



Revista Ambiente & Água

ISSN: 1980-993X

Instituto de Pesquisas Ambientais em Bacias Hidrográficas

Cristaldo, Marcia Ferreira; Souza, Celso Correia de; Jesus, Leandro de; Oliveira, Paulo Tarso Sanches de; Padovani, Carlos Roberto; Viganó, Hevelyne Henn da Gama
Previsão probabilística de enchentes para uma pequena bacia hidrográfica do Pantanal

Revista Ambiente & Água, vol. 13, núm. 4, 2018
Instituto de Pesquisas Ambientais em Bacias Hidrográficas

DOI: 10.4136/ambi-agua.1988

Disponível em: <http://www.redalyc.org/articulo.oa?id=92860429013>

- Como citar este artigo
- Número completo
- Mais artigos
- Home da revista no Redalyc

UAEM redalyc.org

Sistema de Informação Científica Redalyc

Rede de Revistas Científicas da América Latina e do Caribe, Espanha e Portugal
Sem fins lucrativos acadêmica projeto, desenvolvido no âmbito da iniciativa acesso aberto



Previsão probabilística de enchentes para uma pequena bacia hidrográfica do Pantanal

ARTICLES doi:10.4136/ambi-agua.1988

Received: 19 Aug. 2016; Accepted: 08 Jun. 2018

**Marcia Ferreira Cristaldo^{1*}; Celso Correia de Souza²; Leandro de Jesus¹;
Paulo Tarso Sanches de Oliveira³; Carlos Roberto Padovani⁴;
Hevelyne Henn da Gama Viganó⁵**

¹Instituto Federal de Mato Grosso do Sul (IFMS), Aquidauana, MS, Brasil
Departamento de Computação. E-mail: marcia.cristaldo@ifms.edu.br,
leandro.jesus@ifms.edu.br

²Universidade Anhanguera (UNIDERP), Campo Grande, MS, Brasil
Departamento de Estatística. E-mail: csouza939@gmail.com

³Universidade Federal de Mato Grosso do Sul (UFMS), Campo Grande, MS, Brasil
Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia (FAENG).
E-mail: paulotarsoms@gmail.com

⁴Empresa Brasileira de Pesquisa Agropecuária (Embrapa), Corumbá, MS, Brasil
Centro de Pesquisa Agropecuária do Pantanal. Departamento DE Geociências.
E-mail: carlos.padovani@gmail.com

⁵Instituto Federal de Mato Grosso do Sul (IFMS), Campo Grande, MS, Brasil
Departamento de Estatística. E-mail: hevelyne.vigano@ifms.edu.br

*Autor Correspondente

RESUMO

O monitoramento para a previsão de cheias de pequenas bacias hidrográficas é de grande importância tendo em vista a relação dos recursos hídricos com a sociedade, pois pode garantir o uso sustentável às comunidades urbanas de cidades lindeiras à bacia. O rio Aquidauana está inserido na planície Pantaneira sendo considerado vulnerável à inundações, no entanto, falta de um sistema eficiente para previsões de cheias e inundações. Assim, este estudo propõe um sistema de previsão probabilística de enchentes para a bacia do Rio Aquidauana. Para tanto foram utilizadas as redes neurais artificiais (RNAs) do tipo *MultiLayer Perceptron* (treinamento *back-propagation*) com parâmetros otimizados pelos Algoritmos Genéticos. A RNA foi treinada e avaliada com base em dados de chuva acumulada (mm) e nível de rio (cm) à montante entre os anos de 1995 a 2014. A previsão realizada foi de 1 a 5 dias, tendo como melhor desempenho o modelo para 1 dia de previsão, com resultado de coeficiente de determinação e erro quadrático médio de 0,93 e 30 (cm), respectivamente.

Palavras-chave: monitoramento de cota, multilayer perceptron, predição, Rio Aquidauana.

Probabilistic flood forecast for a small Pantanal watershed

ABSTRACT

Monitoring for flood forecasting in small hydrographic basins is of great importance in view of the relationship of water resources with society, as it can guarantee the sustainable use of urban communities in cities bordering the basin. The Aquidauana River, classified as a small



basin, belongs to the Paraguay River basin and is an affluent of the Miranda River, forming part of the Pantanal plain, being inserted in the mapping of rivers vulnerable to flooding in the Central-West region of Brazil. This study deals with the monitoring of the river Aquidauana and uses artificial neural networks (RNAs) of the MultiLayer Perceptron type (training back-propagation) with parameters optimized by Genetic Algorithms. The RNA was trained and tested based on hydrological data between 1995 and 2014, accumulated rainfall (mm) and river level (cm) upstream. The forecast was 1 to 5 days, with the best performance of the model for 1 day of forecast, with a coefficient of determination and mean square error of 0.93 and 30 (cm), respectively.

Keywords: Aquidauana River, multilayer perceptron, prediction, quota monitoring.

1. INTRODUÇÃO

A variação de nível de rios é um processo hidrológico complexo devido à variabilidade espacial e temporal como, características de padrões de terreno, precipitação e outras variáveis associadas ao meio ambiente. Neste sentido, o uso da modelagem e a previsão precisa de eventos de alto e baixo fluxo do nível do rio auxiliam na provisão de informações necessárias para tomada de decisões estratégicas em bacias hidrográficas (Bravo et al., 2012).

Os hidrólogos vêm utilizando uma ferramenta de modelagem para gerar a cota do rio com a ajuda de dados históricos observados, fazendo projetos alternativos para comparação ou otimização, em vez de tomar decisões com base em dados observados de curto prazo. Assim, a questão da previsão de cotas por meio da precipitação tem sido uma área de pesquisa ativa ao longo da evolução da hidrologia. Diversos modelos de previsão de nível de rio, que vão de modelos empíricos a conceituais, têm sido desenvolvidos e aplicados.

Estudos recentes fizeram tentativas de mostrar que as RNAs não são puramente modelos de caixa preta, sendo assim possível esclarecer os processos hidrológicos inerentes a uma RNA, se suas características arquitetônicas forem exploradas. Jain e Prasad Indurthy (2013) investigaram a adequação de algumas técnicas determinísticas e probabilísticas, juntamente com a técnica da RNA para modelar um processo de contingente de chuva baseado em eventos observados. Os autores verificaram que os modelos de RNAs superaram as convencionais com algumas exceções e proporcionaram uma melhor representação de um processo de cota baseado em eventos.

O método de Algoritmos Genéticos (AG) pode ser usado para obter os melhores parâmetros de configuração da RNA. Neste método é utilizada uma técnica de busca e otimização inspirada no princípio de seleção natural e reprodução genética proposto por Charles Darwin, em que a seleção privilegia os indivíduos mais aptos com maior longevidade e, portanto, com maior probabilidade de reprodução. Logo, os melhores indivíduos terão mais descendentes e mais chance de perpetuarem seus códigos genéticos nas próximas gerações.

Normalmente aplicam-se algoritmos genéticos em problemas complexos de otimização: problemas com diversos parâmetros ou características que precisam ser combinadas em busca da melhor solução. Alguns autores utilizaram este processo para determinar o número de nós e camadas ocultas, a taxa de aprendizado, o *momentum* e para inicializar e otimizar os pesos de conexão de rede do BP (Yang e Honavar, 1998; Sexton et al., 1998). Heckerling et al. (2003) utilizou o AG-RNA híbrido em diversas aplicações, como na busca de arquiteturas ótimas de camada oculta, na conectividade e nos parâmetros de treinamento.

O objetivo deste estudo é desenvolver um sistema de previsão probabilística de enchentes para a bacia do Rio Aquidauana, localizado na planície Pantaneira, Estado de Mato Grosso do Sul. O presente estudo categorizou um conjunto de variáveis de entrada para RNA (cota e precipitação) para previsão de cota da bacia do rio Aquidauana, sendo utilizados para tal:

Algoritmo Genético (AG) e o RNA *Multilayer Perceptron* (MLP)- Algoritmo *backpropagation* (BP). Neste trabalho, AGs foram empregados na busca dos melhores parâmetros das RNAs (taxa de aprendizado, *momentum*, função de ativação, número de camadas ocultas e número de nós).

2. APLICAÇÕES DE RNA EM RECURSOS HÍDRICOS

Na última década, os cientistas têm focado na aplicação de RNAs em campos diversos como modelagem, diagnóstico e controle de sistemas, medicina, reconhecimento de padrões e previsão de recursos hídricos. Diversos autores desenvolveram pesquisas relacionadas a recursos hídricos, como Suryanarayana et al. (2014) e Asati e Rathore (2012) que mostraram que os modelos de RLM são aplicáveis à previsão, no entanto, eles exigem uma suposição prévia sobre o tipo e a consistência da relação entre variáveis dependentes e independentes. No mundo real, as variações temporais nos dados nem sempre exibem e satisfazem regularidades simples a esta suposição. Assim, a complexidade e os problemas não-lineares tornam atrativos para tentar abordagens de RNA, na qual solucionam um ou mais problemas específicos, sendo que não pressupõem uma compreensão detalhada das características físicas de um rio e nem exigem um pré-processamento extensivo de dados.

Os conceitos de aplicação de RNA foram revisados, e a RNA mostrou ser uma ferramenta de modelagem alternativa para área de hidrologia. Apesar de vários esforços dedicados na comparação de modelos de previsão pesquisados, uma comparação conclusiva não pôde ser alcançada, pois diferentes dados de entrada foram usados para diferentes tipos de modelo, o que torna a comparação injusta.

3. ÁREA DE ESTUDOS

Neste estudo, foi selecionada a bacia do rio Aquidauana com área de 20.124 km². Esta bacia hidrográfica encontra-se ao sul da região Centro-Oeste do Brasil (Aquidauana) (Figura 1), fazendo parte da Bacia do Alto Paraguai (BAP) no Estado de Mato Grosso do Sul. O clima é tropical com precipitação média anual de 1537,7 mm, dos quais 80,7% da precipitação anual incidente ocorrem na estação úmida (de janeiro a abril). A característica da paisagem tem topografia plana com uma faixa de elevação de 134m-242m; o uso da terra é caracterizada por área natural (88,42%), pastagem cultivada (11,34%), área urbana (0,12%) e área agrícola (0,12%). Os principais tipos de solo segundo a classificação da EMBRAPA (2006) são: franco arenosa e franco-argiloarenosa. As principais culturas cultivadas na bacia do Aquidauana são: milho, mandioca e olerícolas. Na pecuária, conforme IBGE (2015), existem mais de 717 mil cabeças de gado bovino.

Foram usados dados pluviométricos e fluviométricos coletados a partir das estações da Agência Nacional de Águas (ANA, 2016) entre 1995 e 2014 para teste e treinamento. A Figura 1 mostra a bacia do rio Aquidauana com três postos fluviométricos: 66945000 (Aquidauana) (~1995), 66941000 (Palmeiras) (~1965) e 66926000 (Ponte do Grego) (~1982); e quatro estações de chuvas: (01954002) Rochedo, (02055002) Palmeiras, (02055003) Fazenda Lajeado e (02054009) Santa Elisa. Nas estações fluviométricas descritas acima, as datas das instalações (mantidas em sua posição inicial) são mostradas de acordo com ANA. A estação de cota prevista é a Aquidauana (66945000), localizada dentro da cidade de Aquidauana.

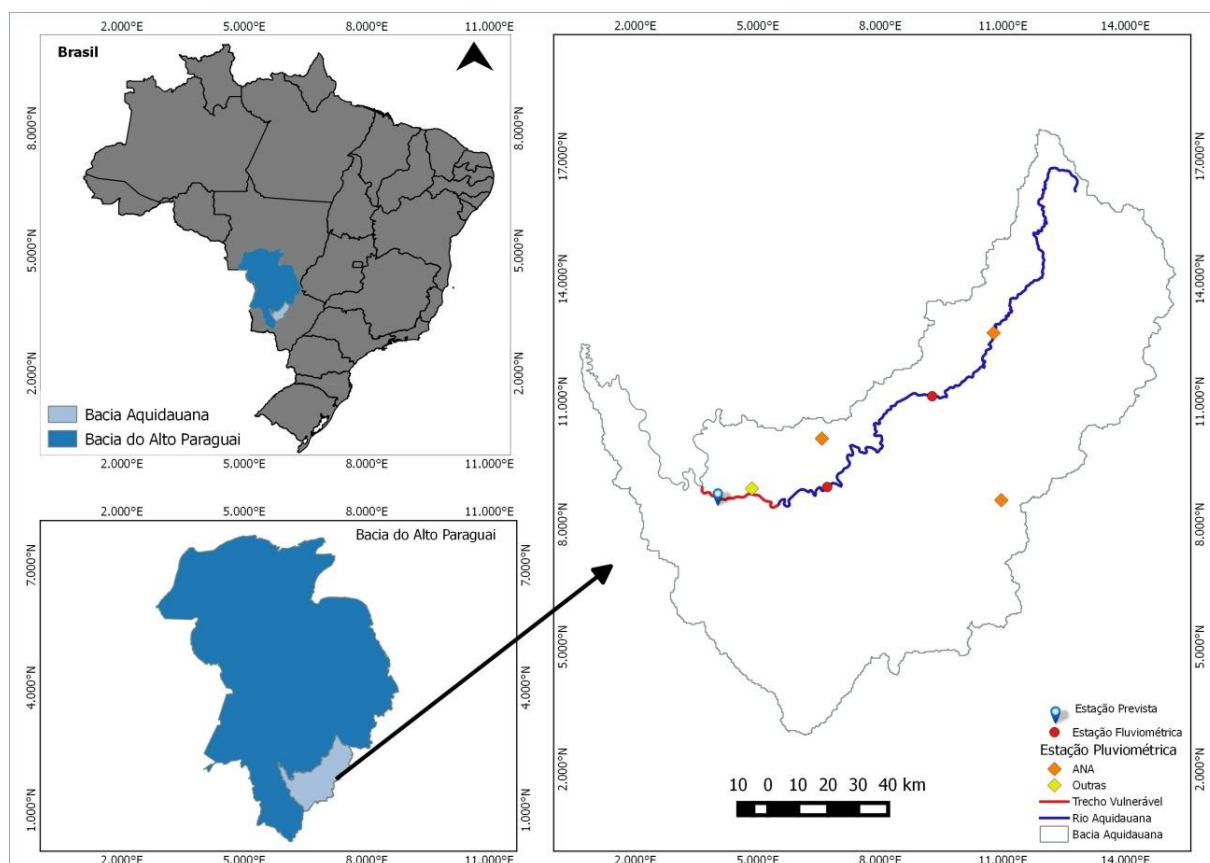


Figura 1. Mapa da bacia hidrográfica Aquidauana e das estações fluviométricas (vermelho) e pluviométricas (laranja/amarelo) do rio Aquidauana (azul). A estação de cota prevista está localizada dentro da cidade entre Aquidauana e Anastácio, local mais vulnerável à inundação.

4. MATERIAL E MÉTODOS

4.1. Pré-processamento dos dados

Para a análise dos postos pluviométricos e fluviométricos, verificou-se, primeiramente, as falhas de leitura de cotas e de precipitação em todo o período existente no banco de dados da ANA para serem usadas no treinamento e testes das RNAs. Depois de verificadas as falhas, foram extraídas do banco de dados a relação das cotas e as chuvas acumuladas diárias efetivamente medidas em ordem cronológica.

Posteriormente os dados disponíveis foram divididos em seus subconjuntos (isto é, de formação e de validação). Foi importante pré-processar os dados numa forma adequada antes de ser aplicada a RNA. O pré-processamento de dados é necessário para garantir a igualdade dos dados durante o processamento, acelerando assim o processo de aprendizagem da RNA. Existem três formas de pré-processar os dados: escalonamento de dados, normalização e transformação (Hall et al., 2009).

Assim, devido à função sigmoide utilizada na RNA, os dados hidrológicos foram normalizados no intervalo $[0, 1]$, para evitar o problema da saturação de sinal de saída que pode, por vezes, ser encontrado em aplicações de RNA. Após o pré-processamento, a base de dados contava com 5.368 dados.

Para a avaliação inicial dos dados e de sua relação com o alagamento na bacia do rio Aquidauana, optou-se por trabalhar apenas a bacia que está dentro dos limites do município de Aquidauana.

4.2. Modelo AG-RNA

Na rede *Multilayer perceptron* (MLP) o algoritmo *backpropagation* (BP) remete a redução do erro entre a função calculada pela rede e o valor esperado, sendo o método do gradiente descendente (utilizado neste trabalho), pode ficar preso num mínimo local impossibilitando de encontrar o mínimo global.

Uma maneira de superar a restrição dos algoritmos de treinamento baseados no gradiente descendente é usar AG para executar o treinamento como uma evolução das conexões sinápticas. Assim, o AG pode ser empregado para uma busca por um conjunto ótimo de pesos globais sem calcular o gradiente descendente, evitando a estagnação precoce do processo de busca em um mínimo local.

A interpelação evolucionária de treino de uma RNA consiste nos seguintes passos:

- 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 (*root mean square error*). 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 AGs com as RNAs (Figura 2) é vantajosa no sentido de agregar a capacidade de busca global dos AGs junto com o algoritmo de treinamento e ajuste de pesos BP.




Figura 2. Fluxograma da interação do Algoritmo Genético e *backpropagation*.

O AG ajuda a resolver os mínimos locais realizando uma busca mais ampla no espaço de estados, pois ele é menos suscetível de ficar estagnado em um mínimo local, pois não depende do gradiente, em comparação com os algoritmos baseados no gradiente (Yao, 2014). Após o AG terminar seu processamento, utiliza-se o BP para uma busca local usando o conjunto de pesos pré-ajustados pelo AG. O primeiro passo do modelo híbrido consiste na formulação de

uma população de cromossomos, criados aleatoriamente (Figura 2). Nesse caso, cada gene representa um peso sináptico da RNA. Em seguida, cada cromossomo é avaliado por uma função de aptidão (função RMSE). 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 é reiniciado.

Neste caso, serão escolhidos 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 alocada, 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.

Neste artigo foi feita a extração de regras de classificação a partir dos atributos codificados e da RNA treinada e, para isso, fez-se uso do algoritmo genético chamado SMAC (*Sequential Model-based Algorithm Configuration*). Os autores Hutter et al. (2011) comprovaram que o algoritmo mostrou um ótimo desempenho para explorar de forma automatizada os ajustes de parâmetros para vários problemas. O simulador utilizado neste trabalho é o pacote de *software* Weka (*Waikato Environment for Knowledge Analysis*), desenvolvido pela Universidade de Waikato da Nova Zelândia, na qual possui licença pública (General Public License), disponível em *World Wide Web* (www.cs.waikato.ac.nz/ml/weka).

4.3. Treinamento e avaliação do modelo

A variável t representa o tempo de previsão de 1 a 5 dias, sendo a janela de treinamento (1995-2013) e teste (2014), e o local previsto é dentro da cidade de Aquidauana para a estação 66945000 (Aquidauana). Os erros são analisados por 6 critérios de avaliação: R - coeficiente de correlação para dados de teste; MAE - Erro Absoluto Médio; RAE - Erro Relativo Absoluto; RMSE — Erro Quadrático Médio Relativo; MSRE – Erro Quadrático Relativo; NSE - Coeficiente de Eficiência Nash-Sutcliffe.

5. RESULTADOS E DISCUSSÕES

Na Tabela 1 são apresentadas as medidas de erro para os cinco modelos em que os pesos foram otimizados pelo Algoritmo Genético.

Tabela 1. Análise comparativa dos desempenhos.

t	R	RMSE (cm)	MAE (cm)	RAE (cm)	NSE
1	0,95	30	0,71	0,6328	0,93
2	0,89	45	0,66	0,4356	0,87
3	0,79	57	0,60	0,3796	0,76
4	0,69	65	0,57	0,339	0,67
5	0,56	69	0,63	0,301	0,54

R - coeficiente de correlação para dados de teste; MAE - Erro Absoluto Médio; RAE - Erro Relativo Absoluto; RMSE — Erro Quadrático Médio Relativo; MSRE – Erro Quadrático Relativo; NSE - Coeficiente de Eficiência Nash-Sutcliffe.

A Tabela 1 indica os parâmetros estatísticos analisados neste processo e observa-se melhores resultados no processo de teste em relação ao treinamento. Nota-se, que os índices de

erro associados às frequências seguiram a tendência de piora, em função do aumento do horizonte de previsão para os 5 dias, além de apresentar valores aceitáveis para uma previsão de nível, onde o erro variou de cerca de 30 cm para o horizonte de 1 dia e de 69 cm para o horizonte de 5 dias. Estes índices, erros associados à frequência, possibilitam um entendimento mais intuitivo e realista da incerteza do modelo de previsão, constituindo uma margem de garantia para uso do tomador de decisão em um sistema de alerta de inundações. Os dados de valores diários de NSE tendem a ser superiores aos dados de valores mensais, o que contradiz as descobertas de alguns estudos individuais (Van Liew et al., 2007). ??individuais??? se a referência é et al) Esta anomalia é potencialmente devido ao aumento de tamanhos de amostra para dados diários. Como esperado, nos NSE e R os valores da previsão foram melhores para os períodos de calibração do que os períodos de validação.

Para a bacia uma previsão ótima seria de 3 a 5 dias, pois um sistema de alerta precisa de tempo para ser acionado e tomada as providências em relação à inundação. Neste estudo, para esta bacia, os resultados são satisfatórios para a previsão de até 5 dias, observando os erros medidos pela RNA.

A Figura 3 mostra as estimativas do nível do rio fornecidas pelo modelo de predição da BP prevendo 1 a 5 dias (1D, 2D, 3D, 4D e 5D), sendo as nomenclaturas descritas no canto inferior esquerdo da Figura 3. Pode-se observar hidrogramas e gráficos de dispersão, com os valores previstos próximos dos observados, confirmando as estatísticas RMSE na Tabela 1.

Como mostra o resultado, o modelo MLP 1 apresentou as estimativas de cota (cm) mais preciso ($r^2=0.95$ e $RMSE = 30$ cm). Para a bacia hidrográfica este erro é aceitável, indicando uma boa precisão de previsão.

Nas análises verificou-se que a qualidade dos resultados depende diretamente dos dados utilizados na calibração (treinamento). Estes dados devem ser os mais abundantes possíveis e cobrir com uma densidade de frequência suficiente todo o domínio de aplicação desejada, de maneira a fornecer ao modelo a capacidade de reproduzir cenários já ocorridos. Para a bacia do Aquidauana o treinamento obtido a partir dos dados disponíveis para este trabalho indicou que o uso de redes neurais na previsão de nível é aconselhado, para o caso de estudo.

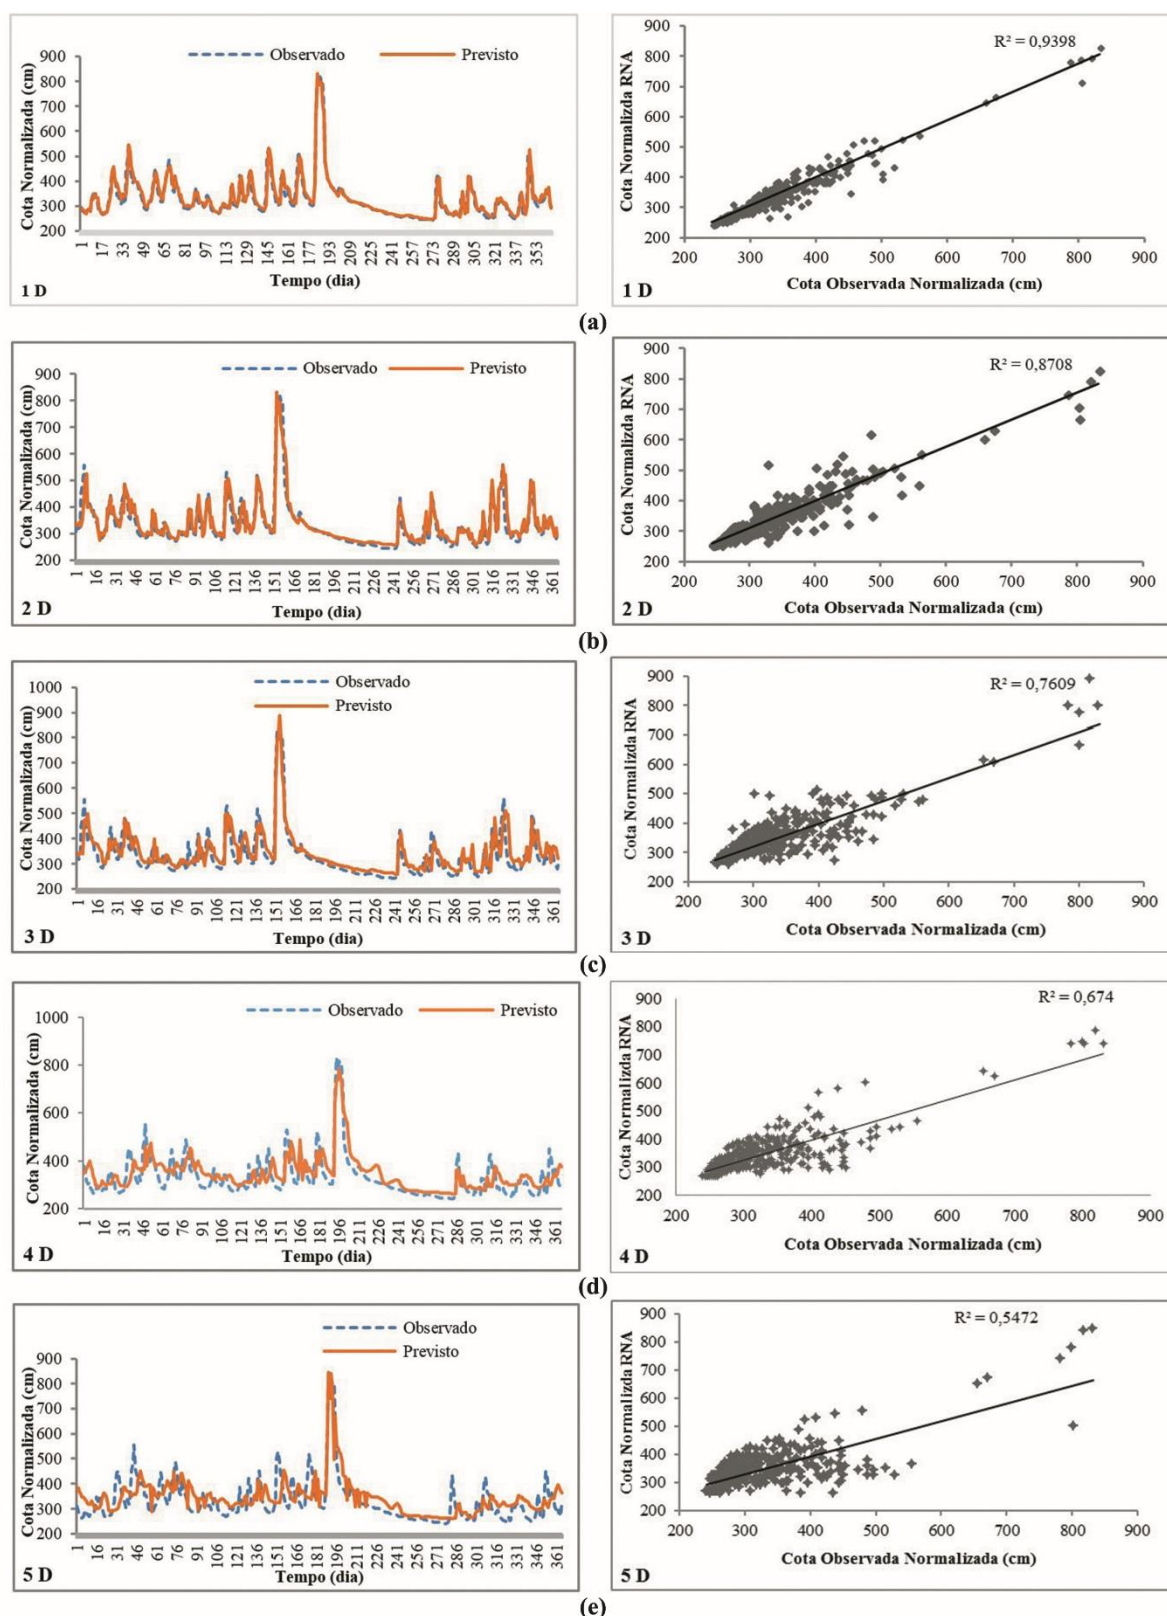


Figura 3. Evolução temporal do nível previsto para 2014 (laranja), observado (azul) e respectivos diagramas (r^2). Os dados correspondentes ao período de 1995 a 2014, obtidos das previsões 1 dia (a), 2 dias (b), 3 dias (c), 4 dias (d), 5 dias (e).

6. CONCLUSÕES

Uma vantagem no uso da modelagem chuva-cota está principalmente ligada à redução da dimensionalidade do fenômeno a duas variáveis. Nesse artigo, utilizou-se apenas a precipitação e a cota para treinamento da rede. Nessa circunstância a RNA acoplada a um AG, conseguiu realizar uma boa aproximação, sendo que no melhor modelo obteve um coeficiente de determinação R^2 0,95 em escala diária e RMSE de 30 cm na cota do rio, sendo um erro satisfatório, podendo ser utilizado como sistema de previsão de até 5 dias para essa bacia estudada.

Os resultados alcançados são bons quando se analisa a baixa correlação entre as duas séries temporais chuva-cota, no caso de 0,54; quando se considera a área total da bacia hidrográfica utilizada como elemento de estudo de caso, e principalmente, por ser na prática, totalmente aceitável para um sistema de alerta de inundação.

O uso dos AG-RNA mostrou-se interessante porque permitiu 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 conjunto de dados para treinamento for muito grande, o que pode aumentar o tempo de processamento.

7. AGRADECIMENTOS

Este é um projeto de pesquisa apoiado pela FUNDECT (Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso do Sul) e pela Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA Pantanal.

8. REFERÊNCIAS

- AGÊNCIA NACIONAL DE ÁGUAS (Brasil). **Website**. Disponível em: <http://www.ana.gov.br/>. Acesso em: 20 jun. 2016.
- ASATI, R. S.; RATHORE, S. S. Comparative study of stream flow prediction models. **International Journal of Life Sciences Biotechnology and Pharma Research**, v. 1, n. 2, p. 139-151, 2012.
- BRAVO, J. M.; ALLASIA, D.; PAZ, A. R.; COLLISHONN, W.; TUCCI, C. E. M. Coupled Hydrologic-Hydraulic Modeling of the Upper Paraguay River Basin. **Journal of Hydrologic Engineering**, v. 17, p. 635-646, 2012. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000494](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000494)
- EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Sistema brasileiro de classificação de solos**. 2. ed. Rio de Janeiro: EMBRAPA, 2006. 306p.
- HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The WEKA data mining software: an update. **ACM SIGKDD Explorations Newsletter**, v. 11, n. 1, 2009.
- HECKERLING, P. S.; GERBER, B. S.; TAPE, T. G.; WIGTONS, R. S. Use of genetic algorithms for neural networks to predict community-acquired pneumonia. **Artificial Intelligence in Medicine**, v. 30, n. 1, p.71-84, 2003. [https://doi.org/10.1016/S0933-3657\(03\)00065-4](https://doi.org/10.1016/S0933-3657(03)00065-4)
- HUTTER, F.; HOOS, H. H.; LEYTON-BROWN, K. Sequential model-based optimization for general algorithm configuration. In: INTERNATIONAL CONFERENCE ON LEARNING AND INTELLIGENT OPTIMIZATION, 2011, Lion. **Proceedings...** Berlin: Springer, 2011. https://doi.org/10.1007/978-3-642-25566-3_40

- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Cidades**. Disponível em: <http://cidades.ibge.gov.br/xtras/perfil.php?codmun=500110>. Acesso em: 15 fev. 2015.
- JAIN, A.; PRASAD INDURTHY, S. K. V. Comparative analysis of event based rainfall-runoff modeling techniques- deterministic, statistical and artificial neural networks. **Journal of Hydrologic Engineering**, v. 8, n. 2, p. 1-6, 2013. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2004\)9:6\(551\)](https://doi.org/10.1061/(ASCE)1084-0699(2004)9:6(551))
- SEXTON, R. S.; DORSEY, R. E.; JOHNSON, J. D. Toward global optimization of neural networks: A comparison of the genetic algorithm and back propagation. **Decision Support System**, v. 22, n. 2, p. 171-185, 1998. [https://doi.org/10.1016/S0167-9236\(97\)00040-7](https://doi.org/10.1016/S0167-9236(97)00040-7)
- SURYANARAYA, C.; SUDHEER, C.; MAHAMMOOD, V.; PANIGRAHI, B. K. An integrated wavelet-support vector machine for groundwater level prediction in Visakhapatnam, India. **Neurocomputing**, v. 145, p. 324-335, 2014.
- VAN LIEW, M. W.; ASCE, M.; VEITH, T. L.; BOSCH, D. D.; ARNOLD, J. G. Suitability of SWAT for the conservation effects assessment project: A comparison on USDA-ARS experimental watersheds. **Journal of Hydrologic Engineering**, v. 12, n. 2, p. 173-189, 2007. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2007\)12:2\(173\)](https://doi.org/10.1061/(ASCE)1084-0699(2007)12:2(173))
- YANG, J.; HONAVAR, V. Feature subset selection using a genetic algorithm. In: LIU, H.; MOTODA, H. (Eds.). **Feature Extraction, Construction and Selection**. Boston: Springer, 1998. https://doi.org/10.1007/978-1-4615-5725-8_8
- YAO, X. Evolutionary artificial neural networks. In: KENT, A.; WILLIAMS, J. G. (Eds.). **Encyclopedia of computer science and technology**. Boca Raton: CRC Press, 2014. p. 137-170.