

PREVISÃO DE VAZÕES BASEADA NO PROCESSAMENTO PARALELO GPGPU DE REDE LSTM

JORDANA WILM DONINELLI^{1,2*}, JOSÉ MARIO VICENSI GRZYBOWSKI³,
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 área considerada nesse estudo é a Bacia Hidrográfica do Rio Apuê, que está localizada na região sul do Brasil e pertence a Bacia do Rio Uruguai, rio que divide os estados de Santa Catarina e Rio Grande do Sul. Com aproximadamente 3.360 km² a bacia está localizada em uma região intensa de atividade agrícola baseada no cultivo de soja e milho no verão, trigo e aveia no inverno, e apenas 36% da área da bacia é coberta por floresta, fato que facilita a ocorrência de inundações, que implicam em numerosos danos para a vida humana, visto que causa perda de atividade agrícola e prejuízos econômicos.

A modelagem hidrológica pode ser realizada por meio de modelos que representam o processo de chuva-vazão de uma bacia hidrográfica. E devido à variabilidade espacial desse processo, torna-se um dos fenômenos mais complexos de representar. Nesse sentido, o presente estudo teve como principal objetivo implementar uma rede neural artificial de arquitetura LSTM (Long Short-term Memory) para previsão de vazão da bacia hidrográfica do rio Apuê.

2 Objetivos

1 Bacharel em Engenharia Ambiental e Sanitarista, Universidade Federal da Fronteira Sul, *campus Erechim*, contato: jwdoninelli@gmail.com.

2 Grupo de Pesquisa: Hidroclima

3 Professor Dr., Universidade Federal da Fronteira Sul, *campus Erechim*,

4 Orientador Professor Dr., Universidade Federal da Fronteira Sul, *campus Erechim*.

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

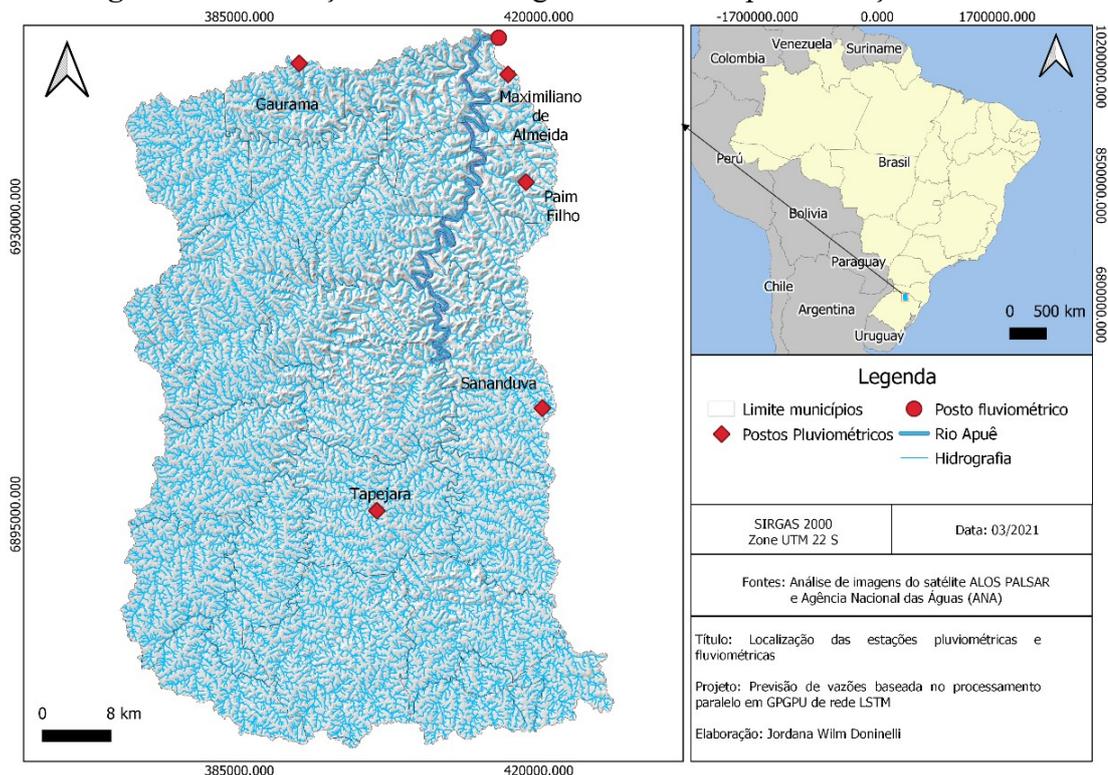
3 Metodologia

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

3.1 Análise de Dados

Para capturar as variações sazonais e realizar o treinamento da rede foram selecionados 5 postos localizados nos municípios de Gaurama, Paim Filho, Sananduva, Tapejara e na UHE Machadinho, respectivamente. Todas as estações se 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 Passo 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. Os dados obtidos das estações (vazão e precipitação) foram submetidas a um processo de normalização com a biblioteca de aprendizado de máquina *scikit-learn*. E para o treinamento da rede, os *datasets* foram divididos 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, antecidos 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*.

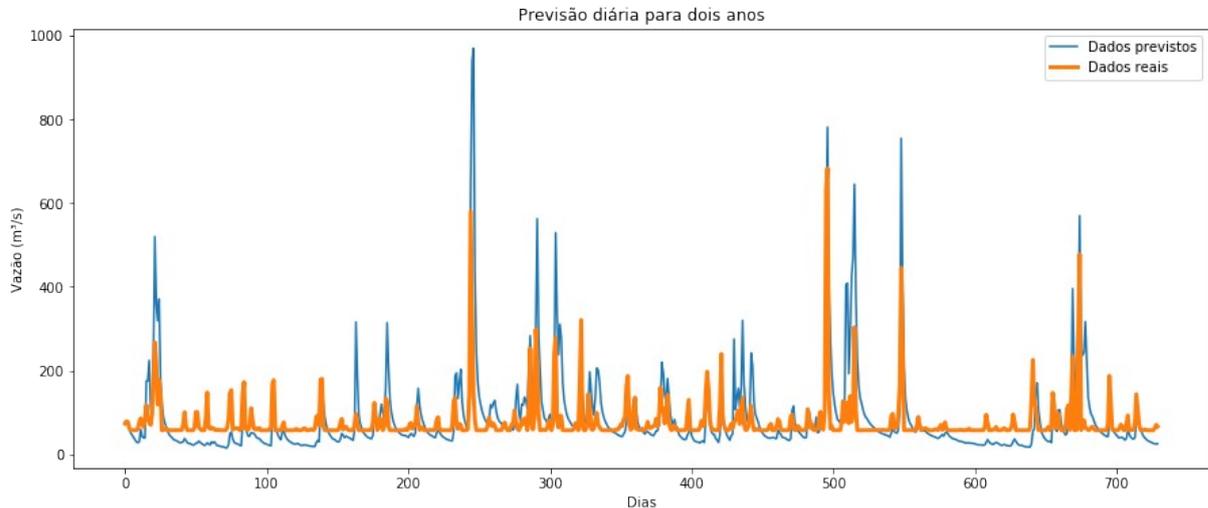
3.3 Teste da Rede Neural Artificial para Previsão de Vazão

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 gráfico (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: elaborada pela autora.

Foi observado o erro a cada passo de tempo e a variância explicada, que mede o quanto da variância dos dados observados é explicado pela rede. Valores de 5773,69 para erro e 0,45 para a variância explicada foram encontrados. O elevado erro (valores próximos de zero são desejáveis) e a baixa variância explicada (valores próximos de um indicam que quase toda a variância é explicada) pode estar associado à desconsideração de variáveis climáticas na previsão (temperatura, pressão, vento e umidade), assim como dados da própria bacia (tipo de solo, uso do solo, dentre outros). A inserção destes dados poderá produzir melhores resultados.

5 Conclusão

Existem diferentes abordagens para simular os fenômenos da natureza, o método que utiliza redes neurais artificiais, considerado como um modelo de representação de fenômenos complexos baseado em dados, dispõe de um desempenho semelhante e até melhor na previsão, em comparação com os demais modelos que baseados em processos (conceituais e fisicamente baseados). As redes neurais artificiais, portanto, são alternativas promissora na modelagem hidrológica (SEDKI; OUAZAR; EL MAZOUZI, 2009).

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.

Referências Bibliográficas

ANA. Hidroweb - Sistema de informações hidrológicas. 2017. Disponível em: <<http://www.snirh.gov.br/hidroweb/>>. Acesso em: 20 set. 2022.

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

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.

Palavras-chave: redes neurais; inteligência artificial; modelagem hidrológica.

Nº de Registro no sistema Prisma: PES-2020-0383.

Financiamento: UFFS