

Previsão de Séries de Vazões com a Meta-heurística PSO

Series Streamflow Forecasting with Meta-heuristic PSO

Levi Lopes Teixeira

Departamento de Matemática

Universidade Tecnológica Federal do Paraná – UTFPR, Curitiba, PR

prof.levilopes@gmail.com

Paulo Henrique Siqueira

Departamento de Expressão Gráfica

Universidade Federal do Paraná – UFPR, Curitiba, PR

paulohs@ufpr.br

Resumo: A matriz energética brasileira é formada principalmente pela energia gerada pelas hidrelétricas, que são totalmente dependentes da vazão dos rios que alimentam seus reservatórios de água. Fazer a previsão destas vazões é de suma importância para o planejamento energético do país. Neste trabalho, a previsão da vazão diária para o posto 266 (Itaipu) foi realizada a partir da meta-heurística *Particle Swarm Optimization* (PSO) e modelos ARMA e ARIMA. Num primeiro estágio a meta-heurística foi utilizada na determinação das ordens p (autorregressão) e q (médias móveis). Em seguida, a mesma meta-heurística foi usada na obtenção dos coeficientes autorregressivos e médias móveis. Os resultados obtidos mostram que o modelo ajustado é adequado à série estudada.

Palavras-chave: meta-heurística PSO; modelos ARMA e ARIMA; previsão de vazões; séries temporais.

Abstract: The Brazilian energy matrix is formed mainly by the energy generated by hydroelectric plants, which are totally dependent on the flow of the rivers that feed its water reservoirs. It is of paramount importance for the country's energy planning

Recebido em 10/08/2013 - Aceito em 06/10/2015.

RECEN 17(2) p. 207-224 jul/dez 2015 DOI: 10.5935/RECEN.2015.02.01

to make the prediction of these flows. In this work the prediction of daily flow for the post 266 (Itaipu) was performed from the meta-heuristic Particle Swarm Optimization (PSO) and ARMA and ARIMA models. In a first stage meta-heuristic was used to determine the orders p (autoregression) and q (moving averages). Then, the same meta-heuristic was used to obtain the autoregressive coefficients and moving average. The results show that the fitted model is appropriate for the series studied.

Keywords: ARMA and ARIMA models; PSO meta-heuristic; streamflow forecasting; time series.

1 Introdução

O processo de desenvolvimento econômico pelo qual o Brasil vem passando está impulsionando o aumento da demanda de energia elétrica por parte das indústrias, comércio e consumidores residenciais. Estimativas da Empresa de Pesquisa Energética (EPE) apontam que o consumo de energia elétrica no Brasil em 2020 será 659.092 GWh, sendo predominante a produção hidráulica em virtude da situação privilegiada do país em relação aos recursos hídricos. A produção de energia, a partir das usinas hidrelétricas, tem ligação direta com a quantidade de água (vazão afluyente) disponível para a movimentação das turbinas geradoras, lembrando que longos períodos de seca podem levar a uma diminuição da capacidade geradora de energia da usina. A relação entre vazões afluentes e geração de energia implica em um cuidado especial com os dados que cercam o problema. A mensuração das vazões é feita diariamente e médias mensais formam séries temporais que permitem fazer previsões através de várias metodologias. O Operador Nacional do Sistema Elétrico (ONS) lança mão de tais informações na otimização da geração de energia e elaboração de estratégias que minimizem efeitos negativos de eventuais enchentes e secas. Para tanto, o ONS faz previsão de vazões naturais para os locais de aproveitamento hidrelétricos que constituem o Sistema Interligado Nacional (SIN), sendo denominado PREVIVAZ o modelo de previsão mais usado.

O PREVIVAZ, usado na previsão de vazões e desenvolvido pelo Centro de Pes-

quisas de Energia Elétrica (CEPEL), é um modelo estocástico univariado [1]. Este modelo é usado para prever as vazões semanais da maioria das bacias do SIN. O PREVIVAZ usa modelos lineares do tipo PARMA(p, q) [1], além de transformações de séries históricas, tipo Box-Cox ou Logarítmicas [2]. O relatório emitido pelo ONS em dezembro de 2011 menciona outros modelos além do PREVIVAZ, tais como: Redes Neurais *Fuzzy* Recorrentes, Modelo de Previsão de Classes de Vazões e SMAP-MEL.

Entre os métodos usados pelo ONS, já citados, ressalta-se a importância dos métodos de Box e Jenkins [1] na análise de séries temporais, devido as estruturas matemáticas relativamente simples destes métodos. Os modelos Box-Jenkins para estimação e previsão de séries temporais são pertencentes à família dos autorregressivos médias móveis (ARMA) subdividido em dois outros modelos: o autorregressivo (AR) e médias móveis (MA). O método MA consiste de processos de ordem q em que cada observação é gerada por uma média ponderada dos erros aleatórios dos q períodos no passado. O método AR(p) modela um parâmetro autorregressivo da variável observável com ela mesma, defasada para os p períodos de defasagem em que a autocorrelação parcial entre as variáveis é significativa. Os modelos ARMA podem oferecer vantagens no processo de previsão, embora tenha-se que enfrentar algumas dificuldades no que se refere à obtenção dos coeficientes ótimos [3], entre elas o caráter multimodal do erro quadrático médio. Entretanto, o uso de meta-heurísticas pode contornar tais dificuldades. Uma meta-heurística bem elaborada tende a mover-se relativamente rápida na direção de soluções muito boas, fornecendo um método bastante eficaz no trato de problemas grandes ou com soluções inviáveis por métodos tradicionais [4].

A proposta deste trabalho é determinar modelos ARMA para a previsão de séries de vazão diária no posto 266 (Itaipu) localizado no rio Paraná, sendo as ordens e parâmetros do modelo obtidas através da meta-heurística *Particle Swarm Optimization* (PSO). Um modelo ARMA de ordens p (autorregressivo) e q (médias móveis) é descrito pela equação 1:

$$Z_t = \delta + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} + a_t \quad (1)$$

O modelo combina valores passados das entradas Z_t e choques aleatórios (a_t) descorrelacionados, de média zero e variância constante. O objetivo é aplicar a meta-heurística PSO a fim de determinar p , q , δ , ϕ_i e θ_j ($i = 1, \dots, p$ e $j = 1, \dots, q$). Nesta linha, Siqueira, et al [4] trabalharam com as meta-heurísticas Algoritmo Genético e *Opt-aiNet* na estimação dos parâmetros ϕ_i e θ_i . Gnanlet e Rajendran [5] propuseram um sistema formado pelas meta-heurísticas Algoritmo Genético e *Simulated Annealing* para a determinação de p , q , ϕ_i e θ_i . Hansen, McDonald e Nelson [6] desenvolveram uma heurística baseada em redes neurais e algoritmos genéticos para a identificação de modelos ARMA. Behnamian e Ghomi (2009) [7]; Silva (2008) [8]; Asadi et al, (2011) [9]; Baragona et al, (2001) [10] e Grebogi (2013) [11] também utilizaram meta-heurísticas em seus trabalhos de previsão de séries temporais.

Foi desenvolvido para este trabalho um sistema formado por dois módulos, o primeiro para a determinação das ordens p e q do modelo ARMA e o segundo na estimação dos parâmetros ϕ_i e θ_j deste modelo. Em ambos, foi usada a meta-heurística PSO no processo de otimização.

2 Vazão

Existem vários fatores que podem influenciar a vazão em um determinado ponto de um curso de água, entre eles: evaporação, precipitação, infiltração e percolação, sendo a precipitação a principal componente na formação da vazão e responsável pela característica aleatória do processo hidrológico.

Para o estudo de vazões em usina hidrelétricas, pode-se destacar as vazões: natural, incremental, turbinada e vertida. A vazão natural é a que seria observada em um posto de medição considerando o rio na sua condição natural. A vazão incremental, por sua vez, é toda vazão lateral captada entre um posto de medição e todos os postos de medição imediatamente à montante deste. A vazão turbinada é aquela que passa pelas turbinas e gera energia, enquanto a vazão vertida é aquela que passa pelos vertedouros da usina e não gera energia.

A fim de se modelar a realidade hídrica, são formadas séries temporais de vazões médias diárias, semanais e mensais. O ONS disponibiliza um banco de dados contendo o registro histórico de vazões naturais de todas as usinas hidrelétricas que com-

põem o SIN. O primeiro registro de vazão natural média mensal é referente ao mês de janeiro de 1931.

3 Séries Temporais

Com o desenvolvimento das tecnologias da informação, deslumbram-se para o setor elétrico metodologias que aumentam a eficiência do planejamento e programação da operação do Sistema Interligado Nacional (SIN). O Operador Nacional do Sistema Elétrico (ONS) possui uma cadeia de modelos para a otimização da operação eletroenergética, os quais utilizam séries de vazões médias diárias, semanais e mensais. Para o ONS, as séries de vazões médias e semanais destinam-se aos modelos de previsão de vazões e controle de cheias.

Segundo Levine et al [12], uma série temporal é um conjunto de dados numéricos obtidos durante períodos regulares ao longo do tempo. O pressuposto básico da análise de séries temporais é de que fatores que influenciaram padrões da atividade no passado e no presente continuarão a fazê-lo, mais ou menos da mesma maneira, no futuro. Portanto, os principais objetivos da análise de séries temporais são identificar e isolar esses fatores de influência, para fins de previsão (prognósticos), bem como para planejamento e controle gerencial. Para alcançar esses objetivos, foram criados muitos modelos matemáticos para pesquisar as flutuações entre os fatores que compõem uma série temporal envolvendo dados de vazão. Lucas et al [13] aplicaram o modelo hidrológico determinístico mensal de dois parâmetros e o modelo estocástico ARIMA para simular a vazão mensal das sub-bacias da região hidrográfica do Xingu no Estado do Pará. Sáfadi [14] analisou o comportamento da série de vazão de água na barragem de Furnas – MG, empregando análise de séries temporais a partir do modelo estocástico ARIMA e estudou o efeito da sazonalidade, tendência e intervenção.

4 Meta-heurística PSO

A otimização por enxame de partículas PSO – *Particle Swarm Optimization* foi criada por James Kennedy e Russel Eberhart em 1995 após estudos da convivência social dos pássaros. De acordo com os pesquisadores, os pássaros trocam informa-

ções na busca de alimento, onde cada membro de um bando de pássaros determina sua velocidade com base em sua experiência pessoal, bem como informações obtidas por meio da interação com outros membros do bando. Cada pássaro, denominado partícula, de início voa pelo espaço de busca e a partir da cooperação social desloca-se na direção do alimento.

Matematicamente, cada partícula é considerada uma possível solução para um problema de otimização e os vetores \mathbf{X} e \mathbf{V} representam a sua posição e velocidade, respectivamente. A atualização de velocidade e posição de cada partícula é realizada através das seguintes fórmulas:

$$V_{ij}^{k+1} = W V_{ij}^k + c_1 r_{1ij} (p_{ij}^k - X_{ij}^k) + c_2 r_{2ij} (g_j^k - X_{ij}^k), i = 1 \dots, m \text{ e } j = 1, \dots, n \quad (2)$$

$$X_{ij}^{k+1} = X_{ij}^k + V_{ij}^{k+1}, i = 1, \dots, m \quad (3)$$

Em que: m é o número de partículas, n representa a dimensão do problema, c_1 e c_2 representam as taxas de aprendizado, r_{1ij} e r_{2ij} números aleatórios entre 0 e 1 e k denota a iteração. Da equação 2, o termo $W V_{ij}^k$ simboliza a inércia, e conduz a partícula para a direção que vinha seguindo. O segundo termo $c_1 r_{1ij} (p_{ij}^k - X_{ij}^k)$ simboliza a memória, atraindo a partícula para o melhor ponto encontrado durante a sua trajetória. O terceiro termo $c_2 r_{2ij} (g_j^k - X_{ij}^k)$ simboliza a cooperação, que conduz as partículas para o melhor ponto até então encontrado pelo enxame.

O algoritmo básico do PSO segue os passos:

1. Inicializar uma população de partículas com posições aleatórias e velocidades, onde cada partícula contém n variáveis;
2. Avaliar a função objetivo para todas as partículas. Fazer p_{ij}^k igual à melhor posição de cada partícula. Fazer g_j^k e seu valor objetivo ser igual à posição e ao valor objetivo da melhor partícula inicial;
3. Atualizar a velocidade e a posição de cada partícula de acordo com as equações 2 e 3;
4. Avaliar os valores objetivo de todas as partículas;

5. Para cada partícula, comparar o seu valor objetivo atual com o valor objetivo da sua melhor posição. Se o valor atual é melhor, atualize p_{ij}^k e seu valor objetivo com a posição e valor objetivo atual;
6. Determinar a melhor partícula do enxame atual com o melhor valor objetivo. Se o valor objetivo é melhor do que o valor objetivo de g_j^k atualize g_j^k e seu valor objetivo com a posição e o valor objetivo da melhor partícula corrente;
7. Se o critério de parada (número de iterações) for atendido, informe g_j^k e seu valor objetivo, caso contrário, vá para ao passo 3.

O PSO descrito deve sofrer adaptações quando usado na otimização de problemas discretos. A primeira sugestão de adaptação foi apresentada em 1997 por Kennedy e Eberhart [15]. Neste método as partículas são representadas por sequências binárias e a velocidade em termos de probabilidades. A forma para calcular a velocidade permanece inalterada e a posição dada pela equação 4.

$$X_{ij}^{k+1} = \begin{cases} 1, & \text{se } \text{sig}(V_{ij}^{k+1}) > r_{ij} \\ 0, & \text{caso contrário} \end{cases} \quad (4)$$

em que, $\text{sig}(V_{ij}^{k+1}) = \frac{1}{1+\exp(-V_{ij}^{k+1})}$. Na equação 4 r_{ij} é um número randômico do intervalo $[0, 1]$.

5 Metodologia

Os dados que compõem a série temporal a ser analisada nesta pesquisa são provenientes das medições de vazões no posto 266. Neste posto são obtidas as vazões afluentes à usina hidrelétrica de Itaipu, que está localizada no Rio Paraná, no trecho de fronteira entre o Brasil e o Paraguai, a 14 km ao norte da Ponte da Amizade. A área da usina se estende desde Foz do Iguaçu, no Brasil, e *Ciudad del Este*, no Paraguai, ao sul, até Guáira (Brasil) e *Salto del Guairá* (Paraguai), ao norte.

A base de dados com as séries históricas das vazões pode ser acessada no portal do ONS, onde se podem obter séries de médias mensais e diárias desde janeiro de 1931. Neste trabalho, foi utilizada a série diária referente ao ano 2009.

As séries temporais de vazões possuem como característica a não-estacionariedade, com a presença de componente sazonal. Ballini [16] sugere extrair tais componentes do processo de previsão através de um tratamento estatístico, onde a série original é transformada em outra a partir de uma padronização. Quando as séries estudadas apresentam indícios de não-estacionariedade, Box; Jenkins e Reinsel, (1994) [1] sugerem a diferenciação da série a fim de se obter séries estacionárias. Neste caso o modelo ARMA(p, q) é substituído pelo ARIMA(p, d, q), sendo d a ordem de diferenciação da série.

A determinação do modelo ARMA(p, q) foi realizada a partir de um sistema composto de dois módulos formados pela meta-heurística PSO, aqui denominado de ARMA-PSO. O módulo 1 foi construído para o cálculo das ordens p e q, sendo as partículas representadas por uma sequência binária com quatro posições, de forma que o total de valores que p e q podem assumir é 16 (0, 1, 2, ..., 15). A saída do módulo 1 é a entrada do módulo 2, onde são estimados os valores de δ , ϕ_i e θ_j ($i = 1, \dots, p$ e $j = 1, \dots, q$). Foi estabelecido para ϕ_i e θ_j o intervalo [-3, 3] e δ calculado através da fórmula:

$$\delta = \frac{1}{n} \sum_{t=1}^n Z_t * (1 - \phi_1 - \phi_2 - \dots - \phi_p) \quad (5)$$

Em que n é o número de observações e Z_t as observações.

O processo de estimação dos parâmetros ϕ_i e θ_j consiste na minimização da raiz do erro quadrático médio (RMSE) e erro médio percentual absoluto (MAPE), da equação 1 tira-se a_t e assim tem-se:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n a_t^2}{n}}, \quad n \text{ é o número de observações} \quad (6)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left\| \frac{a_t}{Z_t} * 100 \right\| \quad (7)$$

Box e Jenkins destacaram dois procedimentos para a obtenção dos a_t . O primeiro, chamado de condicional, onde partindo de suposições razoáveis do ponto de vista teórico, são atribuídos valores não observáveis; o segundo, incondicional, onde os valores não observáveis são estimados a partir da amostra de dados [17]. Neste

trabalho, foi usado o procedimento incondicional, que se inicia com a previsão para o passado (*backforecasting*) de forma a gerar valores anteriores ao início da série [18].

O sistema ARMA-PSO, apresentado de forma resumida na figura 1, determina as ordens p e q no módulo 1 através de PSO para otimização binária conforme [15] e estima, usando PSO tradicional, os parâmetros do modelo no módulo 2. No módulo 1, seleciona-se a solução com menor função objetivo (RMSE ou MAPE). O critério de parada nos dois módulos é o número de iterações.

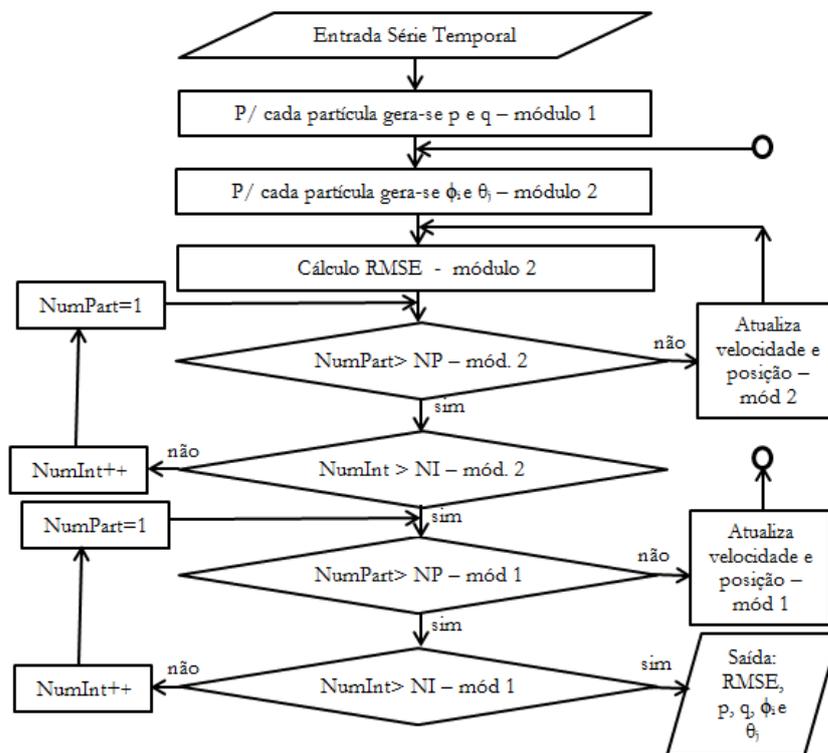


Figura 1. Fluxograma do sistema ARMA-PSO

Vários foram os testes a fim de se determinar os domínios dos parâmetros p , q , ϕ , θ , número de partículas (NumPart), número de iterações (NumIter), taxa de aprendizagem e fator de inércia a serem utilizados no sistema ARMA-PSO. Procurou-se conciliar a convergência e o tempo computacional, chegando-se aos valores relacionados na tabela 1.

Estando o modelo ajustado, é feita uma pesquisa nas vizinhanças de p e q , aumen-

Tabela 1. Parâmetros ARMA-PSO

Parâmetros	Mínimo	Máximo	Valor
p e q	0	15	-
ϕ e θ	-3	-3	-
NumIter(NI)	-	-	100
NumPart(NP)	-	-	20
Taxa aprendizagem (c1 e c2)	-	-	2
Fator de inércia (W)	-	-	0,9 a 0,4

Fonte: autoria própria.

tando em uma unidade os valores de p e q (teste da sobrefixação), verificando se o modelo corresponde aos dados da série ou se é necessário um modelo alternativo.

Das 365 observações da série analisada, sete foram reservadas para testes com valores previstos um passo à frente e 1, 2, 3, ..., 7 passos à frente. Tendo feitas as previsões com o modelo ajustado a partir das primeiras 358 observações, obteve-se o RMSE e MAPE relativos à amostra de teste.

A fim de validar o modelo ajustado foram analisados os resíduos com a construção de gráficos de autocorrelações, buscando mostrar que os mesmos são não autocorrelacionados. A validação é reforçada com o periodograma integrado, segundo [18] se o modelo não for adequado, haverá desvios sistemáticos da reta no gráfico do periodograma acumulado $C(f_j)$ pela frequência (f_j), veja figura 2.

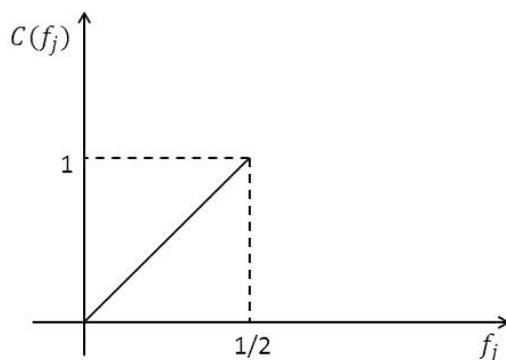


Figura 2. Gráfico periodograma acumulado. Fonte: autor

Para testar a hipótese que todos os coeficientes de autocorrelação ρ_k são iguais a

zero, foi utilizado a estatística $Q = n \sum_{k=1}^m \hat{\rho}_k^2$ desenvolvida por Box e Pierce, em que n é o tamanho da amostra e m a duração da defasagem. A estatística Q tem distribuição qui-quadrado com m graus de liberdade. Quando Q excede o valor crítico, rejeita-se a hipótese nula de que todos os ρ_k são iguais a zero [19].

6 Resultados obtidos

Os aplicativos utilizados nas previsões feitas neste trabalho foram desenvolvidos em ambiente do *Scilab*, que pode ser obtido no portal www.scilab.org e os testes estatísticos realizados nos aplicativos *Statgraphics* e *EViews*.

A análise do correlograma da série observada mostra um decrescimento não muito lento no valor das autocorrelações e ausência de componente periódica, indicando que a série pode ser estacionária e não-sazonal. Na figura 3, está representado o correlograma da série observada, onde se pode observar os indicativos de estacionariedade e não-sazonalidade. A indicação de estacionariedade foi reforçada pelo teste de Dickey Fuller aumentado para um nível de significância de 5% (p -valor obtido = 0,0273). A utilização do teste de Dickey Fuller é válida quando o processo gerador da série temporal é um processo auto-regressivo [19]. A estacionariedade da série favorece a utilização do modelo ARMA(p, q).

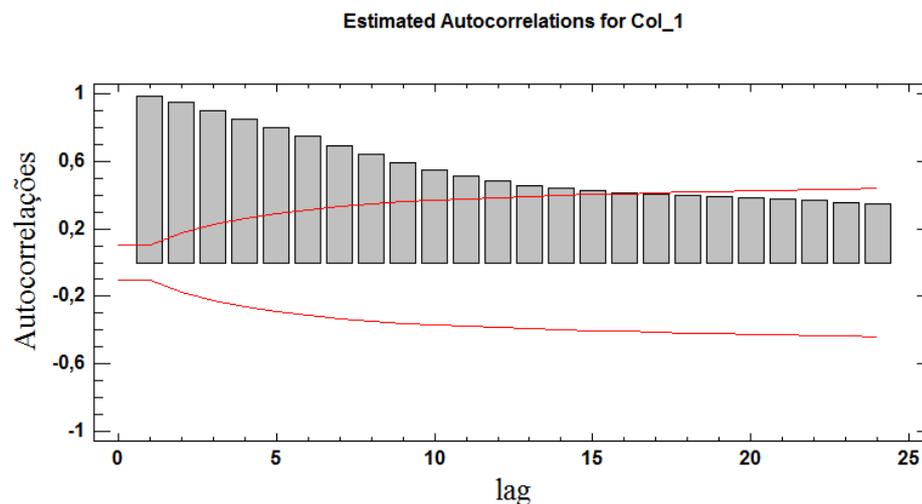


Figura 3. Correlograma das vazões diárias – ano 2009. Fonte: autor

Com os 358 primeiros termos da série observada formou-se a série que será designada por amostra de treinamento, com as últimas sete observações do ano de 2009 formou-se a série denominada amostra de teste. O sistema ARMA-PSO ajustou aos dados da amostra de treinamento um modelo ARMA(3, 2), cujos parâmetros estão representados na tabela 2.

Tabela 2. Parâmetros: ARMA(3, 2)

Parâmetros	Valor
δ	83,252
ϕ_1	1,184
ϕ_2	0,451
ϕ_3	-0,642
θ_1	-1,125
θ_2	-0,355

Fonte: autoria própria.

Na figura 4, estão representados os gráficos da amostra de treinamento e série obtida com o modelo ajustado. Os gráficos apontam para diminutos erros de previsão dentro da amostra de treinamento.

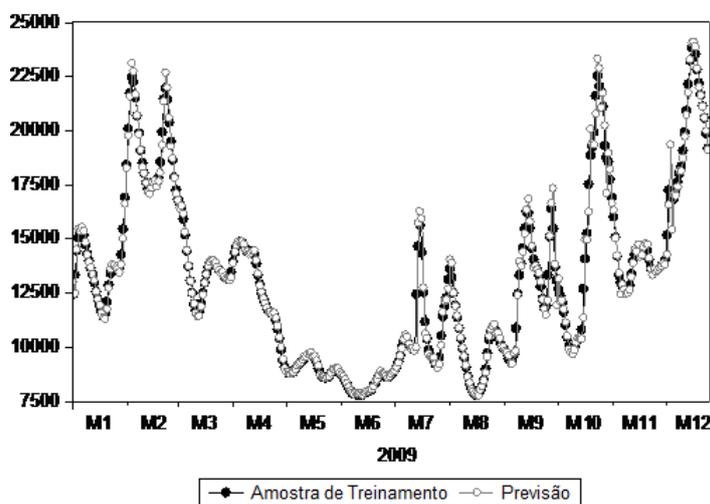


Figura 4. Gráfico das séries de valores reais previstos-amostra treinamento

A figura 5 mostra o correlograma dos resíduos provenientes da modelagem. Con-

siderando que a autocorrelações nos *lags* 13 e 18 sejam valores espúrios, pode-se afirmar pelo teste da autocorrelação residual que o modelo ajustado é adequado. Visto que o correlograma para a série de resíduos mostra valores situados num intervalo no qual a autocorrelação é considerada nula.

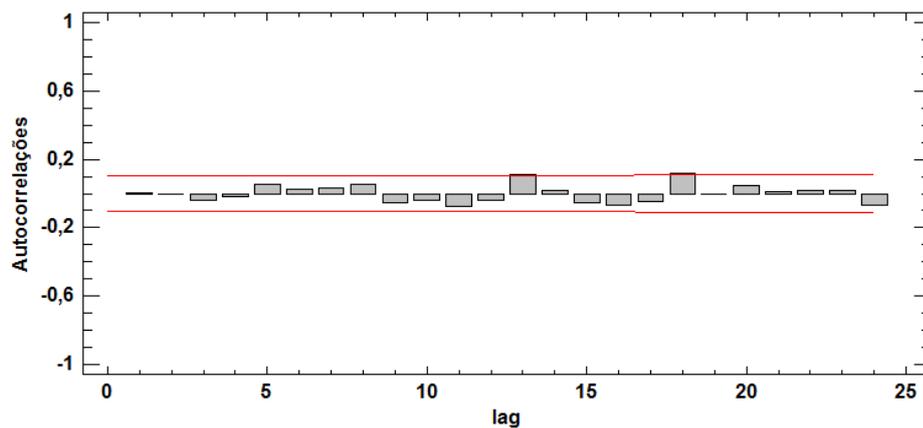


Figura 5. Correlograma dos resíduos. Fonte: autor

Os testes de Box-Pierce e periodograma (figura 6) corroboram com a conclusão obtida com o teste da autocorrelação residual. Como o p -valor (0,3628) obtido com o teste de Box-Pierce é maior que 0,05, não se pode rejeitar, a hipótese que a série de resíduos é randômica ao nível de 5%. O periodograma (figura 6) mostra que o modelo ARMA(3, 2) é adequado aos dados, não tendo os resíduos parte sistemática a ser modelada, estando os resíduos próximos ao ruído branco.

Analisando os resultados dos testes do periodograma, Box-Pierce e autocorrelação residual, conclui-se que o modelo ARMA(3, 2) pode representar o processo gerador da série de vazões diárias – ano 2009 no posto 266 (Itaipu).

A tabela 3 informa os valores da amostra de teste, correspondentes aos últimos sete dias do ano de 2009. Além, das previsões um passo ($h = 1$) à frente e $1, 2, \dots, 7$ ($h = 7$) passos à frente, e respectivos RMSE e MAPE. Onde se pode observar o aumento médio do erro à maneira que se aumenta o horizonte de previsão, ilustrado na figura 7.

A previsão em 25/12/09, por exemplo, foi obtida a partir da equação 8.

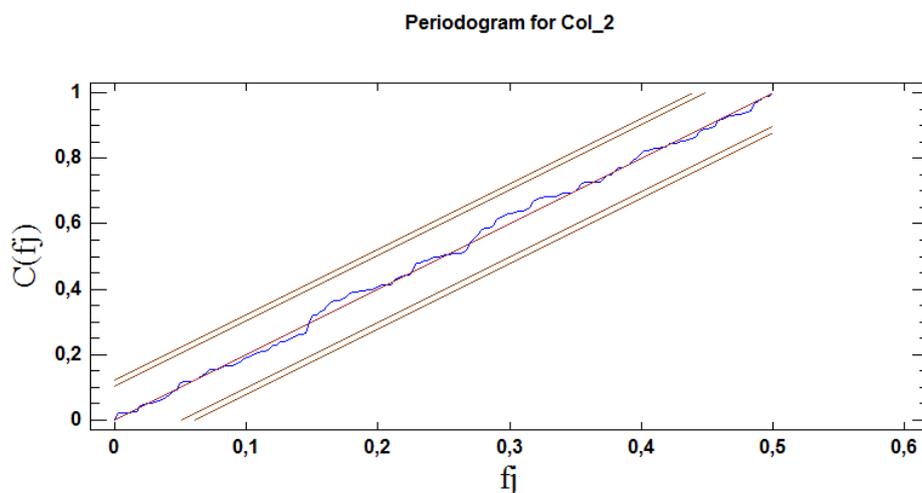


Figura 6. Periodograma para os resíduos. Fonte: autor

Tabela 3. Previsões para a amostra de teste ($h = 1$ e $h = 1, \dots, 7$)

Dia	Amostra de teste	Previsão ($h = 1$)	Previsão ($h = 7$)
25/12/09	18687	18524,88	18524,88
26/12/09	18289	18316,77	18124,83
27/12/09	18221	17911,47	17859,91
28/12/09	18339	18258,65	17987,15
29/12/09	18419	18484,76	18334,33
30/12/09	18639	18430,68	18668,85
31/12/09	19122	18908,11	18916,34
RMSE	-	178,40	226,08
MAPE	-	0,82%	1,05%

Fonte: autoria própria.

$$\hat{Z}_{359} = \delta + \phi_1 Z_{358} + \phi_2 Z_{357} + \phi_3 Z_{356} - \theta_1 a_{358} - \theta_2 a_{357} \quad (8)$$

Em que $z_{358} = 19147$, $z_{357} = 19850$ e $z_{356} = 20585$ são as vazões observadas em 24, 23 e 22/12/09, respectivamente. O resíduo oriundo da previsão em 24/12/09 é $a_{358} = 60,207$ e $a_{357} = -130,227$ em 23/12/09. Variando em (8) os valores das observações e resíduos obtiveram-se as outras seis previsões correspondentes à amostra de teste.

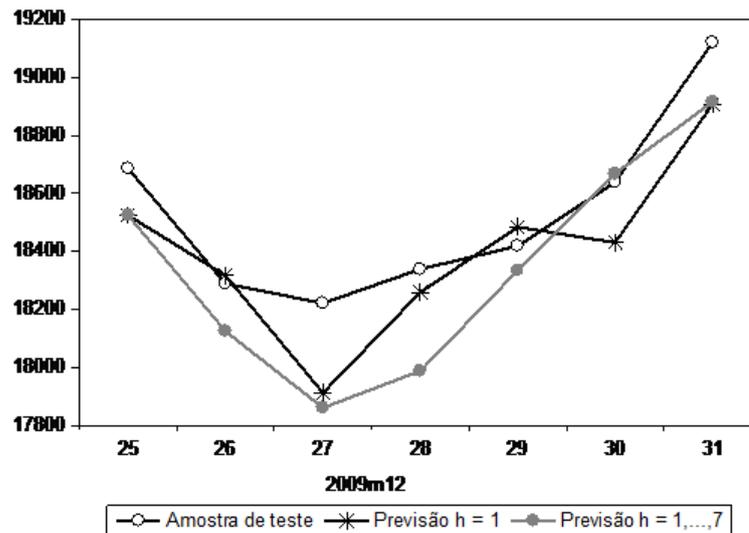


Figura 7. Gráficos: amostra de teste, previsões $h = 1$ e $h = 7$. Fonte: autor

7 Considerações finais

A previsão de aflúncias nos reservatórios das usinas hidrelétricas é de extrema relevância no planejamento da produção de energia, mormente no Brasil onde a geração de eletricidade é feita a partir da energia hidráulica das águas. A previsão de vazões propicia ao operador do sistema interligado nacional elementos para a otimização do total da energia produzida, explorando toda a potencialidade do sistema. Na Itaipu, são frequentes as ações de monitoramento do nível do rio Paraná à jusante da barragem, por conta de tratados firmados com a Argentina e a preocupação com o fenômeno enchente sobre as populações ribeirinhas. Dessa forma, as previsões de aflúncias realizadas com certa antecedência e precisão permitem aos tomadores de decisões elaborarem estratégias que minimizam os efeitos negativos de cheias extraordinárias. As previsões de aflúncias ainda fornecem informações importantes para outros setores envolvidos com o reservatório de água, tais como: abastecimento urbano e agrícola, piscicultura, aquicultura, recreação e lazer.

O setor elétrico brasileiro aplica diversas metodologias para a previsão de vazões e modelos lineares são de uso frequente. Neste sentido, este trabalho associou o modelo linear ARMA com a meta-heurística PSO. O modelo proposto dispensa as aná-

lises das séries a fim de se determinar as ordens autorregressivas (p) e médias móveis (q). Gnanlet e Rajendran, (2009) [5] propuseram um modelo ARMA(p, q) associado às meta-heurísticas Algoritmo Genético e *Simulated Annealing*, onde afirmam que a definição de p e q com domínio $0, 1, 2, 3, \dots, 24, 25$ é suficiente para modelar séries não-estacionárias e sazonais. Com o intuito de se reduzir o tempo de execução do modelo ARMA-PSO, este trabalho usou para p e q valores entre 0 e 15. Esta estratégia apresentou bons resultados para a série analisada e testes estatísticos validaram o modelo.

O sistema ARMA-PSO mostrou-se bastante eficiente na determinação dos coeficientes (ϕ e θ) dos modelos, visto que o aumento sistemático no número de iterações não apresentou diferenças relativas consideráveis na função objetivo. Siqueira et al, (2010) [4] usaram as meta-heurísticas Algoritmo Genético e *Opt-aiNet* na determinação dos coeficientes do modelo ARMA(p, q) e afirmam que os algoritmos foram capazes de realizar uma busca pelos mínimos das estruturas de previsão, tendo em vista a pequena variância nos resultados das várias simulações realizadas.

O sistema proposto apresentou resultados satisfatórios na determinação das ordens p e q e coeficientes ϕ e θ , sendo o tempo computacional, o ponto a ser melhorado. O uso de outras meta-heurísticas poderiam contribuir com o problema do custo computacional. Observando que a execução do sistema é praticamente instantânea quando se conhece previamente os valores de p e q , sendo ϕ e θ os únicos valores a serem calculados.

Referências

- [1] BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. Time series analysis: forecasting and control. 3 ed. Englewood Cliffs. Prentice-Hall, 1994.
- [2] BOX, G. E. P. E COX, D. R. An analysis of transformations. *J R Stat Soc*, vol. 26, n. 2, p. 211-252, 1964.
- [3] SHYNK, J. J. Adaptive IIR filtering. *IEEE ASSP Magazine*. vol. 6, n. 2, p. 4-21, 1989.

- [4] SIQUEIRA, H. V.; ATTUX, R.; LYRA FILHO, C. Exploração de alternativas lineares para previsão de séries de Vazões. In: *Mecânica Computacional XXIX, 2010*, p. 9629-9644, 2010.
- [5] GNANLET, A.; RAJENDRAN, C. Meta-heuristics in ARMA forecasting. *California Journal of Operations Management*, vol. 7, n. 1, p. 38-48, 2009.
- [6] HANSEN, J. V.; MCDONALD, J. B.; NELSON, R. D. Time series prediction with genetic algorithm designed neural networks: an empirical comparison with modern statistical models. *Comput Intell*. vol. 15, n. 3, p. 171-184, 1999.
- [7] BEHNAMIAN, J.; FATEMI GHOMI, S. M. T. Development of a PSO-SA hybrid metaheuristic for a new comprehensive regression model to time-series forecasting. *Expert Sys Appl*, vol. 37, n. 2, p. 974-984, 2009.
- [8] SILVA, C. G. Time series forecasting with a non-linear model and the scatter search meta-heuristic. *Inform Sciences*, vol. 178, n. 16, p. 3288-3299, 2008.
- [9] ASSADI, S.; TAVAKOLI, A.; HEJAZI, S. R. A new hybrid for improvement of auto-regressive integrated moving average models applying particle swarm optimization. *Expert Sys Appl*, vol. 39, n. 5, p. 5332-5337, 2011.
- [10] BARAGONA, R.; BATTAGLIA, F.; CALZINI, C. Genetic algorithms for the identification of additive and innovation outliers in time series. *Comput Stat Data Analysis*, vol. 37, n. 1, p. 1-12, 2001.
- [11] GREBOGI, R. B. Máquina de aprendizagem extrema com otimização por enxame de partículas aplicada à previsão de séries temporais. Dissertação Mestrado. Universidade Federal do Paraná, Curitiba, 2013.
- [12] LEVINE, D. M.; STEPHAN, D. F.; KREHBIEL, T. C.; BERENSON, M. L. Estatística: teoria e aplicações. 1 ed. Rio de Janeiro. LTC, 2000.
- [13] LUCAS, E. W. M.; Souza, F. A. S.; Silva, F. D. S.; Lucio, P. S. Modelagem hidrológica determinística e estocástica aplicada à região hidrográfica do Xingu – Pará. *Rev Bras Meteorol*, vol. 24, n. 3, p. 308-322, 2009.

- [14] SÁFADI, T. Uso de séries temporais na análise de vazão de água na represa de furnas. *Cienc Agrotec*, vol. 28, n. 1, p. 142-148, 2004.
- [15] KENNEDY, J.; EBERHART, R. C. A discrete binary version of the particle swarm algorithm. In: *Proceedings of the 1997 Conference on Systems, Man, and Cybernetics*, vol. 5, p. 4104–4108, 1997.
- [16] BALLINI, R. Análise e previsão de vazões utilizando modelos de séries temporais, redes neurais e redes nebulosas. Tese de Doutorado. Universidade Estadual de Campinas, Campinas, 2000.
- [17] SOUZA, R. C.; CAMARGO, M. E. Análise e previsão de séries temporais: os modelos ARIMA. 1 ed. Rio de Janeiro. Souza e Camargo, 2004.
- [18] MORETTIN, P. A.; TOLOI, C. M. Análise de series temporais. São Paulo. Blucher, 2006.
- [19] GUJARATI, D. N. Econometria básica. São Paulo. Pearson Makron Books, 2000.