

Uso de Redes Neurais Artificiais na previsão da precipitação de períodos chuvosos

Daniel Dantas¹

Tarço Murilo Oliveira Luz²

Maria José Hatem de Souza³

Gabriela Paranhos Barbosa⁴

Eduarda Gabriela Santos Cunha⁵

¹ Engenheiro Florestal (UFVJM).

² Engenheiro Florestal (UFV). Mestre em Ciências Florestais (UFVJM).

³ Engenheira Agrícola (UFV). Mestre em Meteorologia Agrícola (UFV). Doutora em Engenharia Agrícola (UFV). Professora da UFVJM.

⁴ Engenheira Florestal (UFVJM). Mestre em Ciências Florestais (UFVJM). Doutoranda em Ciências Florestais (UFVJM).

⁵ Engenharia Florestal (UFV). Mestre em Ciências Florestais (UFVJM).

Resumo O estudo objetiva estimar a precipitação na estação chuvosa em Diamantina (MG) com base na precipitação das estações secas anteriores por meio de Redes Neurais Artificiais (RNA). Alterou-se a ordem cronológica dos dados de forma que o período seco de um ano estivesse relacionado com o período chuvoso do ano seguinte. Utilizou-se parte dos dados no treinamento e parte na avaliação do desempenho da RNA. Utilizou-se a análise do tipo séries temporais e a melhor rede encontrada foi do tipo função de base radial. A RNA apresentou um erro médio de 10%. A média de precipitação no período de aplicação da rede foi 1.099 mm, enquanto a estimativa média foi 1.128 mm. A utilização de dados dos períodos secos para estimar a precipitação no período chuvoso apresenta resultados satisfatórios e a alteração na ordem cronológica do período seco resultou em uma rede com previsão mais eficaz.

Palavras-chave: Cenários climáticos, modelagem do clima, previsão do tempo.

1. Introdução

O desenvolvimento agrário de uma região está fortemente associado com os níveis de precipitação pluviométrica, uma vez que a escassez de chuvas é um fator desfavorável para o processo produtivo. A precipitação pluviométrica é a forma mais econômica e ambientalmente correta de uso da água na agricultura, contribuindo para a manutenção do equilíbrio dos recursos hídricos existentes em toda a região. Ainda, a necessidade de se importar água através de irrigação eleva consideravelmente os custos de produção.

Segundo Castro (1994) e Andrade *et al.* (2009), muitos produtores brasileiros utilizam a precipitação mensal média para o dimensionamento de seus projetos agrícolas. Desta forma, a modelagem climática torna-se uma ferramenta importante, pois permite a simulação de cenários futuros, tanto para as atividades agrícolas e industriais, como para o conhecimento prévio de possíveis tragédias. A modelagem climática favorece a realização de estudos voltados para o planejamento de recursos hídricos e para a tomada de decisões em relação à geração de energia elétrica e outras atividades (Queiroz *et al.* 2001; Sampaio *et al.* 2007; Ávila *et al.* 2009). A previsão climática da precipitação se apresenta como um ponto importante na meteorologia, uma

vez que é uma variável associada a desastres naturais (secas e enchentes) e safras agrícolas, com impactos nos setores de turismo e transporte (Anochi 2015). Entretanto esta variável meteorológica é de difícil previsão, devido à grande variabilidade temporal e espacial (variável descontínua).

Em meio ao grande destaque que o clima e suas mudanças vêm apresentando na última década, cientistas do mundo inteiro estão procurando compreender os possíveis impactos das mudanças climáticas para a sociedade em geral (Anochi 2015).

Nesse contexto, várias ferramentas podem ser utilizadas no meio meteorológico para estimativas de precipitação pluviométrica e, dentre elas, destacam-se as Redes Neurais Artificiais (RNA), que têm apresentado resultados satisfatórios na projeção climática (Moreira *et al.* 2006; Anochi *et al.* 2009). De uma forma simples, segundo Oikawa e Ishiki (2013), as Redes Neurais Artificiais podem ser definidas como uma ferramenta estatística cujo princípio de funcionamento é regido por um modelo matemático inspirado no funcionamento dos elementos básicos que formam a estrutura neural de organismos inteligentes, que adquirem conhecimento através de experiência e, por meio do processamento de informações, gera uma saída (dados preditos) a partir de uma ou mais entradas apresentadas (preditores). As RNA são compostas por neurônios ou

unidades de processamento, que computam determinadas funções matemáticas, normalmente não lineares (Anochi 2015). Tais neurônios de processamento podem ser distribuídos em uma ou mais camadas e interligados por um grande número de conexões (pesos sinápticos), os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. Através de sucessivas apresentações dos dados de entrada e saída previamente conhecidas, a RNA aprende a relação entre elas (entrada e saída) e através de um algoritmo de minimização de erros, procura reduzir o erro quadrático médio em cada iteração do treinamento.

Devido à complexidade física dos processos de precipitação, as RNA apresentam grande potencial como ferramenta de modelagem e projeção climática, uma vez que têm sido aplicadas com sucesso a uma grande variedade de problemas, consolidando-se como uma técnica de solução de problemas complexos em reconhecimento de padrões, classificação de padrões, sistemas de controle, aproximação de funções e modelo preditivo (Anochi 2015).

Sousa e Sousa (2010) propuseram um modelo baseado em redes neurais para simular e prever vazões médias mensais na estação fluviométrica localizada na cidade de Piancó, no semiárido paraibano. Ruivo *et al.* (2015) utilizaram metodologias de mineração de dados para investigar as causas de eventos climáticos extremos: as grandes secas no Amazonas, ocorridas em 2005 e 2010, e a precipitação extrema ocorrida em Santa Catarina em 2008, em que foi possível apontar alguns parâmetros climatológicos responsáveis por tais eventos.

O objetivo do presente trabalho foi avaliar o desempenho das Redes Neurais Artificiais (RNA) para estimação da

precipitação na estação chuvosa, com base em dados de precipitação nas estações secas e chuvosas anteriores, em Diamantina-MG.

2. Materiais e métodos

O município de Diamantina está localizado na região do Espinhaço Meridional, com altitude de 1.149 m, 18°17'S de latitude e 43°34'W de longitude. Segundo a classificação climática elaborada por Nimer (1989) para Diamantina, o clima é tropical com domínio climático subsequente e subdomínio semiúmido, apresentando uma variedade climática de 4 a 5 meses secos (IBGE, 1977). As formações de vegetação predominantes na região são de Campo rupestre e Cerrado rupestre.

Os dados de precipitação diária, no período de 1977 a 2014, foram obtidos junto à estação climatológica do Instituto Nacional de Meteorologia – INMET, localizada na latitude de 18,25°S, longitude de 43,60°W e altitude de 1296,9 m. Também foram utilizados dados coletados pela estação da Agência Nacional de Águas (ANA), localizada na latitude de 17,61°S, longitude de 43,60°W (Figura 1) e altitude de 1.300 m, para completar alguns dados faltantes na série histórica do INMET durante os meses de fevereiro e março de 1979, e julho de 1990. Os dados foram referentes à precipitação diária ocorrida das 9h de um dia até às 9h do dia seguinte, conforme padronização internacional da OMM (Organização Meteorológica Mundial), ou seja, o volume precipitado em um dia (n) ocorria entre 9 h do dia anterior (n-1) e as 9 h daquele dia.

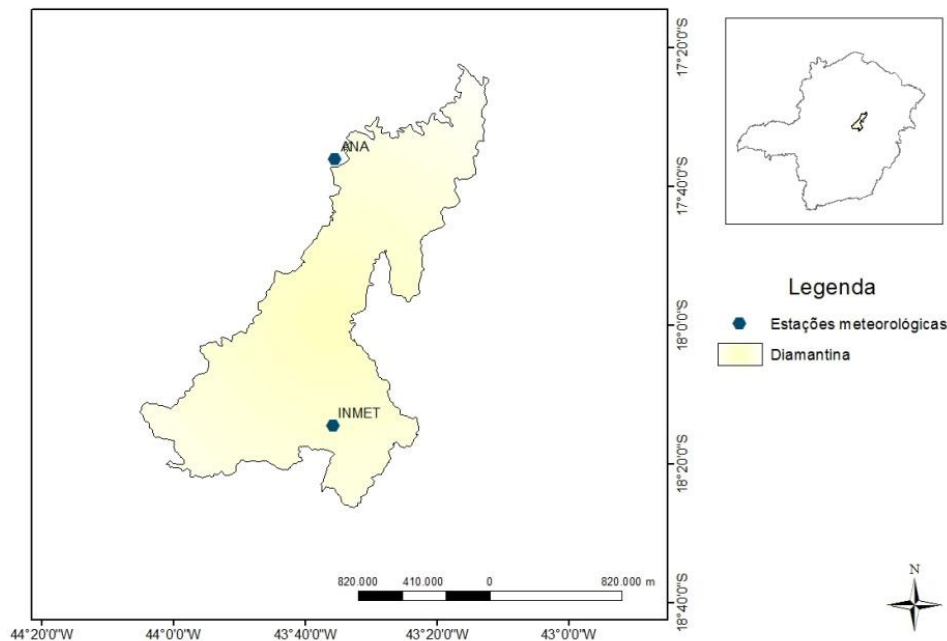


Figura 1: Localização do município de Diamantina, em Minas Gerais, e das estações meteorológicas do Instituto Nacional de Meteorologia – INMET e da Agência Nacional de Águas – ANA, em que foram coletados os dados.

Fonte: Elaboração própria

Vieira *et al.* (2010), em estudo sobre o comportamento da precipitação pluvial no período da estação chuvosa na área de estudo, observaram que a estação chuvosa é compreendida entre os meses de outubro e março, e representa 88% do total precipitado anual. Sendo assim, os dados foram divididos em dois períodos: período seco, correspondente à soma da precipitação verificada entre os meses de abril e setembro, e período chuvoso, correspondente à soma da precipitação verificada entre os meses de outubro e março.

As RNA foram treinadas no Statistica 10 (Statsoft 2014), por meio da ferramenta Automated Neural Networks (ANN), em que o conjunto de treinamento é composto por pares de entrada e saída (x,yd), sendo caracterizada previamente a saída desejada yd para um determinado valor de entrada x. O ajuste de pesos modifica a saída y de forma que a diferença entre y e yd, ou seja, o erro seja reduzido a cada interação (Oikawa e Ishiki 2013). Foi utilizada a análise do tipo séries temporais, que consiste numa rede treinada com valores de uma série temporal, ocorridos em um determinado intervalo de tempo, e com saída como sendo um valor futuro da série. Todas as redes utilizadas foram do tipo *radial basis function* com uma camada de entrada, onde os padrões são apresentados à rede; uma camada oculta, que trabalha como um reconhecedor de características que ficam armazenadas nos pesos sinápticos e são responsáveis pela maior parte do processamento; e uma camada de saída, onde os sinais de saída da rede são apresentados. A escolha do número de neurônios na camada oculta da rede foi feita de forma automatizada pela ferramenta ANN.

As RNA foram treinadas de duas maneiras: os dados de precipitação do período seco foram usados como variável de entrada para prever a precipitação no período chuvoso do mesmo ano (situação 1); e os dados de precipitação no período seco foram usados para prever a precipitação no período chuvoso do ano seguinte (situação 2). Para isso, a ordem cronológica dos dados de precipitação foi alterada, de forma que o período seco de um ano (x) estivesse relacionado com o período chuvoso do ano seguinte (x+1). Por exemplo, o período seco que vai de abril a setembro de 2010 ficou

relacionado com o período chuvoso que vai de outubro de 2011 a março de 2012.

No treinamento das redes não foram incluídos os dados de precipitação dos anos de 2010 a 2014, uma vez que estes foram utilizados exclusivamente para a validação da rede escolhida. Para cada grupo foram executadas 12 sessões de treinamento. Em cada sessão, foram treinadas 50 RNA, sendo retida a rede que apresentasse maior desempenho nos valores de treinamento, teste e validação.

A avaliação dos resultados obtidos com as RNA desenvolvidas foi feita com base no cálculo dos Erros Relativos Médios, ERM% (1) (Schaeffer 1980), histogramas com valores observados e estimados e gráficos de resíduos.

$$ERM \% = \frac{(Vest - Vobs)}{Vobs} \times 100 \quad (1)$$

em que: Vest é o valor estimado e Vobs é o valor observado.

3. Resultados e discussão

A média de precipitação no período chuvoso, considerando-se todos os anos em estudo, foi de 1.170 mm. Com um valor máximo de 1.632 mm, no ano de 1991, e mínimo de 445 mm, no ano de 1982. Para o período seco, a média de precipitação foi de 159,1 mm. Com valor máximo de 365 mm e mínimo de 58 mm, para os anos de 1981 e 1987, respectivamente.

Após o treinamento das RNA, a predição dos períodos chuvosos gerou uma estimativa média de 1.145 mm, na situação 1, em que foram utilizados os dados de precipitação do período seco para prever a precipitação no período chuvoso do mesmo ano. Nesse caso, o Erro Relativo Médio (ERM%) foi de 15,99 %. Tendo sido encontrado um ERM% máximo de 33,19 %, em 2014, em que a rede estimou uma precipitação de 1345,6 mm e o valor observado foi de 899 mm (Figura 2). O ERM % mínimo foi de 0,86 %, no ano de 1997, com valores de precipitação estimado e observado de 1093,6 mm e 1103,0 mm, respectivamente (Figura 2).

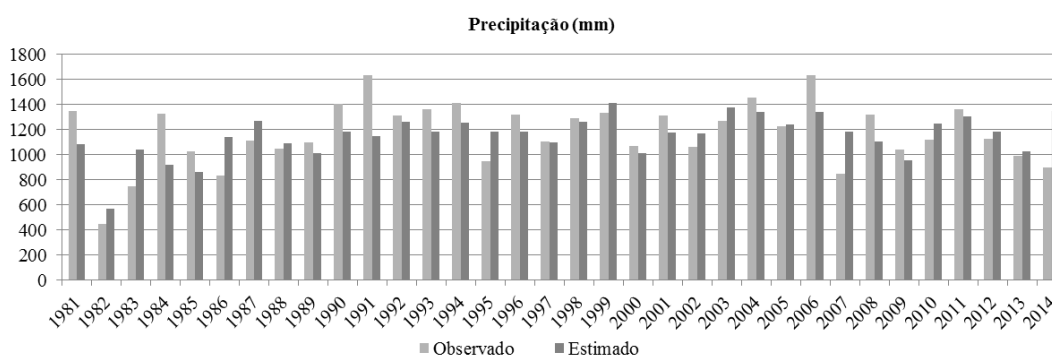


Figura 2: Precipitação observada e estimada por RNA utilizando-se dados de precipitação do período seco para prever a precipitação no período chuvoso do mesmo ano.

Fonte: Elaboração própria

Já na situação 2, em que as redes foram treinadas utilizando-se os dados de precipitação no período seco para prever a precipitação no período chuvoso do ano seguinte, a

RNA apresentou uma estimativa média de 1.160,7 mm, valor bem próximo do real (1.170 mm), e ERM% de 13,36 %. Com ERM% máximo de 54,6 %, em 1982, ano em que se observou

uma grande variação no volume precipitado (445 mm) e, apesar do alto erro obtido, a rede conseguiu acompanhar essa variação e apresentou uma baixa estimativa de precipitação no período (688 mm) (Figura 3). O ERM% mínimo foi de

0,56 %, no ano de 1992, com valores de precipitação estimado e observado de 1307 mm e 1.299,6 mm, respectivamente (Figura 3).




Figura 3: Precipitação observada e estimada por RNA utilizando-se dados de precipitação no período seco para prever a precipitação no período chuvoso do ano seguinte.
Fonte: Elaboração própria

A relação existente entre as precipitações observadas e estimadas na situação 1 mostrou um coeficiente de correlação linear $r = 0,67$ indicando uma correlação moderada, enquanto na situação 2 verificou-se uma forte correlação, com um coeficiente de correlação linear $r = 0,81$.

Isto mostra que as RNA apresentaram resultados satisfatórios e conseguiram descrever as variações na precipitação ao longo do período estudado, tendo como variável de entrada apenas dados de períodos secos anteriores. No entanto, verifica-se uma ligeira tendência de suavização destas variações, uma vez que em períodos muito secos ou muito chuvosos houve um maior ERM.

Considerando-se os dados do período utilizado apenas para aplicação das RNA (de 2010 a 2014), a média de precipitação no período chuvoso foi de 1.099 mm, enquanto que as redes apresentaram estimativas médias, no mesmo período, de 1.221 mm na situação 1, e 1.128 mm na situação 2 que, novamente, apresentou um valor médio bem próximo

do real. As RNA apresentaram um erro percentual médio de, 11 e 10 %, para as situações 1 e 2, respectivamente

O uso de RNA como modelos de previsões meteorológicas foi aplicado em vários estudos, apresentando resultados satisfatórios, dentre os quais se podem citar Srivastava *et al.* (2010); Talei *et al.* (2010) e Wu *et al.* (2010), mostrando seu potencial nesta área de estudo. Zhang *et al.* (1997) e Menezes *et al.* (2015), que em estudos com redes neurais artificiais para a predição de chuvas também obtiveram estimativas com ERM de 10 %. O ERM% máximo foi de 33 % para a situação 1 (Figura 4) e 19 % para a situação 2 (Figura 5); já o ERM% mínimo foi de 3,5 % para ambas as situações (Figuras 4 e 5). Isto mostra que a alteração na ordem cronológica dos dados, realizada neste estudo, resultou em uma leve melhoria no desempenho das redes treinadas.




Figura 4: Precipitação observada e estimada por RNA utilizando-se dados de precipitação no período seco para prever a precipitação no período chuvoso do mesmo ano. E erro percentual da estimativa.
Fonte: Elaboração própria




Figura 5: Precipitação observada e estimada por RNA utilizando-se dados de precipitação no período seco para prever a precipitação no período chuvoso do ano seguinte. E erro percentual da estimativa.

Fonte: Elaboração própria

Em síntese, pode-se dizer que o problema de prever a precipitação pluviométrica não é uma tarefa simples de se modelar matematicamente, uma vez que as variáveis que causam o fenômeno são altamente não lineares e apresentam comportamento complexo. As variações meteorológicas, especialmente a precipitação em um curto espaço de tempo ao longo dos anos, não têm tendência definida. No entanto, é possível verificar um desempenho satisfatório das RNA treinadas para estimação do período chuvoso, uma vez que diversos fatores influenciam na dinâmica da chuva ao longo dos anos e, ainda assim, a RNA apresentou ERM% de 10% na estimação de períodos chuvosos tendo como variável de entrada no treinamento apenas as informações de precipitação no período de estiagem de anos anteriores. Com a inclusão de mais variáveis, é possível que sejam obtidas estimativas ainda mais precisas. Sendo assim, as RNA apresentam um potencial de se tornarem uma importante ferramenta na estimação de variáveis climáticas.

4. Conclusões

As Redes Neurais Artificiais conseguem descrever as variações na precipitação ao longo do período estudado embora apresente uma leve tendência de suavização destas variações. A utilização de dados dos períodos secos e chuvosos para estimar a precipitação no período chuvoso apresenta resultados satisfatórios e a alteração na ordem cronológica do período seco resultou em uma rede com previsão mais eficaz.

5. Agradecimento

À Fundação de Amparo à Pesquisa do estado de Minas Gerais – FAPEMIG, pelo apoio financeiro.

REFERÊNCIAS

Andrade ARS, Freitas JC, Brito JIB, Guerra HOC, Xavier JF. 2009. Aplicação da probabilidade condicional e do processo de cadeia de Markov na análise da ocorrência de períodos

secos e chuvosos para o município de Garanhuns, PE, Brasil. *Ambiente e água*, Taubaté 4 (1): 169-182.

Anochi JÁ, Silva JDS. 2009. Uso de redes neurais artificiais e teoria de conjuntos aproximativos no estudo de padrões climáticos sazonais. *Revista da Sociedade Brasileira de Redes Neurais* 7 (2): 83-91.

Anochi JÁ. 2015. *Previsão climática de precipitação por redes neurais autoconfiguradas*. Tese (Doutorado em Computação Aplicada), Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

Ávila LF, Mello CR, Viola MR. 2009. Mapeamento da precipitação mínima provável para o sul de Minas Gerais. *Revista Brasileira de Engenharia Agrícola e Ambiental*, Campina Grande, v. 13, p. 906-915.

Castro R. 1994. *Distribuição probabilística da frequência de precipitação na região de Botucatu-SP*. Dissertação (Mestrado em Agronomia), Universidade Estadual Paulista, Botucatu-SP.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. Geografia do Brasil: Região Sudeste. Rio de Janeiro: IBGE, 1977.

Menezes PL, Azevedo CAV, Eyng E, Dantas Neto J, Lima VLA. 2015. Artificial neural network model for simulation of water distribution in sprinkle irrigation. *Revista Brasileira de Engenharia Agrícola e Ambiental*, Campina Grande, v. 19, n. 9, p. 817-822.

Moreira MC, Cecilio RA, Pinto FAC, Pruski FF. 2006. Desenvolvimento e análise de uma rede neural artificial para estimativa da erosividade da chuva para o estado de São Paulo. *Revista Brasileira de Ciência do Solo*, Viçosa, v. 30, p. 1069-1076.

Nimer E. 1989. *Climatologia do Brasil*. IBGE: Rio de Janeiro.

Oikawa RT, Ishiki HM. 2014. Modelos estatísticos e de redes neurais artificiais utilizados na previsão de precipitação. *Periódico Eletrônico Fórum Ambiental da Alta Paulista*, São Paulo 9 (8): 19-34.

- Queiroz EF, Silva RJB, Oliveira MCN. 2001. Modelo de análise de regressão periódica da precipitação mensal, da bacia atlântico sudeste, no Paraná. *Pesquisa Agropecuária Brasileira*, Brasília **36** (5): 727-742.
- Ruivo H, Campos Velho H, Sampaio G, Ramos F. 2005. Analysis of extreme precipitation events using a novel data mining approach. *American Journal of Environmental Engineering* **5** (1):96-105.
- Sampaio SC, Longo A J, Queiroz MMF, Gomes BM, Boas MAV, Suszek M. 2007. Estimativa e distribuição de precipitação decendiais para o estado do Paraná. *Irriga*, Botucatu **12** (1): 38-53.
- Schaeffer DL. 1980. A model evaluation methodology applicable to environmental assessment models. *Ecological Modelling, Tennessee*. **8**: 275-295.
- Sousa W, Sousa F. 2010. Rede neural artificial aplicada à previsão de vazão da bacia hidrográfica do Rio Piancó. *Revista Brasileira de Engenharia Agrícola e Ambiental*. **14** (2): 173-180.
- Srivastava G, Panda SN, Mondal P, Liu J. 2010. Forecasting of rainfall using ocean-atmospheric indices with a fuzzy neural technique. *Journal of Hydrology* **395** (3-4): 190-198.
- Talei A, Chua LHC, Quek C. 2010. A Novel Application of a Neuro-Fuzzy Computational Technique in Event-Based Rainfall-Runoff Modeling. *Expert Systems with Applications* **37** (12): 7456-7468.
- Wu CL, Chau KW, Fan C. 2010. Prediction of Rainfall Time Series Using Modular Artificial Neural Networks Coupled with Data-Preprocessing Techniques. *Journal of Hydrology* **389** (1-2):146-167.
- Zhang M, Fulcher J, Scofield RA. 1997. Rainfall estimation using artificial neural network group. *Neurocomputing* **16** (2): 97-115.

Use of Artificial Neural Networks in precipitation forecasting of rainy season

Daniel Dantas ¹
Tarço Murilo Oliveira Luz ²
Maria José Hatem de Souza³
Gabriela Paranhos Barbosa⁴
Eduarda Gabriela Santos Cunha⁵

¹ Forestry Engineer (UFVJM).

² Forest Engineer (UFV). Master in Forest Engineering (UFVJM).

³ Agricultural Engineer (UFV). Master in Agricultural Meteorology (UFV). Doctorate in Agricultural Engineer (UFV). Professor at UFVJM.

⁴ Forest Engineer (UFVJM). Master in Forest Engineering (UFVJM). Graduate student in Forest Engineering (UFVJM).

⁵ Forest Engineer (UFV). Master in Forest Engineering (UFVJM).

Abstract This study aims to estimate the precipitation in the rainy season in Diamantina (MG) based on precipitation of dry previous seasons, by using Artificial Neural Networks (ANN). The chronological order of the data was changed so that the dry season of and year was related to the rainy season of the next year. A part of the data was used in the ANN training and other part used to evaluate the performance of it. The used analysis was time series and the best network found was of radial basis function type. The ANN found showed an average of error of 10%. The average precipitation of the period used in application of the network was of 1099 mm, while the average estimation was 1128 mm. The use of dry season's data to estimate the precipitation of the rainy season presented satisfactory results and, the change of the chronological order of the dry period result in a neural network with more effective forecasting despite the unchanged one.

Keywords: Climatic sceneries, climate modeling, weather forecasting.

Informações sobre os autores

Daniel Dantas

Endereço para correspondência: Campus JK. Rodovia MGT 367 - Km 583, nº 5000. Alto da Jacuba CEP 39100-000. - Diamantina/MG.

E-mail: dantasdaniel12@yahoo.com.br

Link para o currículo lattes: <http://lattes.cnpq.br/3905001239237950>

Tarço Murilo Oliveira Luz

Endereço para correspondência: Campus JK. Rodovia MGT 367 - Km 583, nº 5000. Alto da Jacuba CEP 39100-000. - Diamantina/MG.

E-mail: tarcomurilo@gmail.com

Link para o currículo lattes: <http://lattes.cnpq.br/9229295573210338>

Maria José Hatem de Souza

Endereço para correspondência: Campus JK. Rodovia MGT 367 - Km 583, nº 5000. Alto da Jacuba CEP 39100-000. - Diamantina/MG.

E-mail: mariahatem@yahoo.com.br

Link para o currículo lattes: <http://lattes.cnpq.br/7970272190518262>

Gabriela Paranhos Barbosa

Endereço para correspondência: Campus JK. Rodovia MGT 367 - Km 583, nº 5000. Alto da Jacuba CEP 39100-000. - Diamantina/MG.

E-mail: barbosa_gabriella@hotmail.com

Link para o currículo lattes: <http://lattes.cnpq.br/3456687357556594>

Eduarda Gabriela Santos Cunha

Endereço para correspondência: Campus JK. Rodovia MGT 367 - Km 583, nº 5000. Alto da Jacuba CEP 39100-000. - Diamantina/MG.

E-mail: eduardagscunha@gmail.com

Link para o currículo lattes: <http://lattes.cnpq.br/0911836384314320>

Artigo Recebido em: 06/05/2016

Artigo Aprovado em: 07/07/2016