*”. *Journal of Irrigation and Drainage Engineering*, 132(2), pp. 112–122.
- STEDINGER, J. R.; TAYLOR, M. R. (1982). “*Synthetic streamflow generation. 1. Model verification and validation (Delaware River, New York State)*”. *Water Resources Research*, pp. 909-918.
- STEDINGER, J. R. (2001). “*Report on the evaluation of cephel’s par models*”. Technical report, School of Civil and Environmental Engineering - Cornell University, Ithaca, New York.
- THOMAS, H. A.; FIERING, M. B. (1962). “*Design of Water Resources Systems*”. Harvard University Press, Cambridge, Mass., chapter 12, Mathematical synthesis of streamflow sequences for the analysis of river basins by simulation, pp. 459–493.
- TODOROVIC, P.; ZELENHASIC, E. (1970). “*A stochastic model for flood analysis*”. *WaterResources Research* 6(6), pp. 1641–1648.
- VICENS, G. J.; RODRIGUEZ-ITURBE, I.; SCHAAKE, JR. J. C. (1975). “*Bayesian generation of synthetic streamflows*”. *Water Resources Management* 11(6), pp. 827–838.