

Modelos Lineares Realimentados de Previsão: Um Estudo Utilizando Algoritmos Evolucionários

Hugo Valadares Siqueira

Departamento Acadêmico de Engenharia Eletrônica
Universidade Tecnológica Federal do Paraná - UTFPR
Ponta Grossa-PR, Brasil
E-mail: hugosiqueira@utfpr.edu.br

Ivette Luna

Instituto de Economia
Universidade Estadual de Campinas - UNICAMP
Campinas-SP, Brasil
E-mail: ivette@eco.unicamp.br

Resumo - A previsão das séries de vazões a usinas hidrelétricas é de vital importância para o planejamento energético em países como o Brasil, que possuem um parque gerador predominantemente hidráulico. Técnicas lineares são bastante utilizadas no âmbito desse problema. Desse conjunto de modelos possíveis, os modelos realimentados surgem como uma alternativa no ensejo de obter modelos mais acurados para fins de previsão e embora o processo de estimação dos parâmetros desse tipo de modelos seja significativamente mais complexo. Visando contribuir com o desenvolvimento de técnicas de otimização adequada a este problema, o presente trabalho busca a análise de algoritmos bio-inspirados, como técnicas de estimação de parâmetros de modelos ARMA e de filtros lineares com resposta ao impulso infinita. O estudo contempla três algoritmos bio-inspirados: algoritmo genético e duas propostas de algoritmos imunológicos, uma baseada em pequenas alterações do CLONALG e a opt-aiNet. Os resultados indicam a existência, do ponto de vista de otimização, de um ganho de desempenho trazido pelas meta-heurísticas bio-inspiradas e, do ponto de vista estrutural, revelam a validade da adoção de estruturas recorrentes.

Palavras Chaves - *previsão linear de vazões, filtros IIR, modelos Box & Jenkins, algoritmos evolucionários.*

I. INTRODUÇÃO E DESCRIÇÃO DO PROBLEMA

No Brasil, a geração de energia elétrica é predominantemente baseada em usinas hidrelétricas, com cerca de 80% do total fazendo com que os recursos hídricos sejam essenciais neste contexto [1][2]. Dessa forma, torna-se importante investigar a aplicação de metodologias para previsão das vazões afluentes destas usinas, subsídios necessários para o planejamento energético [1][2][3][4][5]. Apesar de existir uma série de métodos de previsão, os modelos lineares Box & Jenkins [1][6], ainda são bastante empregados pelo setor elétrico brasileiro (SEB).

Os preditores lineares basicamente podem ser alocados em duas categorias: os de resposta ao impulso finita – FIR – (que não possuem laços de realimentação) e de resposta ao impulso infinita – IIR – que têm intrínsecos a sua estrutura a realimentação de alguma informação de saída [7]. No primeiro caso se encontra o modelo autorregressivo (AR), que, pela sua concepção, pode ter seus coeficientes estimados através de

uma solução formal fechada dada pelas equações de Yule-Walker ou Wiener-Hopf [7]. No segundo, estão os modelos autorregressivos e de médias móveis (ARMA) e os filtros lineares realimentados ou filtros de resposta ao impulso infinita (IIR), que utilizam outras informações estatísticas além da entrada do modelo, já que realimentam à entrada, dados provenientes da saída do preditor [6][7][8].

Embora as estruturas realimentadas possuam mais informação para formação da resposta de saída, para o cálculo dos seus coeficientes algumas considerações precisam ser feitas [9]: **i)** a impossibilidade de obter soluções fechadas de modo direto; **ii)** a existência de dificuldades para obtenção das derivadas de uma função custo baseada em uma medida de erro quadrático médio (MSE); **iii)** o caráter potencialmente multimodal da função de erro quadrático médio; **iv)** a possibilidade de que, num processo iterativo de escolha de parâmetros, alcance-se uma configuração instável, o que inviabilizaria a convergência do método.

Entretanto, tais dificuldades podem ser contrabalançadas pela utilização de técnicas de otimização que possuam potencial de busca global e que não necessitem de manipulações da função custo baseada no MSE. Meta-heurísticas populacionais são robustas, podendo ser candidatas para essa tarefa. Assim, este trabalho propõe a utilização de métodos evolutivos bio-inspirados de otimização: algoritmos genéticos [10], algoritmos imunológicos [11][12] e a opt-aiNet [13].

A análise geral trata de aspectos da implementação computacional dos algoritmos. Nos cenários abordados os modelos de previsão linear serão aplicados às série de vazões médias mensais do posto de FURNAS em dois períodos de características hidrológicas diferentes.

O artigo está organizado da seguinte maneira: na Seção II, serão abordadas as metodologias de previsão lineares; a Seção III, por sua vez, descreve a ferramentas evolutivas para otimização dos parâmetros dos modelos: os algoritmos genético e imunológico e a opt-aiNet. A Seção IV fala sobre as séries de vazões médias mensais, os resultados computacionais obtidos com a respectiva análise, enquanto a Seção V apresenta as conclusões.

II. PREVISÃO LINEAR

A previsão de séries temporais é um importante campo de pesquisa, com aplicações nas mais variadas áreas da ciência. No caso das metodologias lineares, de maneira geral o processo se dá por meio da combinação ponderada de valores passados para que seja estimado o seu valor P passos à frente. Para tal, é necessário a identificação do modelo mais adequado, assim como a estimação dos seus parâmetros [2][6].

O ajuste dos parâmetros desses modelos usualmente é realizado via a minimização do erro quadrático médio [8]. Sendo assim, o erro de previsão pode ser definido por:

$$e_t = x_t - \hat{x}_t \quad (1)$$

sendo x_t o valor da série no instante t e \hat{x}_t o valor estimado ou previsto pelo modelo tendo por base valores anteriores da série. No caso de um modelo linear genérico, vale a Expressão 2 [7]:

$$x_t = \sum_{k=1}^p \alpha_k x_{t-k} \quad (2)$$

na qual os coeficientes α_k são os pesos, ou ponderações, das observações passadas ou atrasos x_{t-k} . Quando o modelo é usado para fins de previsão, após a identificação e ajuste do modelo, os valores previstos \hat{x}_t serão dados pela saída do modelo, que será alimentado pelos valores passados e conhecidos de x_t .

De acordo com o critério de Wiener de filtragem ótima, para o cálculo dos melhores coeficientes de uma estrutura linear, é necessário minimizar o erro quadrático médio (MSE) entre a resposta desejada e a saída do preditor, ou seja, encontrar os parâmetros α_i e β_j de maneira que a função custo \mathbf{J}_w baseada no MSE, definida em (4), seja minimizada [7]:

$$\mathbf{J}_w = E[\mathbf{e}_t^2] \quad (3)$$

com $E[\cdot]$ sendo o operador de esperança matemática.

Após esta discussão inicial, discutiremos alguns modelos lineares baseados na metodologia Box & Jenkins [6].

A. Modelo Auto-Regressivo (AR)

Um dos modelos lineares mais utilizados em previsões de séries temporais estacionárias são os chamados modelos autorregressivos cuja expressão matemática é apresentada na Equação (5):

$$\hat{x}_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + a_t \quad (4)$$

onde x_{t-i} , $i = 1, \dots, p$ são os atrasos da série observada, \hat{x}_t , o valor predito no instante t , $\phi_i, \dots, i=1, \dots, p$, os coeficientes do modelo autorregressivo e a_t a componente aleatória não modelada que é estimada pelo erro de previsão. No caso da previsão múltiplos passos à frente, a formulação se adequa de

forma direta fazendo $t \rightarrow t+p$ e realimentando os valores antes previstos quando necessário [14].

Analiticamente, a solução que minimiza a função custo em (3), dada por:

$$\Phi = \mathbf{R}^{-1} \mathbf{r} \quad (5)$$

sendo

$$\mathbf{R} = \begin{bmatrix} r_0 & r_1 & \dots & r_{p-1} \\ r_1 & r_0 & \dots & r_{p-2} \\ \dots & \dots & \dots & \dots \\ r_{p-1} & r_{p-2} & \dots & r_0 \end{bmatrix} \quad \text{e} \quad \mathbf{r} = \begin{bmatrix} r_p \\ r_{p+1} \\ \dots \\ r_{p+p} \end{bmatrix}$$

a matriz de autocorrelação das entradas do filtro e o vetor de correlação cruzada entre as entradas e o sinal desejado (no caso, \mathbf{x}_t), respectivamente. O termo P refere-se ao número de passos adiante que se pretende prever, p a ordem do modelo AR e $\Phi = [\phi_1, \phi_2, \dots, \phi_p]$ é o vetor de estimadores otimizados.

A Equação (5) é a solução das equações de Yule – Walker, também conhecidas como solução de Wiener-Hopf, que aponta os coeficientes ótimos do modelo AR(p). Note que estes são únicos para cada problema, já que a função de erro encontrada é um hiper-parabolóide [6].

Entretanto, para modelos nos quais temos componentes de médias móveis, não é possível a obtenção de soluções fechadas para os estimadores ótimos do modelo, além de que e o cálculo das derivadas da função custo pode não ser trivial. Alguns deles são expostos a seguir.

B. Modelos Auto-Regressivos e Médias Móveis (ARMA)

Os modelos autorregressivos e médias móveis (ARMA) são bastante usuais em análise e previsão de séries temporais [6]. Sua gênese está na fusão de dois outros modelos, o autorregressivo (AR) e o de médias móveis (MA). A diferença entre o modelo MA e o modelo AR se dá no fato de que enquanto o último combina valores passados da variável em análise, o outro agrega choques aleatórios a_t de forma a gerar o sinal desejado, sendo que a_t é considerada uma variável aleatória não correlacionada. Um modelo MA de ordem q (MA(q)) é expresso da seguinte forma:

$$x_t = -\theta_1 a_{t-p} - \theta_2 a_{t-p-1} - \dots - \theta_q a_{t-p-q+1} + a_t \quad (6)$$

sendo θ_i , $i=1, 2, \dots, q$, os parâmetros do modelo e P o horizonte de previsão [6].

No caso MA, diferentemente dos modelos AR, a estimação dos parâmetros não é direta: é necessário resolver um sistema de equações não-lineares [7].

Um modelo mais geral, entre um modelo AR e um modelo MA é o modelo “misto” autorregressivo e de médias móveis (ARMA). Matematicamente, um modelo ARMA(p, q) é descrito da seguinte forma:

$$x_t = \phi_1 x_{t-p} + \phi_2 x_{t-p-1} + \dots + \phi_p x_{t-p-p+1} - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} + a_t \quad (7)$$

com ϕ_i e θ_i sendo os parâmetro, da parte AR e MA do modelo, respectivamente. Assim, como no caso do modelo MA, para o cálculo dos parâmetros é necessário resolver um sistema de equações não-lineares [6]. Por outro lado, com uma identificação do modelo e estimação adequada dos parâmetros, pode-se ter um preditor linear ótimo.

C. Filtros de resposta ao impulso infinita (IIR)

Além do modelo ARMA, outra possibilidade construtiva comumente aplicada a problemas de previsão é o filtro de resposta ao impulso infinita (IIR). A diferença entre eles é que a entrada é realimentada à saída imediatamente anterior do preditor, em detrimento ao erro de previsão. Neste espírito, a expressão do preditor, que agora será chamado apenas de filtro IIR ou filtro linear realimentado será:

$$\hat{x}_t = c_1 x_{t-p} + c_2 x_{t-p-1} + \dots + c_p x_{t-p-p+1} - b_1 \hat{x}_{t-1} - b_2 \hat{x}_{t-2} - \dots - b_q \hat{x}_{t-q} \quad (8)$$

na qual $c_i, i=1, \dots, p$ são os parâmetros livres que ponderam as entradas diretas enquanto $b_j, j=1, 2, \dots, q$, são os coeficientes relativos às realimentações [7][8].

Da mesma forma que os modelos ARMA, este filtro contém zeros e pólos na sua função de transferência mas não há, na literatura precedentes para o cálculo ótimo de seus parâmetros de forma determinística.

III. FERRAMENTAS EVOLUTIVAS DE OTIMIZAÇÃO

A. Algoritmos Genéticos

Algoritmos genéticos (AG) são ferramentas de busca e otimização que se inspiram na teoria moderna de evolução das espécies e foram propostos por Holland [10]. Esta técnica baseia-se na ideia de que cada solução do problema abordado é um indivíduo e que seu genótipo se relaciona diretamente com os parâmetros livres. O grau de adaptação ao ambiente é dado por uma função de avaliação, ou adequabilidade conhecida por *fitness*, havendo uma relação direta entre ela e a função custo a ser otimizada. O processo iterativo entre a função de *fitness* e os operadores, faz com que os indivíduos passem por um processo de modificação genotípica, que, em termos práticos, trata-se de uma forma de interação que permite a exploração do espaço de busca subjacente ao problema tratado.

Segundo [13], para que este algoritmo possa ser utilizado alguns aspectos precisam ser considerados:

- A definição de uma representação genotípica para as soluções candidatas (codificação);
- A elaboração de uma função de avaliação ou *fitness* que quantifica o grau de adaptação do indivíduo ao ambiente;
- A definição de operadores genéticos responsáveis pela modificação e seleção dos indivíduos;

- A determinação de valores para os diversos parâmetros livres do algoritmo (tamanho da população, probabilidades de aplicação dos operadores genéticos etc.).

Em [15] é descrita a estrutura geral do AG empregado neste trabalho. Basicamente, a busca ocorre por meio de um processo iterativo, no qual são criadas gerações de indivíduos que terão seu genótipo modificado com intuito de se encontrar pontos de ótimo na função de *fitness*. As modificações mais comumente aplicadas são *crossover* (troca de genes entre indivíduos diferentes) e *mutação* (perturbações pseudo-gaussianas aleatórias em alguns genes do conjunto total de indivíduos). Além disso, após certo número de gerações, o melhor indivíduo tem um valor pseudoaleatório gaussiano somado ao primeiro gene (neste caso, o primeiro parâmetro do modelo a ser otimizado), como forma de inserir uma componente de busca local. Em seguida, seu *fitness* é novamente medido e, se esta perturbação for benéfica, este valor é novamente somado e o indivíduo reavaliado até que as melhorias não mais ocorram. Adiante, o mesmo procedimento é feito para os genes subsequentes. No caso de não haver melhorias na primeira tentativa, o indivíduo tem o valor pseudoaleatório subtraído do gene e o processo repetido.

Neste trabalho, os parâmetros livres foram definidos da seguinte forma:

- a) Codificação real, com valores entre -1 e $+1$;
- b) Crossover de um ponto [15];
- c) Mutação gaussiana dinâmica [5][16];
- d) Seleção via algoritmo da roleta (*roulette wheel*) [13][15].

Testes foram realizados com *crossover aritmético* e seleção via *torneio* [15]. Entretanto, os valores encontrados para o erro quadrático médio foram favoráveis às opções aqui apresentadas.

O *fitness* é definido como:

$$\mathbf{J}_{\text{fit}} = \frac{1}{(1 + \hat{\mathbf{J}}_w)} \quad (9)$$

no qual $\hat{\mathbf{J}}_w$ é uma estimativa da função custo de Wiener baseada em uma média amostral, semelhante à Equação (3). O mapeamento proposto em (9) transforma o problema de minimização do MSE em maximização, mais frequentemente utilizado em abordagens evolutivas.

B. Sistemas Imunológicos Artificiais

Sistemas imunológicos artificiais (SIA) são algoritmos de otimização inspirados na forma de ação do mecanismo de defesa dos organismos superiores contra antígenos [11]. Por conta da sua constituição são classificados como algoritmos evolutivos, assim como os AGs. Neste trabalho, o algoritmo utilizado é uma versão simplificada do CLONALG [12] e será nominado simplesmente por algoritmo imunológico (AI).

O processo de otimização é inspirado no processo biológico de reconhecimento de um antígeno. Uma solução possível de um dado problema, que aqui equivale a um vetor

de parâmetros reais, será vista como um anticorpo que busca maior afinidade possível com um antígeno que, neste caso, é quantificada por uma função de *fitness*.

O princípio básico que inspira o algoritmo é o *princípio da seleção clonal*, segundo o qual quando um dado antígeno é reconhecido, as células de defesa entram em processo de clonagem e todas estas estão sujeitas a um processo de mutação que é diretamente proporcional a afinidade anticorpo-antígeno [13]. Ainda, segundo tal princípio, outros mecanismos estão intrinsicamente envolvidos neste processo como a introdução de novos indivíduos com material genético distinto na população de células de defesa, sujeitas a mudanças espúrias e pressão seletiva.

Tal como o algoritmo genético, esta técnica possui mecanismos de busca local, proporcionado por meio do binômio clonagem/mutação, e potencial de busca global com a inserção periódica de novos indivíduos. A codificação utilizada foi a real. A medida de *fitness* e a função custo são idênticas às apresentadas nas equações (9), transformando assim o processo de otimização em um problema de maximização.

O quadro a seguir apresenta o algoritmo imunológico utilizado [5].

<p>Inicialização - Escolha os parâmetros do algoritmo e inicie aleatoriamente os indivíduos da população.</p> <p>Processo Iterativo - Enquanto um número máximo de iterações ou gerações (<i>gen</i>) não for atingido, faça:</p> <ol style="list-style-type: none"> 1. Calcule o <i>fitness</i> de todos os indivíduos da população; 2. A cada N_i iterações, inclua N_{ind} soluções geradas aleatoriamente no lugar dos N_{ind} indivíduos com menor <i>fitness</i>; 3. Produza N_c cópias de cada indivíduo; 4. Aplique um processo de mutação a cada uma dessas cópias (clones), mantendo, no entanto, o indivíduo original inalterado. A mutação é proporcional ao custo e segue as duas equações a seguir: $c' = c + \mu N(0,1)$ $\mu = (1/\lambda)\exp(-f)$ sendo λ um parâmetro regulador da amplitude de mutação e f o valor de <i>fitness</i> do clone c; 5. Determine o valor do custo dos novos indivíduos e, de cada grupo formado pelos clones e pelo indivíduo original, mantenha apenas a melhor solução; 6. Se o <i>fitness</i> médio da população não for significativamente alterado, continue. Caso contrário, volte ao início; 7. Determine a similaridade dos indivíduos dois a dois e suprima o de menor <i>fitness</i>; 8. Verifique o tamanho da população; 9. Introduza novos indivíduos gerados aleatoriamente, proporcionalmente à população atual original e mantenha apenas a melhor solução.

C. Opt-aiNet

A opt-aiNet (*Artificial Imune Network for Otimization*) faz parte da família de algoritmos *aiNet*, proposta em [11]. Este algoritmo foi concebido para resolução de problemas que vão desde agrupamento até otimização combinatória. Trata-se também de um algoritmo imunológico baseado em seleção clonal, mas com uma pequena diferença em relação a versão modificada do CLONALG da seção anterior: um mecanismo

de controle automático do tamanho da população, que procura reduzir a redundância na informação contida nos anticorpos, por meio da inserção de novos indivíduos aleatoriamente gerados. Contudo, os processos e princípios são semelhantes nos dois algoritmos.

A eliminação de redundância e inserção de diversidade ocorre da seguinte forma: quando o *fitness* médio da população não tem alteração significativa entre um número determinado de iterações, observa-se a estagnação da população, que apresenta uma diversidade muito baixa. Assim, pela distância euclidiana medida entre duplas de anticorpos, suas cargas genéticas (neste caso parâmetros livres do modelo) são comparadas e, havendo redundância ou grande semelhança, o anticorpo de menor *fitness* é eliminado. Após a supressão, novos indivíduos aleatoriamente gerados são inseridos na população para que assim, a diversidade se eleve [11][12][13].

IV. ESTUDOS DE CASOS

A. Séries de Vazões e Pré-Processamento

Séries de vazões médias mensais apresentam uma componente sazonal compatível com o regime pluviométrico das regiões dos rios que abastecem as usinas hidrelétricas, o que a torna não estacionária. Entretanto, tal componente pode ser retirada no processo de previsão através de um tratamento estatístico, sendo este componente sazonal reinserido à resposta final do preditor. Para isso, este trabalho procede com a dessazonalização da série [2]. Assim, a série original x_t é transformada em uma nova série z_t padronizada, por meio da Equação (13):

$$z_{i,m} = \frac{x_{i,m} - \hat{\mu}_m}{\hat{\sigma}_m} \quad (13)$$

onde $\hat{\mu}_m$ é a média histórica de cada mês m , $\hat{\sigma}_m$ o desvio padrão respectivo e $x_{i,m}$ a vazão observada no mês $m = 1, 2, \dots, 12$ do i -ésimo ano $i = 1, 2, \dots, N_y$. A nova série z_t tem média igual a zero e desvio padrão unitário. As médias e variâncias amostrais usadas no processo são estimadas de acordo com [2][3][4][5][6]:

$$\hat{\mu}_m = \frac{1}{N_y} \sum_{i=1}^{N_y} x_{i,m} \quad (14)$$

$$\hat{\sigma}_m = \sqrt{\frac{1}{N_y} \sum_{i=1}^{N_y} (x_{i,m} - \hat{\mu}_m)^2} \quad (15)$$

Assim sendo, as metodologias de previsão serão aplicadas na série dessazonalizada z_t , a qual será dividida em dois subconjuntos: treinamento e teste. Como dito, ao final deste processo, o componente sazonal é reinserido para uma análise geral do erro quadrático médio na escala padronizada e real.

B. Resultados computacionais

Os testes computacionais realizados neste trabalho foram realizados com base em dois períodos da série histórica de vazões médias mensais da usina hidrelétrica de FURNAS, que está localizada no Rio Grande. A base de dados se encontra no site do Operador Nacional do Sistema Elétrico (ONS), que disponibiliza vazões afluentes das usinas hidrelétricas brasileiras desde 1931 [17]. A média histórica desta série é 942,04 m³/s e o desvio padrão 620,28.

Dois períodos de testes foram escolhidos visando analisar os algoritmos e modelos em cenários com características hidrológicas diferentes: de 1972 a 1976, tendo média histórica de 882,63 m³/s e de 1952 a 1956, com média 656,41 m³/s. O primeiro é considerado de vazões medianas enquanto o segundo é considerado um período seco.

De início, procedeu-se com a dessazonalização das séries. A seguir, um modelo AR(2) foi otimizado via equações de Yule-Walker, com base nos dados de treinamento. A escolha da ordem do modelo foi feita mediante ensaios preliminares nos quais fez-se a análise da variância dos resíduos para 1 a 4 entradas. Mediante tal análise, optou-se por duas entradas já que estes resultados foram suficientemente parcimoniosos.

Em seguida passou-se a fase de otimização da função custo de Wiener, ou a busca pelos melhores coeficientes para ajuste dos modelos ARMA e o filtro IIR, com a utilização das 3 técnicas bio-inspiradas descritas Seção III: algoritmo genético, imunológico e a opt-aiNet, com duas entradas e uma realimentação. Com isso é possível realizar uma análise comparativa do impacto direto no desempenho dos modelos pela inserção da realimentação na estrutura do preditor [18]. Os horizontes de previsão escolhidos foram $P = 1, 3, 6$ e 12 passos à frente.

A geração da população é feita de forma aleatória. Para o AG, a taxa de mutação foi de 20%. O número de clones gerados nas demais estratégias foi 5.

A Tabela 1 apresenta os resultados computacionais obtidos para cada modelo e algoritmo de busca respectivo e para os períodos de 1972/76 e 1952/56, em termos de Erros quadráticos médios tanto no domínio real (MSE x) como dessazonalizado (MSE z) e para os quatro horizontes de previsão, dando assim um total de 8 cenários comparativos (4 horizontes de previsão e dois períodos). Em estão destacados em negrito os melhores resultados no domínio real e seu respectivo erro no espaço dessazonalizado. Note-se que os valores contidos nas tabelas são as médias de 30 simulações.

Além disso, observa-se que o teste de Friedman [18] foi aplicado a um dos vetores de saída das 30 simulações que apresentou erro semelhante à média, para cada caso. Os p -valores encontrados foram da ordem de 10^{-4} , o que indica que a mudança no modelo preditor acarreta em alterações significativas no resultado final.

Os resultados apresentados permitem algumas importantes observações:

1) A inserção da realimentação leva diretamente à queda do erro quadrático médio de teste no domínio real;

- 2) Em 6 dos 8 casos, o melhor resultado encontrado no espaço dessazonalizado é perdido com a reintrodução da componente sazonal. Isto é um forte indicativo que a normalização da série é insuficiente para manter as melhores soluções;
- 3) Os algoritmos de otimização foram capazes de realizar uma busca consistente, tendo em vista a pequena variância nos resultados, aqui não colocados por limitação de espaço;
- 4) A série 72/76 não apresenta um padrão para afirmar qual modelo de previsão – ARMA ou filtro IIR – é superior no tocante ao MSE, seja real ou padronizado. Entretanto, na série 52/56, para os P menores (1 e 3) o modelo ARMA destaca-se e para P mais elevados (6 e 12) o filtro IIR se mostra melhor;

TABELA I - Desempenho para previsão da série FURNAS 1972 a 1976 e FURNAS 1952 a 1956

		1972/1976		1952/1956	
Método		MSE x ($\times 10^4$)	MSE z	MSE x ($\times 10^4$)	MSE z
P=1	AR	4.3972	0.3878	5.2964	0.3084
	IIR – Gen.	4.5737	0.4060	5.2630	0.3047
	IIR–Imuno.	4.5750	0.4061	5.2626	0.3078
	IIR – Opt.	4.5747	0.4060	5.3849	0.3094
	ARMA – Gen.	4.1907	0.3915	4.2140	0.2864
	ARMA – Imuno	4.1905	0.3917	4.2113	0.2864
	ARMA– Opt.	4.1910	0.3916	4.0763	0.2834
P=3	AR	4.9578	0.6254	8.1562	0.4064
	IIR – Gen.	4.9752	0.6230	8.2040	0.4028
	IIR–Imuno.	4.9749	0.6229	7.9257	0.3901
	IIR – Opt.	5.0481	0.5614	7.9564	0.3919
	ARMA – Gen.	4.3610	0.6428	7.6658	0.3882
	ARMA – Imuno	4.3606	0.6428	7.6680	0.3881
	ARMA– Opt.	4.3611	0.6945	7.6686	0.3881
P=6	AR	5.7657	0.8704	6.9484	0.4511
	IIR – Gen.	5.6931	0.7617	5.7212	0.4361
	IIR–Imuno.	5.6941	0.7617	5.7267	0.4355
	IIR – Opt.	5.6445	0.7575	5.7322	0.4345
	ARMA – Gen.	5.6875	0.8664	6.1528	0.4660
	ARMA – Imuno	5.6848	0.8660	6.1479	0.4656
	ARMA– Opt.	5.6846	0.8659	6.1492	0.4657
P=12	AR	5.4784	0.8191	1.0210	0.6871
	IIR – Gen.	5.4475	0.7880	7.9499	0.5883
	IIR–Imuno.	5.4495	0.7882	7.9488	0.5787
	IIR – Opt.	5.6543	0.7510	7.9440	0.5869
	ARMA – Gen.	5.1685	0.7660	1.0283	0.6749
	ARMA – Imuno	5.1713	0.7666	1.0295	0.6760
	ARMA– Opt.	5.1703	0.7663	1.0298	0.6761

- 5) Como consequência do item 4) disso não é possível afirmar categoricamente que o modelo ARMA ou o filtro linear realimentado é melhor para resolução do problema em questão;
- 6) É provável que a função custo de Wiener seja mal comportada, apresentando múltiplos mínimos locais. Dessa forma, como a inicialização é aleatória em todos os casos, cada algoritmo pode estar seguindo em um caminho diferente na busca pelas melhores soluções;

- 7) Não é possível apontar que algum dos algoritmos de otimização seja mais eficiente na tarefa de busca dos melhores coeficientes dos modelos: todos tem o potencial de ser igualmente eficientes;
- 8) Não é difícil notar que as previsões 1 passo à frente são menos desafiadoras, tendo em vista que a correlação entre as amostras próximas temporalmente é alta. Portanto os resultados obtidos neste horizonte são superiores tanto no espaço real quanto no padronizado.
- 9) Uma tendência observada para $P=6$ e $P=12$, no espaço real, é que o comportamento da série começa a se repetir, tendendo a mostrar algo parecido com a média de longo termo (MLT). Esta resposta seria equivalente ao preditor ter saída igual à zero. Como o número de passos à frente dificulta o processo de previsão, em dado momento este pode tender a não conseguir extrair mais informações da entrada e para não “comprometer” o resultado, responde apenas com valores pequenos ou nulos.

V. CONCLUSÕES

Neste trabalho foram propostos dois modelos lineares com realimentação – o autorregressivo e médias móveis e um filtro de resposta ao impulso infinita (IIR) - para previsão de vazões médias mensais da usina hidrelétrica de FURNAS, com período de testes compreendidos entre 1972 e 1976 e entre 1952 e 1956, com 60 observações em cada caso. Para cálculo dos coeficientes destes modelos, três propostas de algoritmos de otimização bio-inspirados foram aplicados: algoritmo genético, algoritmo imunológico e a opt-aiNet. O desempenho geral dos modelos de previsão foi comparado a uma abordagem autorregressiva (AR) – sem realimentação, com coeficientes calculados analiticamente pelas equações de Yule-Walker.

O desempenho dos preditores realimentados mostrou que essa abordagem trouxe um ganho de desempenho importante, sobretudo com o crescimento do número de passos à frente. É possível concluir que a memória intrínseca ao modelo capta o comportamento estocástico da série com maior competência. No primeiro período de testes selecionado (1972/1976), o modelo ARMA foi superior para três dos quatro horizontes de previsão propostos. Já os resultados para 52/56 mostraram que o ARMA se comportou melhor para um número menor de passos à frente, 1 e 3, enquanto o filtro IIR foi superior para $P=6$ e 12.

As técnicas de busca aplicadas também se mostraram relevantes para uma maior exploração das possibilidades dos modelos lineares de previsão realimentados. As ferramentas empregadas mostraram potencial homogêneo de otimização, com um pequeno destaque para 4 casos em que a opt-aiNet obteve resultados superiores - em média - dos demais. Isto pode denotar que o controle automático do tamanho da população, bem como a inserção de diversidade, neste caso, pode ser benéfico. Nota-se também que há um equilíbrio entre busca local e global por parte de tais algoritmos, que leva a interessantes níveis de exploração do espaço global e refinamento das soluções obtidas.

Finalmente, este trabalho mostra que a previsão baseada em modelos lineares ainda pode ser explorada devido a seu custo computacional reduzido e em combinação com técnicas alternativas de otimização que superam as dificuldades que modelos como o ARMA apresentam para a estimação dos seus parâmetros. Assim, mesmo com a existência de modelos não lineares mais complexos, a identificação e técnicas de otimização para a estimação dos parâmetros de modelos, independente da natureza do modelo (linear ou não) é uma área que ainda demanda pesquisa.

REFERÊNCIAS

- [1] R. C. Souza, A. L. M. Marcato, B. H. Dias, e I. C. Silva Júnior. "A Pesquisa Operacional e o Planejamento de Sistemas Energéticos." Minicurso - 42° SBPO. Bento Gonçalves, RS, 2010.
- [2] R. Ballini, "Análise e previsão de vazões utilizando séries temporais, redes neurais e redes neurais nebulosa", Tese de Doutorado, FEEC-Unicamp, Brasil, 2000.
- [3] H. V. Siqueira, C. Wada, C., R. Attux, C. Lyra Filho, "Previsão de Vazões com Estruturas Lineares Gerais Ajustadas por um Algoritmo Imunológico", XVII Congresso Brasileiro de Automática (CBA), 2008, Juiz de Fora, Brasil.
- [4] H. V. Siqueira, C., R. Attux, C. Lyra Filho, "Análise do Uso de Ferramentas Bio-Inspiradas de Otimização no Âmbito do Problema de Previsão de Estruturas Lineares Gerais". In: Simpósio Brasileiro de Pesquisa Operacional, 2008, João Pessoa-PB, Brasil.
- [5] H.V.Siqueira, "Previsão de Séries de Vazões com Redes Neurais Artificiais e Modelos Lineares Ajustados por Algoritmos Bio-Inspirados" – Dissertação de Mestrado, FEEC-UNICAMP, Brasil, 2009.
- [6] G. Box, , G. Jenkins. e G. C. Reinsel, Time Series Analysis, Forecasting and Control, 3rd ed, Holden Day, Oakland, California, EUA, 1994.
- [7] S. Haykin, "Adaptive Filter Theory". Prentice Hall, 1997.
- [8] A. V. Oppenheim, , A. S. Willsky and S. H. Nawab, Signals and Systems, Prentice Hall, 1996.
- [9] J. J. Shynk, "Adaptive IIR Filtering", IEEE ASSP Magazine, Vol. 6, No. 2, 1989, pp. 4-21.
- [10] J. H. Holland, Adaptation in Natural and Artificial Systems, MIT Press, 1992.
- [11] L. N. Castro e F. J. Von Zuben, "aiNet: An artificial immune network for data analysis." In: H. A. Abbass, R. A. Sarker, & C. S. Newton (Eds.): Data Mining: A Heuristic Approach, 2001, pp. 231–259, USA: Idea Group Publishing.
- [12] L. N. Castro e F. J. Von Zuben, "Learning and Optimization Using the Clonal Selection Principle", IEEE Transactions on Evolutionary Computation, Vol. 6, No. 3, pp. 239-251, 2002.
- [13] L. N. Castro, Fundamentals of natural computing: basic concepts, algorithms and applications, Chapman & Hall, 2006.
- [14] A. Sorjamaa, J. Hao, N. Reyhani, Y. Ji e A. Lendasse. Methodology for long-term prediction of time series. Neurocomputing, 70, 2007, pp. 2861–2869.
- [15] Michalewicz, Z., Genetic Algorithms + Data Structures = Evolution Programs, Springer, 2006.
- [16] Queiroz, L. M. O. "Algoritmos Genéticos Híbridos para Redução de Perdas Técnicas em Redes Primárias de Distribuição Considerando Variações de Demandas". Dissertação de Mestrado, FEEC-Unicamp, Brasil, 2005.
- [17] ONS, Operador Nacional do Sistema Elétrico. http://www.ons.org.br/operacao/vazoes_naturais.aspx.
- [18] H. Siqueira; L. Boccato; R. Attux; Ch. Lyra. Unorganized Machines for Seasonal Stramflow Series Forecasting. International Journal of Neural Systems, p. 140105195624000, 2014.