

Redes Neurais Artificiais Aplicadas à Modelagem de Instrumentos de Deformação em Barragem de Concreto

Marcelo Kreff¹, Jairo M. Corrêa¹, Tasia Hickmann¹, Samuel B. Rodrigues¹, Cláudio Osako²

¹Federal University Of Technology – Paraná

Avenida Brasil, 4232, 85884-000, Medianeira – Paraná, Brasil

marcelo.kreff@gmail.com, jairocorrea@utfpr.edu.br hickmann@utfpr.edu.br, samuelb@utfpr.edu.br

²Itaipu Binacional

Av. Tancredo Neves, 6731, 85867-900, Foz do Iguaçu – Paraná, Brasil

osako@itaipu.gov.br

Resumo. As usinas hidrelétricas são o principal meio de geração de energia no Brasil. Para garantir a viabilidade deste método de geração, por questões econômicas, sociais e ambientais, este meio precisa ser seguro e monitorado durante todo seu período de operação, garantindo a integridade da estrutura e a segurança para a região em torno da usina. Diversos instrumentos instalados na barragem fornecem, continuamente, dados sobre variáveis como temperatura e deformação. Possíveis anomalias que possam acontecer na barragem podem ser previstas, desde que se use ferramentas numérico-computacionais adequadas. Neste contexto, o artigo apresenta uma metodologia por meio do uso de inteligência artificial para modelar séries temporais, advindas da leitura de um instrumento que mede deformação do concreto, denominado roseta de deformímetro. Esta se localiza no bloco D-38 da barragem da Usina Hidrelétrica Itaipu. As previsões obtidas podem contribuir com a equipe técnica da usina nas tomadas de decisão quanto a uma intervenção preventiva na estrutura da barragem. Utilizou-se duas arquiteturas de redes neurais simuladas na linguagem de programação *Python*, a *MultiLayer Perceptron* (MLP) e a *Long Short Term Memory* (LSTM). Obtiveram-se valores de previsões de dois anos à frente, com menor erro MAPE da amostra teste de 1,07% com a arquitetura MLP.

Palavras-chave: Inteligência Artificial, Roseta de deformímetro, Séries temporais, *Python*.

1 Introdução

Usinas hidrelétricas são grandes construções, comumente de concreto, que represam água para transformar energia potencial gravitacional em energia elétrica. No Brasil, cerca de 60% da matriz energética é provida por esse tipo de geração [1]. A Usina Hidrelétrica de Itaipu (UHI) está localizada no Rio Paraná, entre o Brasil e o Paraguai, e é responsável por fornecer 11,3% da energia consumida no Brasil [2]. Para tornar possível a utilização desse meio de produção, a Itaipu Binacional presa pela confiabilidade em sua estrutura, possuindo um reservatório com um desnível de 120 m (queda bruta nominal) [2], contendo em sua estrutura vários equipamentos que fornecem dados utilizados para monitorar a saúde e integridade da barragem desde sua construção.

A preocupação com a segurança de barragens leva a diversos estudos e discussões, a fim de se obter mais dados e análises que possam garantir o bom monitoramento da estrutura. Pesquisas já foram feitas utilizando tanto métodos estatísticos avançados, decomposição Wavelet de séries temporais, método GARCH, modelos de Box e Jenkins como em [3], aplicados em pêndulos da Usina Hidrelétrica de Itaipu e o trabalho de [4] que descreve uma técnica de modelagem térmica sazonal de um bloco de contrafortes da UHI, por meio do método dos elementos finitos e dados de termômetros internos e superficiais ao bloco.

A deformação, seja ela de dilatação ou contração, é uma variável muito importante a ser monitorada em qualquer estrutura de concreto, em particular, uma barragem de tão grande porte que é a da UHI e é um fenômeno que ocorre devido a diversos fatores externos, como temperatura, eventos geofísicos, nível do reservatório, e outros

[5]. Variados métodos de previsão podem ser utilizados para modelar dados de deformação sejam eles Estatísticos [6] ou redes neurais artificiais (RNAs) [7].

As RNAs são métodos numérico-computacionais utilizados para aprendizagem de máquina que tentam imitar o cérebro humano por meio de conexões de neurônios. Essas ferramentas são amplamente usadas para tarefas como classificação e regressão, tendo sua aplicação em reconhecimento de imagens, previsões, reconhecimento de voz entre outros. Nas redes neurais, ao longo dos anos, várias arquiteturas foram desenvolvidas, que se diferem em complexidade e aplicação, podendo ser otimizadas para diversos fins. Por imitar as sinapses cerebrais por meio da experiência adquirida ao longo de várias iterações, as RNAs são capazes de identificar padrões intrínsecos aos conjuntos de dados [7]. Desta forma, ao detectar tais padrões, pode-se realizar previsões de como determinada série temporal, que representa um instrumento, se comportará num futuro próximo.

Portanto, este trabalho, tem como objetivo, realizar previsões de dados de deformação por meio de um método com RNAs, mais especificamente, das arquiteturas de redes neurais MLP e LSTM. Os resultados são comparados com dados reais por meio do MAPE e assim verifica-se a eficácia de tais redes.

2 Referencial Teórico

2.1 Barragens de Concreto

Barragens de concreto para usina hidrelétricas são grandes construções que possuem o intuito de represar água de afluentes de rios, de modo a criar um declive para usar a força hidráulica produzida pela energia potencial gravitacional presente [8].

No passado utilizavam-se de materiais como pedras, terra e madeira, contudo estes se tornaram obsoletos com a criação do concreto, devido a sua durabilidade, flexibilidade de construção e simplicidade dos materiais que o compõe. Segundo [9], no aspecto construtivo, as barragens de concreto atualmente são construídas essencialmente de materiais granulares naturais como areia, ou produzidos artificialmente como pedras britas, aos quais são adicionados os chamados aglomerantes, comumente cimentos ou pozolanas, além de aditivos incorporadores de ar, retardadores de pega, entre outros.

O concreto é um material que pode sofrer variações em suas dimensões, e quando utilizado em estruturas que possuem dezenas de metros cúbicos, pequenas deformações podem ter consequências severas, afetando na segurança da construção. Essas condições podem ser causadas por influência de tensões, temperatura, fluência, variação higroscópica ou autógena no concreto [9].

2.2 Roseta de deformímetro

As rosetas de deformímetro são dispositivos formados por 5 hastes as quais informam pequenas ou grandes variações de deformações no concreto ao longo de cada uma dessas 5 direções. Consiste assim em uma das principais fontes de informação aos engenheiros da usina quanto à integridade do concreto, já que este sofre deformações devido a fatores sazonais como temperatura e nível do reservatório [10].



Figura 1. Exemplo de roseta de deformímetro [10].

2.3 Séries Temporais

Os conjuntos de dados utilizados para a criação do modelo discutido no artigo são séries temporais, cujos valores, também chamados de dados, são resultantes de aferições periódicas do equipamento em questão. Uma série temporal é uma coleção de observações feitas sequencialmente ao longo do tempo, logo, são dados que devem estar ordenados no tempo [11]. Séries temporais de deformações fornecidas pelas rosetas da UHI possuem como característica, a sazonalidade, devido os principais fatores que geram a dilatação e a contração da estrutura serem a temperatura e o nível do reservatório, variáveis que estão diretamente ligadas às estações do ano.

2.4 Redes Neurais Artificiais

O cérebro humano é uma máquina extremamente aperfeiçoada para reconhecer padrões. Ele faz isso recebendo um conjunto de estímulos sensoriais que ativam um grupo específico de neurônios já treinados por meio da experiência adquirida no tempo. Com o advento dos computadores e o problema de se desenvolver tecnologias para reconhecimento de imagens e padrões, surgem e evoluem as RNAs. Estas procuram imitar o cérebro humano por meio de neurônios artificiais que são treinados para atribuir valores de relevância a entradas com respostas conhecidas, para então ao receber dados semelhantes agir de forma semelhante. As aplicações para esses neurônios matemáticos são amplas, sendo capazes de processar dados compreendendo a fala humana e reconhecendo objetos visualmente [7]. A Figura 2, apresenta um diagrama estrutural base de uma rede neural artificial.

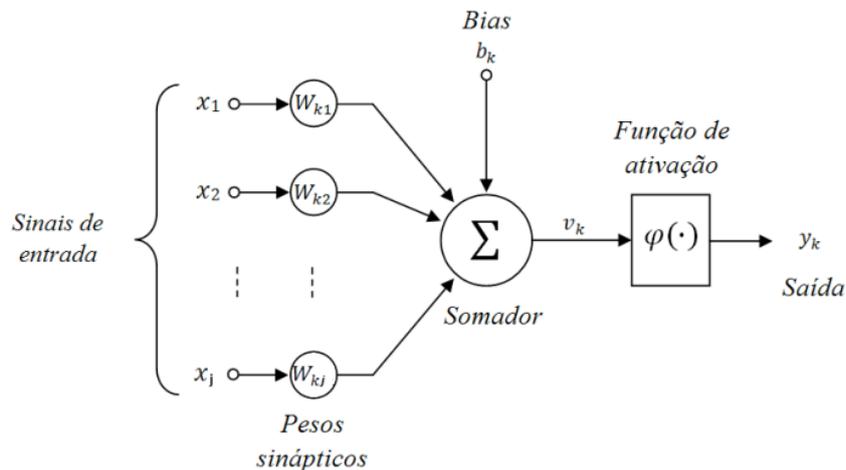


Figura 2. Estrutura básica de uma RNA [7].

Uma rede neural básica obedece a estrutura:

$$\sum_{i=0}^n X_i W_{ki} = U_k \quad (1)$$

X_i = dados de entrada da RNA;

W_{ki} = Peso sináptico;

U_k = Saída do somatório que alimentara a função de ativação.

Cada entrada é multiplicada por seu referido peso, somada e aplicada a função de ativação e então entregar a saída, esta por sua vez durante o treinamento é comparada com um valor esperado, como resultado, obtém-se um erro de treinamento que é utilizado para ajustar os pesos para a próxima iteração de modo a obter uma resposta melhor.

Com o passar dos anos, devido as diversas aplicações de redes neurais, surgiram várias arquiteturas de redes neurais, dentre elas se destaca como a mais simples e intuitiva de se aprender a arquitetura MLP (*MultiLayer Perceptron*), muito utilizada para classificação, como pode ser visto em [7]. Uma das principais vantagens desta rede além de sua facilidade de compreensão é o baixo consumo de processamento quando comparado com outras. Outra arquitetura muito utilizada e bem poderosa é a LSTM (*Long short term Memory*), que é uma rede neural do tipo recorrente, usada em várias ocasiões de processamento de linguagem natural e previsão de séries temporais pois ela é capaz de selecionar entradas arbitrária para melhorar sua saída, segundo [12].

O erro MAPE, utilizado como parâmetro de verificação da eficácia do modelo, é obtido a partir da

Equação 2:

$$E_{mape} = \sum_{i=1}^n \frac{|\tilde{y}_i - y_i|}{y_i} \quad (2)$$

n = número de dados;
 \tilde{y}_i = valor aproximado;
 y_i = valor real.

3 Materiais e Métodos

Para realização da pesquisa foram utilizados dados de deformação da roseta de deformímetro RD-D-003, hastes 1, 2, 3, 4 e 5 do bloco de contrafortes D-38 da barragem da UHI. O Gráfico 1 traz uma representação dos dados da roseta, que são adimensionais, uma vez que a medida é mm/mm e a Figura 3 exibe a estrutura do bloco D38 bem como a localização da roseta RD-D-003. Este instrumento possui medidas não uniformes desde a construção da barragem em 1984 até os dias atuais e o período escolhido para as simulações nesta pesquisa foram de 2000 a 2018, cujos dados foram tratados e ajustados mensalmente por meio de interpolação polinomial.

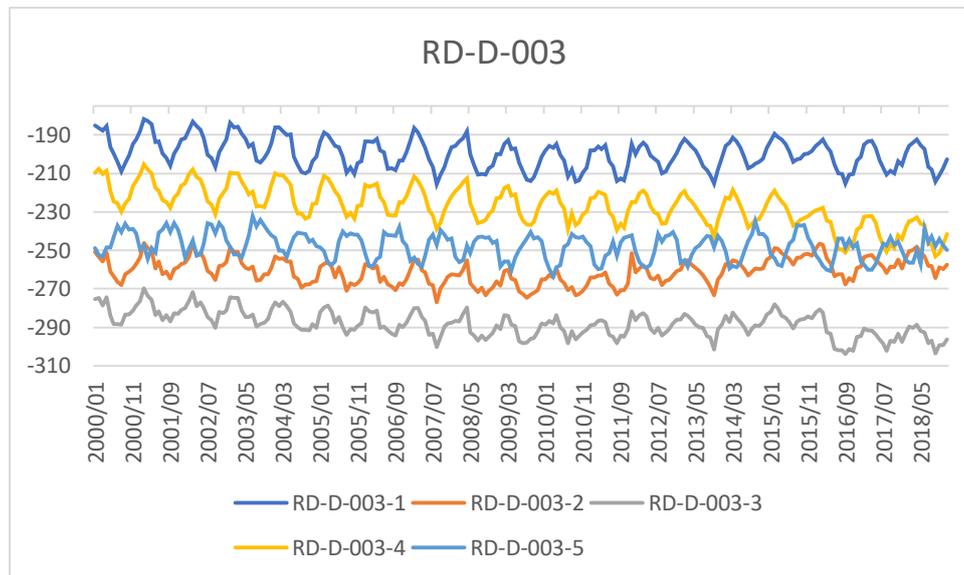


Gráfico 1. Curvas dos dados das hastes 1, 2, 3, 4 e 5 da roseta de deformímetro RD-D-003.

As arquiteturas de redes neurais utilizadas foram desenvolvidas na linguagem de programação de alto nível, o *Python*, em conjunto com bibliotecas de ciência dos dados como *Pandas*, *Numpy* e *Matplotlib*, além de bibliotecas específicas de *Machine Learning* como *Keras* e *TensorFlow*.

Conforme fluxograma da Figura 4, com as duas arquiteturas de redes prontas para serem treinadas, separou-se os dados em 3 conjuntos para treinamento da rede e verificação dos resultados, a fim de se escolher o melhor modelo. O parâmetro escolhido para verificar a qualidade dos resultados obtidos em relação ao esperado é o erro MAPE (*Mean Absolute Percentage Error*).

No primeiro conjunto usou-se dados mensais de 2000 a 2012 para treinamento, sendo que destes 15% para foram para validação, e dados de 2013 a 2014 como amostra teste. Analogamente, foram usados dados de 2000 a 2014 para treinamento e 2015 e 2016 como amostra teste, e por último o período de 2000 a 2016 para treinamento com amostra teste de 2017 a 2018.

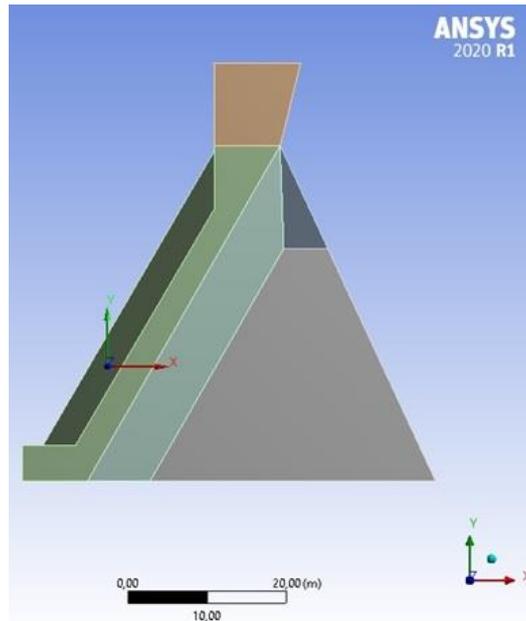


Figura 3. Bloco D38 e localização da roseta RD-D-003.

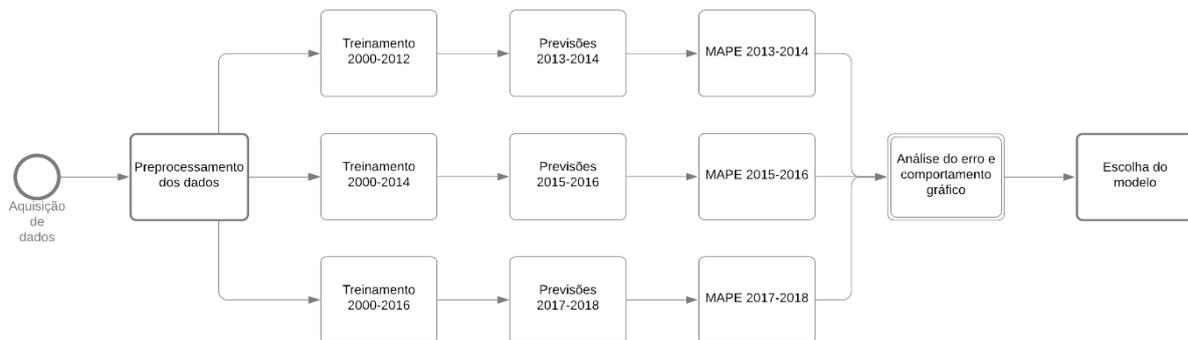


Figura 4. Fluxograma da metodologia para escolha do modelo.

Para realizar as previsões são utilizadas o conceito de janelamento, onde a série temporal unidimensional tem seus valores defasados entre eles em um número de vezes definido conforme as características do conjunto, para assim criar valores de entrada e saída que alimentam a rede.

Tabela 1. Exemplo de Janelamento.

Série Temporal	Entrada _n	Entrada _{n+1}	Entrada _{n+2}	Saída
a ₀	a ₀	a ₁	a ₂	a ₃
a ₁	a ₁	a ₂	a ₃	a ₄
a ₂	a ₂	a ₃	a ₄	a ₅
a ₃	a ₃	a ₄	a ₅	a ₆
a ₄	a ₄	a ₅	a ₆	a ₇
a ₅	a ₅	a ₆	a ₇	a ₈
a ₆				
a ₇				
a ₈				

Com hiperparâmetros semelhantes, respeitando as características intrínsecas de cada arquitetura, as redes foram treinadas utilizando os períodos como descrito acima. Vale salientar que a rede não possui acesso aos dados da amostra teste para o treinamento e adaptação do modelo, os quais foram utilizados apenas para o cálculo do MAPE, com a finalidade de se escolher o melhor modelo. Finalmente, a arquitetura juntamente com os hiperparâmetros que apresentarem o menor MAPE é considerada como a mais eficiente na predição das séries temporais das hastes do deformímetro em estudo.

4 Resultados e Discussões

As simulações foram realizadas seguindo a metodologia descrita no capítulo anterior e as previsões obtidas estiveram próximas aos valores reais para ambas as arquiteturas, como se observa no Gráfico 2 para a haste 1 da reseta RD-D-003, que exibe uma comparativo entre os dados reais reservados na amostra teste e as previsões pelas redes MLP e LSTM. Já o Gráfico 3 apresenta um comparativo entre os dados reais e os resultados obtidos pelas redes para a haste 2 da mesma reseta.

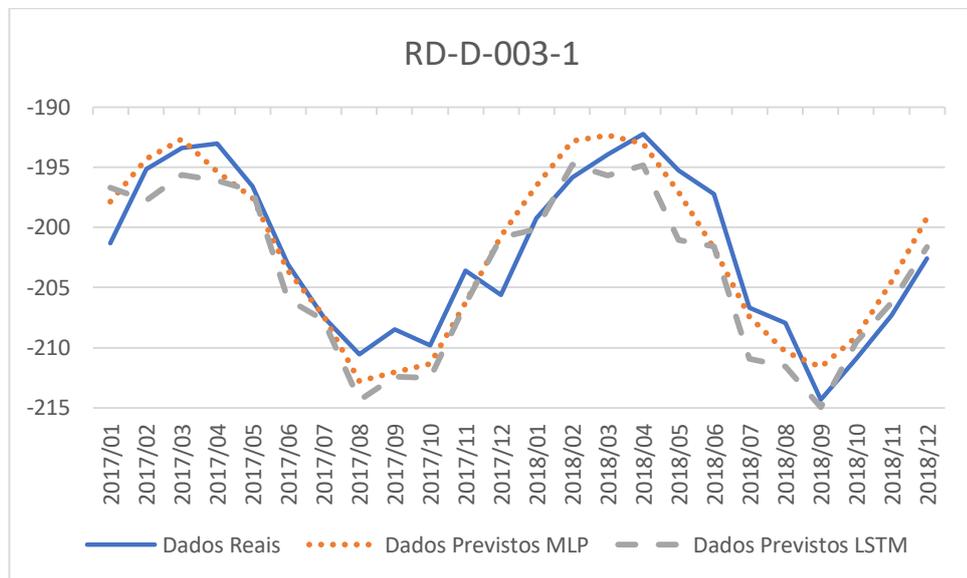


Gráfico 2. Curvas dos dados reais e suas previsões do equipamento RD-D-003 para a haste 1.

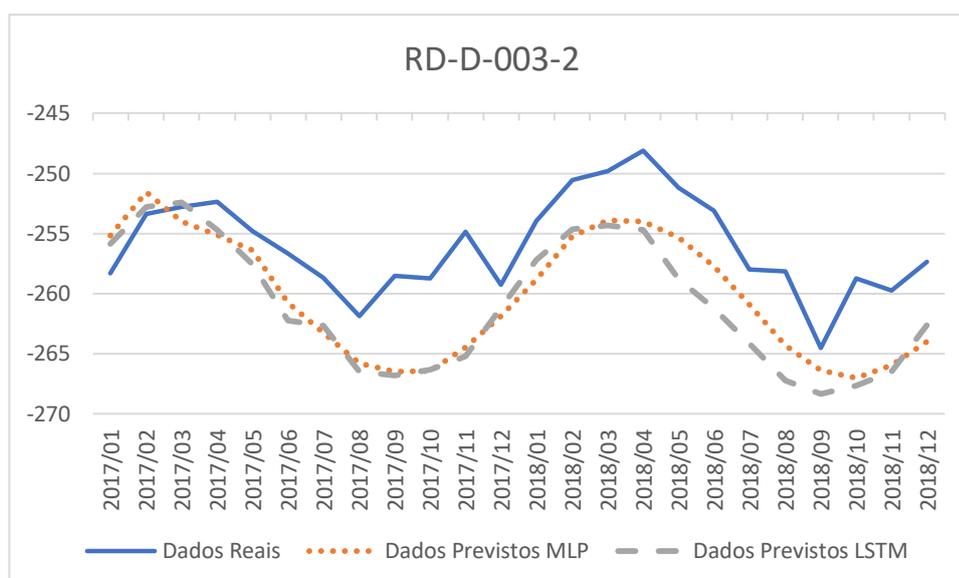


Gráfico 3. Curvas dos dados reais e suas previsões do equipamento RD-D-003 para a haste 2.

Os gráficos acima e a Tabela 2, que aparece na sequência e descreve os MAPEs para as 5 hastes, evidenciam que ambas as redes tiveram bons resultados, mesmo que em alguns casos, o erro é menor na arquitetura MLP, como no caso da haste 2 da roseta, em que todos os períodos os MAPEs da LSTM foram maiores.

A Tabela 2 exhibe os erros resultantes na amostra teste, para todas as simulações realizadas.

Tabela 2 – Erros MAPEs resultantes das simulações.

Equipamento	Arquitetura	MAPE 2013-2014	MAPE 2015-2016	MAPE 2017-2018	MAPE MÉDIA
RD-D-003 haste 1	MLP	1,33%	1,73%	1,07%	1,38%
	LSTM	1,33%	1,51%	1,29%	1,38%
RD-D-003 haste 2	MLP	1,35%	2,18%	1,81%	1,78%
	LSTM	1,66%	3,02%	2,03%	2,24%
RD-D-003 haste 3	MLP	1,09%	1,85%	1,55%	1,50%
	LSTM	1,30%	1,73%	2,71%	1,91%
RD-D-003 haste 4	MLP	1,06%	3,37%	2,02%	2,15%
	LSTM	2,04%	3,06%	4,47%	3,19%
RD-D-003 haste 5	MLP	1,00%	1,29%	1,22%	1,17%
	LSTM	1,14%	1,04%	1,78%	1,32%

Do presente quadro, nota-se que em todos os casos a rede de arquitetura MLP apresentou melhor resultado ou igual nas predições das séries temporais das hastes da roseta de deformímetro, quando comparada com a LSTM. Todos erros foram inferiores a 5%, o que é excelente em termos de engenharia.

5 Considerações Finais

Como se pode observar, ambas as arquiteturas de redes se saíram bem, resultando em erros MAPE menores que 5% em todos os testes. Curiosamente surgiu uma pequena vantagem para a rede de arquitetura mais simples, a MLP, entretanto isso não significa que ela seja melhor, pode-se concluir que para os conjuntos de dados testados ela teve vantagem. Outrossim, prova-se a competência de ambas as redes no propósito da pesquisa, que é identificar a possibilidade de se obter previsões de excelente qualidade para séries temporais de equipamentos de monitoramento de barragens de concreto com a da Usina Hidrelétrica de Itaipu.

Cabe mencionar que a inclusão de variáveis explicativas que possuem boa correlação com a variável em estudo, consiste em um possível trabalho futuro a partir do desenvolvimento de uma rede neural artificial que englobe demais características de séries temporais de equipamentos semelhantes aos estudados, com por exemplo termômetros e piezômetros.

Declaração de autoria. Os autores confirmam que são os únicos responsáveis pela autoria deste trabalho, e que todo o material que foi incluído aqui como parte deste artigo é de propriedade (e autoria) dos autores ou tem a permissão dos proprietários para serem incluídos aqui.

Referências

- [1] EPE. Balanço Energético Nacional 2018. Empresa de Pesquisa Energética – EPE. Rio de Janeiro, 2018
- [2] ITAIPU Binacional. Disponível em: <https://www.itaipu.gov.br>. Acesso em: 04 julho 2020. .
- [3] CORRÊA, Jairo Marlon et al. Time series forecasting with the WARIMAX-GARCH method. Neurocomputing, 2016.
- [4] HICKMANN, Tásia. Análise da variação térmica sazonal em barragem de contrafortes com uso de cálculo fracionário, PhD thesis, Universidade Federal do Paraná, 2016.
- [5] NBR, ABNT. 13028. Mineração-elaboração e apresentação de projeto de barragens para disposição de rejeitos, contenção de sedimentos e reservação de água, 2017.
- [6] BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. Time series analysis, forecasting and control. Englewood Clifs. 1994.
- [7] HAYKIN, Simon. Redes neurais: princípios e prática. Bookman Editora, 2007.
- [8] SILVEIRA, João Francisco Alves. Instrumentação e comportamento de fundações de barragens de concreto. Oficina de Textos, 2003.
- [9] ZUCULIN, Sérgio. Curso segurança de barragens. 2012.
- [10] MATOS, SILVIA FRAZÃO - Avaliação de instrumentos para auscultação de barragem de concreto. Estudo de caso: deformímetros e tensômetros para concreto na barragem de ITAIPU - Dissertação de Mestrado. Curso de Pósgraduação em Engenharia Civil, Universidade Federal do Paraná, 2002.
- [11] HAMILTON, J. D. Time Series Analysis, Princeton University Press, Princeton, 1994.
- [12] GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Deep learning. MIT press, 2016.