

Uso de Redes Neurais Artificiais na Previsão de Deslocamentos em Barragens de Enrocamento com Face de Concreto

Albert Luiz Follmann

Mestrando, Universidade Federal de Santa Catarina, Florianópolis, Brasil, albert.follmann@gmail.com

Rafael Augusto dos Reis Higashi

Professor Adjunto, Universidade Federal de Santa Catarina, Florianópolis, Brasil, rafael.higashi@ufsc.br

Wellison José de Santana Gomes

Professor Adjunto, Universidade Federal de Santa Catarina, Florianópolis, Brasil, wellison.gomes@ufsc.br

Gracieli Dienstmann

Professor Adjunto, Universidade Federal de Santa Catarina, Florianópolis, Brasil, g.dienstmann@ufsc.br

RESUMO: As Barragens de Enrocamento com Face de Concreto são estruturas que usualmente apresentam elevado nível de segurança, no entanto, deformam-se continuamente ao longo do tempo sem que apareçam problemas estruturais que comprometam sua segurança. As deformações observadas possuem, na maioria dos casos, caráter assintótico e são acompanhadas ao longo da vida do empreendimento. Por serem grandezas monitoradas ao longo do tempo, são necessários níveis de referência (valores limite ou esperados) para as deformações, que representem limiares de segurança ou limites para investigações adicionais. Níveis de referência definidos por modelos tensão-deformação são adequados para o primeiro enchimento do reservatório, porém, se mostram inapropriados para os anos vindouros de operação da estrutura. A presente pesquisa descreve a utilização de Redes Neurais Artificiais na predição de deslocamentos horizontais e verticais em duas barragens desse tipo, bem como propõe um novo método para cálculo dos níveis de referência da instrumentação. Mais de vinte marcos superficiais foram analisados e, em conjunto com as variações do nível do reservatório, tempo decorrido desde o início do monitoramento e variações de temperatura, foram utilizados para construir modelos de Redes Neurais Artificiais do tipo Perceptron de Múltiplas Camadas para previsão dos deslocamentos horizontais e verticais. Os deslocamentos horizontais e verticais puderam ser previstos com erros na ordem de décimos de centímetros para uma janela de até 7 anos, apresentando erros menores que os de uma regressão logarítmica para 93,97% das condições avaliadas. Os valores de referência calculados pelo método apresentado não foram superados na janela de estudo e se mostraram próximos aos valores medidos em campo. Portanto, de acordo com o caso avaliado as Redes Neurais Artificiais se mostraram como uma alternativa adequada para a definição de níveis de referência para instrumentação geotécnica de barragens de enrocamento.

PALAVRAS-CHAVE: Barragens de Enrocamento com Face de Concreto, Instrumentação, Inteligência Artificial

ABSTRACT: Concrete Face Rockfill Dams (CFRDs) are structures that usually have a high level of safety; however, they deform over time without presenting structural problems that compromise their safety. The deformations are, in most cases, asymptotic and are monitored throughout the dam lifecycle. Deformations require threshold levels (limit or expected values) are essential to define safety limits or to indicate when further investigations are necessary. Threshold levels defined by stress-strain models are adequate for the first impoundment of the reservoir; however, they already proved to be inappropriate for the overcoming years of dam's operation. This paper describes the use of Artificial Neural Networks in predicting horizontal and vertical displacements in two CFRDs, as well as proposes a new method for calculating instrumentation threshold levels. More than twenty survey points were analyzed, and their readings, associated with reservoir level variations, time elapsed since the beginning of monitoring and temperature variations, were used to construct Multilayer Perceptron Artificial Neural Network models to predict horizontal and vertical displacements. Prediction errors were in the order of tenths of centimeters, smaller than those obtained via

logarithmic regression for 93.97% of the studied conditions. The threshold values calculated by the presented method were not exceeded in the study period and were close to the field measurements. Therefore, the results indicate that Artificial Neural Networks are adequate tools to define threshold levels for geotechnical instrumentation of CFRDs.

KEYWORDS: Concrete Face Rockfill Dams, Instrumentation, Artificial Intelligence

1 INTRODUÇÃO

Uma barragem apresenta diferentes fases em seu ciclo de vida, podendo-se dividir as etapas de forma geral em: projeto, construção, operação e, eventualmente, sua remoção. Cada fase possui grandezas que precisam ser monitoradas para garantir a segurança patrimonial. A vasta maioria das barragens brasileiras, cuja finalidade é a geração de energia, encontra-se em operação, momento que exige acompanhamento rotineiro. O monitoramento é parte do processo de auscultação das estruturas, e é feito por meio de inspeções visuais, sob a ótica da Lei 12.334/2010 bem como por meio da instrumentação. Nesse contexto, a instrumentação exerce papel fundamental na avaliação de desempenho dessas estruturas. Ao longo dos anos, autores como Dunicliff (1988), Fusaro (2007) e Ferreira (2022) evidenciaram a importância de se definir valores limite para as leituras desses instrumentos, denominando-os valores de controle ou referência, a depender de seu significado.

Para a fase de operação, uma prática comum é a definição de limites para piezômetros, associando-se as cargas piezométricas a Fatores de Segurança obtidos por meio do método de equilíbrio limite (Marinero, 2022; Ferreira, 2022). As deformações, por outro lado, costumam ser estimadas por meio de valores de deformação específica tipicamente observados em obras similares, modelos tensão-deformação, ou ainda, estatisticamente (Ferreira, 2022). O uso de modelos tensão-deformação mostra-se adequado para as etapas construtiva e de enchimento do reservatório das Barragens de Enrocamento com Face de Concreto (BEFC), entretanto, não é apropriada para o período de operação (Acosta-González, 2018), pois, conforme expõem Cruz, Materón e Freitas (2014), essas estruturas podem deformar-se continuamente por longos períodos. Ainda nesse contexto, há de se levar em conta que considerar o uso de níveis de referência calculados com dados de obras similares pode não ser uma boa opção em diversos casos, dado que, tal consideração ignora as características intrínsecas de cada estrutura.

Contraopondo as alternativas usuais, as Redes Neurais Artificiais (RNAs) se apresentam como aproximadoras universais de função (Haykin, 1999) e têm sido usadas com sucesso na previsão de poropressão, vazões e deslocamento em barragens de diferentes tipos (Tayfur *et al.*, 2005; Gourine e Khelifa, 2018; Han *et al.*, 2020; Ishfaq *et al.*, 2022). Nesse contexto, a presente pesquisa discute a utilização de Redes Neurais Artificiais do tipo Perceptron de Múltiplas Camadas (MLP – *Multilayer Perceptron*) para previsão de deslocamentos horizontais e verticais (recalques) de duas BEFCs brasileiras, bem como apresenta uma forma para a determinação de valores de referência para a deformação.

2 REDES NEURAS ARTIFICIAIS: PERCEPTRON DE MÚLTIPLAS CAMADAS

Redes Neurais Artificiais (RNA) são idealizações matemáticas baseadas no esquema de funcionamento do cérebro humano (Silva, Spatti e Flauzino, 2016) e constituídas por neurônios artificiais, os perceptrons. Muitos tipos de RNAs existem, cada um com sua arquitetura, suas características e, portanto, diferentes aplicações. Em problemas de regressão, uma das RNAs mais utilizadas é a RNA-MLP.

A RNA-MLP é baseada no conceito de camadas. A camada inicial é a camada de entrada, onde há um neurônio para cada variável de entrada do problema, responsável por receber e efetuar um processamento inicial dos valores da respectiva variável. No caso da presente pesquisa, na camada de entrada estão informações como nível do reservatório, temperatura e outros. Após a entrada, uma ou mais camadas podem existir. Em cada camada um número determinado de neurônios é definido e os dados são processados por meio de funções de ativação. Entre cada passo de cálculo (entrada-camadas-saída) os dados são multiplicados por pesos. Os resultados são obtidos na camada de saída, que tem número de neurônios igual ao número de respostas do problema. No caso em estudo, as saídas consistem nos recalques e deslocamentos horizontais.

Uma arquitetura típica de rede MLP é apresentada na Figura 1, em que os termos X_i , P_{ji} , I_j , Y_j , representam, respectivamente, as variáveis de entrada, as matrizes de pesos sinápticos, as matrizes resultantes das multiplicações entre dados e pesos sinápticos e a matriz que resulta da aplicação da função de ativação sobre a matriz anterior.

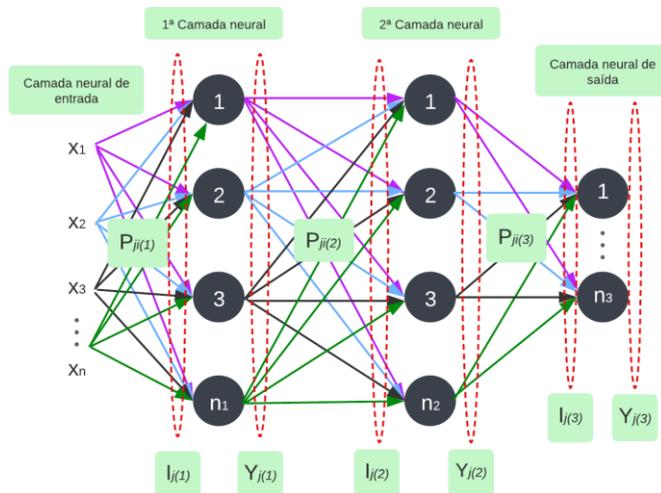


Figura 1. Arquitetura típica de uma RNA tipo MLP. Adaptado de: Silva, Spatti e Flauzino (2016)

Após se definir a quantidade de camadas e de neurônios em cada camada, conforme expõem Silva, Spatti e Flauzino (2016), os pesos sinápticos são gerados aleatoriamente. Para ajustar os pesos de uma RNA-MLP, comumente se utiliza um algoritmo de treinamento denominado *back-propagation*, em que dois passos existem: a propagação e a retropropagação. Na propagação, os pesos são fixados, os dados de entrada são fornecidos à rede e propagados até se obter os resultados na camada de saída. É estabelecida uma métrica de erro e os erros são calculados. Na retropropagação, os gradientes dos erros são calculados e os pesos são ajustados tentando-se minimizar os erros (Haykin, 1999). O objetivo é encontrar os pesos que melhor associem as variáveis de entrada à resposta do problema. Esse processo recebe o nome de aprendizado supervisionado e é feito com parte dos dados disponíveis, o conjunto de treinamento (Haykin, 1999).

Para que o processo de aprendizado da rede funcione de maneira adequada, o conjunto de dados disponíveis é dividido em dados de treinamento e dados para validação. Não há regra para a definição dessa proporção, entretanto, costuma-se usar não menos que 60% dos dados para treinamento e não mais que 90% (Haykin, 1999). O resultado da predição é considerado aceitável quando se atinge o limite de erro estipulado. O conjunto de validação é usado para tentar evitar sobreajuste dos dados.

Mais detalhes a respeito das RNAs-MLP podem ser encontrados, por exemplo, em Haykin (1999), Silva, Spatti e Flauzino (2016) e de Aggarwal (2018).

3 MATERIAIS E MÉTODO

3.1 Barragens estudadas

As BEFCs cujos dados foram utilizados na presente pesquisa são duas estruturas situadas em território brasileiro. Seus nomes e demais dados que as identificam foram descaracterizados para respeitar os direitos dos empreendedores, portanto, elas serão nomeadas de BEFC1 e BEFC2 neste trabalho.

Para que seja possível elaborar um modelo apropriado de Rede Neural Artificial é necessário escolher variáveis que possuam algum tipo de associação, linear ou não-linear, com o resultado a se prever. Como é explicitado por Cruz, Materón e Freitas (2014), a continuidade nos recalques das BEFCs decorre de alguns fatores, como a forma do vale, altura da barragem, quebra de partículas e suas condições construtivas. Alguns destes fatores não são facilmente mensurados ou não são variáveis, o que impossibilita seu uso como dado de entrada para o problema.

Tanto a BEFC1 quanto a BEFC2 apresentam a instrumentação para mensuração de deformação que tipicamente se observa em BEFCs: caixas suecas, extensômetros KM e marcos superficiais (MSs). No entanto, apenas os marcos superficiais encontram-se totalmente operantes e com uma quantidade considerável de dados, o que os tornou objeto de estudo e inviabilizou o uso dos demais instrumentos nas análises. Dessa forma, a Tabela 1 indica os dados disponíveis para a utilização nos modelos.

Tabela 1. Dados disponíveis para realização dos estudos. Fonte: dos Autores (2024)

Barragem	Tipo de dado	Frequência de medição	Total de leituras nos marcos superficiais
BEFC1	Nível do reservatório	Diária	10064
	Temperatura	Diária	
	Marco superficial	Quinzenal	
BEFC2	Nível do reservatório	Diária	4898
	Temperatura	Diária	
	Marco superficial	Quadrimestral	

Quanto aos instrumentos disponíveis, a BEFC1 apresenta 13 marcos superficiais, ao passo que a BEFC2 apresenta 15 marcos superficiais. O instrumento MS4 da BEFC2 foi desconsiderado das análises por apresentar grandes erros de leitura, caracterizados por grandes soerguimentos, em todo o seu histórico.

3.2 Topologia da Rede Neural Artificial

A topologia da RNA foi definida com base em uma série de testes. Para os testes, foram seguidas as orientações apresentadas por Heaton (2005) como ponto de partida, incrementando o número de camadas, de neurônios e testando diferentes funções de ativação, sempre monitorando os erros na etapa de treinamento e aplicando a etapa de validação com o intuito de verificar a ocorrência de sobreajuste (*overfitting*).

A topologia final consistiu em RNAs com 2 camadas escondidas com 64 neurônios em cada camada. A função de ativação foi a retificada linear. O algoritmo de treinamento foi o ADAM (*Adaptive Moment Estimation*), de Kingma e Ba (2015), com uma taxa de aprendizado de 0,015, que consiste em um método de otimização baseado em gradiente. Os dados foram divididos seguindo a proporção 70-30, em que 70% dos dados foram usados no conjunto de treinamento e 30% no conjunto de validação. Ademais, para tentar evitar sobreajuste, foi adicionado ao modelo o critério de parada antecipada, que consiste em interromper o treinamento da RNA sempre que em 500 iterações consecutivas não houvesse redução dos erros.

3.3 RNA-MLP e a Métrica de Erro

O modelo da RNA-MLP foi criado em linguagem Python com auxílio da biblioteca Tensorflow. Para a organização dos dados, foram usados arquivos separados por vírgula (.csv) e a biblioteca Pandas.

Cada instrumento foi avaliado individualmente, sem unir dados de diferentes instrumentos. As variáveis usadas para prever os deslocamentos verticais e horizontais foram o nível do reservatório, a temperatura ambiente e o tempo em dias desde a realização da leitura-alvo. Para a BEFC2, entretanto, o nível do reservatório não pôde ser utilizado em decorrência de falta de dados em algumas leituras e a temperatura ambiente foi obtida da estação INMET mais próxima.

Com o intuito de verificar a capacidade do modelo em prever leituras futuras, os últimos 7 anos foram excluídos do conjunto de dados da BEFC1 (coincidindo com o período para realização da Revisão Periódica de Segurança de Barragem indicado na Resolução ANEEL nº 696/2015) e os últimos 3 anos foram excluídos da BEFC2. A exclusão em diferentes períodos se deu pelo baixo número de dados disponíveis na BEFC2 em relação à BEFC1. A RNA não obteve acesso a esses dados nem para o treinamento ou etapa de validação. Após o treinamento dos modelos com os dados restantes, esses dados foram passados à RNA, permitindo a avaliação mencionada.

Além disso, faz-se necessário utilizar uma métrica de erro para avaliar a qualidade dos dados previstos. No presente trabalho, foi utilizada a métrica *Root Mean Squared Error* (RMSE), apresentada na Equação 1.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Previsão_i - DadoDeCampo_i)^2} \quad (1)$$

Nesse contexto, foram avaliadas a capacidade do modelo prever todo conjunto de dados (inclusive os excluídos) bem como a capacidade de se prever apenas as leituras que foram excluídas. Em ambos os casos, a comparação foi feita em relação ao dado de campo e os respectivos nomes atribuídos foram de Erro Global e Erro de Previsão. Esses erros foram comparados ao erro gerado pela previsão nos mesmos cenários por uma regressão logarítmica, que possui o mesmo caráter assintótico das medições.

4 RESULTADOS E DISCUSSÃO

4.1 Previsão de Recalques e Deslocamentos Horizontais

A Figura 2 apresenta um comparativo entre as médias ao longo dos anos para os recalques e deslocamentos horizontais previstos pela RNA-MLP (barras) e as medições de campo (linhas), em que se observa erros mais baixos para a BEFC1, tanto na previsão de recalques (séries com final REQ), quanto na previsão de deslocamentos horizontais (séries com final DH). O RMSE médio da BEFC1 foi de 0,28 cm para os recalques e 0,30 cm para os deslocamentos horizontais, ao passo que, para a BEFC2 foi observado RMSE de 1,31 cm para os recalques e 0,90 cm para os deslocamentos horizontais.

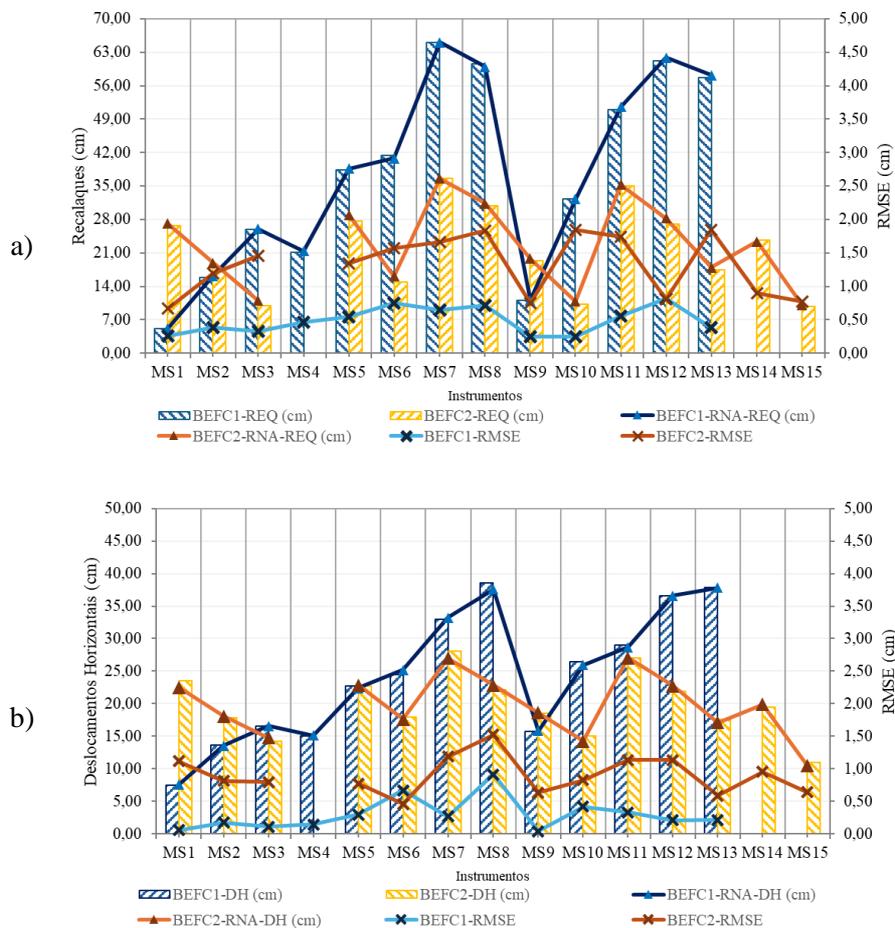


Figura 2. Comparação entre as previsões médias da RNA-MLP e as medições de campo, apresentando o RMSE correspondente no eixo secundário. a) comparações dos recalques; b) comparações dos deslocamentos horizontais. Fonte: dos Autores (2024).

4.2 Comparação das previsões da RNA com Regressão Logarítmica

O desempenho do modelo da RNA-MLP é aqui comparado ao de um modelo mais simples e com eficácia reconhecida. A regressão logarítmica é apropriada por poder se gerar uma curva com característica assintótica, similar ao comportamento de deformação observado em BEFCs.

A comparação entre a RNA-MLP e a regressão logarítmica foi feita usando a métrica RMSE, por meio de duas verificações: uma verificação global em que todo o conjunto de dados previsto é avaliado; e uma verificação de previsão, em que apenas os dados de previsão futura são usados. Os resultados obtidos estão apresentados na Figura 3.

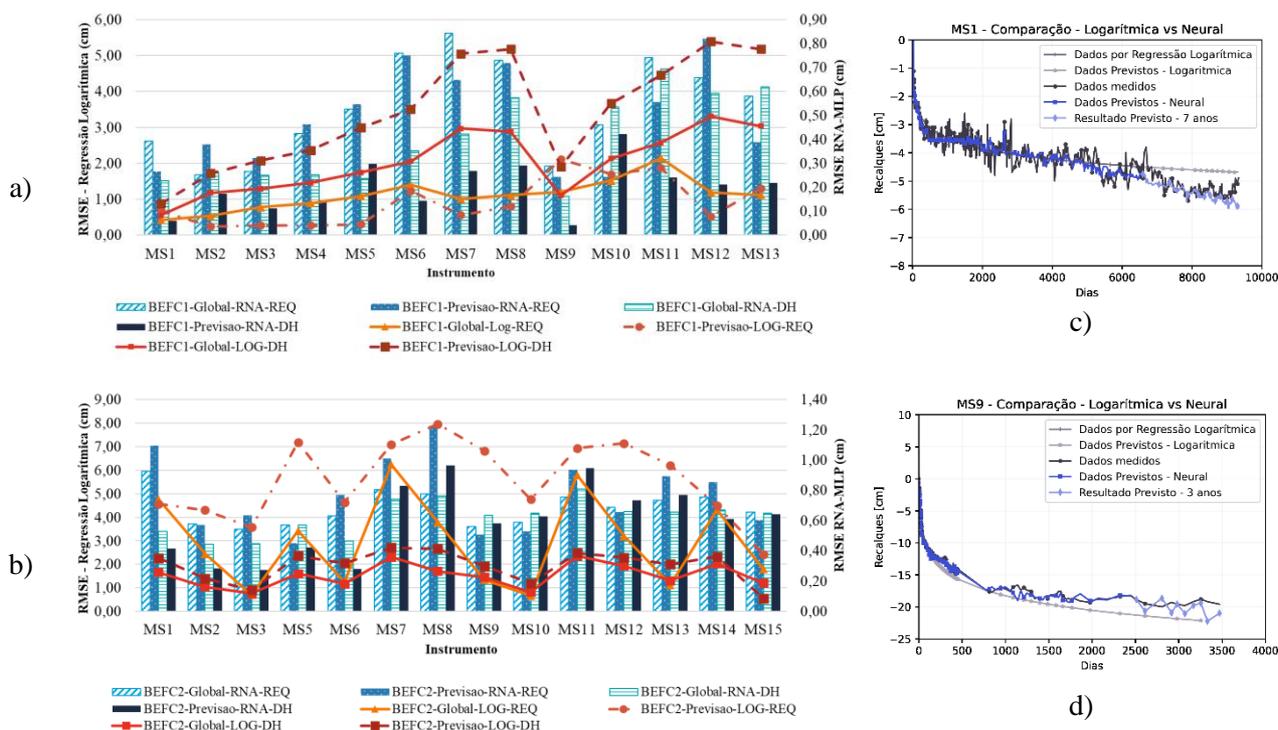


Figura 3. Comparação entre RNA-MLP e Regressão Logarítmica: a) comparações para BEFC1; b) comparações para a BEFC2; c) e d) curvas típicas de previsão da série histórica e comparação com a regressão para BEFC1 e BEFC2, respectivamente. Fonte: dos Autores (2024).

A RNA-MLP apresenta desempenho superior à regressão logarítmica tanto na generalização da série histórica quanto na capacidade de se estimar leituras futuras para mais de 80% dos instrumentos na BEFC1 e mais de 95% dos instrumentos na BEFC2. Quando o conjunto de dados é considerado, a RNA-MLP apresenta-se superior em 93,27% dos casos. A regressão logarítmica tornou-se boa alternativa quando as variações no conjunto de dados foram pequenas ou quando não houve alteração no comportamento ao longo do tempo, ao passo que a RNA-MLP se adaptou a todos os cenários. Resultados típicos das curvas assintóticas previstas com o tempo podem ser visualizados nas Figuras 4c e d.

4.3 Método alternativo para a definição dos níveis de referência

Para a definição de níveis limite para uma BEFC, há de se considerar que não é possível estabelecer a condição exata que leva a uma situação de atenção, alerta ou emergência apenas com a leitura de instrumentos de deformação. Nesse sentido, entende-se que estabelecer níveis de referência é uma prática mais adequada para esse tipo de estrutura.

Nesse contexto, a definição do nível de referência para os marcos superficiais usando a RNA-MLP foi feita utilizando a técnica do melhor e pior cenário, considerando as máximas móveis sobre o conjunto de dados.

Nessa técnica, usa-se máximas e mínimas móveis sobre um determinado período de tempo, com o intuito de considerar os desvios na série de dados (pontos mais extremos), fazendo com que a RNA aprenda os comportamentos das extremidades e possa prever os valores sem deixar de considerar o comportamento de cada instrumento. O período em que o nível de referência é válido está associado ao tempo de previsão efetuado, neste caso, 7 anos para a BEFC1 e 3 anos para BEFC2. Com base na Tabela 2 observa-se que as leituras se encontram dentro do esperado para ambas as barragens avaliadas dentro dos respectivos períodos de previsão.

Tabela 2. Definição dos níveis de referência usando a RNA-MLP. Fonte: dos Autores (2024).

Instrumento	Recalque		Deslocamento horizontal	
	Valor de Referência	Última leitura	Valor de Referência	Última leitura
BEFC1				
MS1	5,79	5,70	7,85	7,50
MS2	16,83	16,50	14,54	13,70
MS3	28,35	27,10	16,58	16,50
MS4	22,36	21,70	15,32	15,20
MS5	41,09	40,75	23,29	22,70
MS6	42,58	42,10	24,58	24,60
MS7	67,72	66,40	33,85	33,30
MS8	62,83	61,30	38,70	38,50
MS9	11,77	11,30	15,81	15,80
MS10	33,82	33,00	26,55	26,40
MS11	54,01	51,80	29,64	29,00
MS12	64,81	62,90	36,79	36,60
MS13	60,06	58,60	38,58	38,50
BEFC2				
MS1	28,91	27,60	25,22	24,22
MS2	19,41	18,30	19,10	18,51
MS3	11,37	10,60	15,21	14,72
MS5	29,23	28,20	23,43	23,32
MS6	16,79	15,30	18,69	18,49
MS7	38,37	37,00	29,41	29,07
MS8	32,46	31,20	23,27	22,83
MS9	19,78	20,00	20,32	19,21
MS10	11,45	10,90	15,74	15,58
MS11	35,70	35,50	28,76	28,07
MS12	28,15	27,70	22,82	22,36
MS13	19,23	17,70	19,07	18,20
MS14	25,59	24,20	20,33	20,31
MS15	10,77	10,20	12,52	11,48

5 CONCLUSÕES

Este artigo discutiu a aplicação das RNAs na previsão de medições de campo de BEFCs. Os resultados obtidos indicam que as RNAs podem ser utilizadas para estimar o comportamento das barragens, fornecendo previsões dos dados usualmente obtidos por meio dos marcos superficiais, e auxiliar nos processos de investigação quanto a comportamentos anômalos destas estruturas.

Ademais, há de se mencionar que o melhor desempenho observado com os dados da BEFC1 se deve à qualidade das medições (pouco ruído nos dados), bem como à disponibilidade de dados completos de nível do reservatório e medição de temperatura na barragem. Nesse contexto, verifica-se que a RNA pode servir para

definir níveis de referência, desde que o monitoramento da BEFC seja efetuado de maneira adequada, o que resultará em um conjunto de leituras de boa qualidade e confiabilidade.

Por fim, a definição dos níveis de referência usando a RNA-MLP gerou sempre níveis acima das leituras efetuadas de campo (máximo de 2 cm), ou muito próximas às últimas leituras efetuadas. Assim, o método para definição dos níveis apresentado nesse artigo mostra-se adequado, dado que considera o comportamento histórico da barragem e obtém níveis que podem ser considerados os esperados para as leituras futuras. Entretanto, há de se mencionar que o julgamento de engenharia sobre os níveis obtidos é indispensável e deve sempre ser feito sobre qualquer análise que envolva a segurança de uma estrutura.

REFERÊNCIAS

- ACOSTA-GONZÁLEZ, L. E. *et al.* (2018). Displacements Study of an Earth Fill Dam Based on High Precision Geodetic Monitoring and Numerical Modeling. *Sensors* 2018, 18(5), 1369. Disponível em: <https://www.mdpi.com/1424-8220/18/5/1369>. Acesso em 18 de fev. 2024.
- AGGARWAL, C. C. (2019). *Neural Networks and Deep Learning: A Textbook*. 2 ed. Londres: Springer, 520 p.
- CRUZ, P. T.; MATERÓN, B.; FREITAS, M. (2014). *Barragens de enrocamento com face de concreto*. 2. ed. São Paulo: Oficina de Textos, 359 p.
- DUNNICLIFF, J. (1988). *Geotechnical Instrumentation for Monitoring Field Performance*. EUA: John Wiley & Sons.
- FERREIRA, J. A. (2022). *Avaliação dos Planos de Segurança de Barragens e sua Efetividade em Relação à Prevenção de Acidentes*. Dissertação de Mestrado, Programa de Pós-Graduação em Desastres Naturais, Departamento de Geologia, Universidade Federal de Santa Catarina/UFSC, 128 p.
- FUSARO, T. C. (2007). *Estabelecimento estatístico de valores de controle para a instrumentação de barragens de terra: estudo de caso das barragens de Emborcação e Piau*. Dissertação de Mestrado, Programa de Pós-graduação em Engenharia Geotécnica, Escola de Minas, Universidade Federal de Ouro Preto/UFOP, 155 p.
- GOURINE, B.; KHELIFA, S. (2018). Analysis of Dam Deformation Using Artificial Neural Networks Methods and Singular Spectrum Analysis. In: *Recent Advances in Environmental Science from the Euro-Mediterranean and Surrounding Regions*, p 871-874.
- HAN, B. *et al.* (2020). Statistically Optimized Back-Propagation Neural-Network Model and Its Application for Deformation Monitoring and Prediction of Concrete-Face Rockfill Dams. In: *Journal of Performance of Constructed Facilities - Volume 34*, Issue 4.
- HAYKIN, S. (1999). *Neural Networks: A Comprehensive Foundation*. 2 ed. India: Pearson Education, 823 p.
- HEATON, J. (2005). *Introduction to Neural Networks with Java*. 1 ed., Saint Louis: Heaton Research Inc, 382p.
- ISHFAQUE, M. *et al.* (2022). Use of Recurrent Neural Network with Long Short-Term Memory for Seepage Prediction at Tabela Dam, KP, Pakistan. In: *Energies* 2022, 15, 3123
- KINGMA, D. P.; BA, J. L. (2015). ADAM: A Method for Stochastic Optimization. In: *Proceedings of the Third International Conference on Learning Representations*, San Diego, CA, May 7–9.
- MARINARO, R. A. *Proposta de Metodologia para definição dos níveis de controle da Instrumentação associados aos modos de falha: estudo de caso em uma barragem para disposição de rejeitos de mineração*. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Geotécnica, Universidade Federal de Ouro Preto/UFOP, 160p.
- SILVA, I.; SPATTI, D. H.; FLAUZINO, R. A. (2016). *Redes Neurais Artificiais para engenharia e ciências aplicadas: fundamentos teóricos e aspectos práticos*. 2ª ed. São Paulo: Artliber, 431 p.
- TAYFUR, Gokmen *et al.* (2005). Case Study: Finite Element Method and Artificial Neural Network Models for Flow through Jeziorsko Earthfill Dam in Poland. In: *Journal of Hydraulic Engineering* 131, p.431-440.