



# PREVISÃO PLUVIOMÉTRICA POR MEIO DA APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS RECORRENTES ALIMENTADAS COM DADOS METEOROLÓGICOS EM TEMPO ATUAL

JORDANA WILM DONINELLI <sup>1,2\*</sup>, JOSE MARIO VICENSI GRZYBOWSKI <sup>2,3</sup> ROBERTO VALMIR DA SILVA <sup>2,4</sup>

## 1 Introdução

Considerada um dos elementos fundamentais para o ciclo hidrológico, a precipitação é um evento climático importante pela influência que exerce na vida humana em vários aspectos (AKBARI ASANJAN et al., 2018). A previsão de precipitação tem relevância para a agricultura, atividades socioeconômicas, no estudo de desastres, como sistemas de alerta de deslizamentos, bem como no gerenciamento ou planejamento dos recursos hídricos. O processo de previsão pode ser realizado através da aplicação de diferentes modelos, como os modelos globais de circulação e modelos baseados em dados.

No conjunto de modelos baseados em dados estão as *Artificial Neural Networks* (ANNs), que são definidas por sistemas que em alguns aspectos reproduzem o cérebro humano (NUNES, 2012). As redes vêm sendo muito utilizadas em diversos processos hidrológicos não lineares, como no processo chuva-vazão, na qualidade da água, e também no estudo de águas subterrâneas.

As ANNs possuem diferentes arquiteturas que pertencem a categorias específicas, e no modelo proposto, a *Recurrent Neural Network* (RNN) com arquitetura LSTM (*Long Short Term Memory*) apresenta bons resultados na previsão de séries temporais.

## 2 Objetivos

Implementar, treinar e validar uma rede neural artificial recorrente de arquitetura LSTM para previsão pluviométrica de curto prazo com dados obtidos em tempo atual de uma estação meteorológica.

## 3 Metodologia

### 3.1 Implementação, treinamento e validação da rede neural artificial

1 Graduanda em Engenharia Ambiental e Sanitária, Universidade Federal da Fronteira Sul, *campus* Erechim/RS, Bolsista, \*contato: jwdoninelli@gmail.com

2 Grupo de Pesquisa Hidroclima

3 Docente do curso de Engenharia Ambiental e Sanitária, Universidade Federal da Fronteira Sul, *campus* Erechim/RS, Colaborador.

4 Docente do curso de Engenharia Ambiental e Sanitária, Universidade Federal da Fronteira Sul, *campus* Erechim/RS, Orientador.



Foram utilizadas as bibliotecas de *Deep Learning: Keras* (CHOLLET; OTHERS, 2015) e *TensorFlow* (MÁRTIN ABADI et al., 2015), implementadas em *Python*. Igualmente a biblioteca *Pandas* cujas funções organizam e manipulam o banco de dados monitorados e a *NumPy* que fornece basicamente a álgebra linear para *Python*.

Foi adquirida uma longa série de dados de alta resolução de uma estação meteorológica localizada em Okinawa, no Japão. Os dados foram obtidos através do NOAA (*National Oceanic Atmospheric Administration*), do período de 01/05/2010 à 01/04/2020, para capturar as variações sazonais e proporcionar o treinamento da rede. Optou-se por essa base de dados pois há disponibilidade direta de séries longas, sem falhas e com resolução temporal de uma hora. Além disso, em virtude dos dados não se adequarem a distribuição normal, foi aplicada a transformação Box-Cox (BOX E COX, 1964) nos *datasets* selecionados.

Os *datasets* da série histórica utilizados como entrada foram os de umidade, temperatura, pressão, vento e precipitação, e foram divididos em conjuntos de treino, validação e teste. Sendo instanciada pela classe *Sequential*, de forma arbitrária, a rede foi definida com seis *layers*. O primeiro recebendo as variáveis meteorológicas (camada de entrada da rede), com 12 neurônios, e subdivididas em precipitações de doze horas antecedentes, o último (camada de saída) contendo 8 neurônios e uma função de ativação *sigmoid*, provendo previsões de precipitações em intervalos de tempo variando de oito horas. Para as camadas ocultas foram dispostos quatro *layers*, com 50 neurônios cada, antecedidos pela função *dropout* igual a 0,5.

O algoritmo para otimização utilizado para treinar o modelo foi o denominado “Adam” e a função de perda empregada a “*binary crossentropy*”. Iniciado em 3 iterações, o tamanho do *batch*, que define a quantidade de amostras para cada iteração, foi fixado em 16. Para cada iteração os pesos foram ajustados usando o algoritmo de retropropagação (*backpropagation*), e como critério de parada foi usado o *early stopping*.

### 3.2 Teste da rede neural artificial para previsão pluviométrica de curso prazo

Os dados de precipitação foram convertidos para valores de 0 ou 1 usando o valor de 0,03 polegadas (aproximadamente 0,76 mm) como limiar. A saída da rede também foi mapeada para 0 ou 1, desta forma uma saída de 0 significa que não há previsão de chuva e 1 há previsão de chuva. Para analisar o resultado da rede usou-se a função *model.predict* que produz previsões a partir dos dados de teste. O desempenho foi analisado a partir da acurácia, precisão e recall, que são métricas derivadas da matriz de confusão que representa de forma visual os erros e acertos da rede: Verdadeiros Positivos (VP), Verdadeiros Negativos (VN), Falsos Positivos (FP) e Falsos Negativos (FN).



#### 4 Resultados e Discussão

Os resultados em termos de índices de precisão de previsão apresentam-se na tabela abaixo.

**Tabela 1.** Desempenho da rede conforme a matriz de confusão

Intervalo (h)	VP (%)	VN (%)	FP (%)	FN (%)	Acurácia (%)	Precisão (%)	Recall (%)
0-1	55,17	11,86	26,71	6,37	66,96	67,38	89,65
1-2	55,24	11,93	26,64	6,30	67,09	67,46	89,76
2-3	55,33	12,02	26,55	6,21	67,27	67,57	89,91
3-4	55,37	12,05	26,52	6,18	67,34	67,62	89,96
4-5	55,39	12,07	26,49	6,15	67,39	67,64	90,00
5-6	55,36	12,04	26,53	6,19	67,32	67,60	89,94
6-7	55,33	12,02	26,55	6,21	67,27	67,57	89,91
7-8	55,31	11,99	26,57	6,23	67,23	67,55	89,87

Fonte: Elaborada pelo autor.

O resultado do teste, com base na Tabela 1, apresenta bom desempenho na previsão dos verdadeiros positivos. Considerando a média de aproximadamente 90% nas métricas de *recall*, o desempenho da rede se mostra alto, visto que é baixo o valor de falsos negativos observados. Essa métrica é considerada importante, pois os eventos de chuvas podem provocar grandes estragos se não previstos. Em relação à precisão, que considera o quão exato é a classificação dos positivos, a rede obteve em média 67%, e acurácia também de 67%. Os resultados são promissores, mostrando-se similares aos observados em estudos anteriores, apesar da chuva ser um componente complicado de compreender e modelar (HUNG et al., 2009).

#### 5 Conclusão

Os resultados obtidos a partir do método proposto fundamenta os estudos apontados como revisão de literatura, que serviram de base para a pesquisa. Desta forma, os resultados indicam que a rede foi capaz de aprender os padrões da série temporal da base de dados de uma estação meteorológica, trazendo bom desempenho em termos de previsão de verdadeiros positivos. Uma pesquisa direcionada ao aumento do intervalo de tempo da previsão pode ser favorável para obtenção de melhores resultados com esse método.

#### Referências

AKBARI ASANJAN, A. et al. Short-Term Precipitation Forecast Based on the PERSIANN System and LSTM Recurrent Neural Networks. **Journal of Geophysical Research: Atmospheres**, v. 123, n. 22, p. 12,543-12,563, 27 nov. 2018.



BOX, G.; COX, DR. Na analysis of transformations. **Journal of the Royal Society**, v.26, p. 211-252, 1964.

CHOLLET, François; OTHERS. **Keras**. 2015 Disponível em <<https://keras.io/>>

DATA-ACCESS. **NOAA (National Oceanic Atmospheric Administration)**, Estados Unidos, 14 de out. de 2019. Disponível em: < <https://www.ncdc.noaa.gov/data-access/>>. Acesso em: 14 de out. de 2019.

HUNG, N. Q. et al. **Hydrology and Earth System Sciences An artificial neural network model for rainfall forecasting in Bangkok, Thailand**Hydrol. Earth Syst. Sci. [s.l: s.n.]. Disponível em: <[www.hydrol-earth-syst-sci.net/13/1413/2009/](http://www.hydrol-earth-syst-sci.net/13/1413/2009/)>.

**Palavras-chave:** redes neurais, inteligência artificial, precipitação.

## **Financiamento**

UFFS