

APLICAÇÃO DE REDE NEURAL LINEAR PARA MODELOS AUTORREGRESSIVOS EM ESTAÇÕES FLUVIOMÉTRICAS DA BACIA DO RIO TAQUARI NO RIO GRANDE DO SUL

Daniel Vieira Mendes¹ ; Francisco F. N. Marcuzzo² & Franco Turco Buffon²

Abstract: Hydrological forecasting is an important tool for predicting hydrological disasters. Therefore, having models that can perform in extreme events become crucial. This study aims to apply Linear Neural Network to obtain multiple linear autoregressive regression equations for water level forecasting at streamgages of the Hydrological Alert System (SAH) in the Taquari River Basin under two flood event scenarios, with three forecast horizons (4h, 3h, and 2h). For this study, the TensorFlow framework with Keras was used via Python scripting to develop the autoregressive models. Stage data from streamgages belonging to the National Hydrometeorological Network and that are in Taquari River Basin SAH were utilized. It was found that the streamgage with the best model metrics was Taquari (86950000). It was also observed that using flood data starting from the attention level improved results by 86,1% at 4h, 36,1% at 3h, and 63,9% at 2h. Furthermore, the best forecast results were achieved with horizons of 2h, 3h, and 4h, respectively. It was concluded that as it moves downstream, the models produce better results. Additionally, using data from the attention level provides better results than using data from the alert level. Furthermore, shorter forecast horizons also provides better results.

Resumo: A previsão hidrológica se mostra como uma importante ferramenta para a previsão dos desastres hidrológicos. Assim, possuir modelos que consigam performar em eventos extremos se torna preponderante. Este estudo tem por objetivo a aplicação de Rede Neural Linear para obtenção de equações de regressão linear múltipla autorregressiva para previsão de nível em estações do Sistema de Alerta Hidrológico (SAH) da Bacia do Rio Taquari em dois cenários de eventos de cheia, com três horizontes de previsão (4h, 3h e 2h). Para o artigo, foi utilizado o *Framework TensorFlow* com *Keras*, através de *script* em *Python*, para obtenção dos modelos autorregressivos. Foram utilizados dados fluviométricos de cota de estações da Rede Hidrometeorológica Nacional e que fazem parte do SAH da Bacia do Rio Taquari. Verificou-se que a estação que tem o modelo com melhores métricas é Taquari (86950000). Constatou-se também que usar dados de cheia a partir da cota de atenção melhorou os resultados em 86,1% em 4h, 36,1% em 3h, e 63,9% em 2h. Ainda, os resultados de previsão tiveram seus melhores valores com os horizontes de 2h, 3h e 4h, respectivamente. Concluiu-se que, conforme se avança de montante para jusante, melhores são os resultados dos modelos. Além disso, utilizar dados a partir da cota de atenção fornecem melhores resultados que os a partir de alerta. Ainda, conforme se diminui o horizonte de previsão, melhores também são os resultados.

Palavras-Chave – Redes Neurais, Modelagem Hidrológica, Desastres Hidrológicos

1) Estagiário do SGB/GEHITE – PA. Eng. Ambiental e Sanitária – CAV/UDESC – Universidade do Estado de Santa Catarina. Avenida Luiz de Camões, 2090 – Conta Dinheiro, Lages/SC – CEP 88.520-000, Tel.: (49) 3289-9100. danielmendesdaniel@hotmail.com

2) SGB - Serviço Geológico do Brasil - Rua Banco da Província, 105 - Santa Teresa - Porto Alegre/RS - CEP 90.840-030, Tel.: (51) 3406-7300. francisco.marcuzzo@sgb.gov.br; franco.buffon@sgb.gov.br

INTRODUÇÃO

Atualmente, ao passo que os desastres hidrológicos vêm se tornando cada vez mais frequentes, vide, por exemplo, as grandes cheias no Rio Grande do Sul em 2023 e 2024, possuir modelos de previsão hidrológica acurados e que conseguem performar em eventos extremos fazem-se preponderantemente necessários.

Modelo hidrológico constitui-se uma importante ferramenta para a previsão de inundações e cheias e o consequente desastre hidrológico. Servem como base para conhecimento da variação dos níveis dos rios ao longo do tempo, propiciando a geração e emissão de boletins com vistas à prevenção de danos à vida e ao patrimônio (SGB, c2024, Santos *et al.* 2019). Dentre os modelos de previsão de cota, pode-se citar os autorregressivos como uma ferramenta para previsão hidrológica (Lucas *et al.*, 2009; Moreira, 2016, Lappicy *et al.*, 2021).

Os modelos empíricos, como as equações de regressão, têm os pesos definidos com base em dados observados (Moreira, 2016). Uma das formas de se realizar previsão hidrológica, fazendo-se uso desses dados, é através de aprendizado de máquina, por meio da utilização do *Framework TensorFlow* com *Keras*, através de *script* em *Python* (Antoniassi, 2022, Godinho, 2021). O *Keras* é caracterizado por criar e treinar modelo de aprendizado profundo, sendo fácil de ser utilizado, com poucas restrições, permitindo criação de novas camadas, métricas e funções (TensorFlow, 2020).

Este estudo tem por objetivo a aplicação de Rede Neural Linear para obtenção de equação de regressão linear múltipla autorregressiva para previsão de nível em estações da Rede Hidrometeorológica Nacional que também fazem parte do Sistema de Alerta Hidrológico (SAH) da Bacia do Rio Taquari.

MATERIAL E MÉTODO


Área de estudo

A área objeto deste estudo compreende estações fluviométricas da RHN que também fazem parte do SAH da Bacia do Rio Taquari, as quais são operadas pelo SGB de Porto Alegre (Tabela 1 e Figura 1).

Tabela 1 – Estações fluviométricas utilizadas no estudo. Fonte: ANA (2024) e SGB (2025).

Bacia Hidrográfica (BH)	Estação fluviométrica	Código	Município	Latitude	Longitude	Período utilizado	Total de Anos
RIO TAQUARI	Linha José Júlio	86472000	Santa Tereza	-29.0978	-51.6997	Set/2015 – Mai/2024	5,87
RIO TAQUARI	Muçum	86510000	Muçum	-29.1672	-51.8686	Abr/2015 – Jul/2024	8,76
RIO TAQUARI	Encantado	86720000	Encantado	-29.2344	-51.8550	Jul/2015 – Jul/2024	8,26
RIO TAQUARI	Estrela	86879300	Estrela	-29.4733	-51.9622	Jul/2015 – Jul/2024	7,92
RIO TAQUARI	Bom Retiro do Sul	86881000	Bom Retiro do Sul	-29.6081	-51.9511	Nov/2018 – Jul/2024	3,77
RIO TAQUARI	Porto Mariante	86895000	Venâncio Aires	-29.6922	-51.9700	Nov/2014 – Out/2024	5,56
RIO TAQUARI	Taquari	86950000	Taquari	-29.8070	-51.8758	Jul/2015 – Jul/2024	6,32

Figura 1 – Mapa de localização das estações utilizadas no estudo.



Fonte: Os autores (2025).

Rede Neural Linear – Tensor Flow/Keras

Por meio de script em *Python*, foi utilizada o *Framework TensorFlow* com API *Keras* para construção do modelo. Para execução da modelagem, outras bibliotecas de manipulação de dados foram utilizadas, como *pandas* e *numpy*. Para fins práticos, objetivou-se elaborar uma equação para aplicação direta com os valores das cotas. Assim, objetivou-se a concepção de um modelo de rede neural simples (Quadro 1).

Quadro 1 – Construção do Modelo de Rede Neural Linear.

Parâmetros	
Camada densa	1
Neurônios na camada	1
Função de ativação	Nenhuma
Regularização	L2 e Early Stopping
Otimização	Adam

Fonte: Os autores (2025).


O modelo é composto por apenas um neurônio de saída, porquanto se quer apenas obter o valor de uma variável, a cota em um momento futuro. Não foi aplicada função de ativação, uma vez que se busca que o modelo aprenda e consiga reproduzir equações lineares interpretáveis (Vicentini e Oliveira-Filho, 2021; Marcon, 2019). Na etapa de compilação do modelo, foi utilizado Erro Absoluto Médio como a função de perda, ou seja, por meio desse parâmetro se identificaria os erros entre o previsto e o observado. E, para ajustar os pesos da equação para que o modelo tenha resultados mais acurados, foi utilizado o otimizador Adam, sendo uma boa escolha para ajuste dos pesos (Siqueira, 2021; Júnior e Ribeiro, 2020, Antoniassi, 2022). Foi aplicada ainda a técnica do *Early Stopping* para adicionar mais robustez ao modelo (Antoniassi, 2022; Godinho, 2021).

Cenários e dados utilizados

Para treinamento do modelo, utilizou-se todos os dados para calibração, para que se tivesse o melhor resultado possível, conforme corroborado por Shen *et al* (2022), Arsenault *et al.* (2018).

Para fins de acurácia no modelo, foram fornecidos somente os dados de eventos de cheia. Assim, o modelo consegue identificar mais claramente os padrões de mudança de cota em momentos de cheia. Desse modo, para cada série de dados de cada respectiva estação, foram selecionados previamente os eventos que estão compreendidos entre cotas de referência (Figura 2).

Figura 2 – Cenários de cheia analisados com base nas cotas de referência.



Fonte: Os autores (2025).

Sabendo-se que quanto menor o horizonte de previsão, melhor a acurácia (Magro, 2021; Pedrollo, 1999; Gorodetskaya *et al.*, 2018; Bravo *et al.*, 2008) e que o rio Taquari possui variação rápida de nível em alguns pontos, estabeleceu-se cenários de previsão de 2h, 3h e 4h.


RESULTADOS E DISCUSSÃO

Métricas e avaliações gráficas

Para análise dos resultados de um modelo hidrológico, é necessário avaliar as métricas de desempenho (Antoniassi, 2022; Silva *et al.*, 2023, Godinho, 2021). A análise de um só indicador pode não representar o desempenho do modelo na sua totalidade. As métricas para os cenários 1 e 2 e para os horizontes estabelecidos são apresentadas nas tabelas 2, 3 e 4. Nas figuras 3 e 4, mostra-se a aplicação gráfica na estação Taquari (86950000). A estação Linha José Júlio (86472000) não possui cota de inundação, somente de atenção e alerta, assim, somente uma análise foi feita com relação aos cenários. Por mais que ela tenha sido alocada na parte da tabela que se destina às análises que se iniciam na cota de atenção e finalizam na de inundação, seus valores são para o único grupo de cotas que possui, atenção e alerta. A análise da melhora dos resultados do modelo é realizada pelas mudanças dos valores dos parâmetros, mais especificamente pela diminuição dos: Erro Médio, Erro Absoluto Médio, Erro Absoluto Máximo, Raiz do Erro Quadrático Médio, Desvio Padrão dos Erros; e aumento do R^2 .


Conforme as tabelas 2, 3 e 4, comparando as previsões das cotas de referência, verificou-se que a melhoria dos parâmetros das previsões que se iniciam na cota de atenção, em relação às de alerta são: 86,1% dos parâmetros em 4h, 36,1% em 3h, e 63,9% em 2h. Isto é, inserir dados do início da cheia propicia que o modelo desempenhe melhor, ou seja, usar dados de cheia que se iniciam na cota de atenção desempenham melhor que os que se iniciam na cota de alerta. O que já era esperado, visto que o modelo consegue ter mais dados para identificar os padrões de comportamento.

Figura 3 – Comparação entre valores observados e preditos pelo modelo na estação Taquari (86950000) - Cenário 1.



Fonte: Os autores (2025).

Figura 4 – Comparação entre valores observados e preditos pelo modelo na estação Taquari (86950000) - Cenário 2.



Fonte: Os autores (2025).

Tabela 2 – Métricas de desempenho para o horizonte de 4h.

Código	Nome da estação	Descrição do teste	Erro Médio	Erro Absoluto Médio	Erro Absoluto Máximo	Raiz do Erro Quadrático Médio	Desvio Padrão dos Erros	R ²
86472000	LINHA JOSÉ JÚLIO		30.254	67.106	802.449	113.148	109.094	0.950
86510000	MUÇUM	Início: Cota	37.926	72.121	528.321	117.777	111.675	0.958
86720000	ENCANTADO	de Atenção	28.557	53.745	427.687	83.881	78.925	0.971
86879300	ESTRELA	Fim: Cota	14.048	31.344	248.514	48.379	46.316	0.987
86881000	BOM RETIRO DO SUL	de	0.467	26.413	331.114	46.027	46.084	0.983
86895000	PORTO MARIANTE	Inundação	1.847	24.808	217.729	38.567	38.571	0.984
86950000	TAQUARI		1.025	11.304	89.697	17.177	17.160	0.995
86472000	LINHA JOSÉ JÚLIO		-	-	-	-	-	-
86510000	MUÇUM	Início: Cota	38.514	72.637	542.037	118.991	112.759	0.958
86720000	ENCANTADO	de Alerta	19.890	53.938	423.414	82.943	80.579	0.971
86879300	ESTRELA	Fim: Cota	25.680	34.851	259.637	54.525	48.122	0.986
86881000	BOM RETIRO DO SUL	de	10.270	27.640	346.435	49.596	48.583	0.984
86895000	PORTO MARIANTE	Inundação	9.302	25.806	225.378	40.502	39.468	0.984
86950000	TAQUARI		5.025	11.833	101.614	18.426	17.742	0.994

Fonte: Os autores (2025).

Tabela 3 – Métricas de desempenho para o horizonte de 3h.

Código	Nome da estação	Descrição do teste	Erro Médio	Erro Absoluto Médio	Erro Absoluto Máximo	Raiz do Erro Quadrático Médio	Desvio Padrão dos Erros	R ²
86472000	LINHA JOSÉ JÚLIO		29.533	52.757	623.304	88.574	83.556	0.970
86510000	MUÇUM	Início: Cota	15.729	57.427	367.999	89.191	87.928	0.972
86720000	ENCANTADO	de Atenção	18.797	36.231	326.098	58.208	55.127	0.985
86879300	ESTRELA	Fim: Cota	7.463	20.719	163.400	32.404	31.547	0.994
86881000	BOM RETIRO DO SUL	de	-0.064	18.675	221.368	31.558	31.599	0.992
86859000	PORTO MARIANTE	Inundação	-0.979	19.303	141.856	29.003	29.023	0.991
86950000	TAQUARI		2.056	7.615	67.044	11.856	11.686	0.997
86472000	LINHA JOSÉ JÚLIO		-	-	-	-	-	-



86510000	MUÇUM	Início: Cota de Alerta Fim: Cota de Inundação	28.150	47.003	386.162	78.056	72.915	0.981
86720000	ENCANTADO		15.486	36.149	313.692	58.126	56.064	0.985
86879300	ESTRELA		19.440	24.479	173.089	38.407	33.140	0.993
86881000	BOM RETIRO DO SUL		4.755	18.151	238.106	31.137	30.812	0.993
86859000	PORTO MARIANTE		2.206	18.338	141.101	28.333	28.283	0.992
86950000	TAQUARI		1.320	7.409	63.352	11.459	11.392	0.998

Fonte: Os autores (2025).

Tabela 4 – Métricas de desempenho para o horizonte de 2h.

Código	Nome da estação	Descrição do teste	Erro Médio	Erro Absoluto Médio	Erro Absoluto Máximo	Raiz do Erro Quadrático Médio	Desvio Padrão dos Erros	R ²
86472000	LINHA JOSÉ JÚLIO		16.805	30.682	369.279	50.082	47.206	0.990
86510000	MUÇUM	Início: Cota	11.909	23.762	248.211	40.421	38.667	0.996
86720000	ENCANTADO	de Atenção	9.127	20.242	205.076	34.118	32.897	0.995
86879300	ESTRELA	Fim: Cota	0.761	12.195	92.965	18.090	18.083	0.998
86881000	BOM RETIRO DO SUL	de	0.438	10.850	124.736	18.270	18.335	0.997
86859000	PORTO MARIANTE	Inundação	0.238	10.907	84.834	16.789	17.290	0.997
86950000	TAQUARI		0.022	4.666	39.652	7.163	7.168	0.999
86472000	LINHA JOSÉ JÚLIO		-	-	-	-	-	-
86510000	MUÇUM	Início: Cota	17.708	26.161	260.091	44.097	40.428	0.996
86720000	ENCANTADO	de Alerta	4.785	21.525	199.054	35.130	34.827	0.994
86879300	ESTRELA	Fim: Cota	4.903	11.310	89.315	18.222	17.558	0.998
86881000	BOM RETIRO DO SUL	de	0.587	10.000	129.133	17.569	17.581	0.997
86859000	PORTO MARIANTE	Inundação	2.449	10.819	112.561	17.058	16.902	0.997
86950000	TAQUARI		0.812	4.994	49.969	7.832	7.796	0.999

Fonte: Os autores (2025).

Graficamente, com o exemplo da estação de Taquari (86950000), percebe-se que, tanto no cenário 1 quanto no cenário 2, os resultados foram muito bons, identificando grande proximidade entre os valores observados e preditos. Analiticamente, ao comparar os resultados de todas as equações de 4h para 3h (tabelas 2, 3 e 4), verifica-se que houve melhora em 98,7% dos parâmetros, ou seja, as métricas diminuíram, com exceção do R^2 , que, pelo seu comportamento inverso, aumentou. De 3h para 2h, o valor de melhora compreendeu 96,2% dos parâmetros. Isto é, verifica-se que quanto menor o horizonte de previsão, melhores são os resultados, mais assertivo é a estimativa, conforme também identificaram Magro (2021), Pedrollo (1999), Gorodetskaya *et al.* (2018), Bravo *et al.* (2008).

Por meio das métricas (tabelas 2, 3 e 4), verifica-se que, de forma geral, conforme se move de montante para jusante, os modelos tendem a ficar mais acurados, os erros diminuem e o R^2 aumenta. Quanto mais se direciona para jusante (Moreira, 2016), ou quanto mais lento tende ser o rio, maior assertividade do modelo autorregressivo. Assim, a estação de Taquari (86950000) é a que tem o modelo mais preciso, dentre as estações analisadas.

Conforme análise das equações geradas para os cenários acima, as componentes das equações que tiveram maior peso, estão nas diferenças. Ao analisar as três variáveis que mais tinham influência em cada equação, de cada cenário, chegou-se aos valores da tabela 5.

Tabela 5 - Distribuição das variáveis de maior influência nas equações.

Variável da equação	Frequência
Cenário: Início: Cota de Atenção	
$C - C_{3h}$	13
$C - C_{2h}$	12
$C - C_{4h}$	9
Cenário: Início: Cota de Atenção	
$C - C_{3h}$	12
$C - C_{2h}$	10
C	9

Fonte: Os autores (2025).

A diferença $C - C_{3h}$ (diferença da cota atual com a de 3h atrás) não significa que ela foi a que teve maior peso nas equações, mas sim que, ao analisar as três componentes que tiveram maior peso, ela ficou entre essas, podendo ser, por exemplo, a de menor valor absoluto entre as três.

A quantidade de dados e eventos apresenta-se como um fator limitante, visto que, quanto maior a série histórica disponível para treinamento, melhor é o aprendizado. Além disso, é necessário que dados de entrada estejam consistidos, para não causar vieses. Um outro limitante que se tem é o modelo em si, que foi adotado como uma rede neural simples, de apenas uma camada, para que fosse possível obter uma equação de regressão, podendo, assim não conseguir capturar padrões mais complexos.

CONCLUSÃO

Utilizou-se a aplicação de Rede Neural Linear para obtenção de equações de regressão linear múltipla autorregressiva em estações da RHN que também fazem parte do SAH da Bacia do Rio Taquari, através do *Framework TensorFlow* com Keras, usando-se *script* em *Python*. Por meio dos resultados obtidos, verificou-se que modelos que possuem dados de cheias a partir da cota de atenção tendem a ter melhores resultados do que aqueles a partir da cota de alerta. Constatou-se que, quanto

menor o horizonte de previsão, melhores os resultados fornecidos pelos modelos. Ainda, conforme se move de montante para jusante, melhores tendem a ser os resultados dos modelos. Ademais, a metodologia apresentada se mostra eficaz na gestão de desastres hidrológicos, fornecendo modelos de aplicabilidade prática e direta no uso dos dados hidrológicos.

REFERÊNCIAS

- AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO – ANA. (2024). Sistema Nacional de Informações sobre Recursos Hídricos (SNIRH) – *Hidroweb*. Disponível em: <https://www.snirh.gov.br/hidroweb>.
- ANTONIASSI, R. A. dos S. (2022). *Predição de nível de rios da Região Hidrográfica do Rio Paraguai utilizando algoritmos de Aprendizado de Máquina*. Dissertação de Mestrado, 85p. Universidade Federal de Mato Grosso do Sul. Disponível em: https://repositorio.ufms.br/bitstream/123456789/4642/1/mestrado_defesa_rogerio_antoniassi.pdf. Acesso em 22 jun. 2025.
- ARSENAULT, R.; BRISSETTE, F.; MARTEL, J. L. (2018). “*The hazards of split-sample validation in hydrological model calibration*”. Journal of Hydrology, v. 566, pp. 346-362. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0022169418307145?via%3Dihub>. Acesso em: 22 jun. 2025.
- BRAVO, J. M.; PEDROLLO, O. C.; COLLISCHONN, W.; PAZ, A. R. da; UVO, C. B. (2008). “*Previsões de Curto Prazo de Vazão Afluente ao Reservatório de Furnas Utilizando Redes Neurais Artificiais*”. Revista Brasileira de Recursos Hídricos, v. 13, n. 2, pp.77-88. Disponível em: Previsões de curto prazo de vazão afluente ao reservatório de Furnas utilizando redes neurais artificiais. Acesso em: 22 jun. 2025.
- GODINHO, J. da S. (2021). *Previsão Hidrológica na Bacia Hidrográfica do Rio Macaé com Redes Neurais*. Trabalho de Conclusão de Curso, 61p. Universidade Federal do Rio de Janeiro. Disponível:https://engenharias.macaee.ufrj.br/images/testetcc/2021/TCC_Julia_Godinho.pdf.
- GORODETSKAYA, Y.; DA FONSECA, L. G.; RIBEIRO, C. B. de M. (2018). “*Previsão de vazão de curto prazo utilizando Redes Neurais Artificiais. Estudo de Caso: Rio Paraíba do Sul*” in Anais III Simpósio de Recursos Hídricos do Rio Paraíba do Sul, Juiz de Fora, Ago. 2018, 9p. Disponível em: <https://anais.abrhidro.org.br/job.php?Job=3837>. Acesso em 22 jun. 2025.
- LAPPICY, T.; LIMA, C. H. R.; FIORUCCI, J. A. (2021). “*Uso de modelos estocásticos para previsões de vazões mensais dos reservatórios ligados ao SIN utilizando o conceito de energia equivalente*” in Anais do XXIV Simpósio Brasileiro de Recursos Hídricos, Belo Horizonte, Nov. 2021, 10p. Disponível em: <https://anais.abrhidro.org.br/job.php?Job=13140>. Acesso em 22 jun. 2025.
- LUCAS, E. W. M.; DE SOUSA, F. de A. S.; SILVA, F. D. dos S.; LUCIO, P. S. (2009). “*Modelagem Hidrológica Determinística e Estocástica aplicada à Gestão Hidrográfica do Xingu – Pará*”. Revista Brasileira de Meteorologia, v. 24, n. 3, pp. 308-322. Disponível em: <https://www.scielo.br/j/rbmet/a/YSv5hcy3WDZKJPXtx9hzKYy/>. Acesso em: 22 jun. 2025.
- MAGRO, R. B. (2021). *Aplicação de Redes Neurais Artificiais para Previsão de Inundação em uma área urbana*. Dissertação de Mestrado, 134p. Universidade do Estado de Santa Catarina. Disponível em: https://www.udesc.br/arquivos/cav/id_cpmenu/2846/1__Dissertacao_RenataBMagro_capa_16650821216082_2846.pdf. Acesso em 22 jun. 2025.

- MARCON, R. F. (2019). *Uso de Redes Neurais para obtenção de Modelos de Predição para Controladores Preditivos Lineares*. Departamento de Automação e Sistemas. Relatório, 86p. Universidade Federal de Santa Catarina. Disponível em: <https://repositorio.ufsc.br/bitstream/handle/123456789/204766/PFC.pdf?sequence=1>. Acesso em 21 jun. 2025.
- MOREIRA, G. C. (2016). *Previsão de níveis fluviais em tempo atual com modelo de regressão adaptativo: aplicação na Bacia do Rio Uruguai*. Dissertação de Mestrado, 153p. Instituto de Pesquisas Hidráulicas. Universidade Federal do Rio Grande do Sul. Disponível em: <https://lume.ufrgs.br/bitstream/handle/10183/147081/000998810.pdf;jsessionid=6C04A37BD9BDC7D7E09F86D934EF94BF?sequence=1>. Acesso em: 22 jun. 2025.
- PEDROLLO, O. C. (1999). “*Previsão Hidrológica de curto prazo com chuvas efetivas determinadas pela função sigmóide*”. Revista Brasileira de Recursos Hídricos, v. 4, n. 2, pp. 19-30. Disponível em: <https://lume.ufrgs.br/bitstream/handle/10183/232492/000234660.pdf?sequence=1>. Acesso em: 22 jun. 2025.
- RIBEIRO, A. M.; JUNIOR, F. de P. S. A. (2020). “*Um Estudo Comparativo Entre Cinco Métodos de Otimização Aplicados Em Uma RNC Voltada ao Diagnóstico do Glaucoma*”. Revista de Sistemas e Computação, v. 10, n. 1, pp. 120-130. Disponível em: <https://revistas.unifacs.br/index.php/rsc/article/view/6488>. Acesso em: 21 jun. 2025.
- SANTOS, A. C. N; TOMASELLA, J.; CARAM, R. C. (2019). “*Simulação Hidrológica na Bacia do Rio Sapucaí com o Modelo Hidrológico Distribuído utilizando precipitação observada e dados do Produto Merge*” in Anais XXIII Simpósio Brasileiro de Recursos Hídricos, Foz do Iguaçu, Nov. 2019, p. 10. Disponível em: <https://anais.abrhidro.org.br/job.php?Job=5897>. Acesso em: 22 jun. 2025.
- SHEN, H.; TOLSON, B. A.; MAI, J. (2022). “*Time to Update the Split-Sample Approach in Hydrological Model Calibration*”. Water Resources Research. 26p. Disponível em: <https://agupubs.onlinelibrary.wiley.com/doi/10.1029/2021WR031523>. Acesso em 22 jun. 2025.
- SILVA, V. A.; SOUZA, R. de F.; OLIVEIRA, M. P.; SANTOS, F. L. dos. (2023). “*Aplicação de machine learning e deep learning para modelagem de uma bacia hidrográfica*”. Revista Paranoá, n 34, 21p. Disponível em: <https://www.cbhmedioparaiba.org.br/conteudo/aplicacao-learning-deep-bacia.pdf>. Acesso em 22 jun. 2025.
- SIQUEIRA, F. M. F. (2021). *Estratégia de otimização de processos com o uso de Redes Neurais. Escola de Engenharia*. Dissertação de Mestrado, 206p. Universidade Federal Fluminense. Disponível em: <https://app.uff.br/riuff/handle/1/22073>. Acesso em: 22 jun. 2025.
- SERVIÇO GEOLÓGICO DO BRASIL – SGB. (c2024). *Hidrologia*. SGB – CPRM. Ministério de Minas e Energia Disponível em: <https://www.sgb.gov.br/hidrologia>.
- SERVIÇO GEOLÓGICO DO BRASIL – SGB. (2025). SACE: SISTEMA DE ALERTA DE EVENTOS CRÍTICOS. Disponível em: <https://www.sgb.gov.br/sace/>.
- TENSOR FLOW. (2020). *Keras*. Disponível em: <https://www.tensorflow.org/guide/keras?hl=pt-br>. Acesso em 21 jun. 2025.
- VICENTINI, E. D.; OLIVEIRA-FILHO, A. G. S. (2021). “*Introdução às Redes Neurais para regressões não-lineares: ajuste de superfícies de energia potencial*”. Quím. Nova, vol. 44, n. 2, pp. 229-324. Disponível em: <https://www.scielo.br/j/qn/a/gDX7ZGVnPPdBPfjvLpdqC4d/>. Acesso em: 22 jun. 2025.