

PREVISÃO DE VAZÕES BASEADA NO PROCESSAMENTO PARALELO GPGPU DE REDE LSTM

JORDANA WILM DONINELLI ^{1,2*}, JOSE MARIO VICENSI GRZYBOWSKI ^{2,3},
ROBERTO VALMIR DA SILVA ^{2,4}

1 INTRODUÇÃO

Para atender as demandas solicitadas no planejamento apropriado das bacias hidrográficas, como gestão de recursos hídricos e plano de conservação do solo, compreende-se a necessidade de previsões precisas de vazão (BROOKS *et al.*, 2003). Portanto, empregar modelos de captação que descrevam corretamente os processos de chuva-vazão transformou-se numa área importante na hidrologia (PIOTROWSKI; NAPIORKOWSKI, 2011).

A variabilidade espacial dos processos de chuva-vazão os torna fenômenos complexos de representar. Essa representação pode ser feita por modelos baseados em dados (estatísticos e estocásticos) e baseados em processos (conceituais e fisicamente baseados). As redes neurais artificiais são modelos baseados em dados, e são alternativas promissoras na modelagem hidrológica (SEDKI; OUAZAR; EL MAZOUZI, 2009).

O presente estudo teve como objetivo implementar uma rede neural artificial de arquitetura LSTM (Long Short-Term Memory) para previsão de vazão da bacia hidrográfica do rio Apuê, localizado na região sul do Brasil e pertencente a Bacia do Rio Uruguai.

2 OBJETIVOS

Implementar metodologia com rede LSTM e processamento em GPGPU para previsão de vazões na exutória de uma bacia hidrográfica.

3 METODOLOGIA

As etapas para realizar a previsão de vazão constituíram em análise dos dados, implementação, treinamento, validação e teste da rede neural artificial recorrente, respectivamente.

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

2 Grupo de Pesquisa: Hidroclima

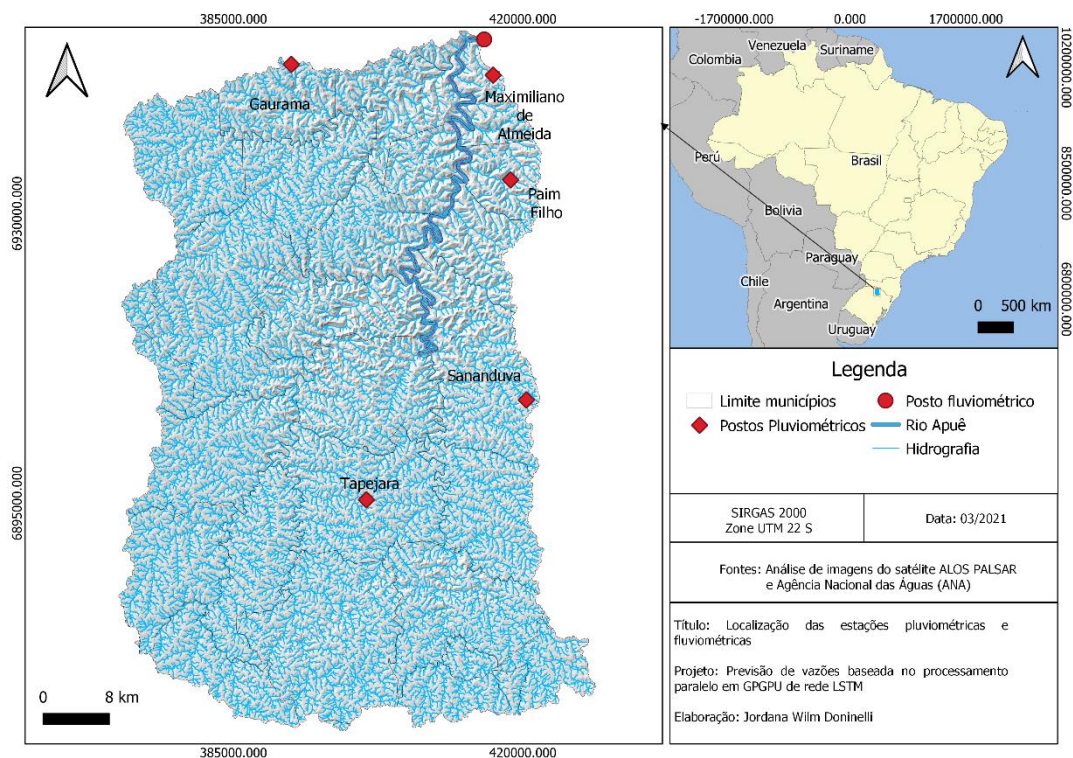
3 Docente do curso de Engenharia Ambiental e Sanitária, Universidade Federal da Fronteira Sul, campus Erechim/RS, **Colaborador**.

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

3.1 Análise de dados

Para capturar as variações espaciais e realizar o treinamento da rede foram selecionados 5 postos localizados nos municípios de Gaurama, Paim Filho, Sananduva, Tapejara e na UHE Machadinho, respectivamente. Ambas as estações encontram-se no perímetro da bacia hidrográfica do rio Apuê (Figura 1). As informações foram coletadas na base de dados da Agência Nacional das Águas (ANA, 2017) no período de 01/01/2010 à 31/12/2019. A bacia tem exutório na estação fluviométrica Passos Colombeli, também monitorada pela ANA.

Figura 1. Localização Bacia Hidrográfica do Rio Apuê e estações escolhidas.



Fonte: a autora.

3.2 Implementação, treino e validação da rede neural

Foi utilizada uma rede neural artificial recorrente de arquitetura LSTM (*Long-Short Term Memory*), considerada apropriada na simulação de série de dados temporais, com o auxílio das bibliotecas Keras (CHOLLET; OTHERS, 2015) e TensorFlow, implementadas em Python. Além dessas as bibliotecas *Pandas* e *Numpy* também foram empregadas.

Os dados obtidos das estações (vazão e precipitação) foram submetidos a um processo de normalização com a biblioteca de aprendizado de máquina *scikit-learn*. E para o treinamento da rede, o dataset foi dividido em conjuntos de treino, validação e teste, método da validação cruzada. Antes

de ajustar o modelo os dados foram remodelados para uma matriz 3D utilizando a função *reshape* (). A rede foi instanciada pela classe *Sequential*, e atribuída com quatro layers no total. O primeiro *layer* recebeu as variáveis meteorológicas, e possui dois neurônios, a camada de saída com um neurônio e uma função de ativação *tanh*, provendo previsão de vazões com intervalo de um dia. Nas camadas ocultas da rede foram determinados dois *layers*, cada um com vinte neurônios, antecedidos pela função *dropout* igual a 0,1.

Para treinar o modelo foi utilizado o algoritmo de otimização *Adam* e a função de perda empregada foi a *Mean Squared Error* (MSE), que calcula o erro quadrático médio dos dados. O processo de treinamento foi iniciado em cinquenta iterações com sessenta e quatro amostras processadas em cada uma. A validação foi realizada com 10% dos dados, é nessa etapa que o erro é monitorado e ocorre o ajuste dos parâmetros da rede. Os pesos foram ajustados com o algoritmo de retropropagação (*backpropagation*), e o critério de parada foi usado o *early stopping*.

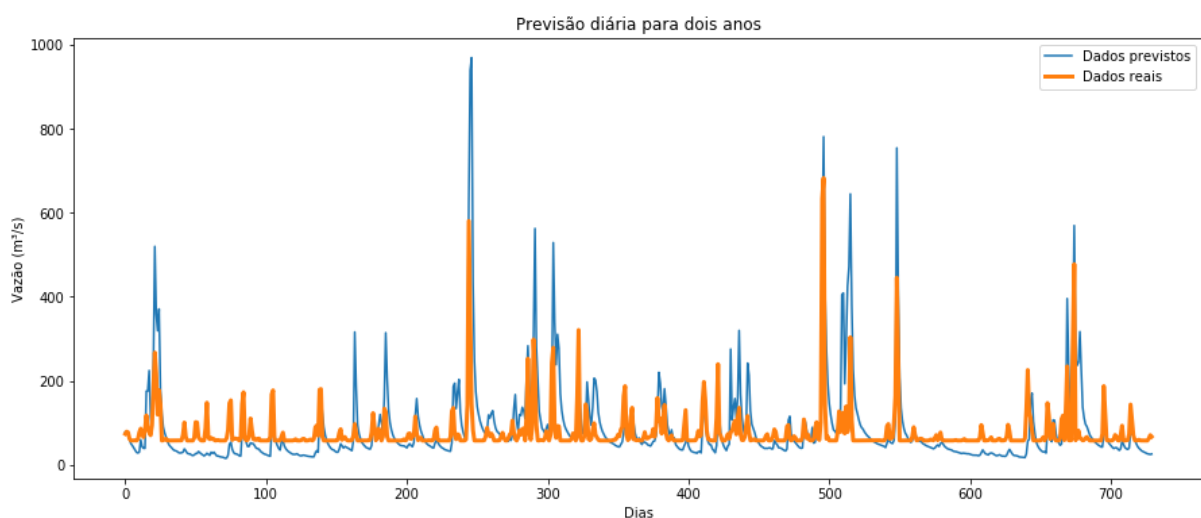
3.3 Teste da rede neural artificial para previsão de vazão

Para testar o funcionamento do modelo a partir de dados não vistos por ele antes, foi utilizado a função *model.predict*, que gera previsões a partir dos dados de teste separados pela validação cruzada. O desempenho do teste foi observado através do hidrograma (Figura 2).

4 RESULTADOS E DISCUSSÃO

Após a simulação de vazões foi gerado um hidrograma que possui como finalidade representar de forma visual o resultado da previsão de vazões diárias na Bacia do rio Apuê (Figura 2).

Figura 2. Resultado da previsão de vazão da Bacia do rio Apuê.



Fonte: elaborado pela autora.

Foi observado o erro relativo a cada passo de tempo e a variância, que mede a dispersão dos dados entre si. Índices de 5773,69 para erro e 0,45 para variância foram encontrados. O alto índice de erro pode ser explicado pela a desconsideração de outros fatores climáticos na previsão (temperatura, pressão, vento e umidade), indicando que com a utilização de uma quantidade maior de variáveis de entrada relacionadas à vazão resultados melhores poderão ser encontrados.

5 CONCLUSÃO

A partir dos resultados da pesquisa é possível observar que a rede neural artificial de arquitetura LSTM possui capacidade de acompanhar a tendência dos dados de vazão, sendo considerada eficaz na modelagem chuva-vazão na Bacia do Rio Apuê. Destaca-se que a utilização de dados de clima como temperatura, umidade e pressão, ofereceriam melhores resultados na simulação. Além disso, uma pesquisa possuindo uma quantidade maior de dados diários pode ser favorável para alcance de resultados superiores aos encontrados nessa pesquisa.

Palavras-chave: Redes neurais artificiais recorrentes. Modelagem hidrológica. Estações fluviométricas.

Nº de Registro no sistema Prisma: PES 2020-0383

Financiamento

Universidade Federal da Fronteira Sul (UFFS).

REFERÊNCIAS BIBLIOGRÁFICAS

ANA. Hidroweb - Sistema de informações hidrológicas. 2017. Disponível em: <<http://www.snirh.gov.br/hidroweb/>>. Acesso em: 20 out. 2015.

BROOKS, K.N.; FFOLIOTT, P.F.; GREGERSEN, H.M.; DEBANI, L.F.; 2003. **Hydrology and the Management of Watersheds**. Iowa State Press, Ames, IA

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

PIOTROWSKI, A. P.; NAPIORKOWSKI, J. J. Optimizing neural networks for river flow forecasting - Evolutionary Computation methods versus the Levenberg-Marquardt approach. **Journal of Hydrology**, v. 407, n. 1-4, p. 12-27, 2011.

SEDKI, A.; OUAZAR, D.; EL MAZOUZI, E. Evolving neural network using real coded genetic algorithm for daily rainfall-runoff forecasting. *Expert systems with applications*, v. 36, n. 3, p. 4523-4527, 2009.