

Modelagem Chuva-vazão utilizando Redes Neurais Artificiais e Algoritmos Genéticos

Felippe Alex Scheidt¹, Maria Angelica de Camargo Brunetto²

^{1,2} Departamento de Computação – Universidade Estadual de Londrina (UEL)
Londrina – PR – Brasil

felippescheidt@gmail.com, angelica@uel.br

Abstract. *In this article it is proposed a methodology for modeling the rainfall-runoff relationship of a specific watershed, through artificial neural networks (ANN) and genetic algorithm. This model was developed in Piquiri river watershed, located at the state of Paraná, Brazil. For comparative purposes, two approaches were developed on the model: a methodology that uses only a MLP ANN and another that uses a MLP ANN with genetic algorithms. As results, the hybrid model fitted better than ANN at representing the rainfall-runoff transformation process.*

Resumo. *Este artigo apresenta uma metodologia para modelagem da relação de transformação chuva-vazão de uma bacia hidrográfica utilizando redes neurais artificiais (RNA) acopladas a um algoritmo genético (AG). Esta modelagem foi desenvolvida na bacia hidrográfica do rio Piquiri, localizada no estado do Paraná, Brasil. Para efeitos comparativos, foram desenvolvidas duas abordagens na modelagem: uma metodologia utilizando apenas uma RNA tipo MLP e outra usando uma RNA MLP com algoritmos genéticos. Observou-se que o modelo híbrido obteve melhor representação do processo de transformação chuva-vazão.*

1. Introdução

O processo de transformação chuva-vazão é um dos mais complexos fenômenos hidrológicos que ocorrem em uma bacia hidrográfica, devido a grande variação temporal e espacial dos diversos elementos do ciclo hidrológico [Sedki 2009]. Dentre tais elementos, podem ser citados precipitação, evapotranspiração e infiltração, e esta diversidade de variáveis pode aumentar a complexidade da definição de um modelo físico que descreva corretamente esse processo.

Modelos chuva-vazão descrevem a relação entre a chuva e a vazão de uma bacia hidrográfica, quantificando a transformação da chuva em vazão de um curso de água. Esta relação é descrita através de um hidrograma, que mostra a variação da vazão do curso de água no tempo, em um determinado ponto de interesse da bacia. Portanto, tem diversas finalidades práticas para a previsão de cheias, da recarga de reservatórios, da disponibilidade de água para abastecimento urbano ou irrigação, dentre outras.

O objetivo deste trabalho é testar o uso das redes neurais artificiais e algoritmos genéticos para a modelagem hidrológica da transformação chuva-vazão em um ponto intermediário da bacia do Rio Piquiri, localizada no estado do Paraná (Brasil), e cuja foz

encontra-se junto ao rio Paraná. A motivação desta pesquisa foi a construção de método de modelagem que possibilitasse trabalhar com um número reduzido de variáveis hidrometeorológicas para a representação do processo chuva-vazão. Este trabalho está organizado nas seguintes seções: a seção 2 apresenta pesquisas relacionadas à modelagem chuva-vazão; a seção 3 expõe os conceitos de redes neurais artificiais, algoritmos genéticos e modelos híbridos; a seção 4 detalha o estudo de caso, a seleção dos dados para processamento, o treinamento da RNA e a definição do algoritmo genético utilizado; a seção 5 apresenta os resultados obtidos com os modelos propostos.

2. Trabalhos Relacionados

Campolo et. al.(1999) utilizam uma rede neural para analisar e prever o comportamento do rio Tagliamento na Itália, durante períodos de fortes chuvas. O modelo proposto faz uso de diversas estações de pluviometria levando em consideração sua distribuição espacial. A área de drenagem da bacia tem um total de 1950km² incluindo diversas sub-bacias. No estudo, foram propostos dois modelos de previsão do nível de água: o primeiro modelo para curtos períodos de tempo (1 hora); o segundo modelo para tempos longos acima de 10 horas.

Em outro estudo proposto por [Nasseri 2008], foi aplicado RNAs para a previsão de precipitação na bacia de Upper Parramatta localizada em Sydney, Austrália, com área aproximada de 112km². Os autores relatam a problemática e o consumo de tempo para encontrar e selecionar uma arquitetura de rede neural adequada. Para contornar tal questão, os autores propõem a utilização de algoritmos genéticos acoplado a uma rede neural tipo MLP para melhorar o desempenho da rede durante a fase de treinamento. O uso de algoritmos genéticos é voltado nesse trabalho para determinar os pesos correspondentes das conexões entre cada neurônio artificial. Essa mesma metodologia é também investigada em [Sedki 2009] numa bacia localizada no Marrocos.

Outro estudo de caso foi conduzido por [Tokar 1999] que aplicam redes neurais para realizar previsões de vazão diária como uma função da precipitação, da temperatura e do derretimento da neve medidos diariamente, na bacia do rio Little Patuxent em Maryland, Estados Unidos. A RNA é comparada a técnicas de regressão estatística e com o modelo SCRR (*simple conceptual rainfall-runoff*), proposto com McCuen e Snyder. Concluem ao final que o modelo obtido com a RNA mostrou resultados mais sistemáticos, com necessidade de menos dados para calibração e melhor previsão.

Em relação aos artigos citados acima, esta pesquisa diferencia-se nos seguintes aspectos: são desenvolvidas duas modelagens do processo de transformação chuva-vazão, uma usando apenas redes neurais artificiais (RNA) e outra usando um modelo híbrido no qual é acoplado um algoritmo genético (AG) junto a RNA. A área total de drenagem da bacia hidrográfica do Rio Piquiri, compreende o total de 3620km², uma área consideravelmente maior do que os trabalhos revisados acima. Isso implica numa maior variabilidade espacial e temporal, exercendo maior influência na correlação entre os dados de precipitação e os dados de vazão. Além disso, são propostos 19 modelos de entradas de dados, para identificação de um conjunto adequado de dados de entrada. Em termos hidrológicos, este artigo apresenta uma técnica importante num cenário no qual existem poucas variáveis de monitoramento na bacia hidrográfica. Neste caso, a modelagem é possível a partir da identificação de duas variáveis tipicamente monitoradas: precipitação(P) e vazão(Q). Assim, essa metodologia tem uma

aplicabilidade maior, pois não necessita da especificação de informações adicionais sobre a bacia hidrográfica.

3. Fundamentação Teórica

A seguir são apresentados as abordagens conceituais de redes neurais artificiais, algoritmos genéticos e modelos híbridos utilizados neste trabalho.

3.1. Redes Neurais Artificiais

O diferencial da modelagem de sistemas usando RNAs é que as mesmas são desenvolvidas a partir de um conjunto de dados de entrada, com ou sem supervisão, não sendo portanto, um modelo baseado no processo físico do fenômeno. O mecanismo básico consiste em treinar esta rede com dados reais, ou seja, dados empíricos com amostras ou exemplos de padrões de entrada-saída para construir uma relação não-linear entre os exemplos e, a partir disso, criar um modelo que permita realizar previsões.

Redes neurais podem ser definidas como estruturas que contém diversas unidades de processamento (também conhecidas como neurônios artificiais) densamente interconectadas sendo capaz de desempenhar grande quantidade de processamento de dados em computação paralela e representação de conhecimento [Basheer 2000]. RNAs também são conhecidas como aproximadores universais de funções já tendo sido demonstrado que são capazes de aproximar qualquer função contínua em qualquer nível de precisão [Cybenko 1989].

3.2. Algoritmos genéticos

Algoritmo genético (AG) é uma estratégia de busca global em um espaço de estados não-linear, no qual soluções iterativas não são adequadas. De acordo com a teoria da seleção natural, na qual apenas os indivíduos mais aptos sobrevivem e geram descendentes, os algoritmos genéticos buscam simular em nível computacional o mesmo efeito através da codificação de possíveis soluções de um problema, numa população de indivíduos.

Esses indivíduos são representados por cromossomos e genes. Inicialmente, cada cromossomo é inicializado com um conjunto aleatório de genes (pesos). Esta solução (cromossomo) é avaliada por uma função de aptidão que verifica a qualidade da solução proposta. Se o cromossomo possui uma boa aptidão ele terá uma probabilidade maior de manter-se na população e gerar descendentes cada vez mais aptos [Rezende 2005].

3.3. Modelos híbridos

Em redes MLP (*Multilayer perceptron*) o algoritmo de aprendizagem *backpropagation* (BP) remete a minimizar o erro entre a função calculada pela rede e o valor esperado. Existem diversas estratégias para realizar esta minimização [Silva 1998]. Uma delas, utilizadas neste trabalho é o método do gradiente descendente, que comumente é usado no *backpropagation*. Este método pode ficar preso num mínimo local impossibilitando de encontrar o mínimo global. Um modo de superar a limitação dos algoritmos de treinamento baseados no gradiente descendente é usar AG para realizar o treinamento como uma evolução das conexões sinápticas. Assim o AG pode ser utilizado para uma

busca por um conjunto ótimo de pesos globais sem calcular o gradiente descendente, evitando a estagnação precoce do processo de busca num mínimo local.

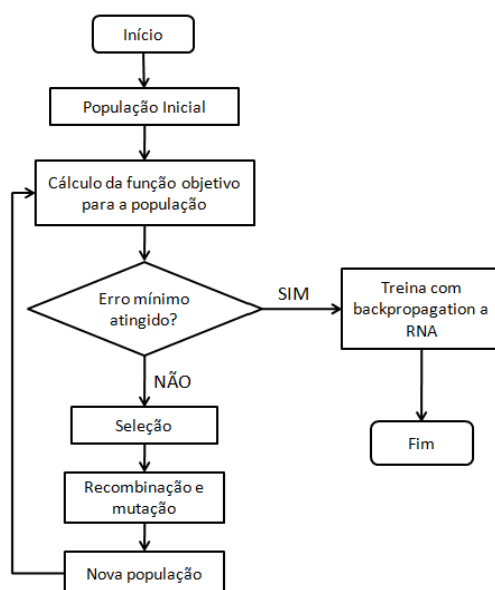


Figura 1 – Rede neural, acoplada a um AG

A abordagem evolucionária de treino de uma RNA consiste nos seguintes passos [Yao 1999]:

1. Codificar cada indivíduo da geração atual, num conjunto de pesos sinápticos e construir a RNA correspondente com os pesos.
2. Avaliar cada RNA usando RMSE (equação 3). A aptidão do indivíduo (cromossomo) é determinada pelo erro. Quanto maior o erro, menor sua aptidão.
3. Selecionar os pais para a recombinação de acordo com suas aptidões.
4. Aplicar operadores de recombinação e mutação gerando descendentes que formarão a próxima população.

A integração dos algoritmos genéticos com as RNAs (Figura 1) é vantajosa no sentido de agregar a capacidade de busca global dos AGs [Back 1997] junto com o algoritmo de treinamento e ajuste de pesos BP. O AG ajuda a superar os mínimos locais efetuando uma busca mais ampla no espaço de estados, pois ele é menos suscetível de ficar estagnado num mínimo local, pois não depende do gradiente, em comparação com os algoritmos baseados no gradiente [Yao 1999]. Após o AG terminar seu processamento, utiliza-se o BP para uma busca local usando o conjunto de pesos pré-ajustados pelo AG.

De acordo com a Figura 1, o primeiro passo do modelo híbrido consiste na formulação de uma população de cromossomos, criados aleatoriamente. Nesse caso, cada gene representa um peso sináptico da RNA. Em seguida, cada cromossomo é avaliado por uma função de aptidão (função RMSE – equação 3). É verificado na população, se algum candidato possui aptidão suficiente de acordo com um erro mínimo desejado. Caso não exista, o ciclo de execução do algoritmo genético será re-iniciado. Para isso, é selecionado cromossomos candidatos que geram novos indivíduos, que por sua vez terão alguns genes alterados de acordo com um percentual de mutação. Em

seguida esses descendentes são alocados na nova população. Esse processo repete-se até que o erro mínimo seja atingido ou um número máximo de iterações seja ultrapassado. Após a finalização do AG, o melhor cromossomo é retirado da população e uma RNA é instanciada, com os pesos equivalentes aos genes desse indivíduo. Essa RNA é passada para o BP que executará um refinamento dos pesos encontrados. Desse modo pode-se entender a fase do AG, como uma etapa de atribuição inicial dos pesos da RNA.

4. Materiais e métodos

A bacia hidrográfica utilizada como estudo de caso foi a bacia do rio Piquiri, sub-bacia da bacia do rio Paraná. O rio Piquiri é um dos principais afluentes da margem esquerda do rio Paraná. Possui 485 quilômetros de extensão aproximada. A bacia hidrográfica do rio Piquiri é a terceira maior em área física do estado do Paraná. Apresenta uma área total de 24.731km².

4.1. Seleção dos Dados para Processamento

Neste trabalho foram utilizadas 5 estações pluviométricas e 1 estação fluviométrica. Cada estação possui uma série histórica em escala diária de medição, com 3103 registros, na qual cada registro representa o total de chuva acumulado no período de 1 dia. No dia 05.10.2008, a vazão apresentou uma máxima de 1991,5 m³/s sendo que no dia 24.07.2006 apresentou uma vazão mínima de 6,47 m³/s.

4.2. Pré-processamento

Antes de serem submetidos a rede neural, as séries históricas de vazão e chuva foram normalizadas no intervalo de [0.1:0.9]. Essa etapa é importante para a adequação das variáveis em um mesmo intervalo, pois geralmente elas estão em diferentes escalas de medida como é o caso da precipitação e da vazão. A normalização é feita de acordo com a equação 1:

$$X_{norm} = 0.1 + 0.8 \left(\frac{X_i}{X_{max}} \right) \quad (1)$$

4.3. Treinamento da RNA

Para treinamento da RNA foi utilizado o método da parada antecipada [Haykin 2008], que é definido de acordo com o monitoramento do erro de treinamento e do erro de validação. Quando o erro de validação pára de diminuir, o treinamento é finalizado.

Uma das questões mais importantes e não bem definidas na literatura sobre RNAs é qual modelo de arquitetura utilizar para um determinado problema [Anders 1999]. Nesse caso, a definição da arquitetura envolve a seleção adequada do número de nodos da camada oculta e do número de neurônios da camada de entrada. Sendo assim, optou-se pela técnica apresentada por [Anders 1999] e [Kwok 2009] na qual parte-se de um ponto de vista *bottom-up*, isto é, inicia-se a rede neural, com um número mínimo de neurônios ocultos, e gradualmente aumenta-se esse número até atingir um critério de parada. A ideia consiste na definição de um modelo inicial de RNA, contendo um número n mínimo de neurônios ocultos, sendo inicialmente $n=1$. Ao término do treinamento, acrescenta-se um neurônio na camada oculta, repetindo o treinamento e calculando novamente o erro. Se essa nova rede contendo mais neurônios mostrar um

erro de validação menor em relação a rede anterior, então o novo modelo é aceito e parte-se para uma nova hipótese de modelo. Esse processo pára quando unidades adicionais de neurônios ocultos não conseguem reduzir o erro de validação em relação ao modelo anterior.

4.4. Definição dos pesos iniciais da RNA usando AG

Uma das metodologias testadas neste trabalho envolve o uso de AG acoplado a uma RNA. Nesse caso antes de avaliar cada modelo de RNA, foi utilizado um algoritmo genético para iniciar a matriz de pesos da RNA. A metodologia de integração de algoritmos genéticos com redes neurais inicia-se pela codificação dos pesos de cada rede em uma população de cromossomos. A codificação por valor foi utilizada para representação de cada peso sináptico, em um respectivo gene. Nessa codificação, o gene é codificado como um tipo *double*, do mesmo tipo do peso sináptico da RNA. O conjunto de genes forma um cromossomo. Cada cromossomo representa uma matriz de pesos de uma possível RNA. A recombinação entre os cromossomos utiliza dois pontos de corte, que são definidos de modo aleatórios, produzindo dois descendentes. Após essa etapa, aplica-se a mutação nos genes, que nesse caso são do tipo *double*, sendo então a mutação uma alteração do valor multiplicado por um percentual definido aleatoriamente.

Durante a fase inicial do AG, é instanciada uma população com 1000 cromossomos representando 1000 possíveis configurações de redes neurais. Para cada cromossomo, é aplicada uma função de aptidão para avaliar a qualidade da solução de cada cromossomo. Para isso, é utilizada a função RMSE (equação 3). O AG executa até atingir um erro mínimo ou um número máximo de 100 gerações, com o objetivo de escapar de um mínimo local inicial e de modo a preparar uma matriz inicial de pesos que facilite a convergência do algoritmo *backpropagation*.

4.5. Modelagem das Redes Neurais Artificiais

O objetivo dos diferentes tipos de modelos, propostos na Tabela 1, é avaliar a influência de diferentes *lags* das variáveis de entrada na RNA. O modelo mais simples, nesse caso, é o modelo 1, no qual explica a vazão $Q(t)$ de acordo com a precipitação $P(t)$. O modelo com maior número de *lags* de entrada é o modelo 19, no qual explica a vazão $Q(t)$ em função da precipitação de $t-5$ e da vazão de $t-4$, onde t , em escala temporal diária, representa 1 dia de medição. Para cada um dos modelos, foi instanciada uma rede neural.

Tabela 1 – Modelos da camada de entrada da RNA

Modelo	Entradas	Saída
1	$P(t)$	$Q(t)$
2	$P(t), Q(t-1)$	$Q(t)$
3	$P(t), P(t-1)$	$Q(t)$
4	$P(t), P(t-1), Q(t-1)$	$Q(t)$
5	$P(t), P(t-1), P(t-2)$	$Q(t)$
6	$P(t), P(t-1), P(t-2), Q(t-1)$	$Q(t)$
7	$P(t), P(t-1), P(t-2), Q(t-1), Q(t-2)$	$Q(t)$
8	$P(t), P(t-1), P(t-2), P(t-3)$	$Q(t)$
9	$P(t), P(t-1), P(t-2), P(t-3), Q(t-1)$	$Q(t)$

10	$P(t), P(t-1), P(t-2), P(t-3), Q(t-1), Q(t-2)$	$Q(t)$
11	$P(t), P(t-1), P(t-2), P(t-3), P(t-4)$	$Q(t)$
12	$P(t), P(t-1), P(t-2), P(t-3), P(t-4), Q(t-1)$	$Q(t)$
13	$P(t), P(t-1), P(t-2), P(t-3), P(t-4), Q(t-1), Q(t-2)$	$Q(t)$
14	$P(t), P(t-1), P(t-2), P(t-3), P(t-4), P(t-5)$	$Q(t)$
15	$P(t), P(t-1), P(t-2), P(t-3), P(t-4), P(t-5), Q(t-1)$	$Q(t)$
16	$P(t), P(t-1), P(t-2), P(t-3), P(t-4), P(t-5), Q(t-1), Q(t-2)$	$Q(t)$
17	$P(t), P(t-1), P(t-2), P(t-3), P(t-4), P(t-5), Q(t-1), Q(t-2), Q(t-3)$	$Q(t)$
18	$P(t), P(t-1), P(t-2), Q(t-1), Q(t-2), PMA7$	$Q(t)$
19	$P(t), P(t-1), P(t-2), P(t-3), P(t-4), P(t-5), Q(t-1), Q(t-2), Q(t-3), Q(t-4)$	$Q(t)$

A taxa de aprendizagem e o momentum foram definidos de forma incremental. A taxa de aprendizagem inicial foi definida em 0.05, onde a partir de 0.2 não se observou melhoria no resultado. De modo semelhante, o valor do momentum foi iniciado em 0.1 e gradualmente incrementado até atingir o valor ótimo de 0.9. A taxa de aprendizado foi investigada de modo incremental, sem a utilização de momentum. Depois de obtida a taxa de aprendizagem, foi então investigada a taxa de momentum. Mantendo a taxa de aprendizado fixo, variou-se o momentum no intervalo de [0,1..0,9].

5. Resultados e discussão

Para avaliação do desempenho de cada modelo, foram utilizados 2 critérios de avaliação: índice de eficiência de *Nash-Sutcliffe* (R^2) (equação 2) e RMSE (equação 3),

$$R^2 = 1 - \frac{\sum_{i=1}^N (Q_i - \hat{Q}_i)^2}{\sum_{i=1}^N (Q_i - \bar{Q}_i)^2} \quad (2)$$

Onde Q_i é a vazão observada, \hat{Q}_i é a vazão calculada, \bar{Q}_i é a média de vazão e N é o número de observações. O índice de eficiência de *Nash-Sutcliffe* pode variar de $-\infty$ a 1 . Um índice igual a 1 corresponde a uma relação perfeita entre a vazão modelada e a vazão observada. Em síntese, quanto mais próximo de 1 o modelo atingir, mais preciso será. Para avaliação da progressão do erro entre valores observados e previstos, utilizou-se o RMSE (*root mean square error*):

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Q_i - \hat{Q}_i)^2}{N}} \quad (3)$$

Onde N é o número total de observações, Q_i é a vazão observada e \hat{Q}_i é a vazão calculada. Quanto menor o erro ou mais próximo de zero, melhor será o ajuste dos dados ao modelo obtido.

5.1 Análise preliminar

Os melhores modelos de entrada de dados selecionados para as simulações foram aqueles que utilizavam além da precipitação, também a vazão como entrada na RNA, ou seja, descartaram-se os modelos que possuíam apenas a precipitação como dado de

entrada, que nesse caso foram os modelos 1, 3, 5, 8, 11 e 14. Esses modelos apresentaram resultados inferiores a 0,5 em termos de R^2 .

5.2 Fase de testes

A seguir são apresentados os resultados da avaliação da fase de teste dos melhores modelos, selecionados na etapa de treinamento. Nessa fase, é apresentado um conjunto de dados reservados, que não foram apresentados anteriormente para a RNA, e portanto, será usado nesse caso para verificação da capacidade de generalização de cada modelo.

5.2.1 Modelos AG-RNA em escala diária

Usando AG-RNA em escala diária, o modelo 9 apresentou um R^2 de 0,856 (Figura 3) e RMSE de 0,01417, apresentando em alguns pontos da aproximação, um erro principalmente nos picos de vazão, conforme Figura 2, e boa representação nos períodos de baixa vazão. O gráfico da Figura 2 mostra um erro maior da previsão do modelo, nas vazões mais altas. Nesse caso, o modelo previu vazões acima daquelas observadas.




Figura 2 – Comparação entre vazão observada e calculada usando AG-RNA

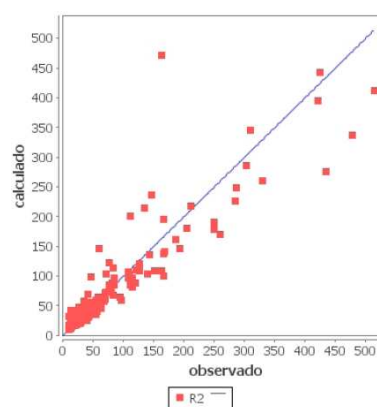


Figura 3 – Coeficiente R^2 - AG-RNA

5.2.2 Modelos RNA em escala diária

O melhor modelo RNA obtido em escala diária foi o modelo 4, que apresentou R^2 de 0,811 (Figura 5) e RMSE de 0,04724. A Figura 4 mostra um período de teste de 1 ano de previsão (vazão calculada) feita pelo modelo, em comparação com os dados observados (vazão observada). Nesse modelo houve uma superestimação maior dos picos de vazão em comparação ao modelo AG-RNA.

5.3. Resultados comparativos

Na etapa de teste da rede, o modelo híbrido AG-RNA apresentou melhores resultados de convergência quando comparado ao de uma RNA, sem AG, conforme apresentado na Tabela 2, ou seja, os modelos AG-RNA conseguiram uma melhor generalização dos dados em relação aos modelos RNA.

A principal vantagem no uso do AG-RNA está na rapidez de convergência. Em diversas simulações o modelo RNA não conseguia convergir, devido a uma má atribuição da matriz de pesos ficando preso num mínimo local. Isso exigia reinicialização da matriz de pesos, para busca num ponto diferente do espaço de estados. Em algumas situações essa matriz precisou ser reiniciada 4 vezes. O AG-RNA precisou de apenas 1 inicialização para conseguir convergência. Observa-se também que existe uma

correspondência entre o erro apresentado na fase de treino e o erro apresentado na fase de teste. Isso significa que a rede está conseguindo uma boa generalização [Atiya 1999].




Figura 4 – Comparação entre vazão observada e vazão calculada (RNA)




Figura 5 – Coeficiente R^2 - RNA

Tabela 2 - Comparação entre RNA e AG-RNA

Técnica	Modelo	Arquitetura	RMSE	R^2
AG-RNA	9	5-5-1	0,01417	0,856
RNA	4	3-4-1	0,04724	0,811

6. Conclusão

A vantagem do uso de RNAs na modelagem chuva-vazão está principalmente ligada à redução da dimensionalidade do fenômeno a duas variáveis. Nesse trabalho, utilizou-se apenas a precipitação e a vazão para treinamento da rede. Nesse cenário a RNA acoplada a um AG, conseguiu realizar uma boa aproximação, sendo que no melhor modelo obteve um coeficiente R^2 de 0.856 em escala diária. Esse resultado foi superior em relação a modelagem utilizando somente RNA, que apresentou um coeficiente R^2 de 0.811. Os resultados obtidos foram considerados bons quando se analisa a baixa correlação entre as duas séries temporais chuva-vazão, no caso de 0.505 e também quando se considera a área total da bacia hidrográfica utilizada como elemento de estudo de caso.

Uma desvantagem do uso de RNAs para a modelagem reside na questão da abordagem tipo caixa preta. Nesses tipos de modelos, obtemos a relação entre uma ou diversas variáveis, não sendo possível, entretanto, identificar como essa relação foi obtida, ou seja, qual o processo físico que melhor descreve o fenômeno. Um outro ponto está na questão da disponibilidade dos dados ou no tamanho da série temporal. Se houver escassez de dados, isso pode prejudicar o aprendizado da RNA, tendo impacto nesse caso, na generalização da rede para eventos onde a rede não foi ensinada. Isso pode levar a um modelo fraco.

O uso dos algoritmos genéticos acoplado a uma RNA mostrou-se interessante permitindo um melhor desempenho da modelagem, entretanto, adiciona-se mais uma etapa de processamento para iniciar a matriz de pesos. Isso deve ser considerado principalmente quando o tamanho do conjunto de dados para treinamento for muito grande, o que pode aumentar o tempo de processamento.

Agradecimentos

Agradecemos a Fundação Parque Tecnológico Itaipu (FPTI), pelo apoio financeiro concedido para desenvolvimento desta pesquisa.

Referências

- Anders, Ulrich and Korn, Olaf. Model selection in neural networks. *Neural Networks*, 12(2):309-323, 1999.
- Atiya, Amir F. e Shaheen, Samir I. A Comparison Between Neural-Network Forecasting Techniques - Case Study: River Flow Forecasting. *IEEE Transactions on Neural Networks*, 10:402-409, mar 1999.
- Back, T. and Hammel, U. and Schwefel H. P. Evolutionary computation: comments on the history and current state. *IEEE Transactions on Evolutionary Computation*, 1(1):317, April 1997.
- Basheer, I.A. and Hajmeer, M. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43:3-31, dec 2000.
- Campolo, Marina and Andreussi, Paolo and Soldati, Alfredo. River flood forecasting with a neural network model. *Water Resources Research*, 35(4):1191-1197, 1999.
- Cybenko, G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems*, 2(4):303-314, December 1989.
- Dawson, Christian W. and Wilby, Robert. An artificial neural network approach to rainfall runoff modelling. *Hydrological Science*, (43):47-66, August 1998.
- Haykin, Simon. *Redes Neurais: Princípios e prática*. Bookman, second edition, 2008.
- Kwok-Wing; Cheng Chun-Tian e Qiu Lin Wang, Wen-Chuan; Chau. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology*, 374(3-4):294-306, August 2009.
- Nasseri, M. and Asghari, K. and Abedini, M. Optimized scenario for rainfall forecasting using genetic algorithm coupled with artificial neural network. *Expert Systems with Applications*, 35(3):1415-1421, October 2008.
- Sedki, A. and Ouazar, D. and Elmazoudi, E. Evolving neural network using real coded genetic algorithm for daily rainfall runoff forecasting. *Expert Systems with Applications*, 36(3):4523-4527, April 2009.
- Rezende, Solange Oliveira. *Sistemas Inteligentes: Fundamentos e Aplicações*. Ed. Manole, 2005.
- Silva, Leandro Nunes de Castro. *Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais*, Dissertação (Mestrado), Universidade Estadual de Campinas. 1998.
- Tokar, A. Sezin and Johnson, Peggy A.. Rainfall-runoff modeling using artificial neural networks. *Journal of Hydrologic Engineering*, 4(3):232-239, 1999.
- Yao, Xin. Evolving artificial neural networks. *Proceedings of the IEEE*, 87(9):1423-1447, Sept 1999.