

MODELAGEM HIDROCLIMATOLÓGICA UTILIZANDO REDES NEURAIS MULTI LAYER PERCEPTRON EM BACIA HIDROGRÁFICA NO SUDOESTE DA AMAZÔNIA

SANTOS NETO, Luiz Alves dos – luizmeteoro@gmail.com
Universidade Federal de Rondônia / UNIR

MANIESI, Vanderlei – maniesi@unir.br
Universidade Federal de Rondônia / UNIR

QUERINO, Carlos Alexandre Santos – carlosquerino@ufam.edu.br
Universidade Federal do Amazonas / UFAM

SILVA, Marcelo José Gama – marcelo.gama@sipam.gov.br
Sistema de Proteção da Amazônia / SIPAM

BROWN, Vera Reis – vlreis.reis21@gmail.com
Instituto de Mudanças Climáticas do Acre / IMC-AC

RESUMO: O rio Acre apresentou, nos últimos anos, uma grande frequência de cheias nas cidades à sua margem, principalmente em Rio Branco, capital do estado do Acre. Na década atual ocorreram 2 das 3 maiores enchentes já observadas na capital acreana desde que se tem registro, que fizeram a cidade entrar em situação de emergência e provocou danos e prejuízos a toda população. O objetivo deste trabalho foi apresentar uma proposta de criação de um modelo hidroclimatológico com aplicação da técnica das Redes Neurais Artificiais (RNA) do tipo Multi Layer Perceptron. Dados mensais de Temperatura da Superfície do Mar (TSM) dos Oceanos Pacífico e Atlântico tropicais, além do Atlântico Sudoeste e de pressão média mensal em Darwin e Tahiti do período de 1971 até 2016 foram utilizados como dados de entrada da RNA. As previsões da cota máxima mensal com antecedência de 1 a até 4 meses foram feitas com simulações de 1 até 30 neurônios na camada escondida para cada horizonte de previsão e usado métricas de desempenho para avaliar sua eficiência do modelo. As simulações obtiveram índices satisfatórios e, dado sua eficiência, sugere-se sua aplicação nos órgãos gestores da Bacia Hidrográfica do rio Acre para conseguir se antecipar com meses de antecedência aos eventos de cheia e facilitar na mitigação de tomadas de decisão antes do acontecimento deste extremo hidrológico

PALAVRAS-CHAVE: Amazônia, Simulação, Rio Acre, Climatologia.

HIDROCLIMATOLOGICAL MODELING USING ARTIFICIAL NEURAL NETWORK MULTI LAYER PERCEPTRON IN A WATERSHED IN THE SOUTHWEST AMAZONIA

ABSTRACT: Acre's River has present, thought the last years, high frequency of floods in the city in its bank, mainly in Rio Branco, capital of Acre State. On the actual decade, had happened 2 from the 3 biggest floods already observed in the in the Acre's capital since data started to be registered, which put the city into emergency status and caused injuries and loss to the entire population. The aim of this paper was to present a propose to create a hidroclimatological model by using Artificial Neural Network (ANN) Multi-Layer Perceptron type. Monthly data from Sea Surface Temperature (SST) from the Pacific and Atlantic tropical oceans, besides from the Southwestern Atlantic and monthly averaged pressure from Darwin and Tahiti, throughout the period from 1971 to 2016, was used such as entrance data of the ANN. The maximum monthly advance cote forecast from 1 to 4 months were carried out by using simulations from 1 up to 30 neuros in the hidden layer for each forecast horizon and used performance metrics to evaluate the efficiency of the model. The simulations have shown satisfactory indexes and, due to their efficiencies,

we would suggest they application by the manages of the governing bodies of the Acre River Hydrographic Basin to anticipate in advance months the flood events and facilitate the mitigation to take a advance decision before the hydrological extreme.

KEYWORDS: Amazonia, Simulation, Acre's River, Climatology.

1. INTRODUÇÃO

A bacia do rio Acre concentra a maior parte da população do estado do Acre com aproximadamente 55% do total de habitantes do estado (IBGE, 2010). É também responsável pelas maiores taxas de crescimento econômico o que a torna suscetível a alterações na paisagem em comparação as demais bacias hidrográficas acreanas (LATUF, 2011). Por conta dessa exploração econômica, já se observam altas taxas de desflorestamento além do avanço do arco do desmatamento na região da bacia (TRANCOSO, 2006).

No Estado do Acre os desastres naturais observados entre 1991 e 2012, inundações tanto graduais quanto bruscas são as que ocorrem maior frequência (54% dos casos) (CEPED-UFSC, 2013). De acordo com Santos (2014) que observou a frequência de incidências de cheias na bacia, de 2005 até os dias atuais, apenas nos anos de 2007 e 2008 não ocorreram inundações na capital Rio Branco, que é o município acreano mais atingido por este tipo de desastre natural.

Entre fevereiro e março de 2015 ocorreu a maior cheia já observada no rio Acre, onde todas as cidades situadas na sua margem sofreram inundações recordes. A cidade de Rio Branco foi a mais afetada pela cheia, principalmente por ser a maior área urbana que o rio Acre corta ao longo do seu curso natural, o que intensifica os impactos provocados pela inundação. Na capital acreana, o rio Acre atingiu 18,40 metros no dia 05/03/2015, superando em 74 centímetros o último recorde histórico de cheia do rio, que foi de 17,66 metros no dia 14/03/1997 e em 76 centímetros a maior cheia mais recente (e a terceira maior de toda a série histórica) ocorrida no dia 26/02/2012 quando chegou a 17,64 metros. Aproximadamente 2900 famílias ficaram desabrigadas e o prejuízo foi de mais de 70 milhões de reais apenas na cidade de Rio Branco (ACRE, 2015; RIO BRANCO, 2016). Esses tipos de desastres podem ser mitigados caso haja um modelo hidrológico apropriado para a região que permita tomada de providencia antes da catástrofe acontecer.

Um modelo hidrológico é a representação simplificada do sistema hidrológico no mundo real (SOROOSHIAN et al., 2008). Tornou-se uma ferramenta bastante útil para lidar com problemas ambientais por ter a capacidade de prever situações futuras, na qual uma determinada simulação possa ser um cenário potencialmente danoso a sociedade, permita o usuário da informação a se antecipar a este evento extremo afim de auxiliar nos processos de tomadas de decisão nas políticas públicas (ALMEIDA e SERRA, 2017). Para Devi et al. (2015), o melhor modelo hidrológico é aquele que consegue ter resultados simulados próximos da realidade usando a menor quantidade de parâmetros possíveis e com menos complexidade.

Na hidrologia, um dos métodos de construção de modelo hidrológico que está ganhando destaque nos últimos anos é o uso de modelos estatístico/matemáticos empíricos baseados em Inteligência Artificial (IA) (SILVA et al., 2018). Esses modelos utilizam algoritmos de Redes Neurais

Artificiais (RNA) e são fruto da tentativa de representar matematicamente o funcionamento do neurônio biológico (DORNELLES, 2011). Ainda segundo o autor, a RNA é um dos algoritmos criados dentro da Inteligência Artificial (IA) que ultimamente tem ganhado bastante atenção, pois oferece uma gama de opções para tratar problemas de alta complexidade, onde se usa uma grande quantidade de dados, tais como dados de cunho ambiental, para fazer previsões e tarefas que ajudam na tomada de decisão.

Estes modelos baseados em RNA são classificados como "empíricos", pois utilizam métodos estatísticos de regressão e correlação entre suas variáveis para compreender o processo de entrada e saída do regime hídrico, desconsideram os processos físicos do sistema hidrológico e são válidos apenas dentro dos limites geográficos da bacia (DEVI et al., 2015). Em geral, esses modelos hidrológicos são amplamente utilizados para modelar sistemas não-lineares complexos com grande quantidade de dados, pois apresentam resultados satisfatórios na modelagem do tipo chuva-vazão e resultados melhores do que outros tipos de modelos hidrológicos tais como os modelos conceituais (SOUSA e SOUSA, 2010). Com o avanço de métodos de aprendizagem e das arquiteturas, estas RNA's mostram-se ferramentas bastante promissoras, em particular, para o problema de previsão de extremos hidrológicos baseadas em séries temporais (SILVA et al., 2018).

A aplicação das RNA's na hidrologia está bastante difundida e possui bons resultados na previsão hidrológica na modelagem chuva-vazão. Momo et al. (2016) utilizou da técnica de RNA para desenvolver um modelo hidrológico chuva-vazão para bacias hidrográficas pequenas como a do rio Itajaí no município de Brusque-SC. Os autores observaram que este modelo, comparado com os dados observados do rio, apresentaram um coeficiente elevado de correlação, mais precisamente de 0,977 pelo coeficiente de eficiência de Nash & Sutcliffe. Machado (2005) também conseguiu resultados semelhantes utilizando a mesma técnica para o rio Jangada na cidade de União da Vitória-PR. Dornelles (2007) verificou que as RNA's também apresentam bons resultados para a bacia do rio Quaraí, na cidade de Quaraí-RS, ao comparar a vazão modelada com a vazão medida acoplando não somente apenas a chuva observada, mas também a chuva prevista por um modelo meteorológico, fazendo isso de forma contínua e operacional com previsão de vazão para até 5 dias de antecedência na área de estudo.

Já na aplicação da rede em bacias hidrográficas maiores, Rodrigues (2015) utilizou as RNA's para prever o nível do rio Negro em Manaus-AM baseando-se em índices climáticos, como o Índice de Oscilação Sul (IOS), que determina a ocorrência (ou não) dos fenômenos El Niño e La Niña. O autor conseguiu um índice de correlação de 0,755 entre as cotas modeladas e as cotas medidas. Silva et al. (2018) usou as RNA's Multi Layer Perceptron para simular o nível médio mensal do rio Xingú na cidade de Altamira-PA através de dados de Temperatura da Superfície do Mar (TSM) de regiões de monitoramento dos oceanos Pacífico e Atlântico e também de pressões médias ao nível médio do mar mensal na Austrália e no Tahiti e chegaram a um coeficiente de determinação (R^2) de 0.9991 da cota média observada com a cota média prevista pela rede com 30 neurônios na camada escondida.

Diante do exposto e com o intuito de auxiliar o sistema de alerta de cheias sazonais do rio Acre e implementar uma nova metodologia de previsão

hidroclimatológica na região, torna-se primordial o aprofundamento de pesquisas para elaboração de um modelo hidrológico operacional para a bacia do rio Acre (ZHANG et al., 2003). Assim, objetivo deste trabalho foi utilizar Redes Neurais Artificiais (RNA) para gerar um modelo e testar sua eficiência em simular, com meses de antecedência, as cotas máximas mensais do rio Acre na cidade de Rio Branco-AC.

2. MATERIAIS E MÉTODOS

2.1 ÁREA DE ESTUDO

O rio Acre é um dos afluentes do rio Purus e um dos principais afluentes da margem direita do rio Amazonas. O rio Acre corre na direção Oeste-Leste, nasce no Peru em cotas da ordem de 400 m aproximadamente e atinge cotas próximas de 100 m na sua foz (ACRE, 2012). Seu alto curso atua como divisa natural entre Brasil, Peru e Bolívia e adentra em território brasileiro, percorrendo mais de 1190 km desde sua nascente até a sua foz, na altura da cidade de Boca do Acre, estado do Amazonas (NASCIMENTO, 2011) (Figura 1).

A Bacia Hidrográfica do rio Acre (BHA) possui uma área de drenagem de 35.967 km² dos quais 23.651 km² ou 65,7% da área total da bacia encontra-se até o município de Rio Branco (LATUF, 2011), área esta que será utilizada como referência neste trabalho. O regime fluviométrico corresponde a elevação máxima anual durante o período das chuvas na região (entre janeiro e março) com níveis médios de 12,90 m e vazões médias de 1700 m³/s e a vazante ocorre durante a estação seca (entre junho e agosto), com níveis médios de 1,90 m e vazões médias de 80 m³/s (ACRE, 2012).

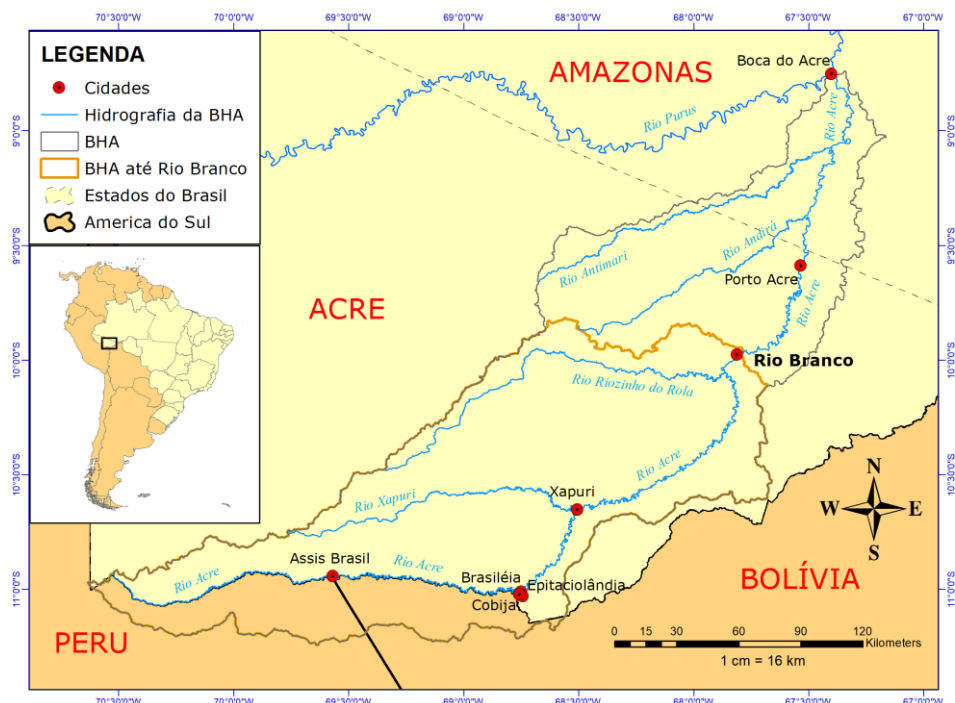


Figura 1 – Bacia hidrográfica do rio Acre (BHA), delimitação da área de estudo e seus principais afluentes desde sua nascente na fronteira do Brasil com o Peru até sua foz no rio Purus na cidade de Boca do Acre-AM.

2.2 DADOS

Os dados de cota máxima mensal do rio Acre em Rio Branco (variável dependente) foram coletados através dos registros diários de cota na cidade de Rio Branco-AC da estação fluviométrica 13600002 (9° 58' 30.00" S; 67° 48' 2.88" W) da Agência Nacional de Águas (ANA). Os registros foram feitos entre janeiro de 1971 e dezembro de 2016 e estão disponíveis no banco de dados da rede hidrometeorológica da ANA disponíveis no site através da plataforma Hidroweb. Posteriormente, com os dados diários, extraiu-se a maior cota observada dentro de cada mês.

Como variáveis preditoras, ou seja, os dados utilizados como de entrada do modelo foram os dados médios mensais de Temperatura da Superfície do Mar (TSM) para todo o período estudado (1971 a 2016) nas regiões de monitoramento climático do Climate Prediction Center (CPC) NIÑO 1+2 (0°-10°S/90°W-80°W), NIÑO 3 (5°N-5°S/150°W-90°W), NIÑO 4 (5°N-5°S/160°E-150°W), NIÑO 3.4 (5°N-5°S/170°W-120°W), Atlântico Tropical Norte (ATN) (5°N-20°N/60°W-30°W) e Atlântico Tropical Sul (ATS) (0°-20°S/30°W-10°E), além do Atlântico Sudoeste (ASW) (10°S-40°S/60°W-10°W) e fornecido pelo National Oceanic and Atmospheric Administration (NOAA) com resolução 2°x2° grau de pontos de grade e disponíveis no site do CPC (HUANG et al., 2017) (Figura 2). Incluiu-se também a pressão atmosférica, médias mensais, em Darwin – Austrália (LAT 12° 27' S LON 130° 50' E) e em Tahiti – Polinésia Francesa (LAT 17° 37' S LON 149° 26' W), coletadas através do portal do CPC para o mesmo período de análise.




Figura 2 - Localização das regiões oceânicas consideradas para análise.

De posse dos dados mensais tanto de TSM como de pressão atmosférica média, foi feito o cálculo da correlação de Pearson através da correlação cruzada entre cada parâmetro analisado com o nível máximo mensal do rio Acre em Rio Branco-AC para cada lag de tempo mensal que variou de -1 a -12 meses, afim de se obter uma melhor análise na força de correlação entre as variáveis analisadas (Tabela 1).

Tabela 1 – Correlação da TSM média mensal das regiões oceânicas do El Niño 1+2 (EN 1+2), El Niño 3 (EN 3), El Niño 3.4 (EN 3.4), El Niño 4 (EN 4), Atlântico Tropical Norte (ATN), Atlântico Tropical Sul (ATS) e Atlântico Sudoeste (ASW), além das pressões médias mensais em Darwin (PD) e Tahiti (PT) com os lags no tempo variando de 1 a 12 meses.

Regiões	Meses											
	T-1	T-2	T-3	T-4	T-5	T-6	T-7	T-8	T-9	T-10	T-11	T-12
EN 1+2	0,5	0,1	-0,3	-0,6	-0,8	-0,7	-0,5	-0,1	0,3	0,6	0,8	0,8
EN 3	0,1	-0,3	-0,5	-0,6	-0,6	-0,4	-0,2	0,2	0,4	0,6	0,6	0,4
EN 3.4	-0,2	-0,4	-0,4	-0,4	-0,3	-0,1	0,1	0,2	0,3	0,3	0,2	0,0
EN 4	-0,3	-0,2	-0,1	0,0	0,1	0,1	0,2	0,1	0,0	-0,1	-0,2	-0,3
ATN	-0,6	-0,2	0,3	0,6	0,8	0,7	0,5	0,1	-0,3	-0,6	-0,8	-0,8
ATS	0,5	0,1	-0,4	-0,7	-0,9	-0,8	-0,5	-0,1	0,3	0,7	0,9	0,8
ASW	0,9	0,8	0,5	0,1	-0,4	-0,7	-0,9	-0,8	-0,6	-0,1	0,3	0,7
PD	-0,8	-0,7	-0,5	0,0	0,4	0,7	0,8	0,7	0,4	0,0	-0,4	-0,7
PT	-0,7	-0,5	-0,2	0,1	0,4	0,7	0,7	0,5	0,2	-0,1	-0,4	-0,6

Após calculadas as correlações, foi criada uma base de dados baseado nas variáveis com a melhor correlação em cada lag por região oceânica e pressão atmosférica média analisada. Posteriormente montou-se a configuração de variáveis de entrada do modelo (variáveis preditoras) com previsão para 1, 2, 3 e 4 meses de antecedência, sendo que o mês 1 (tempo T de previsão) refere-se ao mês após a obtenção da variável preditora mensal mais recente (lag T-1), o mês 2 (tempo T+1 de previsão) refere-se ao segundo mês após a obtenção da variável preditora mais recente (lag T-2) e assim sucessivamente. As combinações de correlações entre as variáveis e os lags permitiria gerar um modelo de previsão de até 12 meses. Contudo, como o intuito foi avaliar a capacidade da RNA em prever cotas máximas mensais baseando somente em dados médios mensais de oceano e pressão atmosférica, optou-se por limitar o horizonte de previsão para somente até 4 meses para teste de eficiência do método.

A base de dados das variáveis preditoras para cada mês de previsão ficou configurada em: i) para previsão com 1 mês de antecedência (tempo T de previsão) serão usados o EN 1+2 (T-5), EN 3 (T-4), EN 3.4 (T-3), EN 4 (T-1), ATN (T-5), ATS (T-5), ASW (T-1), PD (T-1) e PT (T-7); ii) Para previsão com 2 meses de antecedência (tempo T+1 de previsão) a melhor combinação de variáveis com as melhores correlações foi usando o EN 1+2 (T-5), EN 3 (T-4), EN 3.4 (T-3), EN 4 (T-2), ATN (T-5), ATS (T-5), ASW (T-2), PD (T-7) e PT (T-7); iii) Para previsão de cotas máximas mensais do rio Acre em Rio Branco-AC com 3 meses de antecedência (tempo T+2 de previsão) a melhor combinação encontrada foi usando o EN 1+2 (T-5), EN 3 (T-4), EN 3.4 (T-3), EN 4 (T-7), ATN (T-5), ATS (T-5), ASW (T-7), PD (T-7) e PT (T-7) e iv) Para previsão com 4 meses de antecedência (tempo T+3 de previsão) foram usados os dados de EN 1+2 (T-5), EN 3 (T-4), EN 3.4 (T-4), EN 4 (T-7), ATN (T-5), ATS (T-5), ASW (T-7), PD (T-7) e PT (T-7).

Foi feito também um pré-processamento dos dados através da normalização dos mesmos, uma vez que as funções de ativação dos neurônios de entrada e saída trabalham em uma escala que varia de -1 a 1 e os dados usados neste trabalho possuem escalas diferentes (centímetros para nível do

rio, graus Celsius para TSM e milibares para Pressão). A normalização dos dados é importante pois facilita no treinamento da rede neural, melhorando a performance no processamento preliminar dos dados e tornando a rede neural com maior capacidade de extrair a informação que realmente é necessária para seu aprendizado (HAGAN, et al., 2014). A fórmula usada para reescalonar todas as variáveis usadas na rede para uma escala que varia de -1 a 1 está na Eq. (1).

$$D^n = 2 \left(\frac{D - D^{min}}{D^{max} - D^{min}} \right) - 1 \quad (1)$$

onde D^n é o dado normalizado, D é o dado que será normalizado, D^{min} é o menor valor encontrado do dado e D^{max} é o maior valor encontrado do dado.

2.3 MONTAGEM DA REDE NEURAL ARTIFICIAL

Foi construído o modelo baseado em RNA do tipo Multi Layer Perceptron (MLP). A escolha por uma RNA de arquitetura MLP se dá pela capacidade deste tipo de rede solucionar problemas não lineares.

Uma RNA MLP é composta por um número finito de camadas sucessivas, com um número finito de unidades de processamento chamados de neurônios, onde cada neurônio está conectado a todos os neurônios da camada seguinte através dos pesos sinápticos (Figura 3).




Figura 3 – Arquitetura de uma Rede Neural Artificial Multi Layer Perceptron (SILVA et al., 2018).

O sinal de entrada é recebido pela camada de entrada e posteriormente enviado para a camada seguinte. O processo de aprendizado é realizado pelas camadas escondidas através do processamento de cada neurônio (Eq. 2) (SILVA et al., 2018). Um neurônio de uma determinada camada, possui a função de combinar as tarefas realizadas pelos neurônios a ele ligados da camada anterior e contribuir no processamento, auxiliando no armazenamento das informações. A resposta é recebida, na camada de saída, de acordo com as classes

informadas no conjunto de dados, através dos vários processamentos realizados nas camadas anteriores (FACELI, 2011).

$$S_j = f\left(\sum_{i=1}^p x_i w_{ij} + \theta_k\right) \quad (2)$$

onde x_i é a i -ésima entrada para a rede, w_{ij} é o peso da conexão do neurônio de entrada i para o neurônio escondido j , θ_k é o viés do j -ésimo neurônio e $f(\cdot)$ é a função de ativação do neurônio.

Considerando a camada de saída, cada neurônio calcula de acordo com a Eq. (3):

$$y_k = g\left(\sum_{j=1}^m \beta_{kj} S_j\right) + \theta_j \quad (3)$$

onde β_{kj} é o peso da conexão escondida j com neurônio de saída k , y_k é a k -ésima saída da rede, θ_j é o viés da j -ésima saída e $g(\cdot)$ é a função de ativação do neurônio.

A rede neural aqui estudada possui um tipo de treinamento supervisionado, onde se sabe o valor esperado que a rede neural calcule (alvo). Caso a rede não atinja o valor esperado é gerado então um erro e este erro é trabalhado no reajuste dos pesos sinápticos entre os neurônios de saída e de entrada, afim de minimizar o erro e melhorar a acurácia da RNA, uma vez que os pesos sinápticos entre os neurônios são definidos aleatoriamente pela rede. Este tratamento é feito durante o processo de aprendizado da RNA através de algoritmos, da qual existe uma grande variedade, sendo cada um adequado para solucionar um determinado tipo de problema.

Para esta pesquisa, foi escolhido o algoritmo backpropagation, que retropropaga o erro produzido (diferença entre o valor obtido na saída da rede e o valor que se desejava alcançar) no momento da saída da rede, ou seja, o erro é disseminado de forma inversa através dos pesos de conexão do neurônio de saída até os neurônios de entrada e então o cálculo da rede é refeito com os pesos de conexão reajustados pelo erro produzido. Este processo de aprendizado é feito e refeito até que o neurônio de saída consiga atingir um valor aceitável onde o erro produzido seja mínimo.

Neste processo de recálculo dos pesos sinápticos entre os neurônios também há uma gama de algoritmos que podem ser usados. Neste trabalho optou-se por usar o método do gradiente descendente, uma ferramenta que atualiza os erros e os bias das conexões entre os neurônios através do gradiente negativo da performance da função iterativamente com o objetivo de encontrar seu mínimo, técnica muito usada para resolver problemas em Machine Learning (BEALE et al., 2017). As funções de ativação escolhidas na camada oculta na camada de saída foram a tangente hiperbólica e a linear, respectivamente.

Aplicando as equações nos dados desta pesquisa temos que os valores que entram na rede são as Variáveis Predictoras (VP), por serem os dados que serão utilizados pela rede neural para buscar os padrões e fazer a previsão, contabilizando 9 variáveis de entrada. Já o dado de saída da rede é a Variável Dependente (VD), um dado único que será previsto pela rede neural. A rede foi montada com um número de neurônios na camada oculta que varia de 1 a 30 e feito uma comparação entre o valor previsto em cada arquitetura e o valor real

observado para verificar a melhor saída através de métricas estatísticas de desempenho.

Ao todo, cada base de 1 a 4 meses de previsão contém 552 informações ou entradas de rede. Para a base de treinamento da RNA foram usados os dados mensais de 1971 a 2010 (87% da base total dos dados e corresponde o dado do 1 ao 480) e para teste foi usado a base de dados mensais de 2011 a 2016 (13% da base total de dados e corresponde do dado 481 ao 552). Neste período separado para teste do modelo contém a maior (2015) e a terceira maior (2012) cota já observada do rio Acre em Rio Branco desde que se tem registro e, assim, abre a possibilidade de avaliar o comportamento da rede em detectar estes dois "outliers" da série histórica.

As cotas previstas pela rede na fase de testes foram inseridas nas equações de métricas estatísticas de desempenho do modelo juntamente com os dados observados do mesmo período para avaliação da eficiência da RNA. Tais métricas utilizadas nesta pesquisa serão discutidas no próximo tópico.

2.4 MÉTRICAS ESTADÍSTICAS DE DESEMPENHO DO MODELO

O desempenho da RNA em prever cotas máximas mensais com até 4 meses de antecedência foi avaliado através do Coeficiente de Determinação (R^2), a Raiz do Erro Médio Quadrático (RMSE), o Coeficiente de Eficiência de Nash-Sutcliffe (CENS) e o Índice de Confidência (IC).

O Coeficiente de Determinação (Eq. 4) é o quadrado do coeficiente de correlação de Pearson (ρ) e mede a proporção da variância da variável dependente em torno da sua média e varia de 0 a 1 e quanto maior for o valor de R^2 , melhor a previsão da variável dependente (HAIR JR et al., 2005). A Raiz do Erro Quadrático Médio (REQM), (Eq. 5) é frequentemente usada na verificação da acurácia dos modelos, por ser mais sensível aos grandes erros provocados pelos "outliers" e quanto mais próximo de 0, mais perfeita é a simulação do modelo (HALLAK & PEREIRA FILHO, 2011). O Coeficiente de Eficiência de Nash-Sutcliffe (CENS) (Eq. 6) é uma estatística normalizada que indica qual o grau de eficiência do modelo ao comparar os dados simulados com os dados reais um por um e variar de $-\infty$ a 1, e quanto mais próximo de 1, mais ajustada está a modelagem (NASH & SUTCLIFFE, 1970). Por fim, o Índice de Confidência (Eq. 7) proposto por Willmot (1982) que é o produto do coeficiente de correlação de Pearson entre as cotas medidas e previstas (ρ) com o Índice de Concordância (COUTINHO et al., 2018), que varia de 0 a 1 no qual 1 é mais perfeita concordância (HALLAK & PEREIRA FILHO, 2011).

$$R^2 = \frac{\sum_{i=1}^N (\mu - \tau)^2}{\sum_{i=1}^N (\delta - \tau)^2} \quad (4)$$

$$.REQM = \sqrt{\frac{1}{N} \sum_{i=1}^N (\mu - \delta)^2} \quad (5)$$

$$CENS = 1 - \left[\frac{\sum_{i=1}^N (\delta - \mu)^2}{\sum_{i=1}^N (\delta - \tau)^2} \right] \quad (6)$$

$$IC = \rho \cdot \left[1 - \frac{\sum_{i=1}^N (\mu - \delta)^2}{\sum_{i=1}^N (|\mu - \tau| + |\delta - \tau|)^2} \right] \quad (7)$$

onde μ é a cota máxima mensal prevista pelo modelo, δ é a cota máxima mensal medida na estação, τ é a cota máxima mensal média dos dados medidos e N representa o número de observações.

Após fazer todas as 120 simulações (30 para cada lag) e calculado o índice de desempenho de cada uma das simulações, verificou-se que cada arquitetura de rede analisada apresentou desempenho diferente ao analisar separadamente por índices, sendo melhor em um índice, mas pior em outro, o que torna difícil escolha da rede com melhor acurácia para cada lag. Para resolver este problema buscou-se uma equação que analisasse todos os índices de uma só vez, conforme Eq. (8):

$$DG = R^2 + CENS + IC - RMSE \quad (8)$$

Como o R^2 , o CENS e o IC propõem o valor 1 como o valor de referência para a perfeição da acurácia do modelo e o RMSE indica o valor 0 para o mesmo fim, usou-se a equação de Desempenho Geral (DG) para tornar possível a escolha das melhores arquiteturas de rede simuladas.

3. RESULTADOS E DISCUSSÕES

O lag -1 apresentou para as arquiteturas com 5, 8, 17, 25 e 26 neurônios na camada escondida os melhores índices em relação as 25 outras arquiteturas simuladas. A arquitetura com 17 e 25 neurônios, por apresentarem o mesmo DG, tiveram melhor desempenho no geral para este horizonte de previsão. O lag -2 apresentou os melhores desempenhos com as arquiteturas de 12, 16, 23, 27 e 28 neurônios na camada escondida. Contudo, a camada com 23 neurônios, de uma maneira geral, sobressaiu-se em relação às demais de acordo com o DG. O lag -3, as 5 melhores arquiteturas foram as com 4, 13, 14, 21 e 30 neurônios na camada escondida, do qual a rede com 4 neurônios obteve, em média, um desempenho melhor, tanto pelo DG como pela análise isolada por índice. Por fim, o lag -4 teve as redes com 13, 14, 20, 23 e 27 neurônios na camada escondida com melhor previsão, com destaque para a rede com 27 neurônios que obteve não só um DG maior em relação as outras arquiteturas, como também foi superior ao analisar cada índice de desempenho separadamente (Tabela 2).

Como é possível notar, a diferença entre cada uma das 5 melhores arquiteturas é mínima, por muitas vezes na casa dos centésimos. De uma maneira geral, todas as 30 redes propostas para cada lag apresentaram valores de R^2 , CENS e IC superiores a 0.7 e RMSE inferiores a 0.3.

Tabela 2 – Índices estatísticos de desempenho das 4 arquiteturas de RNA com melhor acurácia de previsão do nível do rio Acre com 1 mês (tempo T), 2 meses (tempo T+1), 3 meses (tempo T+2) e 4 meses (tempo T+3) de antecedência, onde NN representa o número de neurônios na camada escondida.

LAGS DE TEMPO	NN	R²	RMSE	CENS	IC	DG
TEMPO T	25	0.8362	0.2374	0.8284	0.8691	2.2963
	17	0.8351	0.2368	0.8294	0.8686	2.2963
	26	0.8352	0.2416	0.8224	0.8648	2.2808
	8	0.8292	0.2450	0.8174	0.8594	2.2610
	5	0.8327	0.2483	0.8123	0.8615	2.2582
TEMPO T+1	23	0.8450	0.2336	0.8340	0.8502	2.3170
	27	0.8451	0.2385	0.8270	0.8714	2.3050
	16	0.8362	0.2411	0.8231	0.8683	2.2865
	28	0.8255	0.2454	0.8168	0.8569	2.2538
	12	0.8236	0.2497	0.8102	0.8563	2.2404
TEMPO T+2	4	0.8483	0.2297	0.8395	0.8770	2.3351
	30	0.8336	0.2455	0.8167	0.8618	2.2666
	14	0.8303	0.2537	0.8042	0.8569	2.2404
	21	0.8172	0.2481	0.8127	0.8520	2.2338
	13	0.8223	0.2517	0.8073	0.8519	2.2298
TEMPO T+3	27	0.8412	0.2330	0.8348	0.8731	2.3161
	13	0.8305	0.2386	0.8267	0.8648	2.2834
	23	0.8363	0.2429	0.8204	0.8671	2.2809
	20	0.8305	0.2392	0.8260	0.8632	2.2805
	14	0.8330	0.2416	0.8223	0.8627	2.2764

Ao analisar a simulação das redes com melhor desempenho para cada lag e comparar seus resultados com as cotas máximas observadas entre 2011 e 2016 (Figura 5) percebemos que o dado simulado pela RNA conseguiu acompanhar a oscilação observada do nível máximo mensal do rio, mesmo sendo um modelo empírico (quando não há representação explícita dos processos físicos do ciclo hidrológico na construção do modelo) e determinístico (quando a resposta do modelo é a mesma para um mesmo conjunto de dados de entrada) (ALMEIDA & SERRA, 2017).

Em todas as melhores arquiteturas encontradas para cada lag foi possível identificar que neste período selecionado para testar a eficiência da RNA em prever a cota máxima mensal do rio Acre em Rio Branco-AC ele obteve um desempenho muito satisfatório em prever a cota máxima no ano de 2013 e de 2016, onde a curva da cota prevista pela RNA praticamente se sobrepõe a da cota medida, o que indica a boa acurácia do método e que concorda com os demais autores que utilizaram a mesma metodologia (RODRIGUES, 2015; SILVA et al., 2018).

Já em outros anos como 2012 e 2015 a diferença entre a cota simulada e a cota medida foi grande, com as curvas apresentando um distanciamento significativo entre elas no maior valor de cota destes anos. Isto ocorreu por 2 motivos: primeiro que a maior cota registrada nos anos de 2012 e 2015 são considerados "outliers" dentro de todo o período estudado, por serem, juntamente com o ano de 1997, os 3 maiores níveis do rio Acre em Rio Branco desde 1971, que proporcionaram cheias históricas em toda a bacia. Segundo

que os motivos que ocasionaram as cheias de 2012 e 2015 foram de caráter meteorológico (SANTOS NETO et al., 2017; MARENGO et al., 2013), onde seu impacto ocorre em uma escala de tempo menor que a mensal, uma influência que esta metodologia de simulação de cota não consegue detectar por estar definida em escala mensal, cuja finalidade é de captar condições climáticas mensais favoráveis para a ocorrência de extremos ou não. Um outro ponto importante é que o rio Acre responde de forma rápida (menos de uma semana) a eventos extremos de precipitação dentro da bacia em curto período de tempo como os eventos que ocorreram em 2012 e 2015.




Figura 5 – Cotas máximas mensais do rio Acre em Rio Branco – AC registradas entre 2011 e 2016 e simuladas pela RNA para o mesmo período com 1 mês de defasagem das variáveis predictoras (tempo T de previsão) e arquitetura de 25 neurônios na camada escondida (a), com 2 meses de defasagem das variáveis predictoras (tempo T+1 de previsão) e 23 neurônios na camada escondida (b), com 3 meses de defasagem das variáveis predictoras (tempo T+2 de previsão) e 4 neurônios na camada escondida (c) e com 4 meses de defasagem das variáveis predictoras (tempo T+3 de previsão) e 27 neurônios na camada escondida (d).

No ano de 2012, o Oceano Pacífico Equatorial apresentou anomalias negativas de TSM em janeiro e fevereiro, configurando um evento de La Niña de intensidade moderada (CPTEC, 2012a, 2012b), que alterou o padrão normal de circulação atmosférica e contribuiu fortemente para a ocorrência de excessos de precipitação em toda a bacia amazônica e, consequentemente, de cheias recordes nos rios da região durante todo o verão austral de 2012 (MARENGO et al., 2013). Além das condições do Pacífico, o Oceano Atlântico que apresentou anomalias de TSM negativas no ATS e positivas no ATN também contribuiu com os superávits de precipitação na Amazônia nos primeiros meses de 2012, proporcionando um aumento na convergência de umidade em 38% a mais do que a climatologia, fazendo com que o volume de chuva médio diário na

Amazônia Ocidental aumentasse em 2.5 mm/dia (SATYAMURTY et al., 2013). Com este cenário climático-oceânico, o rio Acre atingiu em fevereiro de 2012 a cota de 17,64 m em Rio Branco, valor apenas 2 centímetros abaixo do maior nível já observado na capital acreana (1997) até este ano em questão.

Ao analisar a resposta da RNA para este ano de 2012, observa-se que o modelo conseguiu captar as condições oceânicas citadas e sinalizou um aumento na cota em relação ao ano anterior (2011) mesmo sendo um "outlier", dando um indicativo que este ano em questão haveria uma cheia maior do que o ano anterior, pois o cenário de TSM mensal apresentado era favorável para ocorrerem cotas superiores ao do ano de 2011, o que realmente aconteceu, porém errando na intensidade do evento que foi maior do que o previsto pela RNA. Já para a cheia de 2015 não foi possível dizer o mesmo, pois a maior cheia de toda a série histórica do rio Acre teve somente interferência meteorológica, como o acoplamento da Zona de Convergência Inter-Tropical com a Zona de Convergência do Atlântico Sul que provocaram acumulados de precipitação superiores aos esperados para todo o mês na BHA em menos de uma semana (SANTOS NETO et al., 2017).

A região tropical dos oceanos Pacífico e Atlântico apresentavam neutralidade quanto suas anomalias de TSM no início de 2015, tendo apenas a região do Atlântico Sudoeste com águas mais quentes que o normal (SIPAM, 2015), bem diferente do quadro apresentado no início de 2012, não havendo assim sinais oceânicos significativos que pudessem indicar a possibilidade desta alagação e, portanto, não havia como o modelo conseguir captar o sinal deste evento. Ressalta-se que não só estas melhores arquiteturas de cada lag não conseguiram captar o evento da cheia de 2015, como o mesmo também ocorreu em todas as outras simulações feitas, sinalizando a limitação da rede em detectar possíveis eventos em escala sub-mensal.

4. CONCLUSÃO

Pelos valores dos índices estatísticos usados para mensurar a eficiência da rede, pode-se dizer que a mesma atendeu ao propósito desta pesquisa. Apesar da limitação do método em não captar sinais de ordem meteorológica na escala sub-mensal, o modelo mostrou-se capaz de simular bem quando poderá haver uma cheia, confirmando a capacidade da rede neural em generalizar complexos relacionamentos não lineares entre variáveis ambientais, revolucionando os estudos de modelagem hidrológica com um novo método de previsão e podendo inclusive ser usado de forma operacional em órgãos que lidam diretamente com a gestão da BHA para tomadas de decisão.

Apesar de demonstrar sua eficiência, a proposta deste modelo empírico é que ele não seja usado isoladamente e sim em conjunto a um modelo conceitual. O modelo hidroclimatológico ajudaria na interpretação das condições climático-oceânicas em escala mensal dando indicativos a longo prazo, enquanto que o modelo hidrometeorológico do tipo chuva-vazão refinaria as previsões a curto prazo, baseado nas informações de tempo obtido em escala de dias. Ao acoplar os dois modelos, com métodos de análises diferentes, mas que se complementam, torna-se possível captar a resposta do rio aos eventos meteorológicos e climáticos nas diferentes escalas de tempo, minimizando assim os erros.

5. AGRADECIMENTOS

O autor agradece a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de doutorado no programa de Pós-Graduação em Desenvolvimento Regional e Meio Ambiente da Universidade Federal de Rondônia (UNIR) para a realização desta pesquisa.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ACRE (2015). Enchente 2015: Relatório de Avaliação de Danos e Prejuízos na Área Rural. GOVERNO DO ESTADO DO ACRE, Rio Branco-AC, 177 p.

ACRE. Plano Estadual de Recursos Hídricos do Acre. Rio Branco: SEMA, 2012. 243 p.

ASKEW, A. J. Real-Time Intercomparison of Hydrological Models. In: Symposium on Surface Water Modelling. Baltimore: IAHS Publ. 181. p. 125-132. 1989.

BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B. Neural Network Toolbox™ user's guide. The MathWorks, v. 11, 2017.

CASTRO, A. R. G.; MIRANDA, V.; LIMA, S. Transformer fault diagnosis based on autoassociative neural networks. In: International Conference on Intelligent System Applications to Power Systems, 16, 2011.

CEPED-UFSC. Atlas Brasileiro de Desastres Naturais 1991 a 2012. 2º edição. Florianópolis: CEPED-UFSC, v. Acre, 2013. 93 p.

COUTINHO, E. R.; DA SILVA, R. M.; MADEIRA, J. G. F.; COUTINHO, P. R. O. S.; BOLOY, R. A. M.; DELGADO, A. R. S. Application of Artificial Neural Networks (ANNs) in the Gap Filling of Meteorological Time Series. Revista Brasileira de Meteorologia, v. 33, n. 2, pp. 317-328, 2018.

CPTEC. Climanálise. v. 14, n. 1, 2012a.

CPTEC. Climanálise. v. 14, n. 2, 2012b.

DEVI, G. K.; GANASRI, B. P.; DWARAKISH, G. S. A Review on Hydrological Models. Aquatic Procedia, v. 4, pp. 1001-1007, 2015.

DORNELLES, F. Previsão Contínua de Níveis Fluviais com Redes Neurais Utilizando Previsão de Precipitação. 2007. 117 f. Dissertação (Mestrado em Engenharia) – Pós-Graduação em Recursos Hídricos e Saneamento Ambiental, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.

FACELLI, K.; LORENA, A. C. G. J. C. A. Inteligência Artificial: uma abordagem de aprendizado de máquina. Rio de Janeiro: LTC. 2011

FERREIRA, J. C.; PAIS, M. S.; YAMANAKA, K.; CARRIJO, G. A.; TEIXEIRA, M. B.; DA SILVA, R. T.; RABELO, C. G. Previsão de vazão da bacia do Ribeirão João Leite utilizando redes neurais artificiais. Irriga, v. 16, n. 3, pp. 339-350, 2011.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H.; DE JESUS, O. Neural Network Design. 2º Edição. Stillwater: Oklahoma State University, 2014.

HAIR JR, J. F.; ANDERSON, R. E.; TATHAM, R. L.; BLACK, W. C. Análise multivariada de dados. 5º Edição. Porto Alegre: Bookman, 2005.

HALLAK, R. & PEREIRA FILHO, A. J. Metodologia para análise de desempenho de simulações de sistemas convectivos na Região Metropolitana de São Paulo com o modelo ARPS: sensibilidade a variações com os esquemas de advecção e assimilação de dados. *Revista Brasileira de Meteorologia*, v. 26, n. 4, pp. 591-608, 2011.

HAYKIN, S. *Redes Neurais: Princípios e Prática*. 2ª Edição. São Paulo: Bookman, 2001.

HUANG, B.; THORNE, P. W.; BANZON, V. F.; BOYER, T.; CHEPURIN, G.; LAWRIK, J. H.; MENNE, M. J.; SMITH, T. M.; VOSE, R. S.; ZHANG, H. M. NOAA Extended Reconstructed Sea Surface Temperature (ERSST), Version 5. NOAA National Centers for Environmental Information. doi: 10.7289/V5T72FNM. Disponível em: <<https://esrl.noaa.gov/psd/data/gridded/data.noaa.ersst.v5.html>>. Acesso em: 07 ago. 2019.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. *Censo Demográfico - 2010*. Rio de Janeiro: IBGE, 2010.

LATUF, M. O. *Modelagem Hidrológica Aplicada ao Planejamento dos Recursos Hídricos na Bacia Hidrográfica do Rio Acre*. 2011. 240 f. Tese (Doutorado em Geografia) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente, 2011.

MACHADO, F. W. *Modelagem Chuva-Vazão Mensal Utilizando Redes Neurais Artificiais*. 2005. 174 f. Dissertação (Mestrado em Engenharia de Recursos Hídricos e Ambiental) - Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental, Universidade Federal do Paraná, Curitiba, 2005.

MARENGO, J. A.; LINCOLN, M.; ALVES, W.; SOARES, R.; RODRIGUEZ, D. A.; CAMARGO, H.; RIVEROS, M. P.; PABLÓ, A. D. Two Contrasting Severe Seasonal Extremes in Tropical South America in 2012: Flood in Amazonia and Drought in Northeast Brazil. *Journal of Climate*, v. 26, pp. 9137-9154, 2013.

MOMO, M. R.; ZANCHET, P. S.; ARAÚJO, C. Z.; CORREIA, W.; ABREU, C. R. C. RNA Aplicada a Modelagem Hidrológica. In: *WORKSHOP DE INICIAÇÃO CIENTÍFICA EM SISTEMAS DE INFORMAÇÃO*, 3, 2016. Anais... Florianópolis: SBSI, 2016.

NASCIMENTO, J. A. S. *Vulnerabilidade a Eventos Climáticos Extremos na Amazônia Ocidental: Uma Visão Integrada na Bacia do Rio Acre*. 2011. 285 f. Tese (Doutorado em Planejamento Energético e Ambiental) - COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

NASH, J. E. & SUTCLIFFE, J. V. River Flow Forecasting through Conceptual Model. Part 1—A Discussion of Principles. *Journal of Hydrology*, v. 10, pp. 282-290, 1970.

RIO BRANCO (2016). *Plano de Contingência Operacional de Enchente*. PREFEITURA MUNICIPAL DE RIO BRANCO, Rio Branco-AC, 70 p.

RODRIGUES, M. M. *Otimizando a Previsão de Cheias Sazonais para o Rio Negro Utilizando Redes Neurais de Propagação Direta*. 2015. 83 f. Dissertação (Mestrado em Engenharia Elétrica) - Pós-Graduação em Engenharia Elétrica, Universidade Federal do Amazonas, Manaus, 2015.

SANTOS NETO, L. A.; MANIESI, V.; SILVA, M. J. G.; SILVA, D. C.; QUERINO, C. A. S.; REIS, V. L.; PIMENTEL, A.; LIMA, Y.; GOMES, J. B. Sistemas meteorológicos que contribuíram para a cheia do Rio Acre em 2015. In: Simpósio Brasileiro de Recursos Hídricos, 22, 2017. Anais... Florianópolis: ABRH, 2017.

SANTOS, G. L. P. (2014). Resposta a Eventos Extremos na Região Trinacional - MAP - Amazônia Sul-Occidental. In: Anais da LXVI Reunião Anual da Sociedade Brasileira para o Progresso da Ciência, Rio Branco-AC.

SATYAMURTY, P.; COSTA, C. P. W.; MANZI, A. O.; CANDIDO, L. A. A quick look at the 2012 record flood in the Amazon Basin. *Geophysical Research Letters*, v.40, p.1396–1401, 2013.

SIPAM. Boletim Climático da Amazônia. v. 12, n. 125, 2015.

SILVA, A. G.; CASTRO, A. R. G.; VIEIRA, A. C. Modelo de previsão hidrológica utilizando redes neurais artificiais: um estudo de caso na bacia do Rio Xingu – Altamira-PA. *Revista Brasileira de Computação Aplicada*, v. 10, n. 3, pp. 52-62, 2018.

SOROOSHIAN, S. et al. *Hydrological Modelling and the Water Cycle: Coupling the Atmospheric and Hydrological Models*. Berlin: Springer Science & Business Media, v. 63, 2008. 291 p.

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*, Campina Grande, v. 14, n. 2, p. 173-180, 2010.

TRANCOSO, R. (2006). Mudanças na Cobertura da Terra e Alterações na Resposta Hidrológica de Bacias Hidrográficas na Amazônia. 132 f. Dissertação (Mestrado em Ciências de Florestas Tropicais) – Pós-Graduação em Biologia Tropical e Recursos Naturais, Universidade Federal do Amazonas, Manaus-AM.

WILLMOT, C. J. Some Comments on the Evaluation of Model Performance. *Bulletin of the American Meteorological Society*, v. 63, pp. 1309-1313, 1982.

ZHANG, Z. et al. Advance in Researches on the Effect of Forest on Hydrological Process. *The Journal of Applied Ecology*, v. 14, n. 1, p. 113-116, 2003