

EXPLORAÇÃO DE ALTERNATIVAS LINEARES PARA PREVISÃO DE SÉRIES DE VAZÕES

Hugo Valadares Siqueira^a, Romis Attux^b e Christiano Lyra Filho^c

^a Departamento de Engenharia de Sistemas (DENSIS), Faculdade de Engenharia Elétrica e de Computação (FEEC), Universidade Estadual de Campinas – UNICAMP, Caixa Postal 6101 CEP 13081-970 – Campinas, SP, Brasil, hugo@densis.fee.unicamp.br

^b Departamento de Engenharia da Computação e Automação Industrial (DCA), Faculdade de Engenharia Elétrica e de Computação – FEEC, Universidade Estadual de Campinas – UNICAMP, Caixa Postal 6101, CEP 13081-970 – Campinas, SP, Brasil, attux@dca.fee.unicamp.br

^c Departamento de Engenharia de Sistemas (DENSIS), Faculdade de Engenharia Elétrica e de Computação (FEEC), Universidade Estadual de Campinas – UNICAMP, Caixa Postal 6101 CEP 13081-970 – Campinas, SP, Brasil, chrlyra@densis.fee.unicamp.br

Palavras Chave: previsão linear de vazões, filtros IIR, modelos estatísticos, computação bio-inspirada.

Resumo: A previsão das séries de vazões em 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, sobretudo filtros com resposta ao impulso finita, cujos coeficientes ótimos podem ser calculados com o auxílio das equações de Yule-Walker (ou Wiener-Hopf). Entretanto, o projeto de preditores lineares gerais exige que estruturas de resposta ao impulso infinita possam ser utilizadas, embora o processo de obtenção dos coeficientes ótimos de estruturas desse tipo seja significativamente mais complexo. É exatamente nesse contexto que se insere este trabalho, que busca avaliar o desempenho de diversos modelos lineares de previsão e metodologias de ajuste de parâmetros junto a séries de vazões mensais da Usina Hidrelétrica de FURNAS. É proposta a utilização de modelos auto-regressivos e médias móveis (ARMA) e de filtros lineares com resposta ao impulso infinita, ambos tendo seus coeficientes calculados através de três algoritmos bio-inspirados: um algoritmo genético e duas propostas de algoritmos imunológicos, uma baseada em pequenas alterações do CLONALG e a *opt-aiNet*. Os resultados indicam a validade do uso de meta-heurísticas bio-inspiradas e estruturas recorrentes.

1 INTRODUÇÃO

O desenvolvimento industrial e o acesso ao fornecimento de energia por uma parcela maior da população em um país levam à necessidade de geração de energia elétrica em maior escala. No Brasil, isto se dá predominantemente através de usinas hidrelétricas, fazendo com que os recursos hídricos sejam essenciais. Dessa forma, torna-se importante conceber metodologias para previsão das vazões afluentes destas usinas. Estas vazões são entendidas como volume de água que transpassa as turbinas geradoras, o que tem uma relação direta com a quantidade de energia elétrica que pode ser gerada. Assim, elas são mensuradas e sua média mensal forma uma série temporal sazonal, cujos valores futuros podem ser estimados por várias metodologias.

Apesar de haver diversos métodos de previsão, os modelos empregados no setor elétrico baseiam-se geralmente nos métodos de Box & Jenkins (Box et al., 1994). Isso permite que a análise e a síntese das estruturas de previsão sejam, em certa medida, matematicamente mais tratáveis do que mapeadores não-lineares.

Os preditores lineares basicamente podem ser alocados em duas categorias: os de resposta ao impulso finita – FIR –, que não possuem laços de realimentação, e os de resposta ao impulso infinita – IIR – que fazem intrinsecamente uso da realimentação de alguma informação de saída. No primeiro caso se encontra o modelo auto-regressivo (AR), que, pela sua concepção, pode ter seus coeficientes calculados através de fórmula fechada, as chamadas equações de Yule-Walker ou Wiener-Hopf (Haykin, 1997). No segundo caso estão os modelos auto-regressivos e médias móveis (ARMA) e os filtros lineares realimentados, que utilizam outras informações estatísticas além das entradas atuais do modelo, o que pode ser benéfico para a previsão. Tal benefício, no entanto, vincula-se a algumas dificuldades no que se refere à obtenção dos coeficientes ótimos (Shynk, 1989): **1**) a impossibilidade de obter soluções fechadas de modo direto; **2**) a existência de dificuldades na obtenção das derivadas de uma função custo baseada em uma medida de erro quadrático médio; **3**) o caráter potencialmente multimodal da função de erro quadrático médio; **4**) a possibilidade de que, num processo iterativo de escolha de parâmetros, alcance-se uma configuração instável, o que inviabilizaria a convergência do método.

Todavia, tais dificuldades podem ser minimizadas com a utilização de técnicas de otimização que possuam potencial de busca global e que não necessitem de manipulações da função custo do erro quadrático médio. Meta-heurísticas populacionais costumam ser robustas ao aparecimento de más soluções, podendo ser candidatas para essa tarefa. Tendo isso em vista, este trabalho propõe o uso de ferramentas bio-inspiradas de otimização bastante bem-estabelecidas no âmbito da literatura da área: algoritmos genéticos (Holland, 1992), sistemas imunológicos artificiais (Castro e Von Zuben, 2002) e a opt-aiNet (Castro e Timmis, 2002b). A seguir, será discutido o problema e a aplicabilidade de técnicas para sua solução.

2 DESCRIÇÃO DO PROBLEMA

O problema de previsão de vazões é estocástico e não-linear, devido às características destas, que dependem de chuvas e climas muito variados para sua formação. Isto se mostra de maneira clara pelo fato de o sistema elétrico brasileiro ser construído em regiões geográficas distribuídas pela extensão continental do país. Assim, as redes de aquisição de dados são

muito distintas e largamente espaçadas, o que leva a uma considerável incerteza na informação hidrológica disponível. Isto traz entraves à obtenção e construção de modelos de previsão.

Apesar das dificuldades, não é possível fazer um planejamento adequado da necessidade de energia, baseado na demanda imediata e de médio e longo prazos, sem que se saiba a disponibilidade dela em um certo intervalo de tempo futuro. Por isso, a previsão de vazões torna-se um problema essencial no caso brasileiro, já que com essa informação (mesmo que estimada) é possível que se tome uma série de decisões sobre o crescimento do fornecimento de energia elétrica, e necessidade e velocidade de ampliação do parque gerador. Observa-se que cerca de 80% da energia elétrica gerada no Brasil é proveniente de usinas hidrelétricas.

Por conta disso, este trabalho se propõe a explorar algumas técnicas de previsão de séries temporais, mas com uma abordagem ainda pouco usual ao problema em questão: os modelos ARMA e filtros lineares realimentados, com seus coeficientes calculados via algoritmos populacionais bio-inspirados. Tais algoritmos estão estabelecidos na literatura como eficientes técnicas de otimização e, pela potencialidade de haver mínimos locais na função a ser minimizadas, são candidatos relevantes que devem ser explorados neste contexto.

Em todos os cenários de estudo, os métodos de previsão linear serão aplicados ao modelamento da série de vazões médias mensais do posto de FURNAS em dois períodos distintos, um problema bastante abordado em investigações na área.

Este artigo está organizado da seguinte maneira: na Seção 3, serão abordadas as metodologias de previsão lineares; a Seção 4, por sua vez, descreve a ferramentas de busca dos parâmetros do filtro: os algoritmos genético e imunológico e a opt-aiNet. A Seção 5 discute as séries de vazões médias mensais, os resultados computacionais obtidos e sua análise, enquanto a Seção 6 apresenta as conclusões.

3 PREVISÃO LINEAR

A previsão de séries temporais estacionárias é um importante campo de pesquisa tanto para a área de estatística quanto para a de processamento de sinais. Este processo se dá por meio da combinação ou mapeamento de valores observados da série para que seja estimado o seu valor P passos à frente. Para tal, é necessário escolher adequadamente um modelo e fazer o ajuste de seus parâmetros livres. Uma estratégia bastante usual é ajustar os parâmetros de um modelo linear por meio de um critério de mínimo erro quadrático médio (Haykin, 1997). Sendo assim, o erro de previsão pode ser definido pela equação 1:

$$e(n) = x(n+P) - \hat{x}(n+P) \quad (1)$$

sendo $x(n+P)$ o valor da série no instante $n+P$ e $\hat{x}(n+P)$ o valor fornecido pelo modelo tendo por base o valor $x(n)$ e, eventualmente, valores anteriores da série. No caso de um modelo linear genérico, vale a expressão 2 (Oppenheim et al., 1996):

$$\hat{x}(n) = \sum_{k=0}^{\infty} w_k x(n-k) \quad (2)$$

A equação (2) leva à função de transferência genérica do preditor:

$$W(z) = \frac{a_0 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_M z^{-M}}{1 - b_1 z^{-1} - b_2 z^{-2} - \dots - b_R z^{-R}} \quad (3)$$

Os termos a_i são referentes aos coeficientes que ponderam os atrasos da entrada $x(n+P)$, e definem os zeros da referida função. Os termos b_i são as respectivas ponderações de versões atrasadas da saída do preditor $\hat{x}(n+P)$ que definem os pólos de $W(z)$. Quando os termos $b_1 = b_2 = \dots = b_R = 0$, tem-se o caso particular de um filtro com resposta ao impulso finita (FIR) e a função passa a ser composta apenas por zeros, ficando evidente que não há realimentação.

O cálculo destes coeficientes se baseia na busca pela minimização da esperança matemática do erro quadrático de predição, ou seja, o que se procura é o conjunto de parâmetros a_i , $i = 1, \dots, M$ e b_i , $i = 1, \dots, R$ tal que a seguinte função custo J_w seja minimizada

$$J_w = E[e(n)^2] \quad (4)$$

com $E[.]$ sendo o operador de esperança matemática. Esse é o conhecido critério de Wiener de filtragem ótima (Haykin, 1997).

3.1 Filtros FIR: Modelo Auto-Regressivo (AR)

Alguns dos modelos lineares mais utilizados em previsões de séries temporais são os chamados modelos auto-regressivos (AR), os quais podem ser vistos como equivalentes estruturais de um filtro FIR. Sua expressão matemática é apresentada na equação (5):

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + a_t \quad (5)$$

Observe que neste caso, os termos ϕ_i serão correspondentes aos coeficientes a_i da equação (3).

Caso o filtro tenha uma resposta ao impulso finita (como é o caso do modelo AR), é possível calcular analiticamente a solução que minimiza a função custo descrita em (4), dada por:

$$w = \mathbf{R}^{-1} \mathbf{r} \quad (6)$$

sendo

$$\mathbf{R} = \begin{bmatrix} r(0) & r(1) & \dots & r(M-1) \\ r(1) & r(0) & \dots & r(M-2) \\ \dots & \dots & \dots & \dots \\ r(M-1) & r(M-2) & \dots & r(0) \end{bmatrix}$$

a matriz de autocorrelação das entradas do filtro e

$$\mathbf{r} = \begin{bmatrix} r(P) \\ r(P+1) \\ \dots \\ r(P+M) \end{bmatrix}$$

o vetor de correlação cruzada entre as entradas e o sinal desejado (no caso, $x(n)$). Esta é a solução das equações de Yule-Walker, também conhecida como solução de Wiener, que aponta os coeficientes ótimos do modelo. Note que estes são únicos em cada problema, já que a função de erro encontrada é um hiperparabolóide (Box et al., 1994).

Entretanto, para modelos nos quais b_i , $i=1, \dots, R$ não são nulos, não é possível a obtenção de fórmulas fechadas e o cálculo das derivadas não é trivial. Tais modelos são expostos a seguir.

3.2 Filtros IIR: Modelo Auto-Regressivo e Médias Móveis (ARMA) e Filtros Lineares Realimentados

Os modelos auto-regressivos e médias móveis (ARMA) são bastante usuais em análise e previsão de séries temporais, podendo ser entendidos como uma fusão de dois outros modelos, o AR e o MA, ou de médias móveis. A diferença entre o modelo MA e o modelo AR se dá no fato de que, enquanto o último combina valores passados das entradas, o outro agrega choques aleatórios a_t - decorrelacionados e de média zero e variância constante - de forma a gerar o sinal desejado. Um modelo MA de ordem q é expresso da seguinte forma:

$$z_t = -\theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} + a_t \quad (7)$$

sendo θ_i , $i=1, 2, \dots, q$, os parâmetros do modelo.

Neste caso, fazendo um paralelo com os filtros lineares IIR, tem-se um caso de filtro “all-pole”, ou seja, apenas com pólos. No caso MA, diferentemente dos modelos AR, não é direto o processo de otimização dos parâmetros: obrigatoriamente é necessário resolver um sistema de equações não-lineares (Haykin, 1997).

O modelo ARMA é mais geral, como um filtro IIR com zeros e pólos. Matematicamente, um modelo ARMA(p,q) é descrito da seguinte forma:

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} + a_t \quad (8)$$

com ϕ_i e θ_i sendo os parâmetros. Assim, como no caso do modelo MA, para cálculo dos parâmetros, é necessário resolver um sistema de equações não-lineares. Em todo caso, se a escolha destes parâmetros for adequada, pode-se ter um preditor linear ótimo, uma vez que a ordem do mesmo seja a correta. Neste trabalho, os choques a_t serão idealmente os erros na saída do preditor que realimentarão a entrada do modelo.

No mesmo espírito do modelo ARMA, outra possibilidade de filtro com resposta ao impulso infinita que é comumente aplicada ao problema de previsões é a que realimenta a

entrada com filtro com a saída imediatamente anterior do preditor, em vez da utilização o erro de previsão. Neste espírito, a expressão do preditor, que agora será chamado apenas de filtro linear realimentado (ou filtro IIR) será:

$$\hat{z}_t = c_1 z_{t-p} + c_2 z_{t-p-1} + \dots + c_p z_{t-p-p+1} - b_1 \hat{z}_{t-1} - b_2 \hat{z}_{t-2} - \dots - b_q \hat{z}_{t-q} \quad (9)$$

Da mesma forma que os modelos ARMA, este filtro contém zeros e pólos na sua função de transferência, e se pode observar o paralelo com a função de transferência da equação (3).

Na seção seguinte, serão descritos os métodos de otimização utilizados neste trabalho para cálculo dos coeficientes dos modelos realimentados.

4 FERRAMENTAS EVOLUTIVAS DE OTIMIZAÇÃO

4.1 Algoritmos Genéticos

Uma das classes dos algoritmos de otimização baseados na moderna teoria de evolução das espécies são chamados algoritmos genéticos e foram propostos por Holland (1992). Esta técnica se baseia na idéia de que cada solução do problema abordado corresponde a um indivíduo cujo genótipo se relaciona diretamente com os parâmetros livres. O grau de adaptação ao ambiente é dado por uma função de *fitness* que possui uma relação direta com a função a ser otimizada. O processo de interação entre a função de *fitness* e os operadores genéticos faz com que os indivíduos passem por um processo de modificação genotípica que, em termos práticos, leva à exploração do espaço de busca subjacente ao problema tratado.

Segundo Holland (1992), para que este algoritmo possa ser utilizado como uma ferramenta aplicável, alguns aspectos precisam ser considerados:

- definição de uma representação genotípica para as soluções candidatas (codificação);
- uma função de avaliação ou *fitness* que quantifica o grau de adaptação do indivíduo ao ambiente (neste caso a capacidade das soluções candidatas resolverem o problema);
- operadores genéticos responsáveis pela modificação e seleção dos indivíduos;
- determinação de valores para os diversos parâmetros livres do algoritmo (tamanho da população, probabilidades de aplicação dos operadores genéticos etc.).

Em Michalewicz (1996), 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 melhorias 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 um certo número de gerações, o melhor indivíduo tem um valor pseudo-aleatório gaussiano somado ao primeiro gene (neste caso, o primeiro parâmetro do modelo a ser otimizado). 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. Em seguida, o mesmo procedimento é feito para os genes subsequentes. No caso de não haver melhorias na primeira tentativa, o indivíduo tem o valor pseudo-aleatório subtraído do gene e o processo repetido.

No quadro seguinte, é apresentada a estrutura geral do algoritmo (Siqueira, 2009):

Inicialização

- Escolha os parâmetros do algoritmo e inicialize aleatoriamente os (N_{pop}) indivíduos da população.

Processo Iterativo

- Enquanto um número máximo de iterações ou gerações (*gen*) não for atingido, faça:

- 1- Mantenha uma população de potenciais soluções (cromossomos);
- 2- Aplique alterações na população, por meio de *crossover* e mutação, para formar novas soluções potenciais;
- 3- Avalie cada solução e produza uma medida de sua adaptação, ou *fitness*;
- 4- Selecione N_{pop} indivíduos da população total;
- 5- A cada k iterações, aplique o mecanismo de busca local no melhor indivíduo.

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

- a) codificação real, com valores entre -1 e $+1$;
- b) *crossover* de um ponto (Michalewicz, 1996), com formação de uma população intermediária que tem o dobro do tamanho da original e composta por todos os pais e filhos gerados;
- c) mutação gaussiana dinâmica (Queiroz, 2005), com taxa de ocorrência dada por:

$$DMR(\%) = R_{max} \left(1 - \frac{\bar{f} - f'}{\bar{f}} \right), \quad (10)$$

sendo R_{max} o valor máximo permitido de taxa de mutação e \bar{f} e f' os valores médio e máximo de *fitness*, respectivamente;

- d) seleção da população final via algoritmo *roulette wheel* (ou roleta) (Holland, 1992).

Veja que a mutação proposta possibilita que sua taxa oscile de acordo com a variabilidade genética total da população, de modo inversamente proporcional: quanto menor a diversidade, maior a taxa final de mutação. No *crossover*, os pais são selecionados aleatoriamente na população, e todos eles participam do processo de geração dos filhos. Testes também foram realizados com *crossover aritmético* e seleção via *torneio* (Michalewicz, 1996), embora os valores encontrados para o erro quadrático médio tenham sido favoráveis às opções aqui apresentadas.

A medida de custo (ou *fitness*) é definida como:

$$J_{fit} = \frac{1}{(1 + \hat{J}_w)} \quad (11)$$

na qual \hat{J}_w é uma estimativa da função custo de Wiener baseada numa média amostral:

$$EQM(\hat{J}_w) = \frac{1}{N} \sum_{t=1}^N (x(n+P) - \hat{x}(n+P))^2 \quad (12)$$

O mapeamento proposto em (11) transforma o problema de minimização do EQM em maximização, mais adequado na utilização de abordagens evolutivas.

4.2 Sistemas Imunológicos Artificiais

Sistemas imunológicos artificiais (SIA's) são algoritmos de otimização inspirados na forma de ação do mecanismo de defesa dos organismos superiores contra antígenos (de Castro, 2006). Por conta de sua constituição, podem, a nosso ver, ser classificados como algoritmos evolutivos, assim como os AG's. Neste trabalho, o algoritmo utilizado é uma versão modificada do CLONALG (de Castro & Von Zuben, 2002), e será denominado simplesmente algoritmo imunológico (AI). A uma modificação da proposta original se dá no sentido de empregar codificação real.

O processo de otimização deste algoritmo é baseado 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 custo ou função de *fitness*.

Em termos simples, a idéia básica que inspira o algoritmo é o *princípio da seleção clonal* é: 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 (Castro e Timmis, 2002a). Ainda segundo tal princípio, outros mecanismos estão intrinsicamente envolvidos neste processo, como a introdução de novos indivíduos com material novo na população de células de defesa.

O quadro abaixo apresenta o algoritmo imunológico utilizado (Siqueira, 2009):

Inicialização

- Escolha os parâmetros do algoritmo e inicialize aleatoriamente os indivíduos da população.

Processo Iterativo

- Enquanto um número máximo de iterações ou gerações (*gen*) não for atingido, faça:

1- Calcule o custo (*fitness*) de todos os indivíduos da população.

A cada N_{it} iterações, inclua N_{ind} soluções geradas aleatoriamente no lugar dos N_{ind} indivíduos com menor *fitness*.

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:

$$c' = c + \alpha N(0,1)$$

$$\alpha = (1/\beta) \exp(-f),$$

sendo β um parâmetro regulador da amplitude de mutação e f o valor de *fitness* 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.

Tal como o algoritmo genético da seção 3.1, esta técnica possui mecanismos de busca local, baseados no binômio clonagem/mutação, e potencial de busca global com a inserção periódica de novos indivíduos. A codificação utilizada foi a real, idêntica à do AG da seção 3.1. A medida de *fitness* e a função custo são as mesmas apresentadas nas equações (11) e

(12), com o mapeamento de (11) transformando o processo de otimização como sendo de maximização.

4.3 Opt-aiNet

A *opt-aiNet* (*Artificial Immune Network for Optimization*) faz parte da família de algoritmos *aiNet* e foi proposta por de Castro e Von Zuben (2001). Este algoritmo foi concebido para resolução de problemas que vão desde clusterização e agrupamento até otimização combinatória. Trata-se também de um algoritmo imunológico baseado em seleção clonal, mas com uma diferença significativa em relação à versão modificada do CLONALG da seção 3.2: um mecanismo de controle automático do tamanho da população, que procura reduzir a redundância na informação contida na população, por meio da inserção de novos indivíduos aleatoriamente gerados, que se baseia na teoria da “rede imunológica”. Afora isto, os processos e princípios são semelhantes nos dois algoritmos.

O processo de eliminação de redundância e inserção de diversidade é simples: quando o *fitness* médio da população não tem significativa alteração entre um número determinado de iterações, observa-se que a população se estagnou, possuindo baixa diversidade. Assim, por alguma medida de distância – euclidiana, por exemplo - 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 a diversidade se eleve.

Desta forma, a *opt-aiNet* mostra um promissor equilíbrio entre busca local e global. Sua estrutura geral é apresentada no quadro seguinte (Siqueira, 2009):

Inicialização

- Escolha os parâmetros do algoritmo e inicialize aleatoriamente os indivíduos da população.

Processo Iterativo

- Enquanto um número máximo de iterações ou gerações (*gen*) não for atingido, faça:

1. Calcule o custo (*fitness*) de todos os indivíduos da população.
2. A cada N_{it} iterações, inclua N_{ind} soluções geradas aleatoriamente no lugar dos N_{ind} indivíduos com menor *fitness*.
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:

$$c' = c + \alpha N(0,1)$$

$$\alpha = (1/\beta) \exp(-f),$$
 sendo β um parâmetro regulador da amplitude de mutação e f o valor de *fitness* 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 *fitness* 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 *fitness*;
8. Verifique o tamanho da população;
9. Introduza novos indivíduos gerados aleatoriamente, proporcionalmente à população atual. original, mantenha apenas a melhor solução.

5 ESTUDOS DE CASOS

5.1 Séries de Vazões e Pré-Processamento

Séries temporais, em muitos casos práticos, possuem componentes sazonais ou tendências, mostrando um comportamento não-estacionário. Séries de vazões médias mensais, as quais serão objeto do nosso estudo, são tipicamente não-estacionárias e com uma forte componente sazonal, que é reflexo dos períodos de seca e de chuvas nas proximidades dos rios do país.

Entretanto, pode-se buscar excluir tais componentes do processo de previsão através de um tratamento estatístico, e, após isto, elas são reinseridas na resposta final do preditor. A metodologia aqui utilizada, doravante denominada padronização, é baseada na proposta de Ballini (2000), na qual as observações $x(n)$ que formam a série original são transformadas em uma nova série $z(n)$, pela equação (13):

$$z(n) = \frac{x(n) - \mu(n)}{\sigma(n)} \quad (13)$$

onde $\mu(n)$ é a média de cada mês e $\sigma(n)$ o desvio padrão respectivo. A nova série $z(n)$ tem média $\mu(n)$ igual a zero e desvio padrão $\sigma(n)$ unitário. Estes valores são calculados através de estimativas baseadas nas suas médias amostrais (Box et al., 1994):

$$\mu(n) = \frac{1}{N} \sum_{t=1}^N x(n) \quad (14)$$

$$\sigma(n) = \sqrt{\frac{1}{N} \sum_{t=1}^N (x(n) - \mu(n))^2} \quad (15)$$

Assim sendo, as metodologias de previsão serão aplicadas à série $z(n)$, ou à série padronizada que é estacionária, dividida em dois subconjuntos: treinamento e teste. Como dito, ao final deste processo, a componente sazonal é reinserida para uma análise geral do erro quadrático médio.

5.2 Resultados computacionais

Os testes computacionais realizados neste trabalho foram baseados 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 sítio da ELETROBRÁS (www.eletrobras.gov.br), que apresenta tais vazões desde 1931. Os períodos escolhidos foram: de 1972 a 1976, com o período de treinamento compreendido nos 5 anos imediatamente anteriores, ou seja, de 1967 a 1971, tendo média 882,63 m³/s; e de 1952 a 1956, com conjunto de treinamento entre 1947 e 1951, com média 656,41 m³/s. Estes períodos são bastante usuais em estudos deste tipo, pois compreendem um período mediano de chuvas e outro seco, o que contribui para uma análise de desempenho mais confiável, com cenários distintos, do ponto de vista do preditor.

De início, fez-se a padronização das séries, conforme descrito na seção 5.1. De posse dos dados de treinamento, passou-se à fase de otimização da função custo de Wiener, ou busca pelos melhores coeficientes para ajuste dos modelos ARMA e o filtro linear realimentado pelo uso das técnicas bio-inspiradas da seção 3: algoritmos genético, imunológico e a *opt-aiNet*, com duas entradas e uma realimentação. A população dos 3 algoritmos foi de 20 indivíduos, com 40 deles na população intermediária, sendo cada um composto por 3 coeficientes. A opção por dois coeficientes *forward* e um pólo se deu mediante testes computacionais preliminares e pela necessidade de uma análise direta da inserção da realimentação.

Os cenários abordados para previsão foram com $P = 1$ passo à frente. Paralelamente a isso, os coeficientes do modelo auto-regressivo (ou filtro FIR – sem pólos) foram calculados via equações de Yule-Walker, com duas entradas. Com isso é possível uma análise comparativa da inserção da realimentação na estrutura do previsor.

A seguir, nas tabelas 1 e 2 respectivamente são apresentados os modelos e os respectivos algoritmos de busca, para as séries FURNAS 1972/76 e 1952/56 tanto real como padronizada, nos conjuntos de treinamento e teste:

Método	EQM real ($\times 10^4$) – trein.	EQM padro. – trein.	EQM real ($\times 10^4$) - teste	EQM padro. - teste
AR(2)	3.8872	0.3421	4.3972	0.3878
IIR – Genético	3.6997	0.3384	4.5737	0.4060
IIR–Imunológico	3.6983	0.3384	4.5750	0.4061
IIR – Opt-aiNet	3.6979	0.3384	4.5747	0.4060
ARMA – Gen.	3.4895	0.3261	4.1907	0.3915
ARMA – Imuno	3.4910	0.3261	4.1905	0.3917
ARMA– Opt-aiNet	3.4909	0.3261	4.1910	0.3916

Tabela 1 – Erro quadrático médio e melhores desempenhos de previsão para série FURNAS 1972/1976

Método	EQM real ($\times 10^4$) – trein.	EQM padro. – trein.	EQM real ($\times 10^4$) - teste	EQM padro. - teste
AR(2)	10.614	0.3775	5.2964	0.3084
IIR – Genético	10.676	0.3735	5.2630	0.3047
IIR–Imunológico	10.503	0.3636	5.2626	0.3078
IIR – Opt-aiNet	10.540	0.3710	5.3849	0.3094
ARMA – Gen.	7.2178	0.3375	4.2140	0.2864
ARMA – Imuno	7.2166	0.3375	4.2113	0.2864
ARMA– Opt-aiNet	7.2290	0.3376	4.0763	0.2834

Tabela 2 – Erro quadrático médio e melhores desempenhos de previsão para série FURNAS 1952/1956

Os resultados sumarizados nas tabelas 1 e 2 são médias de 10 simulações. Tais resultados permitem algumas importantes observações:

- 1) a inserção da realimentação leva diretamente à queda do erro quadrático médio de treinamento em praticamente todos os casos, com destaque para o modelo ARMA;
- 2) nas amostras de teste, o modelo ARMA apresenta resultados significativamente melhores dos demais, tanto para a série real quanto padronizada, com exceção da série padronizada de 72/76 de testes. O filtro IIR, apesar de ter um EQM menor no treinamento, teve

resultados inferiores ao modelo AR na série 72/76 e valores de EQM semelhantes na série 52/56;

- 3) os algoritmos de otimização foram capazes de realizar uma busca pelos mínimos das estruturas de previsão, tendo em vista a pequena variância nos resultados individuais das 10 simulações para cada caso e, para cada metodologia – ARMA e filtro IIR – os resultados foram muito próximos. Assim, pode-se dizer que os três têm o potencial de ser igualmente eficientes, sendo que se abre a perspectiva de que outras meta-heurísticas populacionais não testadas aqui possam ser utilizadas;
- 4) pela proximidade nos valores de EQM de treinamento – sobretudo padronizado –, não é possível afirmar categoricamente que o modelo ARMA seja superior ao filtro IIR, devendo ser as pequenas discrepâncias no contexto padronizado devidas ao desempenho dos algoritmos de otimização.
- 5) nem sempre se constata a proporcionalidade no EQM de treinamento e teste quando se passa da série real para a padronizada. Isto parece ser reflexo direto da metodologia adotada para deixar a série estacionária, ou seja, a padronização. Assim, abrem-se perspectivas para a ponderação de regiões mais importantes da série no momento da otimização, ou seja, os trechos em que uma maior redução na distância das curvas real e prevista pode reduzir também o EQM final.

Este trabalho foi concebido com um período de treinamento reduzido, composto por poucas amostras, o que não é usual e mostra que, em casos de difícil previsão, as metodologias propostas podem contribuir de forma significativa. Além disso, não foram abordadas previsões com mais de 1 passo à frente, ainda mais difíceis de serem realizadas, mas que podem ser tratáveis com esta metodologia.

Nas figuras 1 a 6 são apresentados os gráficos das séries de vazões reais e padronizadas, juntamente com os melhores resultados obtidos para cada método de previsão contido nas tabelas 1 e 2.

-Série FURNAS 1972 a 1976 (real e padronizada)

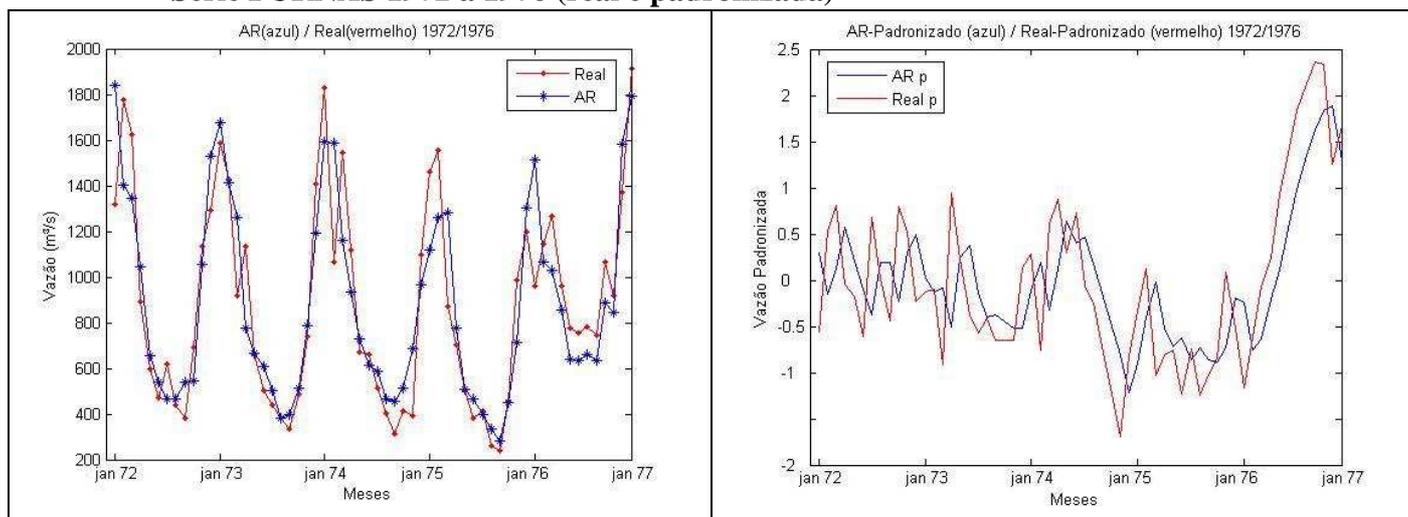


Figura 1 – Resultados da previsão para série FURNAS 1972/1976 - modelo AR

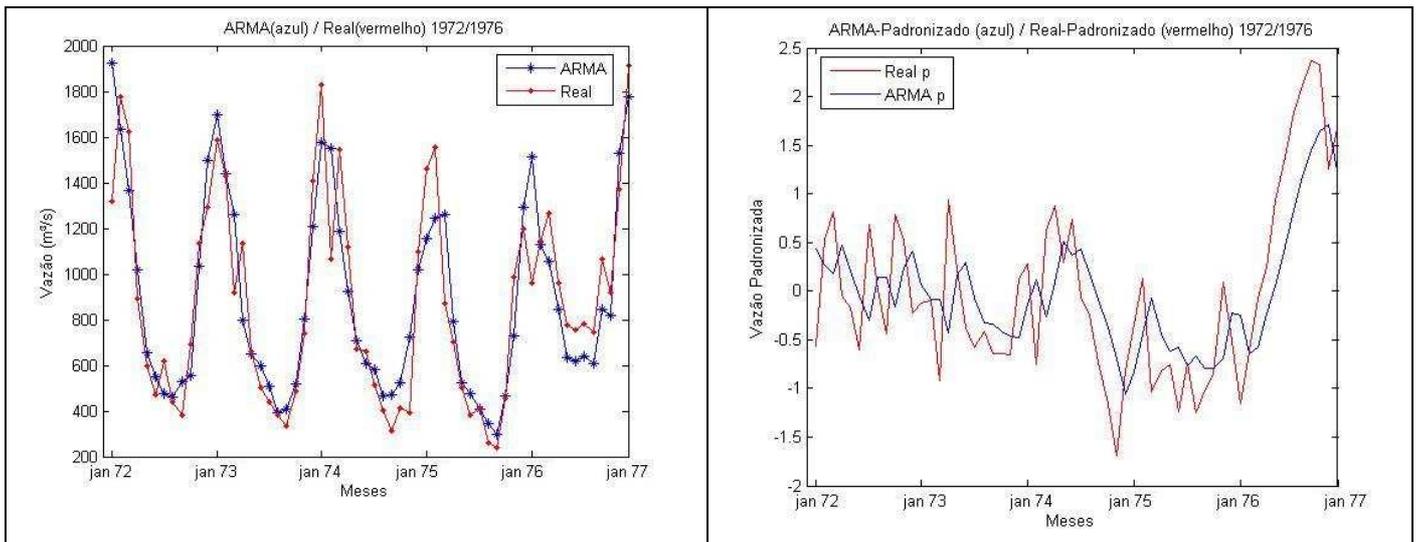


Figura 2 – Resultados da previsão para série FURNAS 1972/1976 - Modelo ARMA

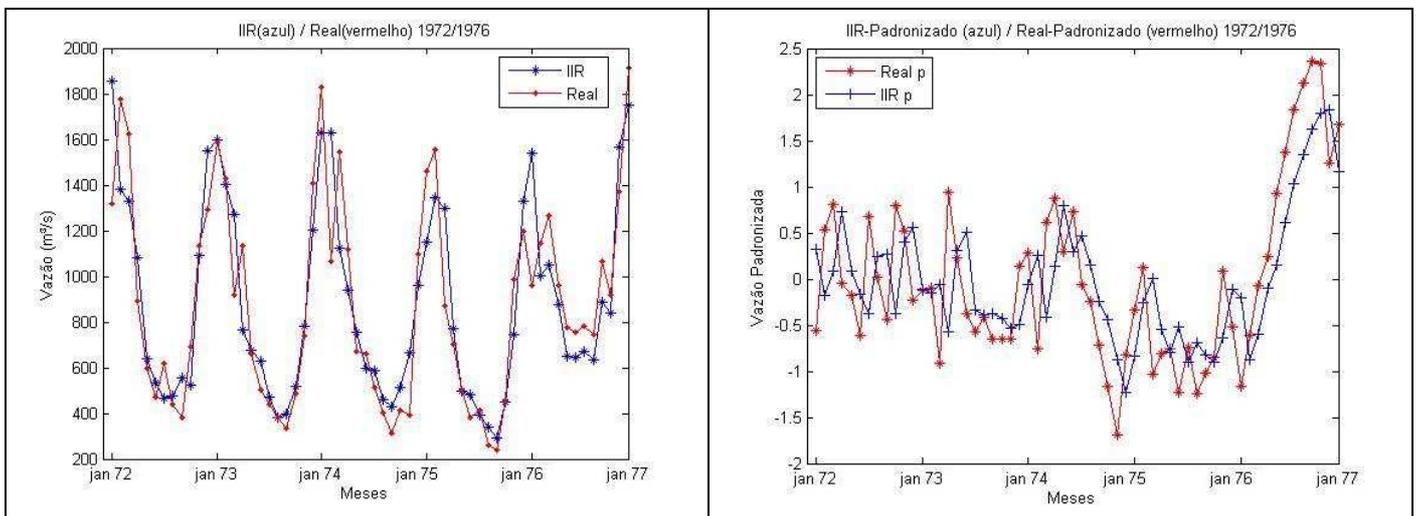


Figura 3 – Resultados da previsão para série FURNAS 1972/1976 - Filtro IIR

-Série FURNAS 1952 a 1956 (real e padronizada)

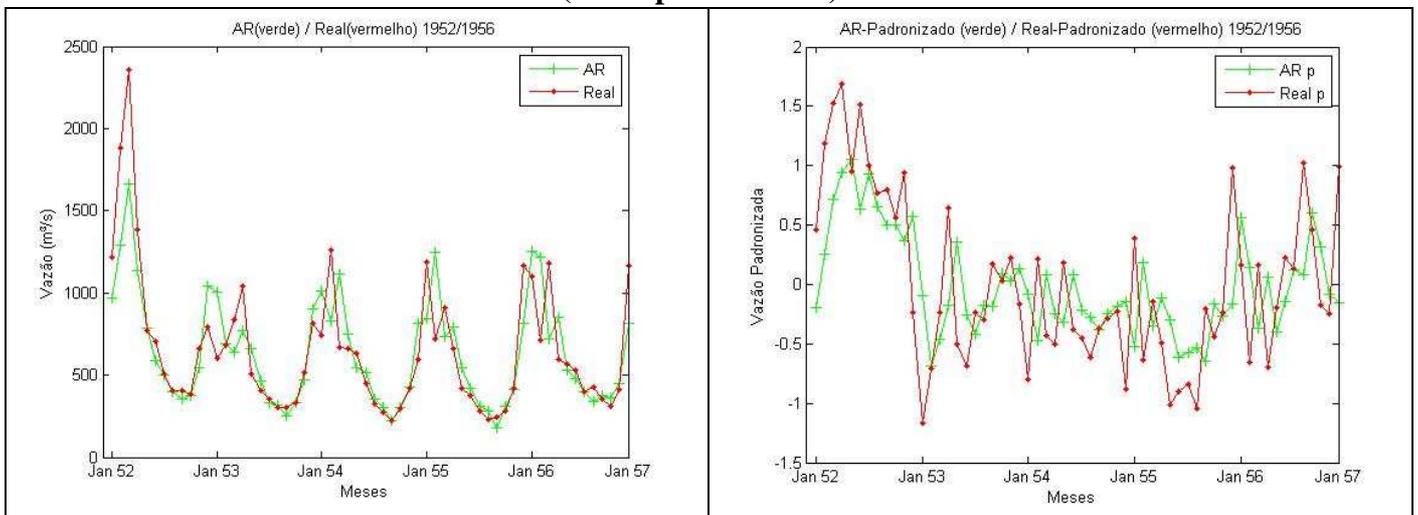


Figura 4 – Resultados da previsão para série FURNAS 1952/1956 - modelo AR

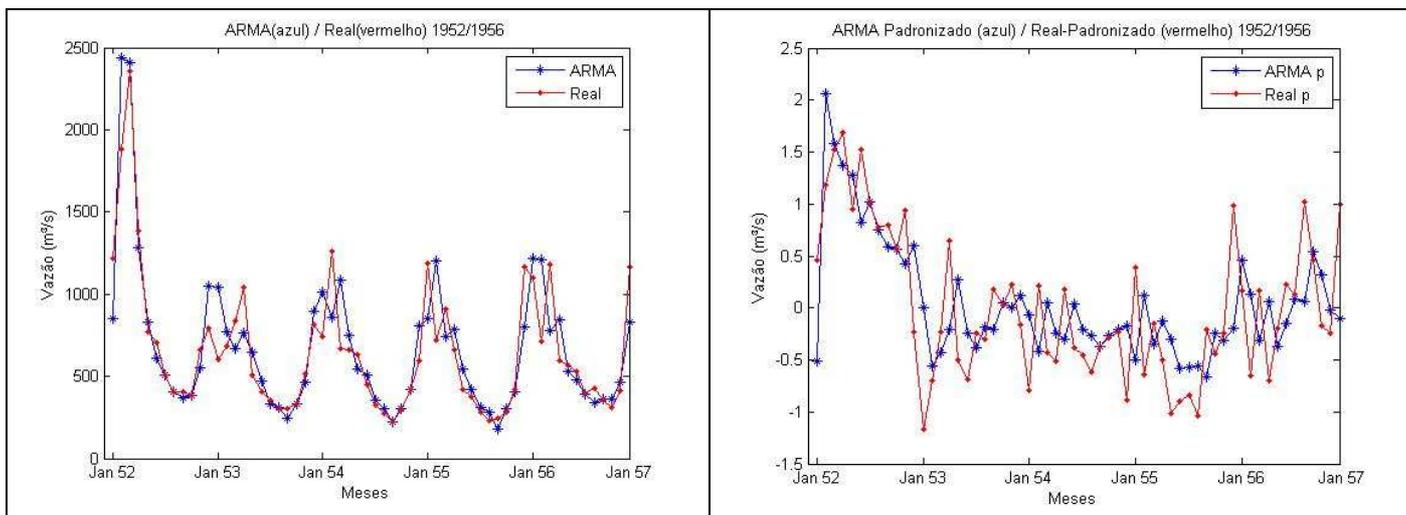


Figura 5 – Resultados da previsão para série FURNAS 1952/1956 - Modelo ARMA

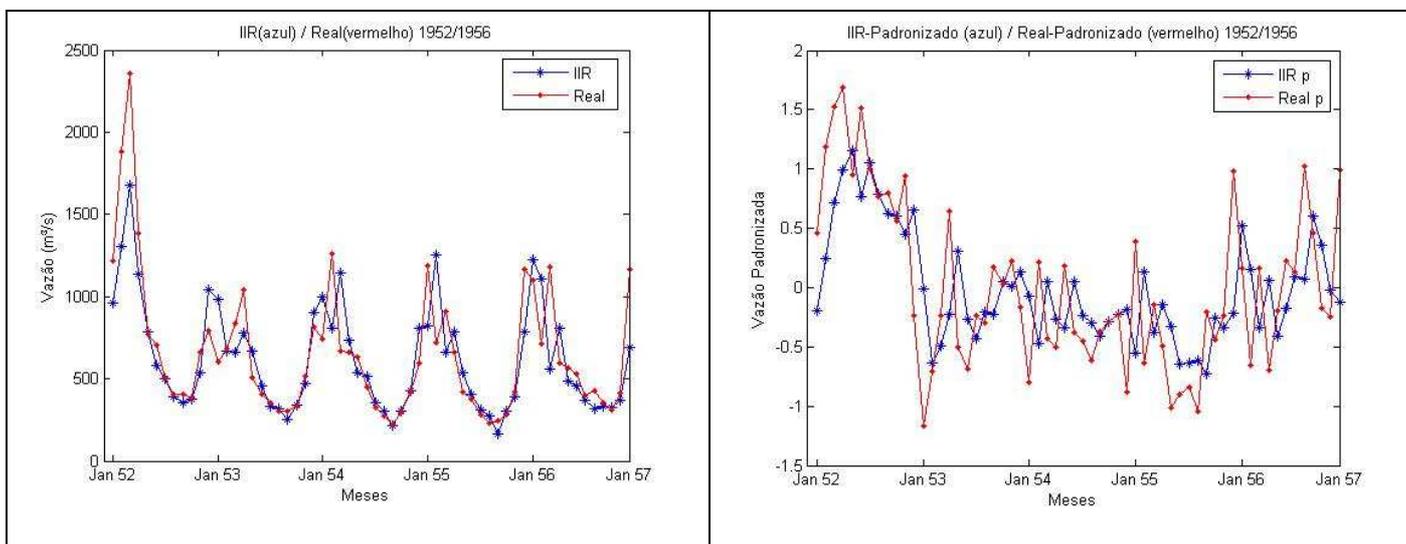


Figura 6 – Resultados da previsão para série FURNAS 1952/1956 - Filtro IIR

6 CONCLUSÕES

O problema de previsões de séries de vazões é de extrema importância para a geração de energia elétrica no Brasil, já que 80% dela é feita em usinas hidrelétricas. A metodologia utilizada no setor elétrico é linear e bem sedimentada na literatura, mas outras perspectivas podem ser utilizadas para tal fim, com possibilidades de melhores desempenhos.

Neste intuito, foram propostos dois modelos lineares gerais com realimentação – o ARMA e um filtro linear realimentado - para previsão de vazões médias mensais da usina hidrelétrica de FURNAS, entre os anos 1972 e 1976 e de 1952 a 1956, com os 5 anos anteriores a cada série como o período de treinamento. Para cálculo dos coeficientes destes modelos, três propostas de algoritmos de otimização bio-inspirados foram aplicadas: algoritmo genético, sistemas imunológicos artificiais (uma alternativa ao algoritmo CLONALG) e a opt-aiNet. O desempenho geral dos modelos de previsão foi comparado a uma abordagem auto-regressiva (AR) – sem realimentação.

O desempenho dos preditores realimentados mostrou que abordagens desse tipo podem trazer ganhos de desempenho importantes. É possível concluir que a memória intrínseca ao modelo deve captar o comportamento estocástico da série estacionária com maior competência. Entretanto, faz-se necessária a utilização de algum método de padronização que permita que melhores previsões no espaço padronizado sejam respeitadas no espaço real. Além disso, previsões com mais passos à frente são de grande interesse e as técnicas aqui estudadas abrem boas perspectivas nessa linha, já este outro problema é de mais difícil solução.

As técnicas de busca aplicadas também se mostraram relevantes para uma maior exploração das possibilidades dos modelos lineares de previsão realimentados, tendo apresentado potencial de otimização similar. Vale lembrar que o conjunto de treinamento é pequeno e isto torna a previsão mais desafiadora. Testes com um conjunto que tenha mais amostras podem elevar ainda mais o desempenho dos preditores. Além disso, existem outras possibilidades que podem ser exploradas, como a utilização de técnicas de *niching* ou seleções de indivíduos utilizando *rank* para o caso dos algoritmos genéticos, ou mesmo a exploração de outras meta-heurísticas populacionais para otimização dos coeficientes dos modelos.

Finalmente, observa-se que outras perspectivas podem ser (e vêm sendo) adotadas neste problema, como a introdução de técnicas não-lineares de previsão. Entretanto, este trabalho mostra que a previsão linear ainda pode ser explorada e, devido a seu custo computacional reduzido e simplicidade de implementação, é uma alternativa competitiva.

REFERÊNCIAS

- Attux, R. R. F., de Castro, L. N., Von Zuben, F. J., Romano, J. M. T. (2003), “*A Paradigm for Blind IIR Equalization Using the Constant Modulus Criterion and an Artificial Immune Network*”, IEEE International Workshop on Neural Networks for Signal Processing, Toulouse, França.
- Ballini, R. (2000), “*Análise e previsão de vazões utilizando séries temporais, redes neurais e redes neurais nebulosa*”, Tese de Doutorado, FEEC-Unicamp, Brasil.
- Box, G., Jenkins, G. e Reinsel, G. C. (1994), “*Time Series Analysis, Forecasting and Control*”, 3rd edn, Holden Day, Oakland, California, EUA.
- de Castro, L. N. (2006), “*Fundamentals of natural computing: basic concepts, algorithms and applications*”. Chapman & Hall.
- de Castro, L. N., & Von Zuben, F. J. (2001), “*aiNet: An artificial immune network for data analysis*.” In: H. A. Abbass, R. A. Sarker, & C. S. Newton (Eds.): *Data Mining: A Heuristic Approach*, (pp. 231–259). USA: Idea Group Publishing.
- de Castro, L. N and Von Zuben, F. J. (2002), “*Learning and Optimization Using the Clonal Selection Principle*”, IEEE Transactions on Evolutionary Computation, Vol. 6, No. 3, pp. 239-251.

- de Castro, L. N. and Timmis, J. (2002a), “*Artificial immune systems: a new computational intelligence approach*”. Springer.
- de Castro, L. N. and Timmis, J. (2002b), “*An Artificial Immune Network for Multimodal Function Optimization*”, IEEE Congress on Evolutionary Computation, Honolulu, EUA.
- de Castro, L. N. (2006), “*Fundamentals of Natural Computing: Basic Concepts, Algorithms and Application*” Chapman & May.
- Haykin, S. (1997), “*Adaptive Filter Theory*”. Prentice Hall.
- Holland, J. H. (1992), “*Adaptation in Natural and Artificial Systems*”, MIT Press.
- Michalewicz, Z. (1996), “*Genetic Algorithms + Data Structures = Evolution Programs*”, Springer;
- Oppenheim, A. V., Willsky, A. S. and Nawab, S. H. (1996). “*Signals and Systems*”, Prentice Hall.
- Queiroz, L. M. O. (2005), “*Algoritmos Genéticos Híbridos para Redução de Perdas Técnicas em Redes Primárias de Distribuição Considerando Variações de Demandas*”. Dissertação de Mestrado, FEEC-Unicamp, Brasil.
- Shynk, J. J. (1989), “Adaptive IIR Filtering”, *IEEE ASSP Magazine*, Vol. 6, No. 2, pp. 4-21.
- Siqueira, H. V., Wada, C., Attux, R. R. F., Lyra Filho, C. (2008a), “*Previsão de Vazões com Estruturas Lineares Gerais Ajustadas por um Algoritmo Imunológico*”, XVII Congresso Brasileiro de Automática (CBA), Juiz de Fora, Brasil.
- Siqueira, H. V., Attux, R. R. F., Lyra Filho, C. (2008b), “*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.
- Siqueira, H. V. (2009), “*Previsão de Séries de Vazões com Redes Neurais Artificiais e Modelos Lineares Ajustados por Algoritmos Bio-Inspirados*” – Dissertação de Mestrado, FEEC-UNICAMP, Brasil;