



MATEUS ALEXANDRE DA SILVA

**PREVISÃO DA PRECIPITAÇÃO PLUVIAL POR MEIO DE
REDES NEURAS ARTIFICIAIS TREINADAS UTILIZANDO
DIFERENTES VARIÁVEIS CLIMÁTICAS**

**LAVRAS–MG
2021**

MATEUS ALEXANDRE DA SILVA

**PREVISÃO DA PRECIPITAÇÃO PLUVIAL POR MEIO DE REDES NEURAIAS
ARTIFICIAIS TREINADAS UTILIZANDO DIFERENTES VARIÁVEIS
CLIMÁTICAS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Recursos Hídricos, área de concentração em Hidrologia, para a obtenção do título de Mestre.

Prof. Dr. Michael Silveira Thebaldi
Orientador

Prof. Dr. Danton Diego Ferreira
Coorientador

Prof. Dr. Felipe Schwerz
Coorientador

**LAVRAS-MG
2021**

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da
Biblioteca Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

da Silva, Mateus Alexandre.

Previsão da precipitação pluvial por meio de redes neurais
artificiais treinadas utilizando diferentes variáveis climáticas /
Mateus Alexandre da Silva. - 2021.

55 p. : il.

Orientador(a): Michael Silveira Thebaldi.

Coorientador(a): Danton Diego Ferreira, Felipe Schwerz.

Dissertação (mestrado acadêmico) - Universidade Federal
de Lavras, 2021.

Bibliografia.

1. Precipitação pluvial. 2. Previsão. 3. Redes Neurais
Artificiais. I. Thebaldi, Michael Silveira. II. Ferreira, Danton
Diego. III. Schwerz, Felipe. IV. Título.

MATEUS ALEXANDRE DA SILVA

**PREVISÃO DA PRECIPITAÇÃO PLUVIAL POR MEIO DE REDES NEURAIAS
ARTIFICIAIS TREINADAS UTILIZANDO DIFERENTES VARIÁVEIS
CLIMÁTICAS**

**RAINFALL PREDICTION BY ARTIFICIAL NEURAL NETWORKS TRAINED
USING DIFFERENT CLIMATE VARIABLES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Recursos Hídricos, área de concentração em Hidrologia, para a obtenção do título de Mestre.

APROVADA em 23 de março de 2021.

Dr. Michael Silveira Thebaldi – UFLA

Dr. Carlos Rogério de Mello – UFLA

Dr. Wilian Soares Lacerda – UFLA

Dr. Eusímio Felisbino Fraga Junior – UFU

Prof. Dr. Michael Silveira Thebaldi
Orientador

Prof. Dr. Danton Diego Ferreira
Coorientador

Prof. Dr. Felipe Schwerz
Coorientador

**LAVRAS-MG
2021**

AGRADECIMENTOS

Primeiramente, gostaria de agradecer a Deus pela oportunidade, por estar presente nos momentos de incertezas e por ser meu refúgio nos momentos difíceis.

À minha mãe Gilda Laudelina da Silva e ao meu pai Leonildo Alexandre da Silva por todo apoio e carinho, a vocês todo o meu amor e gratidão.

Aos familiares e amigos que estiveram ao meu lado durante esta jornada.

Ao Dr. Michael Silveira Thebaldi pela orientação, amizade, paciência e conhecimento compartilhado.

Ao Dr. Danton Diego Ferreira e ao Dr. Felipe Schwerz pela coorientação.

A todos os docentes do Programa de Pós-Graduação em Recursos Hídricos.

Aos colegas discentes do Programa de Pós-Graduação em Recursos Hídricos.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO GERAL

Métodos que preveem a precipitação pluvial auxiliam a evitar e mitigar danos ocasionados por seu déficit ou excesso, além de proporcionarem as ferramentas necessárias para a tomada de decisão em setores socioeconômicos e para o desenvolvimento de um planejamento adequado aos usos dos recursos hídricos. Diante disto, objetivou-se por meio da presente pesquisa, prever a precipitação mensal, com um mês de antecedência, em quatro municípios da mesorregião metropolitana de Belo Horizonte utilizando modelos de redes neurais artificiais treinadas com diferentes variáveis climáticas. Ainda, objetivou-se indicar a adequabilidade de tais variáveis como entradas destes modelos. Os modelos foram desenvolvidos por meio do *software* MATLAB® versão R2011a, utilizando a *toolbox* NNTOOL. O treinamento das redes neurais artificiais foi feito utilizando a arquitetura *multilayer perceptron* e o algoritmo *feedforward backpropagation*. Inicialmente, utilizou-se como entrada da rede neural artificial no treinamento o número sequencial correspondente ao mês e a série de precipitação total, em escala mensal, dos anos de 1970 a 1999 para a previsão das precipitações, em escala mensal, ocorridas nos anos de 2000 a 2009. Posteriormente, utilizou-se para o treinamento das redes neurais artificiais as entradas: número sequencial correspondente ao mês, e séries históricas mensais de precipitação total, temperatura média compensada, velocidade média do vento e umidade relativa média do ar, aliados a dados sobre a ocorrência do fenômeno ENOS, dos anos de 1970 a 1999, a fim de prever a precipitação em escala mensal, ocorridas nos anos de 2000 a 2009, comparando-se os resultados. Por fim, calculou-se a correlação entre as variáveis utilizadas e a precipitação do mês seguinte e, posteriormente, utilizou-se as 3 variáveis mais correlacionadas para o treinamento dos modelos. Constatou-se que as variáveis mais correlacionadas com a precipitação do mês seguinte foram o número sequencial correspondente ao mês, a precipitação total e a temperatura média compensada, e que o treinamento com estas obteve desempenho superior aos demais. Concluiu-se que as redes neurais artificiais são adequadas para a previsão da precipitação, porém apresentam uma limitação para prever meses com elevada precipitação.

Palavras-chave: ENOS. Modelagem Hidrológica. *Multilayer Perceptron*.

GENERAL ABSTRACT

Methods for predicting rainfall help to avoid and mitigate damage caused by its deficit or excess, in addition to providing the necessary tools for decision-making in socio-economic sectors and for the development of water resources use adequate planning. Thus, the aim with this research was to predict monthly precipitation, one month in advance, in four municipalities of the metropolitan mesoregion of Belo Horizonte, MG, Brazil, using models of artificial neural networks trained with different climatic variables. Also, the aim was to indicate the suitability of such variables as these model inputs. The artificial neural networks were developed using MATLAB® software version R2011a, with NNTOOL toolbox. The artificial neural networks training was done using the multilayer perceptron architecture and the feedforward backpropagation algorithm. Initially, the sequential number corresponding to the month and total rainfall, on monthly scale, from the years 1970 to 1999 were used as input to training, to forecast the rainfall occurring in the years 2000 to 2009. Subsequently, the data of the sequential number corresponding to the month, total rainfall, compensated average temperature, average wind speed and average relative humidity, together with data of the ENSO phenomenon occurrence, also between the years 1970 to 1999, were used to training, to predict rainfall on a month scale, from 2000 to 2009, comparing the results. Finally, the correlation between the used variables and rainfall was calculated and, subsequently, the 3 most correlated variables were used for the training of the models. It was found that the variables most correlated to rainfall of the following month were the sequential number corresponding to the month, the total rainfall and the compensated average temperature, and that the training using them obtained a better performance than the others. It was concluded that artificial neural networks are suitable for forecasting rainfall but have a limitation for predicting months with high values of it.

Keywords: ENSO. Hydrological Modeling. Multilayer Perceptron.

LISTA DE FIGURAS

PRIMEIRA PARTE

- Figura 1 – Fenômenos e processos que compõem o ciclo hidrológico do planeta Terra 15
- Figura 2 – Representação de um neurônio artificial.....20
- Figura 3 – Representação da estrutura de uma rede neural artificial multicamadas.21

SEGUNDA PARTE

- Figura 1 – Localização geográfica dos municípios abordados no estudo 33

LISTA DE TABELAS

PRIMEIRA PARTE

Tabela 1 - Estudos desenvolvidos para a previsão da precipitação utilizando redes neurais artificiais	24
---	----

SEGUNDA PARTE

Tabela 1 – Identificação e características dos municípios abordados no estudo.....	33
Tabela 2 - p-valores e “ τ ” obtidos por meio do teste de Mann-Kendall aplicado às séries históricas de precipitação total mensal das estações climatológicas abordadas nesse estudo, no período de treinamento.....	39
Tabela 3 – Coeficiente de correlação linear de Pearson (r), índice n_t , erro absoluto médio no período seco (MAE_S) e chuvoso (MAE_C) e viés no período seco (V_S) e chuvoso (V_C), calculados para a validação das séries de precipitação pluvial previstas por meio de redes neurais artificiais utilizando para o treinamento a combinação de dados de entrada “C1” (sem parênteses) e “C2” (entre parênteses)	40
Tabela 4 – Coeficiente de correlação linear de Pearson calculado entre as variáveis número sequencial correspondente ao mês (N), precipitação total (P), temperatura média compensada (T), umidade relativa média do ar (U), velocidade média do vento (V) e Índice MEI (MEI), e o alvo para a escolha das variáveis da combinação de dados de entrada “C3”.....	43
Tabela 5 – Coeficiente de correlação linear de Pearson (r), índice n_t , erro absoluto médio no período seco (MAE_S) e chuvoso (MAE_C), viés no período seco (V_S) e chuvoso (V_C) e p-valor (teste de Mann-Whitney), calculados para a validação das séries de precipitação pluvial previstas por meio de redes neurais artificiais utilizando para treinamento a combinação de dados de entrada “C3”	45

LISTA DE GRÁFICOS

SEGUNDA PARTE

- Gráfico 1 - Precipitação mensal média, em mm, observada nas estações climatológicas abordadas no presente estudo.35
- Gráfico 2 – Precipitação observada e prevista pelas redes neurais artificiais utilizando a combinação de dados de entrada “C3” para o treinamento para as estações climatológicas dos municípios de Belo Horizonte (A), Conceição do Mato Dentro (B), Florestal (C) e Sete Lagoas (D).47
- Gráfico 3 – Balanço do erro em escala anual entre a precipitação observada e prevista pelas redes neurais artificiais utilizando a combinação de dados de entrada “C3” para o treinamento para as estações climatológicas de dos municípios de Belo Horizonte (A), Conceição do Mato Dentro (B), Florestal (C) e Sete Lagoas (D).50

SUMÁRIO

PRIMEIRA PARTE	12
1. INTRODUÇÃO GERAL	12
2. REFERENCIAL TEÓRICO	14
2.1. Ciclo hidrológico	14
2.2. Precipitação	15
2.2.1. Formação da precipitação	16
2.2.2. Fatores que influenciam na ocorrência de precipitação	17
2.2.2.1. El Niño-Oscilação Sul (ENOS).....	17
2.3. Importância da previsão da precipitação.....	18
2.4. Redes neurais artificiais	19
2.4.1. Aprendizagem em redes neurais artificiais, rede <i>multilayer perceptron</i> , e o algoritmo <i>feedforward backpropagation</i>	22
2.4.2. Redes neurais artificiais aplicadas à previsão da precipitação.....	23
REFERÊNCIAS	25
SEGUNDA PARTE – ARTIGO	30
ARTIGO - PREVISÃO DA PRECIPITAÇÃO PLUVIAL POR MEIO DE REDES NEURAS ARTIFICIAIS TREINADAS UTILIZANDO DIFERENTES VARIÁVEIS CLIMÁTICAS	30
1. INTRODUÇÃO	31
2. MATERIAL E MÉTODOS	32
2.1. Caracterização do local de estudo	32
2.2. Obtenção dos dados utilizados no treinamento e validação das redes neurais artificiais	34
2.3. Pré-processamento dos dados	35
2.4. Treinamento das redes neurais artificiais e previsão da precipitação do período de validação	36
2.5. Validação da precipitação prevista	37

3.	RESULTADOS E DISCUSSÃO	39
3.1.	Caracterização dos dados de precipitação mensal	39
3.2.	Análise do desempenho dos modelos utilizando as combinações de dados de entrada “C1” e “C2” no treinamento.....	40
3.4.	Análise do desempenho dos modelos utilizando a combinação de dados de entrada “C3” no treinamento.	44
4.	CONCLUSÃO	51
	REFERÊNCIAS	52
	APÊNDICE A	55

PRIMEIRA PARTE

1. INTRODUÇÃO GERAL

A precipitação pluvial além de ser responsável pela entrada de água no ciclo hidrológico é essencial para atividades humanas como: a irrigação, agropecuária, geração de energia, entre outros. Portanto, conhecer o seu comportamento, por exemplo, na escala de tempo mensal, é imprescindível para o dimensionamento de projetos agrícolas e de reservas de armazenamento de água pluvial, planejamento de obras para proteção contra enchentes, fornecer informações necessárias para a tomada de decisões em setores socioeconômicos, além de evitar e mitigar danos que possam ocorrer (LEE et al., 2018; PAPALASKARIS; PANAGIOTIDIS; PANTRAKIS, 2016).

Contudo, a precipitação é uma variável climática complexa, de grande aleatoriedade e que apresenta alta variabilidade temporal e espacial (ANOCHI, 2015; DANTAS et al., 2016; GIMENEZ; NERY, 2017), tendo seu comportamento influenciado por outras variáveis climáticas como a temperatura, e anomalias climáticas, como o evento El Niño Oscilação Sul (FELIX; CARDOSO, 2005; SILVA; MENDES, 2012). Para contornar esta complexidade inerente à precipitação, o desenvolvimento de modelos que permitam a adição de informações que estão de alguma maneira ligadas ao comportamento da precipitação pode auxiliar como uma ferramenta para sua previsão.

Entre os métodos utilizados para a previsão da precipitação, as redes neurais artificiais têm sido amplamente empregadas para esse fim, já que apresentam bons resultados na modelagem de sistemas não-lineares com grande quantidade de dados (SOUSA; DE SOUSA, 2010). As redes neurais artificiais são modelos computacionais baseados no funcionamento do sistema nervoso de seres vivos, possuindo a capacidade de adquirir aprendizado por meio de dados fornecidos. O processamento das informações ocorrem em uma gama de unidades simples denominadas neurônios artificiais que originam funções matemáticas geralmente não-lineares (DA SILVA; SPATTI; FLAUZINO, 2010).

Estas unidades são formadas por uma ou mais camadas interligadas por conexões, que, em sua maioria, são ligadas a pesos, os quais armazenam o conhecimento adquirido por meio de dados de entrada e pondera-os, determinando o sinal de saída da rede (BRAGA; DE CARVALHO; LUDERMIR, 2007; FAUSETT, 1994), prevendo assim o comportamento futuro do problema abordado.

Visto a necessidade e complexidade da previsão da precipitação pluvial e a capacidade das RNA's em resolverem problemas complexos, objetivou-se por meio da presente pesquisa, prever a precipitação pluvial em quatro municípios localizados na mesorregião metropolitana de Belo Horizonte por meio de redes neurais artificiais, analisando o impacto da adição de variáveis climáticas e informações sobre anomalias do clima em seu treinamento, indicando suas adequabilidades para tal.

2. REFERENCIAL TEÓRICO

2.1. Ciclo hidrológico

O ciclo hidrológico é o fenômeno de circulação fechado da água entre a superfície terrestre e a atmosfera, impulsionado pela energia solar, força dos ventos, força da gravidade e rotação terrestre (SILVEIRA, 2001; TUNDISI, 2003). Esse ciclo é constituído por duas fases: uma terrestre, que abrange os continentes e oceanos, na qual ocorre circulação da água no interior e na superfície dos solos, rochas e nos seres vivos (animais e vegetais); e outra na atmosfera, que possui uma diversidade de condições físicas importantes (MIRANDA; OLIVEIRA; SILVA, 2010; SILVEIRA, 2001; TELLES, 2013).

Ainda segundo Telles (2013) e da Silveira (2012), os fenômenos atmosféricos em sua maioria ocorrem na troposfera, uma fina camada da atmosfera situada entre 8 e 16km de espessura, onde está localizada cerca de 90% da umidade atmosférica.


A transferência de água entre a superfície terrestre e a atmosfera ocorre em dois sentidos: no sentido superfície-atmosfera, onde o fluxo de água ocorre fundamentalmente na forma de vapor advindo da evaporação oceânica e da evapotranspiração continental; e no sentido atmosfera-superfície, onde a transferência ocorre em qualquer estado físico, sendo mais significativas, em termos globais, as precipitações de chuva e neve (MIRANDA; OLIVEIRA; SILVA, 2010; SILVEIRA, 2001).

Gribbin (2006), menciona que o ciclo da água tem um funcionamento complexo, mas pode ser explicado simplesmente como etapas:

- a) A água evapora dos oceanos e lagos da Terra;
- b) A água evaporada forma nuvens;
- c) As nuvens deslocam-se pela atmosfera em padrões climáticos globais;
- d) O vapor da água se condensa e se precipita na forma de chuva, neve ou granizo;
- e) A água precipitada chega ao solo e escoar por ele até os pequenos córregos; e
- f) Os córregos escoam para os rios e, finalmente, para os oceanos e os lagos.

Os fenômenos e processos que compõem o ciclo hidrológico são apresentados na Figura 1.

Figura 1 – Fenômenos e processos que compõem o ciclo hidrológico do planeta Terra.



Fonte: Ministério do meio ambiente (2019).

O ciclo hidrológico é fechado apenas em escala global, pois, os volumes evaporados em um determinado local do planeta não precipitarão necessariamente no mesmo local, fato explicado pelos movimentos contínuos e dinâmicas diferentes na atmosfera e também na superfície terrestre (SILVEIRA, 2001). Das fases do ciclo hidrológico apresentadas na Figura 1, tem-se que a precipitação tem função de entrada de água no ciclo, sendo que os demais componentes funcionam como saídas de água do ciclo (TELLES, 2013).

2.2. Precipitação

A precipitação é entendida na hidrologia como a água proveniente do meio atmosférico que cai sobre a superfície terrestre (TUCCI; BERTONI, 2001). Há diferentes formas de precipitação, diferenciadas apenas pelo estado em que a água se encontra, sendo elas: chuva, granizo, neve, orvalho, geada, neblina e saraiva (TELLES, 2013; TUCCI; BERTONI, 2001).

A precipitação pode ser caracterizada por meio de três grandezas: altura pluviométrica, duração e intensidade, onde a intensidade é a altura pluviométrica em função da duração (TELLES, 2013). Segundo Tucci e Bertoni (2001), as precipitações podem ser classificadas segundo o mecanismo fundamental pelo qual se produz a ascensão do ar úmido em:

1. Convectivas - Geralmente de grande intensidade e pequena duração. Este tipo de chuva ocorre quando em tempo calmo, o ar úmido é aquecido próximo ao solo, criando camadas de ar que se mantêm em equilíbrio instável. Quando perturbado este equilíbrio, forma-se uma brusca ascensão local de ar menos denso, que atingirá seu nível de condensação com formação de nuvens e, muitas vezes, precipitações;
2. Orográficas - Geralmente de pequena intensidade e grande duração. Este tipo de chuva ocorre quando ventos quentes e úmidos, soprando geralmente do oceano para o continente, encontram uma barreira física, elevam-se e se resfriam adiabaticamente – por alteração de pressão, sem troca de calor para com o exterior do sistema, havendo condensação do vapor, formação de nuvens e ocorrência de chuvas; e
3. Frontais ou ciclônicas - Geralmente de duração média e grande intensidade. Este tipo de chuva provém da interação de massas de ar quentes e frias. Nas regiões de convergência na atmosfera o ar mais quente e úmido é impulsionado para cima, resfriando-se e conseqüentemente condensando o vapor d'água, de forma a produzir chuvas.

Pode-se distinguir um evento de precipitação de outro por meio do período de estiagem entre eles. Segundo Ferreira (2015), o problema para caracterizar um novo evento de precipitação é definir o tamanho dos períodos sem chuva que tornam dois eventos independentes. Segundo Dunkerley (2008), são adotados em trabalhos períodos que variam de 3 minutos à 24 horas para separação entre eventos, porém os valores de 6 à 8 horas são os mais utilizados. Já para Bemfica, Goldenfum e Silveira (2000) para caracterização de um novo evento de precipitação é necessário um período igual ou maior a 4 horas sem chuva.

2.2.1. Formação da precipitação

Segundo Pinto et al. (1976), a formação de precipitação está ligada à ascensão das massas de ar, gerando um resfriamento que pode fazê-las atingir seu ponto de saturação, seguido da condensação do vapor de água em forma de pequenas gotas que são mantidas em suspensão, como em nuvens e nevoeiros. Para ocorrer uma precipitação é necessário que essas gotas possuam um volume tal que seu peso seja maior que as forças de sustentação fomentadas pelas correntes de ar ascendentes. Quando a força de sustentação é superada pelo peso das gotas, elas

caem (PINTO et al., 1976; TELLES, 2013; TUCCI; BERTONI, 2001; VILLELA; MATTOS, 1975).

Observa-se que, para acontecer o processo de crescimento das gotas por condensação de vapor d'água, é necessário que exista gradientes de tensão de vapor no interior da nuvem (núcleos de condensação) (TUCCI; BERTONI, 2001). Os núcleos de condensação mais ativos podem ser formados por partículas de sais procedentes do mar, cristais de gelo, e produtos de combustão contendo ácidos nítrico e sulfúrico (TELLES, 2013; TUCCI; BERTONI, 2001). O crescimento das gotas de chuva acontece por meio dos processos de colisão e coalescência, onde as gotas coletoras por meio do choque com outras gotas (colisão), aderem-se (coalescência). Para que este último fenômeno aconteça é necessária uma diferença significativa entre a velocidade da gota coletora e gota coletada, caso contrário não há aderência entre ambas (IMAI et al., 2007).

2.2.2. Fatores que influenciam na ocorrência de precipitação

A ocorrência de precipitação pode ser influenciada por diversos fatores, dos quais pode-se destacar: a vegetação, temperatura, pressão, localização geográfica, relevo e anomalias climáticas (BRITTO; BARLETTA; MENDONÇA, 2008; FORGIARINI; VENDRUSCOLO; RIZZI, 2014; MACIEL; BARCELOS; OLIVEIRA, 2012).

A vegetação tem um papel de destaque nos regimes de chuvas, principalmente em regiões que possuem floresta de alta densidade. Segundo Nobre (2014), uma árvore grande pode absorver água do solo e liberar para a atmosfera através da transpiração mais de 1000 litros de água em um único dia.

De acordo com Felix e Cardoso (2005), a temperatura, pressão e a localização geográfica podem influenciar na ocorrência de chuva, de forma que o aumento da temperatura e a baixa pressão favorecem para a evaporação da água. Quanto à localização geográfica, as partículas advindas do movimento das ondas (principalmente cloreto de sódio) em regiões próximas aos oceanos, quando arrastadas pelo vento para atmosfera criam uma condição favorável para a formação de chuva. Ainda, segundo Seluchi, Chou e Gramani (2011), fortes eventos de chuva estão relacionados à distúrbios de nível médio do relevo, onde massas de ar úmido podem se chocar com montanhas e provocar o efeito orográfico de chuva.

2.2.2.1. El Niño-Oscilação Sul (ENOS)

Existem ainda, anomalias climáticas que podem afetar drasticamente a ocorrência de chuvas, dentre as principais, podemos citar o El Niño e o La Niña (ENOS), fenômenos cíclicos que ocorrem em intervalos irregulares.

O fenômeno El Niño-Oscilação Sul (ENOS) é um importante modo de variação climática que altera os padrões em diversas regiões brasileiras (SILVA; MENDES, 2012). O ENOS é constituído de dois componentes: quente (El Niño) e frio (El Niña) (GRIMM; FERRAZ; GOMES, 1998).

O primeiro componente é ocasionado por uma alteração na temperatura das águas do Oceano Pacífico Tropical na costa oeste da América do Sul, região onde habitualmente as águas são frias e subitamente surge uma corrente de água quente, e o segundo componente ocorre quando há um resfriamento dessas águas (CPTEC/INPE, 2019; CUNHA, 2000; ROMERO; MARCUZZO, 2013). Segundo Hu e Federov (2016), este evento ocorre em períodos que variam de 2 à 7 anos.

No Brasil, em anos de El Niño há um aumento dos volumes de chuva na região Sul e diminuição na região Norte, intensificando a seca. Em contraste, em anos de La Niña há aumento dos volumes de chuva na região Norte e diminuição na região Sul (CUNHA, 2011).

Eventos de El Niño extremos como o ocorrido nos anos de 1982-1983 e relatado por Kayano e Moura (1986), causaram impactos socioeconômicos desastrosos para a maioria das áreas afetadas. Para que haja um planejamento diante de tal evento, a previsão de sua ocorrência é extremamente importante, porém, segundo Hu e Federov (2016), prever o El Niño e prever sua progressão ainda é um desafio para os cientistas.

2.3. Importância da previsão da precipitação

A variabilidade climática na Terra, desde a antiguidade, foi um fator determinante na não fixação do homem e de suas atividades em uma determinada região. Os desastres naturais (secas, enchentes, furacões, tempestades de neve, entre outros), são fatores influentes ao desenvolvimento em várias áreas do planeta (ALVES et al., 2005).

Segundo Goddard et al. (2000), os esforços envolvendo previsões climáticas acontecem há centenas de anos. Desde a antiguidade notou-se que certas plantas ou animais podem reagir de maneira peculiar às alterações climáticas, por exemplo: a aparência de uma planta com flores ou a percepção dos pássaros de construir ninhos em um lado específico da árvore pode evidenciar uma próxima estação chuvosa boa ou ruim. Contudo, a atmosfera terrestre é

considerada um sistema caótico onde as alterações atmosféricas que acontecerão daqui duas semanas não podem ser previstas (SAMPAIO; DIAS, 2014).

Dentre os fenômenos climáticos, a precipitação é uma variável de grande interesse devido a sua influência em setores produtivos da sociedade e por provocar desastres naturais por meio de secas e inundações (ANOCHI, 2015; BRAMBILA; FERREIRA; CAPOS VELHO, 2004). Para mais, a precipitação é responsável pela entrada de água no ciclo hidrológico, e, conhecê-la quantitativamente é imprescindível a um planejamento e gerenciamento eficiente dos recursos hídricos.


Apesar da precipitação pluvial ser uma grandeza que apresenta alta variabilidade temporal e espacial (ANOCHI, 2015; DANTAS et al., 2016; GIMENEZ; NERY, 2017), surge como uma solução para a complexidade inerente à este fenômeno, e conseqüentemente de se prevê-lo, os modelos de redes neurais artificiais, que apresentam bons resultados na modelagem de sistemas não-lineares complexos com grande quantidade de dados (SOUSA; SOUSA, 2010).

2.4. Redes neurais artificiais

Desde o aparecimento dos primeiros computadores os seres humanos questionam-se sobre a possibilidade de máquinas possuírem autonomia para pensar. A Ciência da Computação, mais especificamente o ramo de Inteligência Artificial (IA), há algum tempo realizam estudos para atribuir às máquinas a habilidade de pensar de forma autônoma (BREGA, 1996). Ainda segundo Brega (1996), tomando como base a inteligência humana, a IA dividiu-se em duas linhas de pesquisa: a linha simbólica, onde é estudada a psicologia, baseada na lógica, e a linha conexionista com o objetivo de simular componentes do cérebro humano. Na linha de pesquisa conexionista uma das técnicas que se consagraram foram as redes neurais artificiais (RNA's).

As RNA's são modelos computacionais baseados no funcionamento do sistema nervoso de seres vivos, sistemas estes paralelos distribuídos onde o processamento de informações ocorrem em uma gama de unidades simples denominadas neurônios artificiais que originam funções matemáticas geralmente não-lineares (DA SILVA; SPATTI; FLAUZINO, 2010). A representação de um neurônio artificial pode ser visualizada na Figura 2.

Figura 2 – Representação de um neurônio artificial.



Fonte: Os autores (2021).


Segundo Haykin (2007) pode-se identificar três elementos básicos no modelo neuronal (Figura 2):

1. Um conjunto de sinapses, cada uma caracterizada por seu próprio peso (w). Um sinal de entrada x_n na entrada da sinapse n conectada ao neurônio é multiplicado pelo peso sináptico w_n .
2. Um somador (Σ) para somar os sinais de entrada (x), ponderados por suas respectivas sinapses.
3. Uma função de ativação ($g(\cdot)$), utilizada para restringir a amplitude da saída do neurônio.

Segundo ainda o autor, o modelo neuronal (Figura 2) possui também um *bias* (θ) que tem a função de aumentar ou reduzir a entrada da função de ativação.

As RNA's são formadas por uma ou mais camadas, compostas por neurônios artificiais, interligadas por links de conexões, geralmente unidirecionais, conexões essas na maioria dos modelos ligadas a pesos, os quais armazenam o conhecimento adquirido e ponderaram a entrada recebida por cada neurônio para determinar o sinal de saída da rede (BRAGA; DE CARVALHO; LUDERMIR, 2007; FAUSETT, 1994). A estrutura de uma rede neural artificial multicamadas é apresentada na Figura 3.

Figura 3 – Representação da estrutura de uma rede neural artificial multicamadas.



Fonte: Os autores (2021).

A utilização de RNA's vêm se consolidando em escala global como uma eficiente ferramenta para tratar uma ampla classe de problemas complexos, onde há um grande quantidade de dados que devem ser modelados e analisados em um contexto multidisciplinar (KOVÁCS, 2006). A solução de problemas por meio de RNA's é convidativa, já que a forma como estes são representados internamente pela rede e o paralelismo natural inerente à arquitetura das RNA's criam a possibilidade de um desempenho superior aos modelos convencionais (BRAGA; DE CARVALHO; LUDERMIR, 2007; GONÇALVES; SILVA; D'AGOSTO, 2015).

As RNA's podem ser utilizadas em uma ampla variedade de problemas como, armazenar e recuperar dados ou padrões, mapeamentos gerais de padrões de entrada e saída, agrupar padrões semelhantes ou encontrar soluções para problemas de otimização restritos (FAUSETT, 1994).

Segundo da Silva, Spatti e Flauzino (2010) são principais características da aplicação de redes neurais:

1. Adaptação por experiência: as adaptações dos pesos sinápticos internos da rede são ajustadas por meio da apresentação sucessiva de dados (padrões, amostras e

- medidas) relacionados ao comportamento do processo que está sendo submetido ao método, adquirindo o conhecimento por experiência;
2. Capacidade de aprendizado: por meio da submissão a um método de treinamento, a rede consegue extrair as relações entre as variáveis que compõe o processo;
 3. Habilidade de generalização: após o processo de aprendizagem da rede ela se torna capaz de generalizar o conhecimento adquirido, encontrando soluções até então desconhecidas;
 4. Organização de dados: baseada nas características dos dados, a rede realiza uma organização interna que possibilita o agrupamento de padrões que apresentam particularidades em comum;
 5. Tolerância a falhas: devido ao elevado nível de interconexões entre os neurônios, a rede torna-se tolerante a falhas quando parte de sua estrutura interna é sensivelmente corrompida;
 6. Armazenamento distribuído: o conhecimento de determinado processo é adquirido de forma distribuída entre as diversas sinapses de seus neurônios, incrementando assim a robustez do método frente a eventuais neurônios que se tornarem inoperantes;
 7. Facilidade de prototipagem: a prototipagem em hardware ou software da rede após o treinamento se torna simples, pois geralmente, os resultados são obtidos por algumas operações matemáticas elementares.

2.4.1 Aprendizagem em redes neurais artificiais, rede *multilayer perceptron*, e o algoritmo *feedforward backpropagation*

Uma das principais características das RNA's é a capacidade de aprendizado por meio de exemplos. No conexionismo o conhecimento é proporcionado pelo ajuste das intensidades (pesos) das conexões entre os neurônios (BRAGA; DE CARVALHO; LUDERMIR, 2007). As redes neurais aprendem a partir de exemplos (dados de entrada conhecidos) e a partir desses generalizam novos exemplos, abstraindo-se de características de entradas que contenham dados irrelevantes (BREGA, 1996).

No treinamento de uma RNA é apresentado à rede uma série de dados de entrada e saída já conhecidos, onde os pesos sinápticos da rede são iterativamente adaptados, minimizando assim o erro quadrático médio entre a resposta desejada e os dados de entrada e saída (DE OLIVEIRA et al., 2010).

Existem duas formas de aprendizado em modelos de redes neurais artificiais: aprendizado supervisionado e não-supervisionado. No supervisionado é apresentado à rede por um agente externo, conjuntos de padrões de entrada e os correspondentes padrões de saída. Para cada entrada a rede recebe um *feedback* se a resposta calculada é boa ou ruim, realizando assim, ajustes a fim de melhorar as futuras respostas. Já no aprendizado não-supervisionado apenas os padrões de entrada são fornecidos à rede. Estes padrões são processados e, quando detectada regularidades a rede estabelece representações internas para resolver o problema (FERNEDA, 2006).

A definição da arquitetura é um ponto importante no emprego das redes neurais artificiais. Dependendo do problema abordado, uma rede com poucas conexões pode ser incapaz de solucioná-lo devido à quantidade insuficiente de parâmetros ajustáveis. Em contrapartida, conexões demais podem prejudicar a capacidade de generalização da rede (FERREIRA, 2004).

Dentre as várias arquiteturas se destaca a *perceptron*, proposta em 1958 por Frank Rosenblatt (ROSENBLATT, 1958). Segundo Cardon e Müller (1994), a grande vantagem da utilização desta é sua simplicidade, devido à pequena quantidade de parâmetros a ajustar e conforme a aplicação os dados de entrada não precisam de um pré-processamento muito elaborado.

Segundo Coelho (2019), o principal algoritmo de aprendizagem, e, de longe, o mais utilizado é o *backpropagation*, proposto por Rumelhart, Hinton e Williams (1986). Este algoritmo ajusta repetidamente os pesos das conexões na rede, de forma que a diferença entre o valor da saída da rede e o valor desejado seja minimizado (RUMELHART; HINTON; WILLIAMS, 1986), utilizando tal diferença como um dos fatores de ajuste dos pesos.

2.4.2 Redes neurais artificiais aplicadas à previsão da precipitação

Apesar do método de redes neurais artificiais não ser recente, ainda pode contribuir como uma nova forma de abordagem para previsão de variáveis hidrológicas. Tal fato se deve à sua simples aplicação, pouca exigência de máquinas potentes e uma alternativa amplamente aceita que apresenta bons resultados na modelagem de sistemas não-lineares complexos com grande quantidade de dados, especialmente quando as relações dos processos físicos ainda não são completamente compreendidos (SOUSA; SOUSA, 2010).

A aplicação das redes neurais artificiais na hidrologia tem se intensificado e dividem espaço não só com métodos estatísticos (regressão, multivariados, análise de periodicidade,

entre outros) mas também com os métodos dinâmicos (modelo de circulação geral (MCGs), atmosférico (MCGAs) acoplados oceano-atmosfera (MCGC) dentre outros na realização de simulações climáticas futuras (GODDARD, 2000). Segundo Gomes, Montenegro e Valença (2010), o aumento na utilização de tais modelos se deve ao fato de serem de fácil aplicação e proporcionarem resultados satisfatórios.

Estudos hidrológicos utilizando redes neurais artificiais estão sendo cada vez mais empregados, como para preenchimento de falhas diárias (ALMEIDA; ALMEIDA, 2012; GIMENEZ; NERY, 2017) e mensais (CORREIA et al., 2016) de precipitação, modelagem chuva-vazão (GOMES; MONTENEGRO; VALENÇA, 2010; SOUSA; SOUSA, 2010; SCHEIDT; BRUNETTO, 2011), simulação de vazão média mensal (OLIVEIRA; PEDROLLO; CASTRO, 2014), dentre outras aplicações.

Tendo em vista a importância da precipitação dentro da hidrologia, diversos estudos que obtiveram desempenhos satisfatórios utilizando o método de RNA's na previsão de precipitação foram desenvolvidos, como os apresentados na Tabela 1.

Tabela 1 - Estudos desenvolvidos para a previsão da precipitação utilizando redes neurais artificiais.

Autores	Ano de publicação	País de estudo	Técnica utilizada	Objeto do estudo	Dados de entrada	Escala de previsão
Geetha e Selvaraj	2011	Índia	MLP / FFBP	PT	Tméd, Uméd e A	Mensal
Moustris et al.	2011	Grécia	MLP / FFBP	Pmáx, Pméd, Pmín e PA	Pmáx, Pméd, Pmín e PA	Quadrimestral
Abhishek et al.	2012	Índia	MLP / FFBP	PT	Uméd e VVméd	Mensal
Mislan et al.	2015	Indonésia	MLP / FFBP	PT	PT	Mensal
Dantas et al.	2016	Brasil	RBF	PT	PT	Mensal
Lee et al.	2018	Coréia do Sul	MLP / FFBP	PT	IC	Mensal
Yadav e Sagar	2019	Índia	MLP / FFBP	PT	Tmín, Tmáx, Umín, Umáx e VVméd	Mensal

MLP = *Multilayer perceptron*; FFBB = *Feedforward backpropagation*; RBF = *Radial basis function*; PT = Precipitação total; P = Precipitação; PA = Precipitação acumulada; T = Temperatura do ar; U = Umidade relativa do ar; A = Aerossol; VV = Velocidade do vento; IC = Índices climáticos

Fonte: Os autores (2021).

REFERÊNCIAS

- ABHISHEK, K. et al. A rainfall prediction model using artificial neural network. *In: CONTROL AND SYSTEM GRADUATE RESEACH COLLOQUIUM*, 2012, Shah Alam. **Anais [...]**. Shah Alam: IEEE, 2012. p. 82–87.
- ALMEIDA, M. S. S.; ALMEIDA, R. C. Análise do desempenho de redes neurais artificiais no preenchimento de falhas em séries de precipitação diária. **Learning and Nonlinear Models**, v. 10, n. 3, p. 175–180, 2012.
- ALVES, J. M. B. Uma avaliação preliminar de simulações climáticas de um modelo regional espectral aninhado em um modelo global (ECHAM4 .5) sobre o setor norte da região nordeste do Brasil (1971-2000). **Revista Brasileira de Meteorologia**, v.20, n.2, p. 191–206, 2005.
- ANOCHI, Juliana Aparecida. **Previsão climática de precipitação por redes neurais autoconfiguradas**. 2015. 161 p. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2015.
- BEMFICA, D. C.; GOLDENFUM, J. A.; SILVEIRA, A. L. L. Análise da aplicabilidade de padrões de chuva de projeto a Porto Alegre. **Revista Brasileira de Recursos Hídricos**, v. 5, n. 4, p. 5–16, 2000.
- BRAGA, Antonio de Pádua; DE CARVALHO, André Ponce de Leon F.; LUDERMIR, Teresa Bernarda. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2007.
- BRAMBILA, M. C. V.; FERREIRA, N. J.; CAMPOS VELHO, H. F. Downscaling estatístico para previsão de precipitação sobre o sudeste do Brasil. *In: CONGRESSO BRASILEIRO DE METEOROLOGIA*, 13., 2004, Fortaleza. **Anais eletrônicos [...]** Fortaleza: CD-ROM. (INPE-12042-PRE/7388).
- BREGA, José Remo Ferreira. **A utilização de redes neurais artificiais em um sistema de gerência de pavimentos**. 1996. 234 p. Tese (Doutorado em Transportes) - Escola de Engenharia de São Carlos, São Carlos, 1996.
- BRITTO, F. P.; BARLETTA, R.; MENDONÇA, M. Variabilidade espacial e temporal da precipitação pluvial no Rio Grande do Sul: influência do fenômeno el niño oscilação sul. **Revista Brasileira de Climatologia**, v. 3, p. 37-48, 2008.
- CARDON, A.; MÜLLER, D. N. **Introdução às redes neurais artificiais**. Porto Alegre, 1994. Disponível em: http://www.inf.ufrgs.br/~danielnm/docs/intro_rna.pdf. Acesso em: 11 nov. 2019.
- COELHO, Orlando Bisacchi. **O papel das representações vetoriais de palavras na pontuação automática de ensaios**. 2019. 105 p. Tese (Doutorado em Engenharia Elétrica e Computação) - Universidade Presbiteriana Mackenzie, São Paulo, 2019.

- CORREIA, T. P. et al. Aplicação de redes neurais artificiais no preenchimento de falhas de precipitação mensal na região serrana do Espírito Santo. **Geociências UNESP**, v. 35, n. 4, p. 560–567, 2016.
- CPTEC/INPE. **El Niño e La Niña**. Disponível em: <http://enos.cptec.inpe.br/>. Acesso em: 21 set. 2019.
- CUNHA, G. R. et al. El Niño/La Niña - Oscilação Sul e seus impactos na agricultura brasileira: fatos, especulações e aplicações. **Revista Plantio Direto**, v.20, n. 121, p. 18-22, 2011.
- CUNHA, Gilberto. R. **Meteorologia: fatos e mitos - 2**. Passo Fundo: Embrapa Trigo, 2000.
- DA SILVA, Ívan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.
- DANTAS, D. et al. Uso de redes neurais artificiais na previsão da precipitação de períodos chuvosos. **Revista Espinhaço**, v. 5, n. 1, p. 11–18, 2016.
- DE OLIVEIRA, A. C. S. et al. Aplicação de redes neurais artificiais na previsão da produção de álcool. **Ciência e Agrotecnologia**, v. 34, n. 2, p. 279–284, 2010.
- DUNKERLEY, D. Identifying individual rain events from pluviograph records: a review with analysis of data from an Australian dryland site. **Hydrological Processes**, v. 22, n. 26, p. 5024–5036, 2008.
- FAUSETT, Laurene V. **Fundamentals of neural networks**. New Jersey: Prentice-Hall, Inc., 1994.
- FELIX, E. P.; CARDOSO, A. A. Fatores ambientais que afetam a precipitação úmida. **Química Nova na Escola**, n. 21, p. 47-50, 2005.
- FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**, v. 35, n. 1, p. 25–30, 2006.
- FERREIRA, Aida Araujo. **Comparação de arquiteturas de redes neurais para sistemas de reconhecimento de padrões em narizes artificiais**. 2004. 107 p. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de Pernambuco, Recife, 2004.
- FERREIRA, Manoela Gomes Braga. **Análise regional da distribuição temporal de precipitações sub diárias para o estado de Minas Gerais**. 2015. 86 p. Dissertação (Mestrado em Saneamento, Meio Ambiente e Recursos Hídricos) - Universidade Federal de Minas Gerais, Belo Horizonte, 2015.
- FORGIARINI, F. R.; VENDRUSCOLO, D. S.; RIZZI, E. S. Análise de chuvas orográficas no centro do Estado do Rio Grande do Sul. **Revista Brasileira de Climatologia**, v. 13, p. 107–119, 2014.

GEETHA, G.; SELVARAJ, R. S. Prediction of monthly rainfall in chennai using back propagation neural network model. **International Journal of Engineering Science and Technology**, v. 3, n. 1, p. 211–213, 2011.

GIMENEZ, D. F. S.; NERY, J. T. Aplicação das redes neurais artificiais no preenchimento de dados diários de chuva no Estado de São Paulo. *In*: CONGRESSO NACIONAL DE GEOGRAFIA FÍSICA, 1., 2017, Campinas. **Anais [...]** Campinas, 2017. p. 1747–1755.

GODDARD, L. Current approaches to seasonal-to-interannual climate predictions. **International Journal of Climatology**, v. 21, n. 9, p. 1111–1152, 2000.

GOMES, L. F. C.; MONTENEGRO, S. M. G. L.; VALENÇA, M. J. S. Modelo baseado na técnica de redes neurais para previsão de vazões na bacia do rio São Francisco. **Revista Brasileira de Recursos Hídricos**, v. 15, n. 1, p. 5–15, 2010.

GONÇALVES, D. N. S.; SILVA, M. A.; D'AGOSTO, M. A. Procedimento para uso de redes neurais artificiais no planejamento estratégico de fluxo de carga no Brasil. **Journal of Transport Literature**, v. 9, n. 1, p. 45–49, 2015.

GRIBBIN, John E. **Introduction to hydraulics and hydrology with applications for stormwater management**. 3. ed. New York: T. D. Learning , 2006.

GRIMM, Alice M.; FERRAZ, Simone E. T. **Sudeste do Brasil: uma região de transição no impacto de eventos extremos da Oscilação Sul parte 1: El Niño**. 1998, Brasília: SBMET, 1998.

HAIKIN, S. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2007.

HU, S.; FEDEROV, A. V. Exceptionally strong easterly wind burst stalling El Niño of 2014. **Proceedings of the National Academy of Sciences of the United States of America**, v. 113, n. 8, p. 200–2010, 2016.

IMAI, T. et al. *In*: ENCONTRO DE INICIAÇÃO CIENTÍFICA E PÓS-GRADUAÇÃO DO ITA. 13., 2007, São José dos Campos. **Anais [...]** São José dos Campos, 2007. [8] p.

KAYANO, M. T.; MOURA, A. D. O El Niño de 1982-83 e a precipitação sobre a América do Sul. **Revista Brasileira de Geofísica**, v. 4, p. 201–214, 1986.

KOVÁCS, Zsolt L. **Redes neurais artificiais: fundamentos e aplicações: um texto básico**. 4. ed. São Paulo: Livaria da Física, 2006.

LEE, J. et al. Application of artificial neural networks to rainfall forecasting in the Geum River Basin, Korea. **Water (Switzerland)**, v. 10, n. 10, p. 1-14, 2018.

MACIEL, S. A.; BARCELOS, B. F.; OLIVEIRA, L. A. A análise da influência da altitude na temperatura e na precipitação da mesorregião Norte de Minas – Minas Gerais. **Revista Geonorte**, v. 1, n. 5, p. 250–261, 2012.

MINISTÉRIO DO MEIO AMBIENTE. **Ciclo hidrológico**. Disponível em: <https://www.mma.gov.br/agua/recursos-hidricos/aguas-subterraneas/ciclo-hidrologico.html>. Acesso em: 10 set. 2019.

MIRANDA, R. A. C.; OLIVEIRA, M. V. S.; SILVA, D. F. Ciclo hidrográfico planetário: abordagens e conceitos. **Geo UERJ**, v. 1, n. 21, p. 109–119, 2010.

MISLAN, H. et al. Rainfall monthly prediction based on artificial neural network - A case study in Tenggarong Station, East Kalimantan - Indonesia. **Procedia Computer Science**, v. 59, p. 142–151, 2015.

MOUSTRIS, K. P. et al. Precipitation Forecast Using Artificial Neural Networks in Specific Regions of Greece. **Water Resources Management**, v. 25, n. 8, p. 1979–1993, 2011.

NOBRE, A. D. **O Futuro climático da Amazônia: relatório de avaliação científica**. São José dos Campos: ARA: CCST-INPE: INPA, 2014.

OLIVEIRA, G. G.; PEDROLLO, O. C.; CASTRO, N. M. R. O desempenho das redes neurais artificiais (RNAs) para simulação hidrológica mensal. **Revista Brasileira de Recursos Hídricos**, v. 19, n. 2, p. 251–265, 2014.

PAPALASKARIS, T.; PANAGIOTIDIS, T.; PANTRAKIS, A. Stochastic monthly rainfall time series analysis, modeling and forecasting in Kavala city, Greece, North-Eastern Mediterranean basin. **Procedia Engineering**, v. 162, p. 254–263, 2016.

PINTO, Nelson L. de Souza. et al. **Hidrologia básica**. São Paulo: Blucher, 1976.

ROMERO, V.; MARCUZZO, F. F. N. Influência do El Niño e La Niña no número de dias de precipitação pluviométrica do estado de Goiás. **Revista ACTA Geográfica**, v. 7, n. 14, p. 93–106, 2013.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386–408, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533–536, 1986.

SAMPAIO, G.; DIAS, P. L. S. Evolução dos modelos climáticos e de previsão de tempo e clima. **Revista USP**, n. 103, p. 41, 2014.

SCHEIDT, F. A.; BRUNETTO, M. A. C. Modelagem chuva-vazão utilizando redes neurais artificiais e algoritmos genéticos. In: CONGRESSO DA SOCIEDADE BRASILEIRA DE COMPUTAÇÃO, 31., 2011, Natal. **Anais [...]** Natal: SBC, 2011. p. 1399-1408.

SELUCHI, M. E.; CHOU, S. C.; GRAMANI, M. A case study of a winter heavy rainfall event over the Serra do Mar in Brazil. **Geofísica Internacional**, v. 50, n. 1, p. 41–56, 2011.

SILVA, I. A.; MENDES, P. C. O el niño e sua influência nas temperaturas e precipitações na cidade de Uberlândia (MG). **Revista Geonorte**, v. 2, n. 5, p. 485–495, 2012.

SILVEIRA, A. L. L. Ciclo hidrológico e bacia hidrográfica. *In*: TUCCI, C. E. M. **Hidrologia: ciência e aplicação**. 2. ed. Porto Alegre: UFRGS/ABRH, 2001. cap. 2, p 35-40.

SOUSA, W. S.; DE SOUSA, F. A. S. Rede neural artificial aplicada à previsão de vazão da bacia hidrográfica do rio piacó. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 2, p. 173–180, 2010.

TELLES, Dirceu D'Alkmin. **Ciclo ambiental da água: da chuva à gestão**. São Paulo: Blucher, 2013.

TUCCI, C. E. M.; BERTONI, J. C. Precipitação. *In*: TUCCI, C. E. M. **Hidrologia: ciência e aplicação**. 2. ed. Porto Alegre: UFRGS/ABRH, 2001. cap. 5, p 177-231.

TUNDISI, J. G. Ciclo hidrológico e gerenciamento integrado. **Ciência e Cultura**, v. 55, n. 4, p. 31–33, 2003.

VILLELA, Swami Marcondes; MATTOS, Arthur. **Hidrologia aplicada**. São Paulo: Mc Graw Hill, 1975.

YADAV, P.; SAGAR, A. Rainfall prediction using artificial neural network (ANN) for tarai Region of Uttarakhand. **Current Journal of Applied Science and Technology**, v. 33, n. 5, p. 1–7, 2019.

SEGUNDA PARTE – ARTIGO

ARTIGO - PREVISÃO DA PRECIPITAÇÃO PLUVIAL POR MEIO DE REDES NEURAIS ARTIFICIAIS TREINADAS UTILIZANDO DIFERENTES VARIÁVEIS CLIMÁTICAS

RESUMO

Prever a precipitação pluvial pode evitar e mitigar danos ocasionados por seu déficit ou excesso, além de proporcionar ferramentas necessárias para a tomada de decisão em setores socioeconômicos e para um planejamento adequado aos usos dos recursos hídricos. Diante disto objetivou-se, por meio da presente pesquisa, prever a precipitação mensal, com um mês de antecedência, em quatro municípios da mesorregião metropolitana de Belo Horizonte, por meio de redes neurais artificiais treinadas com diferentes variáveis climáticas. Ainda, objetivou-se indicar a adequabilidade de tais variáveis como entradas destes modelos. Os modelos foram desenvolvidos por meio do *software* MATLAB® versão R2011a, utilizando a *toolbox* NNTOOL. O treinamento das redes foi feito utilizando a arquitetura *multilayer perceptron* e o algoritmo *feedforward backpropagation*. Para o treinamento dos modelos foram utilizadas 2 combinações de dados de entrada, com 2 e 6 variáveis, além de 1 combinação de entrada com 3 das 6 variáveis mais correlacionadas à precipitação, ambos do período entre 1970 e 1999, objetivando prever a precipitação dos anos de 2000 a 2009, comparando-se os resultados. Constatou-se que as variáveis mais correlacionadas à precipitação do mês seguinte são o número sequencial correspondente ao mês, precipitação total e temperatura média compensada, e que o treinamento com estas obteve desempenho superior aos demais. Para mais, concluiu-se que o desempenho dos modelos foi satisfatório, entretanto apresentaram limitações para prever meses com elevada precipitação.

Palavras-chave: ENOS. Modelagem Hidrológica. *Multilayer Perceptron*.

ABSTRACT

Predicting rainfall can prevent and mitigate damages caused by its deficit or excess, besides providing necessary tools for adequate planning for the use of water. This research aimed to predict the monthly rainfall, one month in advance, in four municipalities in the metropolitan region of Belo Horizonte, using artificial neural networks (ANN) trained with different climate variables, and to indicate the suitability of such variables as inputs to these models. The models were developed through the MATLAB® software version R2011a, using the NNTOOL toolbox. The ANN's were trained by the multilayer perceptron architecture and the Feedforward and Back propagation algorithm, using two combinations of input data were used, with 2 and 6 variables, and one combination of input data with 3 of the 6 variables most correlated to observed rainfall from 1970 to 1999, to predict the rainfall from 2000 to 2009. The most correlated variables to the rainfall of the following month are the sequential number corresponding to the month, total rainfall and average compensated temperature, and the best performance was obtained with these variables. Furthermore, it was concluded that the

performance of the models was satisfactory; however, they presented limitations for predicting months with high rainfall.

Keywords: ENOS. Hydrological Modeling. Multilayer Perceptron.

1. INTRODUÇÃO

Prever a precipitação pluvial, por exemplo, em escala mensal, é imprescindível para o dimensionamento de projetos agrícolas e de armazenamento de água pluvial, planejamento de obras para proteção contra enchentes, fornecer informações necessárias para a tomada de decisões em setores socioeconômicos, além de evitar e mitigar danos materiais e à vida (LEE et al., 2018; PAPALASKARIS; PANAGIOTIDIS; PANTRAKIS, 2016).

Entretanto, a precipitação é uma das variáveis do ciclo hidrológico mais complexas de se entender e modelar devido à complexidade dos processos atmosféricos e sua alta variabilidade temporal e espacial (NAYAK; MAHAPATRA; MISHRA, 2013). Ainda, tal fenômeno é influenciado por diversos fatores como variáveis climáticas (temperatura do ar, umidade relativa do ar, insolação, velocidade do vento, entre outros) e anomalias do clima (MAWONIKE; MANDONGA, 2017; SILVA; MENDES, 2012).

Segundo Askoy e Dahamsheh (2009), a modelagem que visa a previsão de precipitação utilizando apenas dados históricos da própria precipitação só é benéfica quando variáveis climáticas como a temperatura do ar, velocidade do vento e umidade relativa do ar não estão disponíveis, ou quando se deseja um modelo simples em relação aos dados de entrada. Sendo assim, o desenvolvimento de modelos que permitam a adição de variáveis que estejam diretamente relacionadas ao comportamento da precipitação é uma maneira de contornar a falta de precisão da previsão. Segundo Abhishek et al. (2012), apesar da complexidade envolvida em prever a precipitação, descobriu-se que modelos de redes neurais artificiais são capazes de se adaptar aos padrões de dados que variam irregularmente, como acontece na precipitação.

Redes neurais artificiais são baseadas no funcionamento do cérebro humano, possuindo a capacidade de adquirir aprendizado por meio de dados de entrada. Uma rede neural artificial é formada por uma ou mais camadas, que são compostas por um ou mais neurônios, interligados entre camadas, nos quais são realizadas o processamento dos sinais (dados) de entrada por meio de pesos presentes nas conexões entre neurônios. Cada neurônio se comunica com os neurônios da próxima camada até que seja atingida a camada de saída, onde é calculado o erro entre o sinal de saída e o sinal desejado. Por fim, é feito o ajuste dos pesos e o processo se repete até

que o erro na camada de saída seja aceitável para o problema abordado (DA SILVA; SPATTI; FLAUZINO, 2010; MOUSTRIS et al., 2011).

Objetivando prever a precipitação, alguns pesquisadores foram bem sucedidos, como Geetha e Selvaraj (2011) e Abhishek et al. (2012) na Índia, que utilizaram variáveis climáticas para o treinamento de um modelo de rede neural artificial empregando a arquitetura *multilayer perceptron* e o algoritmo *feedforward backpropagation*. Entretanto, apenas utilizar uma grande quantidade de variáveis para a previsão não é indicado, como explica May, Dandy e Maier (2011) ao citar que o emprego de variáveis que têm pouco ou nenhum poder preditivo afeta a complexidade do modelo e dificulta o aprendizado da rede neural artificial. Desta forma, segundo ainda os autores supracitados, é indicado uma pré-seleção criteriosa de variáveis para compor a entrada dos modelos.

Visto a necessidade de previsão e a complexidade da precipitação pluvial, objetivou-se prever a precipitação em escala mensal para quatro municípios localizados na mesorregião metropolitana de Belo Horizonte, Minas Gerais, Brasil por meio de redes neurais artificiais. Para isto, utilizou-se no treinamento diferentes variáveis climáticas e informações sobre a ocorrência da anomalia climática ENOS visando analisar a influência da adição destas variáveis ao treinamento, além de indicar suas adequabilidades para tal emprego.

2. MATERIAL E MÉTODOS

2.1. Caracterização do local de estudo

O estudo compreendeu 4 municípios da mesorregião metropolitana de Belo Horizonte, no estado de Minas Gerais, Brasil. A identificação dos municípios, bem como algumas de suas características são indicadas na Tabela 1.

Tabela 1 - Identificação e características dos municípios abordados no estudo.

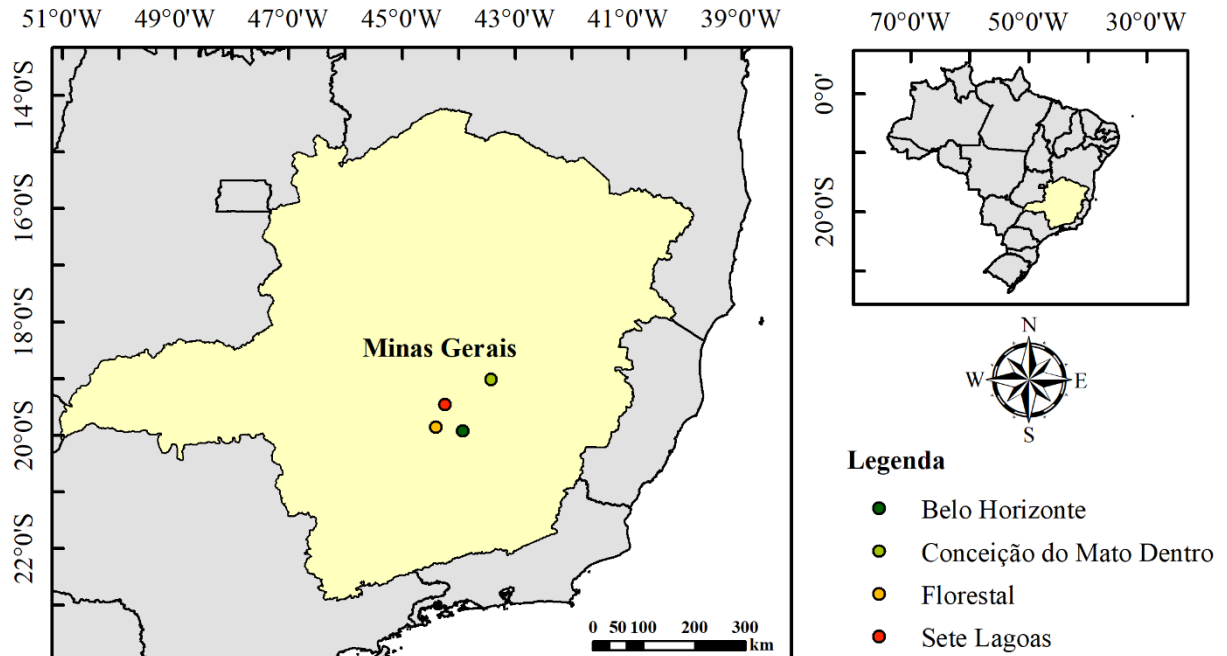
Estação climatológica (Município)	Latitude	Longitude	Classificação		Precipitação anual média (mm)*
			climática - Köppen (MARTINS et al., 2018)	Altitude (m)	
Belo Horizonte	-19.934382	-43.952292	Aw	915,17	1544,64
C. do Mato Dentro	-19.020355	-43.433948	Aw	663,02	1283,50
Florestal	-19.885422	-44.416889	Cwa	753,51	1399,29
Sete Lagoas	-19.48454	-44.173798	Aw	753,68	1325,69

* – Referente ao período dos dados de treinamento (1970 – 1999); Aw – tropical com seca no inverno
Cwa – subtropical com seca no inverno e verão quente.

Fonte: Os autores (2021).

A localização geográfica dos municípios abordados no estudo pode ser vista na Figura 1.

Figura 1 – Localização geográfica dos municípios abordados no estudo.



Fonte: Os autores (2021).

O critério para a escolha da mesorregião foi a existência de pelo menos 4 postos com dados mensais de precipitação total, temperatura média compensada, umidade relativa média do ar e velocidade média do vento no período entre os anos de 1970 a 2009. Para a escolha das


estações climatológicas foram estabelecidos os seguintes critérios: pertencer à mesma mesorregião, possuírem diferença máxima de altitude de 300 m entre si e apresentar, considerando as séries históricas de todas as variáveis supracitadas, o percentual máximo de falhas de 30%.

2.2. Obtenção dos dados utilizados no treinamento e validação das redes neurais artificiais

Para compor o banco de dados de treinamento e validação das redes neurais artificiais foi utilizado o número sequencial correspondente ao mês (1 a 12), além de séries históricas mensais de precipitação total, temperatura média compensada, umidade relativa média do ar e velocidade média do vento dos anos de 1970 a 2009, obtidos por meio da plataforma BDMEP - Banco de Dados do Instituto Nacional de Meteorologia (INMET, 2020). Para fornecer dados sobre a ocorrência dos fenômenos climáticos El Niño e La Niña, utilizou-se o *Multivariate ENSO Index* (MEI) dos anos de 1970 a 2009, com registros bimestrais, obtidos na plataforma Nacional *Oceanic and Atmospheric Administration* (NOAA, 2018). Neste, o menor valor (1) indica casos mais fortes de La Niña, enquanto o valor mais alto (69) indica casos mais fortes de El Niño.

Os valores de precipitação mensal média nas estações climatológicas abordadas no presente estudo, calculados utilizando os meses sem falhas destas, do período de 1970 a 2009, podem ser vistos por meio do Gráfico 1.

Gráfico 1 – Precipitação mensal média, em mm, observada nas estações climatológicas abordadas no presente estudo.



Fonte: Os autores (2021).

2.3. Pré-processamento dos dados

Para a obtenção de um único valor mensal para o MEI, realizou-se uma média ponderada entre os meses sobrepostos (dezembro – janeiro; janeiro – fevereiro; (...); novembro – dezembro) utilizando como peso o número de dias em cada mês.

O banco de dados foi dividido em dois intervalos: treinamento (1970 – 1999) e validação (2000 – 2009), sendo este último variável devido à disponibilidade de dados de cada estação climatológica. Desejando que as características das séries históricas não sofressem alterações, não foi realizado nenhum procedimento para o preenchimento de falhas.

A fim de verificar a homogeneidade hidrológica da região onde as estações climatológicas estão inseridas, bem como a consistência dos dados mensais de precipitação para o período de treinamento, utilizou-se a curva de dupla massa conforme descrito em ANA (2012). Tal verificação foi realizada de forma que a precipitação mensal observada em cada um

dos postos fosse validada (eixo das ordenadas), enquanto a média dos demais postos foram consideradas como a precipitação mensal observada de referência (eixo das abscissas).

A fim de verificar a existência de tendência nas séries históricas de precipitação total mensal do período de treinamento (1970 a 1999), realizou-se o teste de Mann-Kendall admitindo um nível de significância de 5% ($p\text{-valor} < 0,05$).

Para o treinamento da rede, foi definido como alvo a precipitação no tempo “ $t+1$ ” e três combinações de dados de entrada:

C1 - número sequencial correspondente ao mês e precipitação total, ambos no tempo “ t ”.

C2 - número sequencial correspondente ao mês, precipitação total, temperatura média compensada, umidade relativa média do ar, velocidade média do vento e índice MEI, sendo todas no tempo “ t ”.

C3 - três variáveis cujas séries históricas obtiveram maior coeficiente de correlação linear de Pearson em relação à série histórica do alvo, todas no tempo “ t ”.

Devido às diferentes unidades de medida inerente aos dados de entrada, estes foram normalizados utilizando a Equação 1.

$$z = \frac{x - \text{mín}(x)}{\text{máx}(x) - \text{mín}(x)} \quad (1)$$

Em que z representa o valor normalizado, x o valor a ser normalizado, $\text{máx}(x)$ o valor máximo entre os valores a serem normalizados e $\text{mín}(x)$ o valor mínimo entre os valores a serem normalizados.

2.4. Treinamento das redes neurais artificiais e previsão da precipitação do período de validação

As redes neurais artificiais foram desenvolvidas no *software* MATLAB® na versão R2011a, utilizando a *toolbox* NNTOOL. Para o treinamento das redes neurais artificiais com as diferentes combinações de dados, utilizou-se a arquitetura *multilayer perceptron* com o algoritmo *feedforward backpropagation* amplamente citado na literatura devido aos ótimos resultados na previsão de séries de precipitação mensal (AKSOY; DAHAMSHEH, 2009; MISLAN et al., 2015; NAYAK; MAHAPATRA; MISHRA, 2013) e a função de treinamento de Levenberg-Marquardt (LEVENBERG, 1944).

As configurações das redes neurais artificiais foram definidas experimentalmente por “tentativa e erro” e selecionada a configuração com melhor desempenho.

Para os treinamentos que utilizaram as combinações de dados de entrada “C1” e “C3” foram utilizadas duas camadas ocultas com 4 neurônios cada, com as funções de transferência sigmoide tangente hiperbólica e log-sigmoide, respectivamente. Utilizou-se ainda camada de saída com 1 neurônio e a função de transferência linear. Já para os treinamentos que utilizaram a combinação de dados de entrada “C2” utilizou-se duas camadas ocultas com 6 neurônios cada as funções de transferência log-sigmoide e sigmoide tangente hiperbólica, respectivamente. Utilizou-se ainda uma camada de saída com 1 neurônio e a função de transferência linear (APÊNDICE A).

Durante a etapa de treinamento das redes neurais artificiais, cada modelo foi treinado 10 vezes com pesos iniciais de treinamento diferentes, mantendo o melhor resultado e descartando os demais. As previsões que apresentaram valor menor que 0 foram convergidas para 0, visto que não existe valor de precipitação negativo.

2.5. Validação da precipitação prevista

Para a validação da precipitação prevista pelas redes neurais artificiais foram calculados os seguintes indicadores estatísticos: coeficiente de correlação linear de Pearson (r), erro absoluto médio (MAE) e viés (V) (Equações 2, 3 e 4, respectivamente). Com o objetivo de identificar o período no qual ocorreram os maiores erros, além de sua tendência de subestimativa ou superestimativa, o erro absoluto médio e o viés foram calculados separadamente para o período chuvoso (outubro a março) e seco (abril a setembro).

$$r = \frac{\sum_{i=1}^n (P_i - \bar{P}) \cdot (O_i - \bar{O})}{\sqrt{[\sum_{i=1}^n (P_i - \bar{P})^2] \cdot [\sum_{i=1}^n (O_i - \bar{O})^2]}} \quad (2)$$

$$MAE = \frac{1}{N} \cdot \sum_{i=1}^n (|P_i - O_i|) \quad (3)$$

$$V = \frac{1}{N} \cdot \sum_{i=1}^N (P_i - O_i) \quad (4)$$

Em que “ O ” representa os dados observados nas estações climatológicas, “ \bar{O} ” a média dos dados observados, “ P ” os dados previstos pelas redes neurais artificiais e “ N ” a quantidade de dados para validação. Os valores de “ N ” variaram com a disponibilidade de dados de cada estação climatológica no período de validação, sendo para os municípios de Belo Horizonte, Conceição do Mato Dentro, Florestal, e Sete Lagoas, respectivamente, para a combinação de dados “C1”, 120, 119, 109 e 120, para a combinação de dados “C2” e “C3”, 120, 118, 29 e 120.

Se tratando do coeficiente de correlação linear de Pearson, segundo Dancey e Reidy (2006), é possível classificar o grau de correlação entre duas variáveis em três classes: correlação fraca de $0,10 < r < 0,30$; moderada de $0,40 < r < 0,60$; e forte de $0,70 < r < 1,00$.

Para avaliar o desempenho do modelo, utilizou-se o índice n_t (Equação 5) proposto por Ritter e Muñoz-Carpena (2013). O índice n_t sugere que a eficiência do modelo deve ser considerada satisfatória quando o erro é “pequeno”, levando em conta a largura da faixa de dados coberta pelos valores calculados. Este índice garante que um modelo que realize a previsão da precipitação com um valor de erro pequeno dentro de uma faixa de dados pequeno não seja considerado melhor do que outro modelo que prevê com um maior valor de erro, porém, dentro de uma faixa de dados também maior.

Desta forma, avalia-se a eficiência do modelo dependendo do número de vezes (n_t) que a variabilidade das observações é maior que o erro médio do modelo. Para tal, o erro médio é representado pela raiz quadrada do erro médio quadrático ($RMSE$) e a variabilidade dos dados observados pelo desvio padrão populacional (SD).

$$n_t = \frac{SD}{RMSE} - 1 \quad (5)$$

Ritter e Muñoz-Carpena (2013) também definiram quatro classes de desempenho com base no índice n_t , sendo $n_t < 0,7$ insatisfatório, $0,7 \leq n_t < 1,2$ aceitável, $1,2 \leq n_t < 2,2$ bom e $2,2 \leq n_t$ muito bom.

A fim de se verificar possíveis diferenças significativas entre as séries históricas observadas e previstas para a combinação de melhor desempenho, foi realizado o teste de Mann-Whitney, admitindo um nível de significância de 5% (p -valor $< 0,05$).

Ainda, calculou-se a magnitude do erro em escala anual por meio da subtração do valor da lâmina de precipitação anual observada do valor da lâmina de precipitação prevista.

3. RESULTADOS E DISCUSSÃO

3.1. Caracterização dos dados de precipitação mensal

A homogeneidade hidrológica da região onde as estações climatológicas estão inseridas, bem como a consistência dos dados das séries históricas de precipitação mensal foram comprovadas pelos altos valores dos coeficientes de determinação ($R^2 = 0,9976 - 0,9995$), obtidos ajustando a linha de tendência linear à curva de dupla massa. Assim, pode-se afirmar que o comportamento hidrológico nas estações climatológicas é similar, bem como eliminar a ocorrência de erros de transcrição dos dados observados em campo ou alteração do coeficiente angular da reta.

Na Tabela 2 são indicados os p-valores e o “ τ ” obtidos aplicando o teste de Mann-Kendall, a 5% de significância, às séries históricas de precipitação total mensal das estações climatológicas abordadas nesse estudo, no período de treinamento.

Tabela 2 – p-valores e “ τ ” obtidos por meio do teste de Mann-Kendall aplicado às séries históricas de precipitação total mensal das estações climatológicas abordadas nesse estudo, no período de treinamento.

Série histórica (mês)	p-valor (τ)			
	Estação climatológica			
	Belo Horizonte	C. do Mato Dentro	Florestal	Sete Lagoas
Janeiro	0,066 (0,223)	0,196 (0,152)	0,133 (0,174)	0,064 (0,241)
Fevereiro	0,443 (0,092)	0,657 (0,055)	0,454 (0,089)	0,669 (0,057)
Março	0,798 (0,032)	0,766 (0,037)	0,910 (0,015)	0,199 (0,168)
Abril	0,744 (-0,040)	0,755 (0,039)	0,989 (0,003)	1,000 (0,002)
Mai	0,306 (-0,123)	0,109 (-0,192)	0,744 (-0,040)	0,301 (-0,136)
Junho	0,274 (-0,135)	0,926 (0,013)	0,527 (-0,080)	0,427 (-0,108)
Julho	0,155 (-0,177)	0,766 (-0,038)	0,160 (-0,179)	0,229 (-0,163)
Agosto	0,382 (0,108)	0,431 (0,098)	0,945 (-0,010)	0,971 (0,007)
Setembro	0,196 (0,155)	0,966 (-0,007)	0,754 (-0,038)	1,000 (0,000)
Outubro	0,125 (-0,183)	0,002 (-0,378)*	0,007 (-0,317)*	0,019 (-0,299)*
Novembro	0,532 (-0,076)	0,260 (-0,137)	0,264 (-0,132)	0,110 (-0,204)
Dezembro	0,132 (0,180)	0,001 (0,401)*	0,969 (0,006)	0,062 (0,239)

Fonte: Os autores (2021).

Nota-se, por meio da Tabela 2, que foi constatada tendência significativa (p-valor < 0,05) de decréscimo dos valores de precipitação total no mês de outubro ($\tau < 0$) para as séries históricas das estações climatológicas de Conceição do Mato Dentro, Florestal e Sete Lagoas.

Em contraste, houve apenas uma tendência significativa (p -valor > 0) de acréscimo nos valores de precipitação total ($\tau > 0$) para o mês de dezembro para a série histórica da estação climatológica de Conceição do Mato Dentro. Para os demais meses das séries históricas das estações climatológicas analisadas, não houve tendência significativa de acréscimo ou decréscimo do valor de precipitação total.

3.2. Análise do desempenho dos modelos utilizando as combinações de dados de entrada “C1” e “C2” no treinamento.

Na Tabela 3 são mostrados os valores dos indicadores estatísticos calculados para a validação das séries de precipitação pluvial previstas por meio de redes neurais artificiais, utilizando a combinação de dados de entrada “C1” no treinamento.

Tabela 3 – Coeficiente de correlação linear de Pearson (r), índice n_t , erro absoluto médio no período seco (MAE_S) e chuvoso (MAE_C) e viés no período seco (V_S) e chuvoso (V_C), calculados para a validação das séries de precipitação pluvial previstas por meio de redes neurais artificiais utilizando para o treinamento a combinação de dados de entrada “C1” (sem parênteses) e “C2” (entre parênteses).

Estação climatológica	r	MAE_S (mm)	MAE_C (mm)	V_S (mm)	V_C (mm)	n_t
Belo Horizonte	0,84 (0,83)	23,85 (25,57)	86,23 (90,75)	2,94 (-3,28)	-23,50 (-14,61)	0,80 (0,80)
C. do Mato Dentro	0,77 (0,75)	25,90 (25,44)	92,33 (96,27)	10,04 (9,34)	-17,81 (-3,11)	0,55 (0,51)
Florestal	0,78 (0,84)	23,64 (23,85)	76,79 (56,10)	13,87 (21,32)	4,65 (-31,00)	0,60 (0,83)
Sete Lagoas	0,85 (0,78)	21,64 (40,52)	76,43 (72,87)	11,66 (26,37)	-24,66 (-17,12)	0,80 (0,60)

Fonte: Os autores (2021).

Pela Tabela 3 é possível observar que os valores do coeficiente de correlação linear de Pearson obtidos encontram-se entre 0,77 e 0,85 utilizando a combinação de dados de entrada “C1”, e 0,75 e 0,84 utilizando a combinação de dados de entrada “C2”. Segundo a classificação proposta por Dancy e Reidy (2006), todas as séries de precipitação previstas obtiveram correlação forte com as séries de precipitação observadas. Tal classificação indica linearidade entre o aumento dos valores das séries observadas e previstas, sugerindo que se os dados observados estiverem acima da média, os previstos também estarão (FIGUEIREDO FILHO; DA SILVA JÚNIOR, 2009; MARTINS, 2014). Sendo assim, nota-se que os modelos foram

capazes de prever satisfatoriamente a sazonalidade presente na série histórica de dados, identificando os meses com maiores e menores índices pluviométricos.

Entretanto, percebe-se que, com exceção da estação climatológica do município de Florestal, os valores de correlação obtidos utilizando a combinação de dados de entrada “C2” diminuíram em relação aos valores obtidos para o treinamento das redes neurais artificiais utilizando a combinação de dados de entrada “C1”.

Os valores do erro absoluto médio para o período seco encontraram-se entre 21,64 e 25,90 mm utilizando a combinação de dados “C1” e 23,85 e 40,52 mm utilizando a combinação de dados “C2”, sendo que os maiores valores foram obtidos utilizando a combinação de dados de entrada “C2”. Comparando os valores do erro absoluto médio à média da precipitação do período seco, estes podem ser considerados altos, porém, há uma redução brusca no valor da média, ocasionada pelos meses com baixa ou nenhuma precipitação. Sendo assim, os erros do período seco são menos relevantes se comparados aos valores de precipitação de cada mês do período seco.

Analisando também o viés do período seco nota-se que os valores ficaram entre 2,94 e 13,87 mm utilizando a combinação de dados de entrada “C1” e -3,28 e 26,37 mm utilizando a combinação de dados “C2”. Isto mostra, com exceção do modelo desenvolvido para a estação climatológica de Belo Horizonte utilizando a combinação de dados de entrada “C2”, que os modelos superestimaram a precipitação, reforçando a ideia de que os valores obtidos para o erro absoluto médio do período seco foram influenciados pelos meses mais secos do período seco. Para mais, os maiores valores de viés foram obtidos utilizando a combinação de dados de entrada “C2”.

Já os valores do erro absoluto médio do período chuvoso ficaram entre 76,43 e 92,33 mm utilizando a combinação de dados de entrada “C1” e 56,10 e 96,27 mm utilizando a combinação de dados de entrada “C2”, valores altos até para os meses mais chuvosos.

Para o viés deste mesmo período observa-se que os valores compreenderam-se entre -24,66 e 4,65 mm utilizando a combinação e dados de entrada “C1” e -31,00 e -3,11 mm utilizando a combinação de dados de entrada “C2”. Dentre tais valores observou-se apenas um valor positivo, obtido para a estação climatológica do município de Florestal ao se utilizar a combinação de dados de entrada “C1” no treinamento das redes neurais artificiais.

Tal fato indica que os modelos subestimaram a precipitação no período chuvoso, sendo a falta de acurácia das RNA's na previsão dos meses mais chuvosos um possível fator para o aumento do erro e do viés. Apesar dos valores do erro absoluto médio para o período chuvoso

obtidos utilizando a combinação de dados de entrada “C2” indicar, na maioria das estações, uma redução quando comparada à “C1”, exceto para Florestal, esta redução não foi expressiva.

Os valores do índice n_t utilizando a combinação de dados de entrada “C1” ficaram entre 0,55 e 0,80. Para as estações climatológicas dos municípios de Conceição do Mato Dentro e Florestal o modelo foi classificado como insatisfatório e para as estações climatológicas dos municípios de Belo Horizonte e Sete Lagoas classificado como aceitável (RITTER; MUÑOZ-CARPENA, 2013). Já utilizando a combinação de dados de entrada “C2”, os valores do índice n_t encontraram-se entre 0,51 e 0,83. Para as estações climatológicas dos municípios de Conceição do Mato Dentro e Sete Lagoas o modelo foi classificado como insatisfatório e para as estações climatológicas dos municípios de Belo Horizonte e Florestal, aceitável (RITTER; MUÑOZ-CARPENA, 2013).

De forma semelhante ao resultado obtido pelo coeficiente de correlação linear de Pearson, o índice n_t indicou um retrocesso no desempenho do modelo das estações climatológicas de Conceição do Mato Dentro e Sete Lagoas utilizando a combinação de dados de entrada “C2” em relação à utilização da combinação de dados de entrada “C1” para o treinamento das redes neurais artificiais. Para as estações climatológicas dos municípios de Florestal e Belo Horizonte houve aumento e constância do índice, respectivamente.

Por meio da análise conjunta dos resultados, nota-se, em geral, que a adição das variáveis climatológicas prejudicou o desempenho dos modelos. Apesar das variáveis componentes da combinação de dados de entrada “C2” serem utilizadas por meteorologistas para a alimentação de modelos que preveem o clima e sua variabilidade (NOAA, 2011), estas podem apresentar mudanças em seu comportamento em curtos períodos de tempo, sendo mais úteis para a previsão em menor escala temporal, como, por exemplo, na escala horária e diária.

Exemplificando o exposto, Martins et al. (2019) explicam em seu estudo que a umidade relativa do ar atinge maiores porcentagens no período noturno. Sendo assim, em escalas maiores que a horária, como por exemplo a escala mensal, estes valores são reduzidos por serem medidos como a média do período.

Tal comportamento dos modelos também pode ser explicado a partir do exposto por May, Dandy e Maier (2011). Os autores apresentam que os modelos de redes neurais artificiais podem passar por problemas de subespecificações devido à escolha de variáveis de entrada insuficientes ou não informativas, ou ainda por superespecificações em virtude da utilização variáveis não informativas, pouco informativas ou até mesmo redundantes. Estes problemas podem impactar na complexidade do modelo, dificuldade do aprendizado e desempenho da rede neural artificial. Os autores complementam que, para o treinamento de uma rede neural, é

necessário realizar a seleção das variáveis de entrada e um dos métodos amplamente utilizados é a classificação da variável com base na correlação de Pearson, realizando a seleção por ordem decrescente de classificação.

3.3. Seleção de variáveis para o treinamento dos modelos de redes neurais artificiais

Desejando selecionar as variáveis mais correlacionadas à precipitação para comporem a combinação de dados de entrada “C3”, na Tabela 4 estão indicados os valores do coeficiente correlação linear de Pearson obtidos entre as variáveis de entrada utilizadas na combinação de dados de entrada “C2” e o alvo.

Tabela 4 – Coeficiente de correlação linear de Pearson calculado entre as variáveis número sequencial correspondente ao mês (N), precipitação total (P), temperatura média compensada (T), umidade relativa média do ar (U), velocidade média do vento (V) e MEI (MEI), e o alvo para a escolha das variáveis da combinação de dados de entrada “C3”.

Estação climatológica	N	P	T	U	V	MEI
Belo Horizonte	0,33	0,47	0,45	0,21	0,12	0,03
C. do Mato Dentro	0,38	0,44	0,49	-0,08	0,37	0,01
Florestal	0,38	0,43	0,51	0,09	0,08	0,04
Sete Lagoas	0,39	0,47	0,48	0,17	0,26	0,01
Média	0,37	0,45	0,48	0,10	0,21	0,02

Fonte: Os autores (2021).

Por meio da Tabela 4 é possível verificar que tanto para a média quanto individualmente as três variáveis que obtiveram maiores valores para o coeficiente de correlação linear de Pearson foram temperatura média compensada, precipitação total e número correspondente ao mês, respectivamente. Em contrapartida, a umidade relativa média do ar, velocidade do vento e o MEI, em geral, apresentaram pequenos valores de correlação.

Sabe-se que o ar úmido favorece a formação de precipitações, como na ocorrência de precipitações convectivas (TUCCI; BERTONI, 2001) e que a velocidade do vento afeta o comportamento da evapotranspiração (ALENCAR; SEDIYAMA; MANTOVANI, 2015). Contudo nesse estudo, estas variáveis não têm grande poder preditivo para a precipitação do mês seguinte.

No que tange à umidade relativa do ar, o resultado obtido não corrobora com o apresentado por Hung et al. (2009) que, com o objetivo de prever a precipitação uma hora à frente em Bangkok, na Tailândia, utilizando a arquitetura *generalized feedforward*, constataram

que a umidade relativa estava diretamente ligada ao bom desempenho do modelo. A discordância entre resultados pode ser explicada por Mawonike e Mandonga (2017), que apresentam que a variabilidade na umidade relativa do ar afeta a ocorrência de precipitação, porém a maximização deste efeito acontece quando a umidade relativa do ar se encontra acima de 80%. Estes valores são observados com menor frequência em escala mensal, uma vez que dias com baixos valores de umidade relativa do ar reduzem os valores médios.

Já para a variável velocidade do vento, a possível explicação para a baixa correlação, segundo Alencar, Sediya e Mantovani (2015), é que a variação da velocidade média do vento em períodos mensais é relativamente baixa, ou seja, enquanto há uma grande discrepância entre os valores de precipitação mensais os valores de velocidade do vento mensais se mantêm com pouca variabilidade.

Percebe-se também, que o menor coeficiente de correlação linear de Pearson correspondeu ao MEI. Este fato pode ser explicado, segundo Grimm e Ferraz (1998), pela região Sudeste do Brasil, onde está inserida a área de estudo, possuir um caráter de transição. Desta forma, as anomalias (El Niño e La Niña) podem deslocar-se mais para o Norte ou para o Sul de um evento para outro, possibilitando alterar os efeitos em relação a um mesmo evento ocorrido anteriormente, o que não ocorre para o extremo Sul brasileiro.

Sendo assim, para a combinação de dados de entrada “C3”, foram utilizadas as três variáveis que obtiveram maior valor do coeficiente de correlação linear de Pearson com o alvo, ou seja, número correspondente ao mês, temperatura média compensada e precipitação total.

3.4. Análise do desempenho dos modelos utilizando a combinação de dados de entrada “C3” no treinamento.

Os indicadores estatísticos para a validação das séries de precipitação pluviométrica previstas utilizando no treinamento das redes neurais artificiais a combinação de dados de entrada “C3” estão dispostos na Tabela 5.

Tabela 5 – Coeficiente de correlação linear de Pearson (r), índice n_t , erro absoluto médio no período seco (MAE_S) e chuvoso (MAE_C), viés no período seco (V_S) e chuvoso (V_C) e p-valor do teste de Mann-Whitney, calculados para a validação das séries de precipitação pluvial previstas por meio de redes neurais artificiais utilizando para treinamento a combinação de dados de entrada “C3”.

Estação climatológica	r	MAE_S (mm)	MAE_C (mm)	V_S (mm)	V_C (mm)	n_t	p-valor
Belo Horizonte	0,85	21,33	83,92	2,21	-26,72	0,80	0,433 ^{NS}
C. do Mato Dentro	0,80	27,80	83,45	13,24	-8,93	0,66	0,027*
Florestal	0,91	17,79	50,66	11,88	21,48	1,26	0,316 ^{NS}
Sete Lagoas	0,85	20,42	71,46	7,91	-26,06	0,84	0,402 ^{NS}

Em que: * diferença significativa pelo teste de Mann-Whitney à 5% de probabilidade estatística; e NS diferença não significativa pelo teste de Mann-Whitney à 5% de probabilidade estatística

Fonte: Os autores (2021).

Conforme o mostrado na Tabela 5, os valores do coeficiente de correlação linear de Pearson encontram-se entre 0,80 e 0,91, o que segundo Dancey e Reidy (2006) indica forte correlação entre as séries de precipitação observadas e previstas. Além disso, tais valores indicam linearidade entre o aumento dos valores previstos e observados e tendência de valores previstos acima da média quando os valores observados estiverem acima da média (FIGUEIREDO FILHO; DA SILVA JÚNIOR, 2009; MARTINS, 2014).

Percebe-se que com exceção do valor obtido para o modelo da estação climatológica do município de Sete Lagoas utilizando a combinação de dados de entrada “C1” que se manteve constante, houve um aumento dos valores em relação aos obtidos utilizando para o treinamento dos modelos as combinações de dados de entrada “C1” e “C2”.

Os altos valores do coeficiente de correlação linear de Pearson, nesse caso, indicam que as redes neurais artificiais foram capazes de aprender a sazonalidade existente na série temporal de precipitação, sendo capaz de identificar de modo satisfatório os meses com altos e baixos índices pluviométricos.

Os valores do erro absoluto médio para o período seco ficaram entre 17,79 e 27,80 mm, havendo redução deste em relação aos obtidos para o mesmo período utilizando para o treinamento dos modelos as combinações de dados de entrada “C1” e “C2”. Como exceção, para o modelo da estação climatológica de Conceição do Mato Dentro o erro absoluto médio apresentou aumento. Já os valores de viés para o período seco, se situaram entre 2,21 e 13,24 mm, sendo que, de forma análoga ao erro absoluto médio, houve uma redução dos valores de viés para a maioria das estações climatológicas em relação aos valores de viés obtidos para o mesmo período utilizando para o treinamento das redes neurais artificiais a combinação de dados de entrada “C1” e “C2”, mantendo a tendência de superestimativa.

Para o período chuvoso os valores de erro absoluto médio ficaram entre 50,66 e 83,92 mm. Por meio de comparação nota-se que houve uma redução do valor do erro absoluto médio para todas as estações climatológicas em relação à utilização das combinações de dados de entrada “C1” e “C2”. Já os valores de viés para o mesmo período, ficaram entre -26,72 e 21,48 mm, não apresentando tendência definida de redução ou aumento em relação aos valores obtidos para o mesmo índice no mesmo período utilizando para treinamento das redes neurais artificiais as combinações de dados “C1” e “C2”.

Utilizando a combinação de dados de entrada “C3” no treinamento das redes neurais artificiais, o índice n_t apresentou valores entre 0,66 e 1,26. Assim, o modelo foi classificado como insatisfatório para a estação climatológica do município de Conceição do Mato Dentro, aceitáveis para as estações climatológicas dos municípios de Belo Horizonte e Sete Lagoas e bom para a estação climatológica do município de Florestal. Percebe-se que os valores do índice n_t aumentaram para todas as estações climatológicas em relação aos valores obtidos para o treinamento das redes neurais artificiais realizados com as combinações de dados de entrada “C1” e “C2”. Utilizando para o treinamento a combinação de dados de entrada “C3”, houve um menor número modelos classificados como insatisfatórios em relação às demais combinações e um modelo classificado como bom, fato que ainda não havia ocorrido.

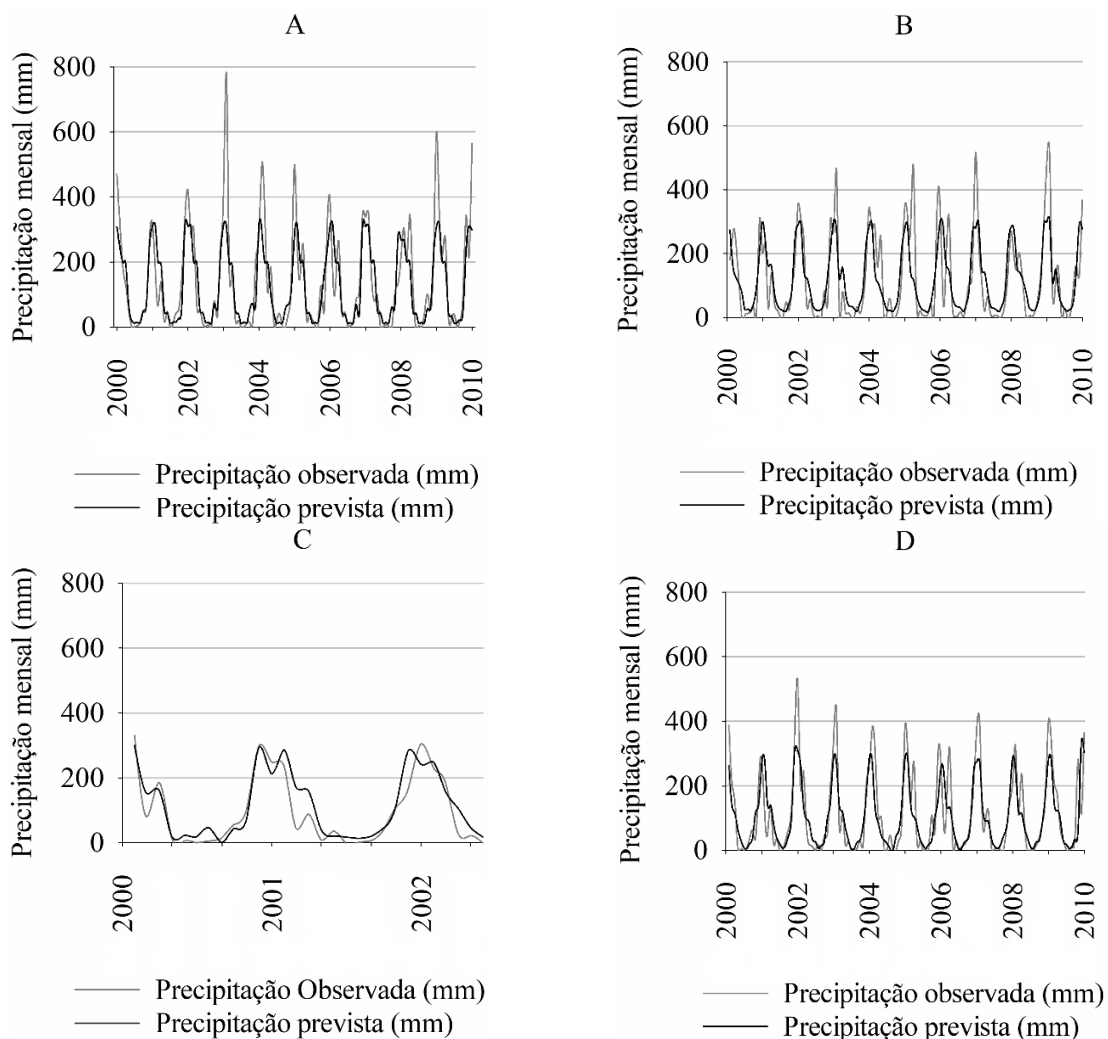
Comparando os resultados obtidos utilizando diferentes combinações de dados de entrada para treinamento das redes neurais artificiais, nota-se que o desempenho do modelo utilizando apenas as três variáveis que obtiveram maiores coeficientes de correlação com o alvo (combinação de dados de entrada “C3”) para o treinamento das redes neurais melhorou. De forma similar, Lee et al. (2018) utilizando a arquitetura *multilayer perceptron* além do algoritmo *feedforward backpropagation* tentaram prever a precipitação pluvial na Coréia do Sul utilizando inicialmente dados de 10 diferentes índices climáticos. Após uma avaliação e seleção de 5 índices que apresentaram melhores resultados, os autores obtiveram um melhor desempenho do modelo.

Ademais, segundo o teste de Mann-Whitney, apenas para a estação climatológica do município de Conceição do Mato Dentro houve diferença significativa entre as séries observada e prevista. Isto pode ser explicado pela maior magnitude do valor do erro absoluto médio para o período seco obtida para o modelo da estação climatológica do município de Conceição do Mato Dentro, sendo este valor cerca de 40% maior do que a média dos valores obtidos para as demais estações climatológicas. Tal aumento de valores faz com que a mediana da série de precipitação prevista também aumente, se tornando estatisticamente significativa.

Para as demais estações climatológicas, não houve evidências suficientes para concluir que houve diferença significativa entre séries observadas e previstas, ou seja, não foram detectadas diferenças discrepantes entre o valor da mediana das séries observadas e estimadas. Isto indica um desempenho satisfatório dos modelos, pois, o fato de que não há uma diferença estatisticamente significativa entre os valores das medianas, aliado aos altos valores do coeficiente de correlação linear de Pearson, significa que as séries previstas reproduziram a sazonalidade inerente à série de precipitação observada.

Objetivando uma análise visual dos resultados obtidos para o treinamento das RNA's utilizando a combinação de dados de entrada "C3", os valores de precipitação observados e previstos pelas redes neurais artificiais em escala mensal foram plotados no Gráfico 2.

Gráfico 2 – Precipitação observada e prevista pelas redes neurais artificiais utilizando a combinação de dados de entrada "C3" para o treinamento para as estações climatológicas dos municípios de Belo Horizonte (A), Conceição do Mato Dentro (B), Florestal (C) e Sete Lagoas (D).



Por meio da análise visual do Gráfico 2, observa-se que não houve uma diferença expressiva entre os dados observados e previstos nos períodos de menores lâminas precipitadas. Percebe-se também que, apesar dos modelos preverem com boa precisão os intervalos com maiores lâminas precipitadas, estes apresentaram dificuldade de prever os valores acima de 300 mm, sendo este o provável motivo para os altos valores de erro absoluto médio e tendência de subestimativa, encontrados para o período chuvoso.

Tal fato pode ter contribuído para que o modelo da estação climatológica do município de Conceição do Mato Dentro tenha sido classificado como insatisfatório pelo índice n_t utilizando a combinação de dados de entrada “C3”. Consolidando o indicado pelo índice n_t , nota-se que o único modelo classificado como bom, correspondente à estação climatológica do município de Florestal, foi o que apresentou melhor concordância visual gráfica entre séries. O desempenho superior deste modelo em relação aos demais pode ser explicado pela ausência de valores de precipitação total mensal que destoam do padrão observado para o período avaliado (> 300 mm), como nas estações climatológicas dos demais municípios.

Para efeito de comparação, pode-se analisar a previsão obtida para a estação climatológica de Belo Horizonte, onde, no ano de 2003, houve o maior pico de precipitação observada para todas as séries, atingindo valores próximos a 800 mm/mês, havendo também um grande valor de erro. Contudo, para a mesma estação, no ano de 2007, nota-se que não houve picos de precipitação que fugiam ao padrão geral avaliado, o que levou a uma boa concordância gráfica entre as séries observada e prevista. O mesmo fato pode ser constatado para as estações climatológicas dos demais municípios, como para Conceição do Mato Dentro, entre os anos de 2008 e 2009 e Sete Lagoas, entre os anos de 2001 e 2002.

Um comportamento análogo de séries previstas foi detectado por Geetha e Selvaraj (2011) e Yadav e Sagar (2019) objetivando prever a precipitação mensal na Índia utilizando a arquitetura *multilayer perceptron* acrescida do algoritmo *feedforward backpropagation*. No treinamento das redes neurais, para os primeiros foram utilizados dados de temperatura média do ar, umidade relativa média do ar, velocidade média do vento e valores de aerossol (RSPM – Material Particulado em Suspensão Respirável), e, para os segundos, dados de temperatura mínima e máxima do ar, umidade relativa mínima e máxima do ar e velocidade média do vento. Estes demonstraram graficamente que os maiores valores de erros apresentados pelo modelo acontecem nos picos de precipitação.

De forma similar, Moustris et al. (2011) utilizando a arquitetura *multilayer perceptron*, o algoritmo *feedforward backpropagation* e dados de entrada de precipitação máxima, mínima, média e cumulativa dos quatro meses anteriores, além de um índice para indicar a sazonalidade

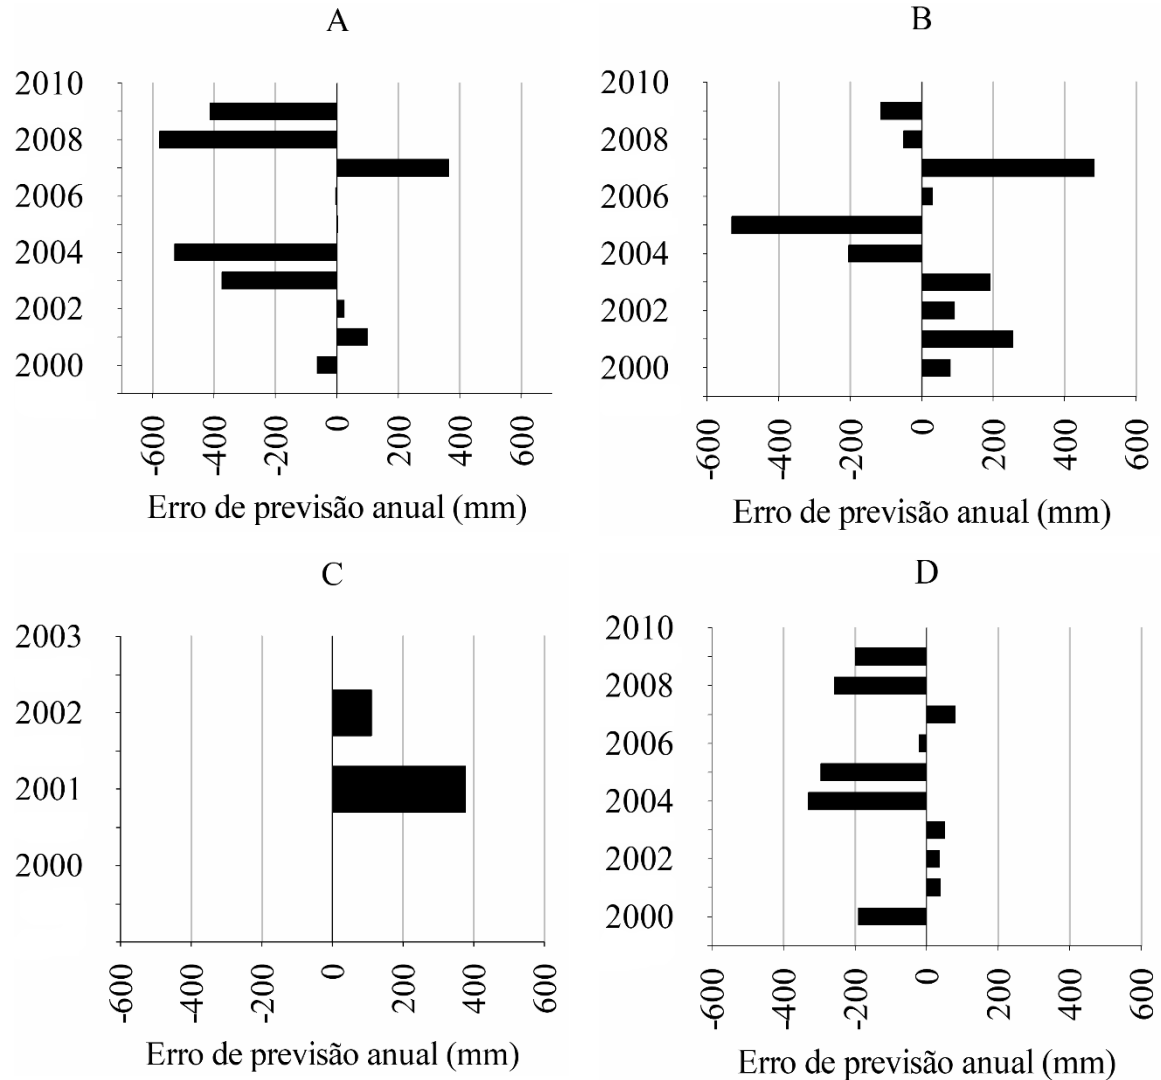
destes e dos 4 meses a serem previstos, objetivando prever séries de precipitação máxima, mínima, média e cumulativa para 4 meses à frente, na Grécia, relatam que o modelo apresentou uma limitação quanto à previsão de picos de precipitação. Tais estudos corroboram com os resultados encontrados para as estações climatológicas dos municípios analisados neste estudo.

Segundo Moustris et al. (2011) a explicação para a limitação em prever períodos com valores extremos acontece pois não há quantidade de dados suficientes para o treinamento. Segundo estes ainda, os extremos positivos de precipitação ocorrem com baixa frequência e com alta aleatoriedade, e, se não houver registros suficientes nos dados utilizados para o treinamento das redes neurais artificiais, estas não irão adquirir a experiência necessária para a previsão.

Percebe-se também que para a estação climatológica do município de Conceição do Mato Dentro houve uma tendência de aumento dos valores de erro para o período chuvoso ao longo dos anos utilizados na validação. Este pode ser explicado pela tendência de aumento nos valores de precipitação constatada para a série histórica do mês de dezembro da estação climatológica de Conceição do Mato Dentro utilizando o teste de Mann-Kendall (Tabela 2), agravando assim, os picos de precipitação do período chuvoso.

O balanço do erro em escala anual entre a precipitação prevista por meio de redes neurais artificiais utilizando a combinação de dados de entrada “C3” no treinamento e observada para as estações climatológicas dos municípios analisados no estudo é indicado no Gráfico 3.

Gráfico 3 – Balanço do erro em escala anual entre a precipitação observada e prevista pelas redes neurais artificiais utilizando a combinação de dados de entrada “C3” para o treinamento para as estações climatológicas de dos municípios de Belo Horizonte (A), Conceição do Mato Dentro (B), Florestal (C) e Sete Lagoas (D).



Fonte: Os autores (2021).

Analisando o Gráfico 3, é possível observar que a magnitude dos erros anuais que indicam subestimativa do balanço é maior em relação à magnitude dos que indicam a superestimativa, com exceção para a estação climatológica do município de Florestal.

Comparando-se a precipitação anual aos valores de erros nota-se que os quatro anos com maiores magnitudes de erros anuais para as estações climatológicas de Belo Horizonte (-577,55; -528,31; -413,50 e -373,80 mm) e Sete Lagoas (-330,10; -296,05; -258,07 e -199,5 mm), correspondem aos 4 anos com maiores lâminas precipitadas observadas. Já para a estação climatológica do município de Conceição do Mato Dentro o ano com maior magnitude de erro (-532,13 mm) correspondeu ao ano com maior volume precipitado observado.

Para mais, o município de Florestal apresentou apenas valores positivos no balanço do erro anual, porém, nota-se que houve apenas 3 anos de dados disponíveis para a validação da precipitação prevista, e que, no ano de 2000, o erro anual foi de 0,47 mm, o qual pode ser desprezado. Comparando a precipitação observada média à precipitação observada nos anos de 2001 e 2002, percebe-se que estas estão com valores abaixo da média, sendo o provável motivo para a estação apresentar apenas erros anuais de superestimativa. Para efeito de comparação, nas outras estações climatológicas, com exceção do ano de 2001 para a estação de Sete Lagoas, os anos de superestimativa coincidiram com anos de precipitação observada abaixo da média.

Ainda se tratando dos anos com balanço que indicam superestimativa, é notório que a maior magnitude foi apresentada pela estação climatológica de Conceição do Mato Dentro no ano de 2007. Comparando a precipitação média observada na referida estação à observada no referido ano, nota-se que esta última está abaixo da média, sendo o ano com menor lâmina precipitada. Analisando ainda as precipitações anuais de anos sem falhas nas estações de Conceição do Mato Dentro no período de treinamento em relação aos valores observados no ano de 2007, nota-se que houve apenas dois anos com menor lâmina. Tal fato reforça que, para que o modelo tenha capacidade de realizar uma boa previsão, a série de dados históricos deve contemplar exemplos de meses com valores extremos em quantidade suficiente para que tais eventos incomuns sejam compreendidos pelas redes neurais artificiais.

4. CONCLUSÃO

As variáveis mais correlacionadas à precipitação do mês alvo foram o número sequencial correspondente ao mês, a temperatura média compensada e a precipitação total. A seleção criteriosa de variáveis aumentou o desempenho do modelo. Os modelos, em geral, previram a precipitação satisfatoriamente, porém houve uma limitação ao prever dados extremos de precipitação.

REFERÊNCIAS

- ABHISHEK, K. et al. A rainfall prediction model using artificial neural network. *In: CONTROL AND SYSTEM GRADUATE RESEACH COLLOQUIUM*, 2012, Shah Alam. **Anais [...]**. Shah Alam: IEEE, 2012. p. 82–87.
- AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Diretrizes e análises recomendadas para a consistência de dados pluviométricos**. Brasília, 2012. Disponível em: <https://arquivos.ana.gov.br/infohidrologicas/cadastro/OrientacoesParaConsistenciaDadosPluviometricos-VersaoJul12.pdf>. Acesso em: 13 abr. 2021.
- AKSOY, H.; DAHAMSHEH, A.; Artificial neural network models for forecasting monthly precipitation in Jordan. **Stochastic Environmental Research and Risk Assessment**, v. 23, n. 7, p. 917–931, 2009.
- ALENCAR, L. P.; SEDIYAMA, G. C.; MANTOVANI, E. C. Estimativa da evapotranspiração de referência (ET_o padrão FAO) para Minas Gerais, na ausência de alguns dados climáticos. **Engenharia Agrícola**, v. 35, n. 1, p. 39–50, 2015.
- DA SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.
- DANCEY, Cristine P.; REIDY, John. **Estatística sem matemática: para psicologia usando SPSS para Windows**. 3. ed. Porto Alegre: Artmed, 2006.
- FIGUEIREDO FILHO, D. B.; DA SILVA JÚNIOR, J. A. Desvendando os mistérios do coeficiente de correlação de Pearson. **Revista Política Hoje**, v. 18, n. 1, p. 115–146, 2009.
- GEETHA, G.; SELVARAJ, R. S. Prediction of monthly rainfall in chennai using back propagation neural network model. **International Journal of Engineering Science and Technology**, v. 3, n. 1, p. 211–213, 2011.
- GRIMM, Alice M.; FERRAZ, Simone E. T. **Sudeste do Brasil: uma região de transição no impacto de eventos extremos da Oscilação Sul parte 1: El Niño**. 1998, Brasília: SBMET, 1998.
- HUNG, et al. An artificial neural network model for rainfall forecasting in Bangkok, Thailand. **Hydrology and Earth System Sciences Discussions**, v. 13, p 1413-1425, 2009.
- INSTITUTO NACIONAL DE METEOROLOGIA - INMET. **Banco de Dados Meteorológicos Para Ensino e Pesquisa**. Disponível em: <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>. Acesso em: 17 Fev. 2020.
- LEE, J. et al. Application of artificial neural networks to rainfall forecasting in the Geum River Basin, Korea. **Water (Switzerland)**, v. 10, n. 10, p. 1-14, 2018.
- LEVENBERG, K. A method for the solution of certain non-linear problems in least squares. **Quarterly of Applied Mathematics**, v. 2, n. 2, p. 164-168, 1944.

MARTINS, F. B. Classificação climática de Köppen e Thornthwaite para Minas Gerais: cenário atual e projeções futuras. **Revista Brasileira de Climatologia**, ano 14, p. 129-146, nov. 2018.

MARTINS, M. E. G. Coeficiente de correlação amostral. **Revista de Ciência Elementar**, v. 2, n. 2, p. 1–4, 2014.

MARTINS, P. S. et al. Variabilidade espaço-temporal de variáveis climáticas na mesorregião sul do Amazonas. **Revista Ibero-Americana de Ciências Ambientais**. v. 10, n. 2, p. 169–184, 2019.

MATLAB®. Version R2011a: MathWorks, 2011.

MAY, Robert; DANDY, Graeme; MAIER, Holger. Review of input variable selection methods for artificial neural networks. *In*: SUZUKI, Kenji. **Artificial neural networks - Methodological advances and biomedical applications**. Rijeka: InTech, 2011. p. 19–44.

MAWONIKE, R.; MANDONGA, G. The effect of temperature and relative humidity on rainfall in Gokwe region, Zimbabwe: A factorial design perspective. **International Journal of Multidisciplinary Academic Research**, v. 5, n. 2, p. 36-46, 2017.

MISLAN, H. et al. Rainfall monthly prediction based on artificial neural network - A case study in Tenggarong Station, East Kalimantan - Indonesia. **Procedia Computer Science**, v. 59, p. 142–151, 2015.

MOUSTRIS, K. P. et al. Precipitation Forecast Using Artificial Neural Networks in Specific Regions of Greece. **Water Resources Management**, v. 25, n. 8, p. 1979–1993, 2011.

NAYAK, D. R.; MAHAPATRA, A.; MISHRA, P. A Survey on rainfall prediction using artificial neural network. **International Journal of Computer Applications**, v. 72, n. 16, p. 32–40, 2013.

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION - NOAA. **Multivariate ENSO Index (MEI)**. Boulder, 2018. Disponível em: <https://www.esrl.noaa.gov/psd/enso/mei.old/>. Acesso em: 13 fev. 2020.

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION - NOAA. **Weather observations**. Boulder, 2011. Disponível em: <https://www.noaa.gov/education/resource-collections/weather-atmosphere/weather-observations>. Acesso em 08 mar. 2021.

PAPALASKARIS, T.; PANAGIOTIDIS, T.; PANTRAKIS, A. Stochastic monthly rainfall time series analysis, modeling and forecasting in Kavala city, Greece, North-Eastern Mediterranean basin. **Procedia Engineering**, v. 162, p. 254–263, 2016.

RITTER, A.; MUÑOZ-CARPENA, R. Performance evaluation of hydrological models: Statistical significance for reducing subjectivity in goodness-of-fit assessments. **Journal of Hydrology**, v. 480, p. 33–45, 2013.

SILVA, I. A.; MENDES, P. C. O El Niño e sua influência nas temperaturas e precipitações na cidade de Uberlândia (MG). **Revista Geonorte**, v. 2, n. 5, p. 485–495, 2012.

TUCCI, C. E. M.; BERTONI, J. C. Precipitação. *In*: TUCCI, C. E. M. **Hidrologia: ciência e aplicação**. 2. ed. Porto Alegre: UFRGS/ABRH, 2001. cap. 5, p 177-231.

YADAV, P.; SAGAR, A. Rainfall prediction using artificial neural network (ANN) for tarai Region of Uttarakhand. **Current Journal of Applied Science and Technology**, v. 33, n. 5, p. 1-7, 2019.

APÊNDICE A – Configuração utilizadas nos modelos de redes neurais artificiais

Figura 1 – Configuração utilizadas nos modelos de redes neurais artificiais treinados com a combinação de dados de entrada "C1".




Figura 2 – Configuração utilizadas nos modelos de redes neurais artificiais treinados com a combinação de dados de entrada "C2".




Figura 3 – Configuração utilizadas nos modelos de redes neurais artificiais treinados com a combinação de dados de entrada "C3".

