

## MODELAGEM MATEMÁTICA PARA O CÁLCULO DE POTÊNCIA GERADA DE UMA PCH POR MEIO DE UMA RNA<sup>1</sup>

Mayara de Lourdes Schreiber Meotti<sup>2</sup>, Francisco Luis Diello Bressan<sup>3</sup>, Joana Garcia  
Câmara<sup>4</sup>, Christian Schneider Sartori<sup>5</sup>, Airam T. Z. R. Sausen<sup>6</sup>

<sup>1</sup> Trabalho realizado na disciplina Projeto Integrador - Modelagem Matemática Aplicada durante o primeiro semestre do ano de 2023.

<sup>2</sup> Estudante do 6º semestre do curso de Engenharia de Software.

<sup>3</sup> Estudante do 6º semestre do curso de Engenharia Elétrica.

<sup>4</sup> Estudante do 6º semestre do curso de Engenharia Elétrica.

<sup>5</sup> Estudante do 6º semestre do curso de Engenharia Elétrica.

<sup>6</sup> Professora da disciplina.

### INTRODUÇÃO

O Brasil por sua grande disponibilidade de recursos está entre os maiores países com potencial de aproveitamento de energia elétrica do mundo, bem como a China e o Canadá. Tal fato fez com que os profissionais da área começassem a considerar soluções inteligentes, a fim de possibilitar a utilização dos recursos hídricos com o máximo de aproveitamento possível para a geração de energia. No entanto, esse processo é considerado complexo e falho se não modelado e planejado adequadamente para solucionar irregularidades.

Almejando uma elevada precisão dos resultados, o trabalho terá como objetivo principal a modelagem matemática por meio do desenvolvimento de uma Rede Neural Artificial (RNA). Com base na solução proposta, é válido selecionar um conjunto de dados que terá informações suficientes para quantificar a geração média anual de energia em hidrelétricas ao redor do mundo.

Realizada a modelagem matemática, o presente trabalho utilizará ferramentas alternativas para a apresentação dos dados. O *software* escolhido foi o *Colaboraty* que será utilizado para criar um código na linguagem de programação Python, este terá como funções compilar e imprimir os resultados obtidos na modelagem matemática realizada anteriormente.

### METODOLOGIA

Os dados obtidos da empresa Hidroenergia, sediada em Ijuí - RS, responsável por diversos projetos na área de empreendimentos hidrelétricos, são da PCH Paredinha. Dentre eles estão a permanência de vazão da unidade, em porcentagem; a vazão turbinável e a vazão turbinada, ambas em m<sup>3</sup>/s; a quantidade de grupos operando, a vazão unitária, ou seja, a vazão

para cada grupo, em m<sup>3</sup>/s; o nível do montante e do jusante, a queda bruta e a queda líquida, as perdas de carga e a energia na saída do tubo de sucção, todas estas em m; o rendimento das turbinas, do gerador e global percentual, a potência total gerada e a potência gerada por unidade, em kW; além da carga percentual do gerador. A partir do grupo de dados, os utilizados na modelagem matemática foram separados, sendo apresentado na tabela 1.

Tabela 1: Dados para a modelagem matemática.

Permanência de vazão (%)	Vazão Turbinada (m <sup>3</sup> /s)	Qnt. de Grupos Operando	Queda líquida (m)	Rendim. Turb. (%)	Potência Ger. (kW)
1	13.38	3	178.064502	94.0	21310.9131
5	13.38	3	178.064502	94.0	21310.9131
10	13.38	3	178.064502	94.0	21310.9131
15	13.38	3	178.064502	94.0	21310.9131
20	13.38	3	178.064502	94.0	21310.9131
25	12.8	3	178.3983011	94.0	20425.33927
30	11.7	3	178.9907436	94.0	18732.03796
35	10.3	3	179.6678208	93.1	16394.49138
40	9.4	3	180.0575799	92.4	14881.68046
45	8.7	2	179.9021937	94.0	13999.8798
50	8.0	2	180.226191	94.0	12896.63731
55	7.4	2	180.4822847	93.8	11920.92292
60	6.9	2	180.6804524	93.2	11056.48075
65	6.4	2	180.8647623	92.7	10210.67043
70	5.9	2	181.0352142	92.1	9360.853397
75	5.5	2	181.1615981	91.2	8646.979166
80	5.0	2	181.3071059	89.8	7714.491419
85	4.6	2	181.4135344	88.2	6974.968252
90	4.2	1	180.965016	94.0	6798.490755
95	3.6	1	181.2396036	93.5	5805.076629
100	2.4	1	181.6620461	89.2	3685.415272

Fonte: Hidroenergia, 2023.

O desenvolvimento da RNA se deu por meio da linguagem de programação Python dentro do Google Collaboratory, para a elaboração foram importadas as bibliotecas *numpy*, *matplotlib.pyplot*, *neurolab* e *pandas*. A biblioteca *numpy* foi empregada na manipulação dos dados para transformá-los em diferentes matrizes e, também, no processo de normalização e desnormalização dos dados. A *matplotlib.pyplot* oferece diversas funcionalidades para a plotagem de gráficos com três dimensões, assim como na sua personalização, com auxílio da *matplotlib.pyplot* é possível otimizar a criação de gráficos na linguagem Python.

A biblioteca *neurolab* foi a responsável pela criação, treinamento e visualização dos aspectos de arquitetura da RNA, além de possibilitar a predição e cálculo da acurácia do modelo. Já a *pandas* foi responsável pela importação e otimização dos dados utilizados. De

início foram importados os dados, transferidos para outra matriz os valores utilizados para entrada (vazão em  $m^3/s$  e rendimento em %) e saída (potência em kW), os dados foram misturados aleatoriamente e transferidos, os de entrada, para uma matriz de duas colunas e os de saída, para uma matriz de uma coluna. Logo após, todos os dados foram normalizados, ou seja, transformados para valores equivalentes entre 0 e 1 e separados para que 75% sejam utilizados para treinamento, e 25% para teste.


Para a RNA foram determinados os seus parâmetros, que são o tamanho de entrada, a matriz determinada anteriormente, a quantidade de neurônios na camada oculta, 10 no total, e a dimensão da camada de saída. Para o treinamento, a RNA recebe os dados, treina por 10000 épocas, então calcula os erros absoluto e relativo para o treinamento e teste, realiza a desnormalização dos dados, transformando os dados em seus valores reais, para que sejam plotados em um gráfico 3D, que relaciona os dados reais com os da RNA.

Para a predição, foram utilizados valores de vazão e rendimento do intervalo nos dados de entrada, em uma matriz de  $3 \times 2$  que foram normalizados, e como resposta a RNA gerou valores de potência. Ao final, a acurácia da predição foi calculada.

## RESULTADOS E DISCUSSÃO

Como resultado, a RNA gerou um gráfico que demonstra o comportamento dos dados originais em relação ao treino e teste, que pode ser observado na figura 1, o eixo x representa a vazão em  $m^3/s$ , o eixo y o rendimento percentual, e o eixo z a potência em kW.

Figura 1: Gráfico resultante da RNA.



Fonte: Autores, 2023.

As métricas estatísticas calculadas a partir do treinamento e teste da RNA estão expostas na tabela 2, o erro absoluto tanto para o teste, quanto para o treinamento demonstrou valores satisfatórios, o que reflete na acurácia da predição da RNA discutida a seguir.

Tabela 2: Resultado dos erros de treinamento e teste da RNA.

	Treinamento	Teste
Erro Absoluto (%)	0,05421	0,426
Erro Relativo (%)	10,444	62,705

Fonte: Autores, 2023.

Com relação a predição, os dados de entrada determinados com valores dentro do intervalo de dados trabalhados e que foram escolhidos de maneira aleatória estão dispostos na tabela 3.

Tabela 3: Valores de entrada da RNA para a predição.

Entradas		Predições
Vazão (m <sup>3</sup> /s)	Rendimento (%)	Potência (kW)
4	95	3752,426
5,56	97,1	6750,618
13,6	94,2	21310,931

Fonte: Autores, 2023.

Por fim, a acurácia da predição foi de aproximadamente 33.33%, demonstrando que os resultados da RNA estão no caminho, mas podem ser melhorados.

## CONSIDERAÇÕES FINAIS

Ao final do processo de modelagem matemática, a RNA alcançou os resultados de acurácia abaixo do esperado, abrindo margem para pesquisas e aprimoramentos futuros, ou

seja poderão ser abordados outros tipos de Redes Neurais e uma melhor abordagem nos dados, ou até mesmo, uma nova coleta de informações de diferentes PCHs.

**Palavras-chave:** Energia. Rede Neural Artificial. Modelagem. Potência.

## REFERÊNCIAS BIBLIOGRÁFICAS

ANEEL. Resolução Normativa nº 875, de 10 de março de 2020. 51. ed. Brasil, 16 mar. 2020. Seção 1, p. 60-60. Disponível em:

<<https://www.in.gov.br/web/dou/-/resolucao-normativa-n-875-de-10-de-marco-de-2020-248070610>>.

Acesso em: 02 maio 2023.

FLECK, Leandro et al. Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47-57, 2016. Disponível em: <4330-15577-1-PB-libre.pdf (d1wqtxts1xzle7.cloudfront.net)> . Acesso em: 2 de maio de 2023.

HAYKIN, Simon. *Redes neurais: princípios e prática*. Bookman Editora, 2001. Disponível em: <<https://integrada.minhabiblioteca.com.br/reader/books/9788577800865/pageid/41>>. Acesso em: 2 de maio de 2023.

KOVÁCS, Zsolt László. *Redes neurais artificiais*. Editora Livraria da Física, 2002.

PINTO, Milton Oliveira. *Energia elétrica: geração, transmissão e sistemas interligados*. Rio de Janeiro: LTC, 2014. Disponível em: <[https://integrada.minhabiblioteca.com.br/reader/books/978-85-216-2526-1/epubcfi/6/36\[%3Bvnd.vst.idref%3Dchapter03\]!/4/206/3:520\[ina%2Cs.\]>](https://integrada.minhabiblioteca.com.br/reader/books/978-85-216-2526-1/epubcfi/6/36[%3Bvnd.vst.idref%3Dchapter03]!/4/206/3:520[ina%2Cs.]>)>. Acesso em: 17 de abril de 2023.

TERRA AMBIENTAL. **PCH Paredinha – Estudo de Impacto Ambiental**. Dezembro de 2018. Disponível: <[https://www.iat.pr.gov.br/sites/agua-terra/arquivos\\_restritos/files/documento/2020-07/10\\_eia\\_paredinha.pdf](https://www.iat.pr.gov.br/sites/agua-terra/arquivos_restritos/files/documento/2020-07/10_eia_paredinha.pdf)>. Acesso em 22 de maio de 2023.

Wang, X., Zhao, Y., and Pourpanah, F. (2020). **Recent advances in deep learning**. *International Journal of Machine Learning and Cybernetics*, 11:747–750.