

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NO PREENCHIMENTO DE FALHAS DE PRECIPITAÇÃO MENSAL NA REGIÃO SERRANA DO ESPÍRITO SANTO

Tamíres Partélli CORREIA¹; Rafael Esteves DOHLER²; Carlos Silva DAMBROZ³; Daniel Henrique Breda BINOTI⁴

(1) Doutoranda na Universidade Federal Rural do Rio de Janeiro, Programa de Pós Graduação em Ciências Ambientais e Florestais, BR 465, km7, UFRRJ, Instituto de Florestas CEP: 23.890-000 Seropédica - RJ. Endereço eletrônico: tamirespartelli@gmail.com

(2) Mestre em Ciências Florestais, Programa de Pós-Graduação em Ciências Florestais da Universidade Federal do Espírito Santo (UFES), Departamento de Ciências Florestais e da Madeira. Avenida Governador Lindemberg, 316, CEP: 25550-000. Jerônimo Monteiro - ES. Endereço eletrônico: rafaelesteves_123@hotmail.com

(3) Prof. do Instituto Federal Fluminense (IFF), *campus* Bom Jesus do Itabapoana. Av. Dário Vieira Borges, 235, CEP: 28360-000. Bom Jesus do Itabapoana - RJ. Endereço eletrônico: csdenf@gmail.com

(4) Pós Doutorando Programa de Pós-Graduação em Ciências Florestais da Universidade Federal do Espírito Santo (UFES), Departamento de Ciências Florestais e da Madeira. Avenida Governador Lindemberg, 316, CEP: 25550-000. Jerônimo Monteiro - ES. Endereço eletrônico: danielhbbinoti@gmail.com

Introdução
Materiais e Métodos
Resultados e Discussão
Conclusão
Agradecimentos
Referências

RESUMO - A qualidade dos dados meteorológicos influencia diretamente o planejamento e a gestão do manejo nas bacias hidrográficas, modelagem hidrológica, qualidade do ar, monitoramento de incêndios florestais. Assim, séries com falhas de precipitação pluvial inviabilizam a execução de muitos estudos na área agrícola. O objetivo desta pesquisa é testar a metodologia de Redes Neurais Artificiais (RNAs) para o preenchimento de falhas em séries mensais de dados de precipitação pluvial. Utilizou-se uma série de dados pluviométricos mensais de quatro estações na bacia do rio Doce, localizada na região serrana do estado do Espírito Santo. Foram admitidas a existência de três diferentes porcentagens de falhas na estação de Itarana, sendo 7, 15 e 30%, realizando sete simulações de preenchimento para cada tipo de falha. A utilização de RNAs no cálculo de preenchimento de falhas em dados mensais de pluviosidade foi eficaz com 7% de falha nos dados, apresentando valores de NSE e R^2 superiores a 0,8. A aplicação das mesmas redes em banco de dados com falhas de 15 e 30%, não foi satisfatório. O resultado da aplicação de RNAs em preenchimentos de falhas em dados de precipitação foi eficiente, o que contribui para estudos que necessitam de séries climáticas confiáveis.

Palavras-Chave: Dupla massa, falhas de precipitação, redes neurais artificiais.

ABSTRACT - The quality of meteorological data directly influences the planning and management of management in river basins, hydrological modeling, air quality, monitoring of forest fires. Thus, the flaws in precipitation series make it impossible to achievement many studies in agriculture. The objective of this research is to test the methodology of artificial neural networks (ANN) to fill flaws in monthly series of rainfall data. Was used a series of monthly rainfall data from four stations in the basin of Rio Doce, located in the mountainous region of the state of Espirito Santo. Were admitted the existence of three different types of failures Itarana station, around 7, 15 and 30%, performing seven filling simulations for each type of failure. The use of RNAs for fill flaws in calculation in monthly rainfall data was effective with 7% of the flawed data, presenting NSE and R^2 values greater than 0.8. The implementation of these networks in database failed 15 to 30%, is not recommended. The result of applying RNAs for fills flaws in data precipitation was satisfactory, contributing to studies that require reliable climatic series.

Keywords: Double mass, precipitation gaps, artificial neural network.

INTRODUÇÃO

O estudo dos padrões e tendências climáticas permite caracterizar as causas de mudanças significativas no ambiente, que influenciam diversas atividades humanas e o equilíbrio dos ecossistemas. A qualidade dos resultados esperados nesses estudos está diretamente relacionada à disponibilidade de séries de

precipitação, sua qualidade e homogeneidade espacial e temporal, distribuição espacial, dinâmicas de fenômenos climatológicos e qualidade dos modelos utilizados para o preenchimento de dados faltantes (Depiné et al., 2013).

A necessidade de um efetivo controle de qualidade é comprovada por qualquer experiência em processamento de dados meteorológicos observacionais. Os dados são parcialmente afetados por digitação ou erros de codificação, mau funcionamento dos instrumentos e outras modificações que ocorrem entre a sua observação até o seu registro final, tais erros podem ter influência relevante sobre os resultados da análise (Radi et al., 2015).

Schneider (2005) classificou os erros em dois tipos: i) sistemáticos e de ii) amostragem. O Erro Sistemático de medição calibre está relacionado com as características do instrumento, como forma, tamanho, altura do solo, face de exposição, com as condições meteorológicas durante o evento da precipitação, que pode ser o tipo da precipitação, velocidade do vento, temperatura e umidade do ar, radiação, como também as fórmulas para correção das calibrações. Já o erro de amostragem tem sido estudado usando densas redes da Austrália, Canadá, Finlândia, Alemanha e EUA, e depende das características e condições climáticas e fisiográficas.

A Organização Meteorológica Mundial (OMM) criou em 1989 o Centro de Climatologia Global de Precipitação (GPCC), que é operada pelo Serviço Meteorológico Nacional da Alemanha e mantém até hoje uma base de dados de precipitação de 176 países, com objetivo de desenvolver uma base suficiente para análise das estruturas espaciais de precipitação. O resultado desses dados já está sendo utilizado em várias instituições em nível mundial, por exemplo, em diversos projetos relacionados a OMM, FAO (Organização das Nações Unidas para Agricultura e Alimentação), UNESCO (Organização das Nações Unidas para a Educação, a Ciência e a Cultura) e do PNUMA (Programa das Nações Unidas para o Meio Ambiente). Essa iniciativa mostra a preocupação global por um banco de dados climáticos confiáveis e denota a importância de se conhecer o padrão dessas variáveis ao longo do tempo para realização de projetos nas diversas áreas citadas (Eischeid et al., 1995).

Existem vários métodos de preenchimento de falhas encontrados na literatura: dupla

massa, resíduo acumulado, teste run, ponderação regional e ponderação com regressão (Bertoni & Tucci, 2007), polígono de Thiessen, vetor regional, regressão linear múltipla (Oliveira et al., 2010), métodos de interpolação espacial e mais recentemente o uso de Redes Neurais Artificiais (RNA) (Lucio et al., 2006; Carvalho, 2007). Não existe o melhor método de preenchimento de falhas, existe o método que melhor se adequa aos dados de uma determinada condição climática, por isso é necessário o teste de vários métodos juntamente com sua avaliação estatística.

As redes neurais artificiais são modelos que buscam simular o funcionamento do cérebro humano, com complexo sistema neural biológico. As RNAs são sistemas formados por unidades de processamento com interconexão, dispostos em camadas paralelas entre si, que são responsáveis pela memória, essas unidades são chamadas de neurônios. A alusão das RNAs com os neurônios biológicos é feita de forma bem simples, utilizando uma regra de propagação e uma função de ativação, ponderadas por pesos sinápticos (Valença, 2010).

O uso de redes neurais artificiais tem sido utilizado em diversas áreas das ciências florestais: prognose da produção de povoamentos (Binotiet al., 2010), ajuste de modelo para estimar volume de espécies florestais (Silva et al., 2009), taper (Leite et al., 2010), modelo de afilamento de cerne (Leite et al., 2011), estimativa da altura de povoamentos equiâneos de eucalipto (Binoti et al., 2013a), modelagem da distribuição de diâmetros (Binoti et., al 2013b), estimação do volume docerne (Souza, 2014), preenchimento de falhas de chuvashorárias (Depiné et al., 2013), detecção de outliers em dados micrometeorológicos (Ventura et al., 2013), interpolação espacial de dados meteorológicos (Wanderley et al., 2011), previsão de vazões (Silva, 2011; Sousa & Sousa, 2010), modelagem hidrológica urbana (Santos & Filho, 2003) entre outras aplicações.

Com isso, o objetivo do trabalho é testar o uso de Redes Neurais Artificiais (RNAs) para o preenchimento de falhas em séries mensais de precipitação pluvial.

MATERIAIS E MÉTODOS

Para se proceder ao preenchimento de falhas utilizando as redes neurais artificiais, selecionaram-se 4 estações pluviométricas da Agência Nacional de Águas (ANA), localizadas na região serrana do Estado do Espírito Santo inseridas na bacia do rio Doce. Na Tabela 1

encontram-se as estações selecionadas, o número de identificação das estações, os municípios, as coordenadas geográficas, as altitudes e os anos de registro extraídos do Hidro Web.

Tabela 1. Estações pluviométricas da Agência Nacional de Águas empregadas no estudo.

Legenda	Município	Nome	Identificação ANA	Latitude	Longitude	Altitude (m)	Anos das séries
LDT	Afonso Cláudio	Laranja da Terra	1941008	19°54'4''	41°3'29''	250	1947 - 2014
ITG	Itaguaçu	Itaimbé	1940012	19°39'49''	40°50'7''	70	1957 - 2014
ITR	Itarana	Itarana	1940000	19°52'28''	40°52'28''	165	1947 - 2014
STP	Santa Teresa	São João de Petrópolis	1940001	19°48'19''	40°40'44''	150	1947 - 2014

As distâncias radiais entre as estações medidas sobre a superfície da Terra variam entre 19,5 e 23,7 km, entre as estações de Itarana e Afonso Cláudio (Laranja da Terra), Itarana e Itaguaçu (Itaimbé), respectivamente. Como os anos de observação das estações selecionadas são variáveis, foram selecionados os anos comuns de registros pluviométricos perfazendo, assim, as séries de totais mensais com 31 anos de observações.

Com o intuito de se verificar a homogeneidade das séries mensais de precipitação pluvial, fez-se a análise de consistência para cada estação isoladamente, empregando-se a metodologia da dupla massa descrita por Bertoni & Tucci (2007). Este método consiste em selecionar a estação de interesse e as estações mais próximas, no qual os totais mensais acumulados onde se pretende avaliar a consistência dos dados são plotados no eixo das ordenadas e os totais mensais das demais estações nas abscissas. É considerada consistência dos dados, quando os totais mensais da estação analisada apresentar uma tendência linear em relação às estações vizinhas. Neste caso, é avaliado o ajuste da equação da reta e do coeficiente de determinação para se verificar a linearidade entre os totais da estação analisada com relação às demais.

Admitiu-se a existência de possíveis falhas na estação de Itarana, na ordem de 7, 15 e 30%.

Foram realizadas combinações para o preenchimento de falhas para Itarana, sendo uma à uma (Itarana com cada estação vizinha), uma à duas (Itarana com 2 estações vizinhas) e uma à três (Itarana com todas as estações vizinhas, totalizando assim, sete simulações para cada tipo de falha (Tabela 2).

Uma rede neural pode ser definida como uma estrutura composta por um conjunto de neurônios artificiais interconectados, sendo que cada neurônio tem uma função de ativação específica. A rede Perceptron de Múltiplas Camadas (MLP) é uma generalização da rede Perceptron simples, pela adição de pelo menos uma camada intermediária (camada oculta) como mostra a Figura 1 (VALENÇA, 2010).

Para o preenchimento das falhas, foram utilizadas nesse trabalho redes neurais do tipo MLP com a utilização do algoritmo de treinamento de Levenberg-Marquardt, juntamente com as funções de ativação Sigmoidais para camada oculta e saída. Utilizou-se uma rede com 8 neurônios na camada oculta. A fase de treinamento, validação e teste das redes neurais tinha como dados de entrada as precipitações das estações de Laranja da Terra, Itaimbé e São João de Petrópolis. A variável mês foi utilizada como entrada categórica e a precipitação de Itarana como saída. Na seleção dos dados, utilizou-se uma amostragem aleatória em que 70% dos dados foram usados para treinar e 30% usados

para validar a rede neural. A descrição da Tabela 2. arquitetura das redes neurais utilizadas está na

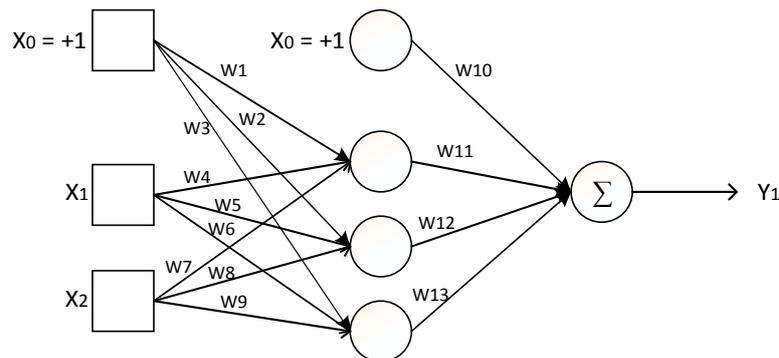


Figura 1. Exemplo da arquitetura MLP.

Foram realizadas análises de correlação, regressão linear simples e cálculos de índices estatísticos. A análise de regressão linear foi usada para obtenção dos coeficientes β_0 e β_1 da equação ($Y = \beta_0 + \beta_1 X$) e do coeficiente de correlação (R^2). Os índices estatísticos calculados foram o percentual de tendência (PBIAS) (Equação 1) e o coeficiente de eficiência de Nash e Sutcliffe (NSE) (Equação 2) com base nas seguintes equações (Nash; Sutcliffe, 1970; Gupta; Sorooshian, 1998):

em que:

n = número de observações;

$Y_{i\text{obs}}$ = valores observados;

$Y_{i\text{est}}$ = valores estimados.

$$NSE = 1 - \frac{\sum_{i=1}^n (Y_{i\text{obs}} - Y_{i\text{est}})^2}{\sum_{i=1}^n (Y_{i\text{obs}} - Y_{i\text{média}})^2} \quad (2)$$

$$PBIAS = \frac{\sum_{i=1}^n (Y_{i\text{obs}} - Y_{i\text{est}})}{\sum_{i=1}^n (Y_{i\text{obs}})^2} \cdot 100 \quad (1)$$

Tabela 2. Descrição das redes neurais artificiais utilizadas para o cálculo de preenchimento de falhas de precipitação mensal na estação de Itarana.

RNA	Falha (%)	Arquitetura	Variáveis de entrada		Variável de saída
			Quantitativa	Qualitativa	
1		14-8-1	STP	Mês	ITR
2		14-8-1	LDT	Mês	ITR
3		14-8-1	ITG	Mês	ITR
4	7	15-8-1	STP, LDT	Mês	ITR
5		15-8-1	STP, ITG	Mês	ITR
6		15-8-1	LDT, ITG	Mês	ITR
7		16-8-1	STP, LDT, ITG	Mês	ITR
8		14-8-1	STP	Mês	ITR
9		14-8-1	LDT	Mês	ITR
10		14-8-1	ITG	Mês	ITR
11	15	15-8-1	STP, LDT	Mês	ITR
12		15-8-1	STP, ITG	Mês	ITR
13		15-8-1	LDT, ITG	Mês	ITR
14		16-8-1	STP, LDT, ITG	Mês	ITR
15		14-8-1	STP	Mês	ITR
16		14-8-1	LDT	Mês	ITR
17		14-8-1	ITG	Mês	ITR
18	30	15-8-1	STP, LDT	Mês	ITR
19		15-8-1	STP, ITG	Mês	ITR
20		15-8-1	LDT, ITG	Mês	ITR
21		16-8-1	STP, LDT, ITG	Mês	ITR

RESULTADOS

A homogeneidade regional das estações pluviométricas foi avaliada pelo método da Curva de Dupla Massa (Bertoni & Tucci, 2007). A partir dessa análise foi possível proceder com

o trabalho de preenchimento de falhas, uma vez que as quatro estações se encontraram em uma região homogênea quanto ao índice pluviométrico (Figura 2).

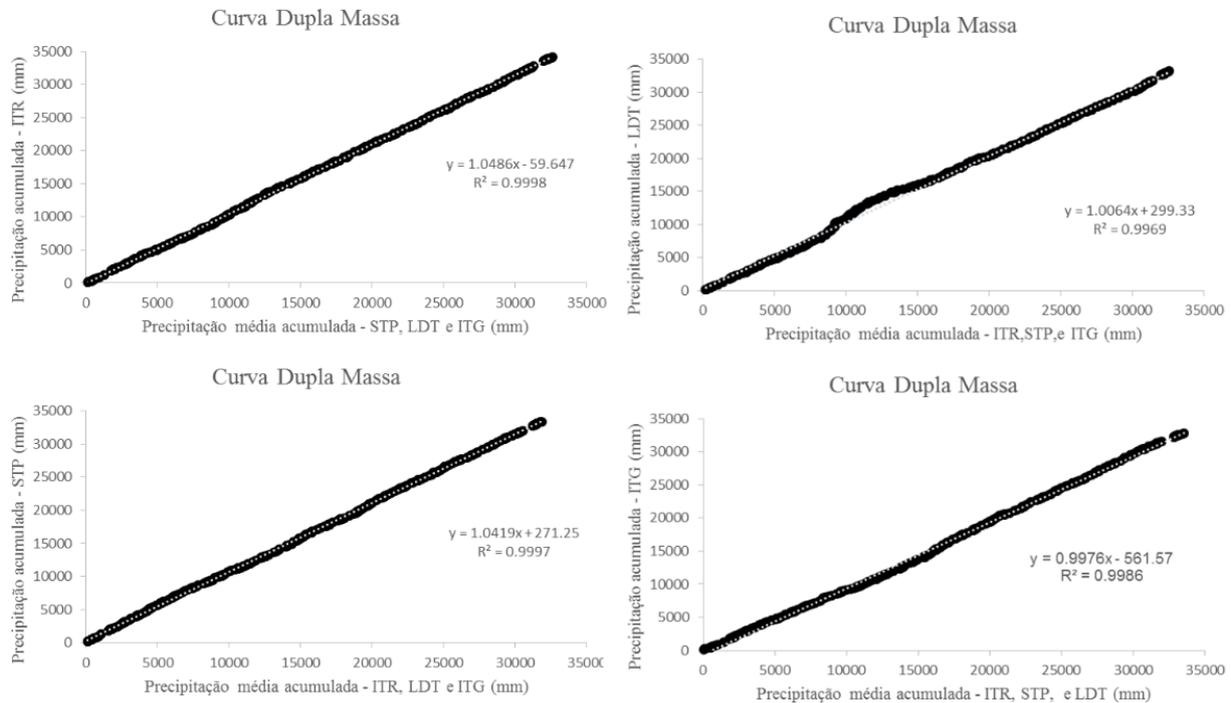


Figura 2. Curva de Dupla Massa da precipitação mensal acumulada, para as estações pluviométricas avaliadas, no período de 31 anos (1984-2015). ITR: Itarana; STP: Santa Tereza; LDT: Afonso Cláudio; ITG: Itaguaçu. Linha de tendência pontilhada cinza.

Considerando que para o treinamento das redes variaram-se apenas os dados de entrada (variável quantitativa) e o número de neurônios na camada de entrada, a utilização de RNAs no cálculo de preenchimento de falhas em dados mensais de pluviosidade se mostrou eficaz dependendo da proporção de falhas encontradas no banco de dados (Figura 3).

A estimativa de valores de pluviosidade mensal em banco de dados com 7% de falha por meio de RNAs foi eficiente, independente dos dados de entrada avaliados nesse caso (Tabela 3), não importando o número ou a combinação de estações pluviométricas utilizadas como variáveis quantitativas de entrada. Assim, no caso de preenchimento de falhas de 7% nos dados observados, bastaria selecionar apenas uma estação próxima à estação com falhas (quando se tratar de uma estação localizada em região homogênea, determinada previamente pelo teste de dupla

massa) para a estimativa do valor faltante. Dessa forma, seria aplicada uma metodologia mais rápida demandando menor esforço na obtenção de dados pluviométricos em mais de uma estação.

Os melhores valores de NSE foram encontrados quando as redes foram aplicadas aos dados com 7% de falha. Nesse caso, todos os valores de NSE foram superiores a 0.80, o que caracteriza uma estimativa muito boa (Collischonn, 2001). Da mesma forma, os valores R^2 foram superiores a 0.80, demonstrando o bom ajuste entre os dados estimados pela rede e o medido na estação pluviométrica. Os valores de PBIAS foram muito próximos de zero, o que caracteriza a falta de tendências em superestimar ou subestimar os valores mensais de precipitação. As redes 3 e 7 (variáveis de entrada: ITG e a combinação das estações STP, LDT e ITG, respectivamente) apresentaram os melhores

ajustes de dados quando comparado aos dados observados (Tabela 3).

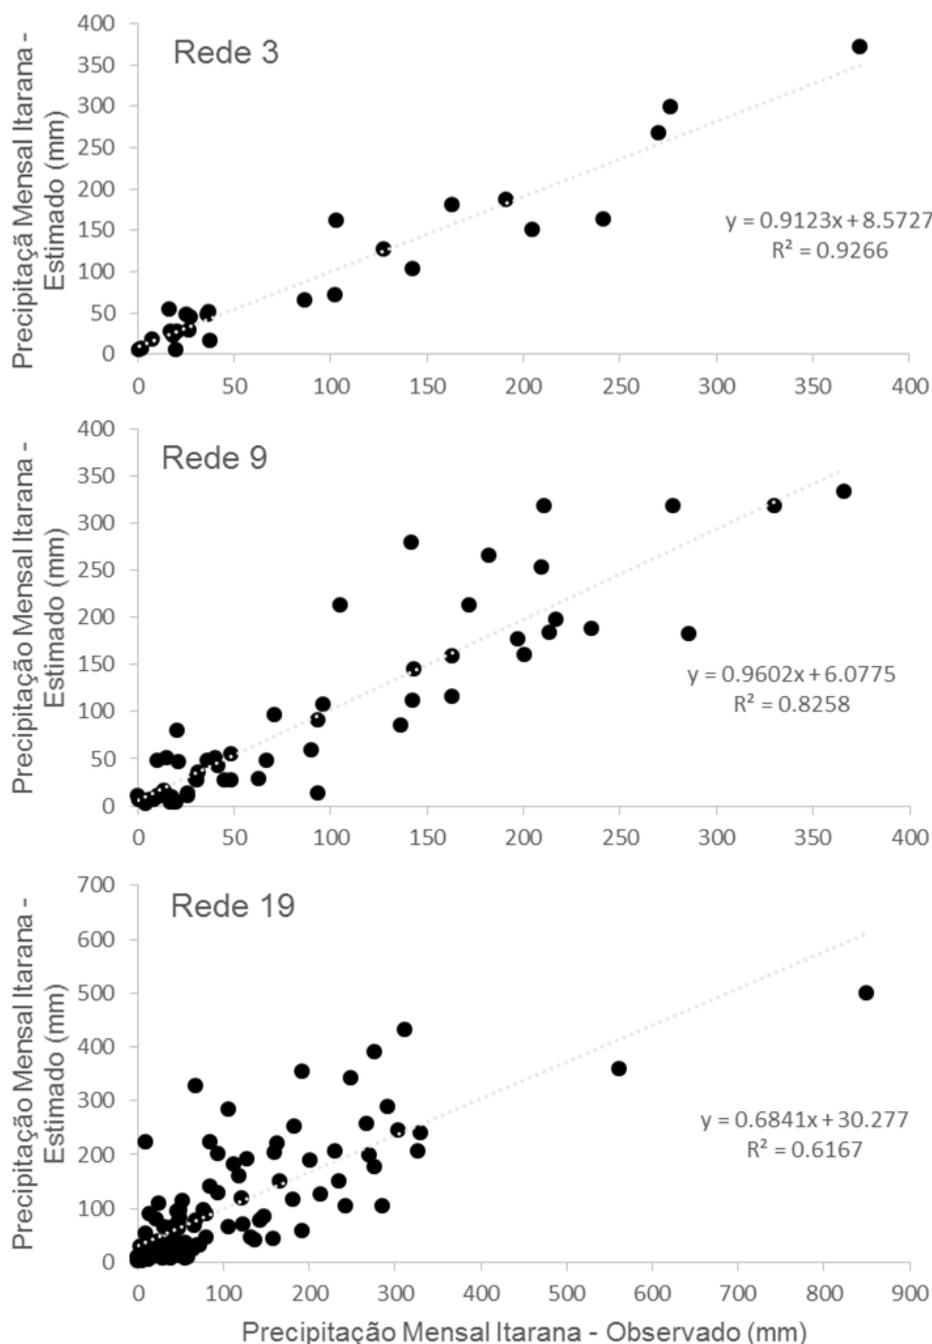


Figura 3. Valores observados e estimados de precipitação mensal na estação de Itarana das melhores RNAs aplicadas em condições de 7%, 15% e 30% de falhas (rede 3, 9 e 19 respectivamente).

A aplicação da mesma configuração das redes em banco de dados com falhas de 15 e 30% não se mostrou tão eficaz, apesar de não apresentarem tendências nas estimativas (PBIAS para todas as redes foi próximo à zero). O uso dessas redes não se mostrou eficiente quando se utilizaram as 3 estações pluviométricas do entorno da estação avaliada (Itarana), porém em alguns casos, o uso de apenas uma estação foi suficiente e eficaz na estimativa.

Quando aplicadas aos dados com 15% de falha, as redes 9,10,12 e 13 apresentaram valores do NSE superior a 0, que é considerado como aceitável (Moriassi et al., 2007), porém nessa faixa de falhas, as redes apresentaram um rendimento pior quando comparadas com dados com 7% de falha. A rede 9 apresentou melhores valores para o ajuste entre os dados observados e estimados (NSE = 0.803 e $R^2 = 0.825$), sendo essa caracterizada pelo uso de dados da estação LDT e 14 neurônios na camada de entrada.

Tabela 3. Estatística do desempenho das RNAs no preenchimento de falhas de dados mensais de precipitação na estação de Itarana. Onde: PBIAS – Percentual de tendência; NSE – Coeficiente de eficiência de Nash e Sutcliffe; R^2 - Coeficiente de determinação; β_0 – Intercepto; β_1 – Inclinação da reta.

RNA	Falha (%)	PBIAS	NSE	R^2	β_1	β_0
1		0.000	0.872	0.868	0.819	12.550
2		0.001	0.956	0.918	0.882	8.819
3		0.000	0.962	0.926	0.912	8.572
4	7	0.000	0.848	0.742	0.888	20.623
5		0.000	0.873	0.820	1.051	-2.421
6		0.000	0.883	0.807	0.953	-4.667
7		0.000	0.957	0.918	0.921	2.753
8		-0.146	-1.220	0.331	1.030	22.920
9		-0.013	0.803	0.825	0.960	6,07
10		0.038	0.603	0.644	0.793	12.610
11	15	-0.200	-1.170	0.420	1.200	16.980
12		0.030	0.687	0.691	0.716	20.940
13		0.018	0.462	0.598	0.882	7.757
14		0.080	-0.528	0.150	0.469	35.130
15		0.001	0.237	0.306	0.441	42.978
16		-0.001	-0.583	0.172	0.519	75.343
17		0.000	0.460	0.545	0.759	21.643
18	30	-0.001	-0.228	0.255	0.590	65.469
19		0.000	0.609	0.617	0.684	30.277
20		-0.001	0.068	0.389	0.730	45.053
21		-0.030	0.030	0.338	0.659	40.941

Diante do um banco de dados com 30% de falhas, duas redes (16 e 18) apresentaram desempenho inaceitável na estimativa da precipitação mensal. Neste caso, a rede 19 (variáveis de entrada: STP e ITG) apresentou o melhor desempenho com NSE e R^2 de 0.609 e 0.617, respectivamente. Seguida pela rede 17 (variável de entrada ITG) com valores de NSE e R^2 de 0.460 e 0.545, respectivamente. Dessa

forma, a adição de uma variável de entrada apresentou aumento na eficiência da rede.

Portanto, em banco de dados onde a porcentagem de falhas exceda 15% deve ser testada a utilização de redes com configurações e estruturas diferentes das apresentadas nesse estudo afim de obter maior eficiência na estimativa de dados mensais de precipitação.

CONCLUSÃO

O método da Curva de Dupla Massa foi importante para verificar se as estações analisadas comportam-se homogeneamente. A utilização de RNAs no cálculo do preenchimento de falhas em dados mensais de pluviosidade foi eficaz com 7% de falhas nos dados, tendo apresentado também os melhores valores de NSE. A aplicação das redes em

banco de dados com falhas de 15 e 30% não é recomendado, com as configurações de redes utilizadas no atual trabalho. Porém, o resultado da aplicação de RNAs, em séries de precipitação com falhas, foi satisfatório, sendo muito úteis para atender pesquisas aplicadas e subsidiar projetos que necessitam de séries climáticas confiáveis, consistentes e sem falhas.

AGRADECIMENTOS

À FAPES, pela concessão da bolsa de Mestrado e Doutorado aos pesquisadores.

REFERÊNCIAS BIBLIOGRÁFICAS

- BERTONI, J.C.; TUCCI, C.E.M. Hidrologia: (Editores), **Precipitação**. Porto Alegre: ABRH, p. 177-242, 2007.

2. BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. Viçosa, 2010. 54 f. Dissertação (Mestrado em Ciência Florestal) – Departamento de Engenharia Florestal, Universidade Federal de Viçosa.
3. BINOTI, M.L.M.S.; BINOTI, D.H.B.; LEITE, G.L. Aplicação De Redes Neurais Artificiais para Estimção da Altura de Povoamentos Equiâneos de Eucalipto. **Revista Árvore**, v. 37, n. 4, p. 639-645, 2013 (a).
4. BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, G.L. SILVA, A.A.L.; ALBUQUERQUE, A.C. Modelagem da Distribuição de Diâmetros Utilizando Autômatos Celulares e Redes Neurais Artificiais. **Cerne**, v. 19, n. 4, p. 677-685, 2013 (b).
5. CARVALHO, A. C. A. **Caracterização da rede pluviométrica do Estado de Sergipe e aplicação das redes neurais para preenchimento de falhas**. Sergipe, 2007. 117 p. Dissertação (Mestrado em Desenvolvimento e Meio Ambiente) - Núcleo de Pós Graduação em Desenvolvimento e Meio Ambiente, Universidade Federal do Sergipe.
6. COLLISCHONN, W. **Simulação hidrológica de grandes bacias**. Porto Alegre, 2001. 194 f. Tese (Doutorado em Engenharia) – Instituto de Pesquisa Hidráulica, Universidade Federal do Rio Grande do Sul.
7. DEPINÉ, H.; CASTRO, N. M. R.; PEDROLLO, O. C. Incertezas no Preenchimento Falhas de Chuvas Horárias Com Redes Neurais Artificiais. **Estudos ambientais**, v. 15, n. 2, p. 48-57, 2013.
8. EISCHEID, J.K; BAKER, B.C; KARL, R.T; DIAZ, H.F. The Quality control of long term climatological Data Using Objective Data Analysis. **Journal Applied Meteorology**, v. 34, n. 12, p. 2787-2795, 1995.
9. GUPTA, H. V.; SOROOSHIAN, S.; YAPO, P. O. Toward improved calibration of hydrologic models: Multiple and noncommensurable mesuares of information. **Water Resources Research**, v. 34, n. 4, p. 751-763, 1998.
10. LEITE, H. G. et al. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v. 130, n. 2, p. 263-269, 2010.
11. LEITE, L.H.; OLIVEIRA-NETO, R.R.; MONTE, M.O.; FARDIN, L.; ALCANTARA, A.M.; BINOTI, M.L.M.S.; CASTRO, R.V.O. Modelo de afilamento de cerne de *Tectona grandis*. **Scientia Forestalis**, v. 39, n. 89, p. 053-059, 2011.
12. LUCIO, P. S.; CONDE, F. C.; CAVALCANTI, I. F.A.; RAMOS, A. M.; CARDOSO, A. O. Reconstrução de séries meteorológicas via redes neurais artificiais. In: Anais XIV CBMET, Florianópolis. **Resumos Expandidos...**São Paulo, 2006, CD ROM.
13. MORIASI, D.N.; ARNOLD, J.G.; LIEW, M.W.V.; BINGNER, R.L.; HARMEL, R.D.; VEITH, T.L. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. **American Society of Agricultural and Biological Engineers**, v. 50, n. 3, p. 885-900, 2007.
14. NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models, Part I - A discussion of principles. **Journal of Hydrology Amsterdam**, v. 10, n. 3, p. 282-290, 1970.
15. OLIVEIRA, L.F.C.; FIOREZE, A.P.; MEDEIROS, A. M. M. SILVA, M. A. S. Comparação de metodologias de preenchimento de falhas de séries históricas de precipitação pluvial anual. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 11, p. 1186-1192, 2010.
16. RADI, N.F. A.; ZAKARIA, R; AZMAN, M. A. Z. Estimation of Missing Rainfall Data Using Spatial Interpolation and Imputation Methods. In: AIP Conference Proceedings, 2, 2015, Malaysia. **Artigo Completo...**Malaysia, The 2nd ISM International Statistical Conference, 2014, p. 42-48.
17. SCHNEIDER, B. R. U. Calculation of gridded precipitation data for the global land-surface using in-situ gauge observations. In: Workshop of the international precipitation working Group, 2, 2005, Germany. **Artigo Completo...**Germany, 2nd Workshop of the International Precipitation Working Group, 2005, p. 231-247.
18. SILVA, V. S. V. **Estimativa de precipitação pontual em diferentes escalas para uso em modelo concentrado chuva-vazão**. Porto Alegre, 2011. 139 p. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental) - Instituto de Pesquisas Hidráulicas, Instituto de Pesquisas Hidráulicas.
19. SILVA, M. L. M. et al. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. **Revista Árvore**, v. 33, n. 6, p. 1133-1139, 2009.
20. SOUSA, W. S & SOUSA, F.A.S. Rede Neural Artificial Aplicada à Previsão de Vazão da Bacia Hidrográfica do Rio Piancó. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 2, p. 173-180, 2010.
21. SOUZA, R.B. Estimção do volume do cerne de *Tectonagrandis* L.f. utilizando Redes Neurais Artificiais (RNA) e Taper. Viçosa. Centro de Ciências Agrárias Departamento de Engenharia Florestal-UFV, 25 p. 2014.
22. VALENÇA, M. (Coordenador). **Fundamentos das Redes Neurais**. Olinda: Livro Rápido Ecológica, 386 p. 2010.
23. VENTURA, T. M. **Preenchimento de Falhas de Dados Micrometeorológicos Utilizando Técnicas de Inteligência Artificial**. Cuiabá, 2012. 73 p. Dissertação (Mestrado em Física Ambiental) – Instituto de Física, Universidade Federal do Mato Grosso.
24. WANDERLEY, H.S.; AMORIM, R.F.C.; CARVALHO, F. O. INTERPOLAÇÃO ESPACIAL DE DADOS COM REDES NEURAIAS ARTIFICIAIS. In: Congresso Brasileiro de Agrometeorologia, 17, 2011, Guarapari. **Resumos Expandidos...**São Paulo: Sociedade Brasileira de Agrometeorologia, 2011, CD ROM.

*Manuscrito recebido em: 14 de Setembro de 2015
Revisado e Aceito em: 20 de Agosto de 2016*