

# Predição de vibrações induzidas por desmontes de rochas por explosivos usando redes neurais artificiais

Prediction of blast-induced ground vibration using artificial neural networks

Predicción de vibraciones inducidas por voladuras de rocas com explosivos utilizando redes neuronales artificiales

Recebido: 12/08/2022 | Revisado: 23/08/2022 | Aceito: 25/08/2022 | Publicado: 03/09/2022

## **Caroline Belisário Zorzal**

ORCID: <https://orcid.org/0000-0001-9323-7848>  
Universidade Federal de Ouro Preto, Brasil  
E-mail: [carolinezorzal@gmail.com](mailto:carolinezorzal@gmail.com)

## **Francisco Lledo dos Santos**

ORCID: <https://orcid.org/0000-0002-7718-8203>  
Universidade do Estado de Mato Grosso, Brasil  
E-mail: [franciscolledo@unemat.br](mailto:franciscolledo@unemat.br)

## **José Margarida da Silva**

ORCID: <https://orcid.org/0000-0001-5695-7213>  
Universidade Federal de Ouro Preto, Brasil  
E-mail: [jms@ufop.edu.br](mailto:jms@ufop.edu.br)

## **Rafael de Freitas Souza**

ORCID: <https://orcid.org/0000-0001-6298-5325>  
Universidade de São Paulo, Brasil  
E-mail: [fsrafael@usp.br](mailto:fsrafael@usp.br)

## **Resumo**

Na indústria mineral, o parâmetro mais utilizado para a quantificação e avaliação do potencial de danos das vibrações sísmicas geradas por desmonte de rochas é a velocidade de vibração de pico de partícula (VPP). Várias iniciativas foram tomadas, ao longo do tempo, com o intuito de estimar os níveis de VPP. Os rápidos avanços na tecnologia computacional fizeram com que sistemas inteligentes se tornassem ferramentas promissoras na estimativa dos resultados de desmonte de rochas. Nesse contexto, este estudo tem como objetivo avaliar as vibrações induzidas por desmontes de rochas por explosivos em uma mina do Quadrilátero Ferrífero por meio de redes neurais artificiais. O banco de dados foi dividido em amostras de treinamento (70%) e teste (30%) das redes. Considerando a importância da seleção de variáveis de entrada adequadas para o treinamento das redes, diferentes grupos de variáveis input foram analisados. A arquitetura que demonstrou melhor desempenho considerou a distância entre o ponto de monitoramento e detonação e a carga máxima por espera como variáveis input. A fim de comparar o desempenho da rede neural com o desempenho de modelos empíricos e de regressão múltipla, os mesmos dados foram utilizados. Por fim, o modelo de redes neurais se mostrou superior às equações empíricas e à regressão múltipla em termos do coeficiente de determinação ( $R^2$ ) e da raiz do erro quadrático médio (RMSE) para os dados medidos e preditos. Além disso, demonstrou-se a importância da seleção das variáveis de entrada adequadas para a estimação de VPP por meio de redes neurais.

**Palavras-chave:** Velocidade de vibração de pico de partícula; Vibrações sísmicas; Desmonte de rochas por explosivos, Redes neurais artificiais; Equações empíricas.

## **Abstract**

The peak particle velocity is the most commonly utilized metric in the mineral sector for quantifying and evaluating the damage potential of blast-induced ground vibration (PPV). Over time, initiatives have been conducted with the goal of measuring PPV levels. Intelligent systems are potential methods for estimating rock blasting results, due to significant improvements in computer technology. In this regard, the goal of this research is to use artificial neural networks to evaluate seismic vibrations caused by rock blasting with explosives in a mine in Quadrilátero Ferrífero. The database obtained in the field was separated into training (70%) and test (30%) samples. Different groups of variables were examined considering the necessity of selecting appropriate input variables for neural network training. The distance between the monitoring and detonation points, as well as the maximum charge per delay, were input variables in the network that performed best. The same database was used to compare the performance of neural networks with the performance of empirical and multiple regression models. Finally, in terms of coefficient of determination ( $R^2$ ) and root mean square error (RMSE) for measured and predicted data, the neural network model

outperformed empirical equations and multiple regression. Furthermore, the importance of choosing the right input variables when using neural networks to estimate PPV was demonstrated.

**Keywords:** Peak particle velocity; Blast-induced ground vibration; Rock blasting; Artificial neural network; Empirical equations.

### Resumen

En la industria minera, el parámetro más utilizado para la cuantificación y evaluación del daño potencial de las vibraciones sísmicas generadas por la voladura de rocas es la velocidad máxima de vibración de partículas (VPP). Se han tomado varias iniciativas con el objetivo de estimar los niveles de VPP. Los rápidos avances en la tecnología informática han convertido a los sistemas inteligentes en herramientas prometedoras para estimar resultados de las voladuras de rocas. En este contexto, este estudio tiene como objetivo evaluar las vibraciones inducidas por la voladura de rocas con explosivos en una mina en el Cuadrilátero Ferrífero por medio de redes neuronales artificiales. La base de datos se dividió en muestras de entrenamiento (70%) y prueba (30%) de las redes. Considerando la importancia de seleccionar variables adecuadas para el entrenamiento de redes, se analizaron diferentes grupos de variables de entrada. La arquitectura que demostró mejor desempeño consideró la distancia entre el punto de monitoreo y detonación y la carga máxima por retardo como variables input. Para comparar el desempeño de la red neuronal con el desempeño de modelos empíricos y de regresión múltiple, se aplicó la misma base de datos. Finalmente, el modelo de red neuronal demostró ser superior a las ecuaciones empíricas y la regresión múltiple en términos de coeficiente de determinación ( $R^2$ ) y raíz del error cuadrático medio (RMSE) para los datos medidos y predichos. Además, se demostró la importancia de seleccionar las variables de entrada adecuadas para estimar el VPP por medio de redes neuronales.

**Palabras clave:** Velocidad máxima de vibración de partículas; Vibraciones sísmicas; Voladura de rocas con explosivos, Redes neuronales artificiales; Ecuaciones empíricas.

## 1. Introdução

No desmonte de rochas, a liberação controlada da energia do explosivo tem como objetivo fundamental fragmentar e extrair o minério do maciço rochoso. Esse método tem se mostrado a forma mais eficiente de se alcançar uma granulometria ou tamanho adequado de material rochoso para o carregamento e transporte, principalmente quando se trata de materiais com resistência moderada a alta. No entanto, somente parte da energia do explosivo é efetivamente aproveitada para o desmonte do material. A energia remanescente é responsável pela geração de efeitos indesejáveis tais como vibrações sísmicas, ultralanchamentos de fragmentos rochosos, poeira, sobrepressão atmosférica, ruídos e outros. Dentre esses, as vibrações sísmicas do terreno se destacam pelo seu potencial de afetar o bem-estar da população no seu entorno, bem como a estabilidade e a integridade do maciço rochoso e de estruturas como barragens, pilhas de estéril, construções civis e outras.

Na indústria mineral, o parâmetro utilizado comumente para a quantificação e avaliação da potencialidade de danos das vibrações sísmicas é a velocidade de vibração de pico de partícula (VPP). A VPP é medida por meio de sismógrafos em três componentes ortogonais entre si: vertical, transversal e longitudinal ou radial. A norma ABNT NBR 9653:2018 (norma vigente no Brasil para regular as vibrações sísmicas causadas por detonações próximas a áreas urbanas) define a VPP como o maior dos três valores máximos obtidos para cada uma das componentes de velocidade de vibração durante determinado intervalo de tempo.

A magnitude das vibrações sísmicas depende de parâmetros de desmonte, parâmetros geomecânicos e geológicos do maciço rochoso, assim como da distância entre o ponto de detonação e o ponto de monitoramento (Trigueros et al., 2017). Várias iniciativas com o intuito de estimar os níveis de vibrações gerados a partir de desmontes de rocha por explosivos foram tomadas ao longo do tempo, incluindo: ensaios de campo, métodos empíricos e técnicas computacionais avançadas.

Os inúmeros fatores que influenciam a geração das vibrações estão associados ao período extremamente curto da passagem da onda provocada pela detonação de explosivos; às condições de anisotropia e heterogeneidade do maciço rochoso; e à complexa dissipação da energia proveniente do desmonte. Tais fatores fazem com que a estimativa das vibrações sísmicas, por meio de ensaios de campo ou laboratório, se torne uma tarefa complexa. Apesar de mais acurada que outras técnicas, os ensaios de campo acabam apresentando custos significativos e longos dispêndios de tempo.

Duvall e Petkof (1958), Langefors e Kihlstrom (1963), Ambraseys-Hendron (1968), Roy (1991) e outros autores

propuseram diferentes modelos empíricos que são largamente aplicados na estimação da VPP. Trata-se de uma metodologia de baixa complexidade e baixo custo. No entanto, de maneira geral, as estimativas obtidas são bastantes conservadoras, impactando nos limites de carga de explosivos a serem utilizadas em desmontes de produção (Ainalis et al., 2017).

Os rápidos avanços na tecnologia computacional fizeram com que sistemas inteligentes se tornassem ferramentas promissoras na estimativa dos níveis de VPP. Nesse contexto, técnicas de soft computing tais como redes neurais artificiais (Bayat et al., 2020; Rezaeineshat et al., 2020), algoritmos genéticos (Ataei & Sereshki, 2017; Dehghani & Beiromvand, 2019), máquina de vetor suporte (Longjun et al., 2011; Li et al., 2012), random forest (Longjun et al., 2011; Zhou et al., 2020) e adaptive neuro-fuzzy inference system (Iphar et al., 2008; Armaghani et al., 2015) têm sido amplamente aplicadas para a predição de vibrações sísmicas induzidas por desmonte de rochas.

As redes neurais foram desenvolvidas ao longo da década de 1980. Apesar de serem um ramo relativamente novo da inteligência artificial, elas têm apresentado bom desempenho para a simulação de problemas complexos, incluindo a estimação de vibrações originadas a partir de desmontes por explosivos. Khandelval e Singh (2006), Khandelval e Singh (2009), Monjezi et al. (2011), Rajabi e Vafaei (2019), Yan et al. (2020) e uma série de outros estudos confirmam que as redes neurais podem superar as técnicas estatísticas e empíricas para a estimativa de vibrações. Conforme pode ser observado na Tabela 1, diferentes estudos consideraram diferentes conjuntos de variáveis “inputs” para a predição de vibrações sísmicas por meio de redes neurais. Nesses estudos, os pesquisadores aplicaram variadas quantidades de camadas e neurônios ocultos a fim de garantir a acuracidade da predição (Yan et al., 2020).

**Tabela 1.** Variáveis de entrada consideradas em redes neurais para predição de vibrações.

Referência	Variáveis de entrada	R <sup>2</sup>
Khandelwal e Singh (2009)	A, BI, D, E <sub>y</sub> , Hf, P, E, V <sub>p</sub> , VOD, Q	0,99
Monjezi et al. (2011)	Hf, T, D, Q	0,95
Khandelwal et al. (2011)	D, Q	0,92
Mohamed (2011)	D, Q	0,94
Mohamednejad et al. (2012)	D, Q	0,85
Monjezi et al. (2013)	D, Q, CT	0,93
Ghoraba et al. (2016)	D, Q	0,91
Rajabi e Vafaei (2019)	D, Q	0,96
Rezaeineshat et al. (2020)	A, E, D, Q, RQD	0,90

Nota: Altura do furo (Hf); tampão (T); distância entre o ponto de monitoramento e detonação (D); carga máxima por espera (Q); carga total (CT); afastamento (A); espaçamento (E); *Rock quality designation* (RQD); *Blastability Index* (BI); módulo de Young (E<sub>y</sub>); coeficiente de Poisson (P); velocidade da onda P (V<sub>p</sub>), velocidade de detonação (VOD). Fonte: Autores.

Nesse contexto, a estimativa de vibrações sísmicas induzidas por desmonte de rochas por explosivos, com o auxílio de redes neurais artificiais, se mostra como uma metodologia que pode contribuir para o entendimento e o controle dos impactos gerados a partir dos desmontes de rochas. Este estudo, portanto, propõe avaliar as vibrações geradas por desmontes de rochas em uma mina do Quadrilátero Ferrífero, próxima a uma comunidade, através de redes neurais artificiais. Os resultados obtidos pelas redes neurais foram comparados a estimativas realizadas por meio de modelos empíricos e de regressão múltipla. Para avaliar o desempenho dos diferentes modelos analisados, os valores de VPP preditos foram comparados aos valores medidos in-situ.

## 2. Metodologia

A estratégia de pesquisa adotada neste estudo foi a de modelagem e simulação, que tem como um de seus objetivos

obter informações sem incomodar o sistema atual (Turrioni & Mello, 2012). Quanto à sua natureza, esta pesquisa é do tipo aplicada uma vez que apresenta interesse prático. Já quanto ao seu objetivo, caracteriza-se como uma pesquisa descritiva visto que visa estabelecer relações entre variáveis. Por fim, trata-se de uma pesquisa quantitativa no que se refere à forma de abordar o problema.

A fim de estimar os níveis de vibrações induzidas por desmontes de rocha por explosivos, este estudo comparou os resultados de equações empíricas, modelos de regressão múltipla e redes neurais artificiais. Para a aplicação da metodologia foi utilizado o software R, v. 4.1.1 (R Project, 2021). Esse software, de licença livre, foi escolhido em virtude de possuir uma enorme gama de pacotes já desenvolvidos para a condução das análises e por apresentar bom desempenho gráfico.

## 2.1 Banco de dados

O banco de dados foi coletado por Silveira (2017) em uma mina localizada a sudeste de Belo Horizonte e encaixada na porção leste do Quadrilátero Ferrífero, Minas Gerais, Brasil, conforme demonstrado na Após o tratamento dos *outliers* realizado por Silveira (2017), o banco de dados passou a ser composto por 132 observações. Cada observação apresenta dados de VPP (mm/s) e de distância do ponto de detonação ao ponto de monitoramento (D), assim como dos parâmetros de desmonte, incluindo carga máxima por espera (Q), afastamento (A), espaçamento (E), altura do furo (Hf), subperfuração (S), tampão (T), número de furos (Nf) e razão de carregamento (RC). Os parâmetros do plano de desmonte para cada um dos 10 desmontes realizados podem ser observados na Tabela 2.

Ao analisar dados multivariados é importante observar os valores extremos considerando todas as variáveis do banco de dados de maneira conjunta. Nesse estudo, a verificação da presença de *outliers* multivariados foi realizada considerando a distância de Mahalanobis ( $D^2$ ). A  $D^2$  é uma medida de distância entre as observações, que mostra o quão longe cada observação está em relação ao centro da distribuição das observações, levando em consideração todas as variáveis e suas covariâncias (Hair et al., 2005). Um valor elevado de distância de Mahalanobis para um dado pode indicar um possível *outlier* multivariado.

. A proximidade existente entre a mina e uma comunidade local, que pode ser observada na Figura 2, justifica a necessidade de se estimar as vibrações sísmicas induzidas pelos desmontes de rochas por explosivos realizados na mina.

**Figura 1.** Localização da mina.



Fonte: Silveira (2017).

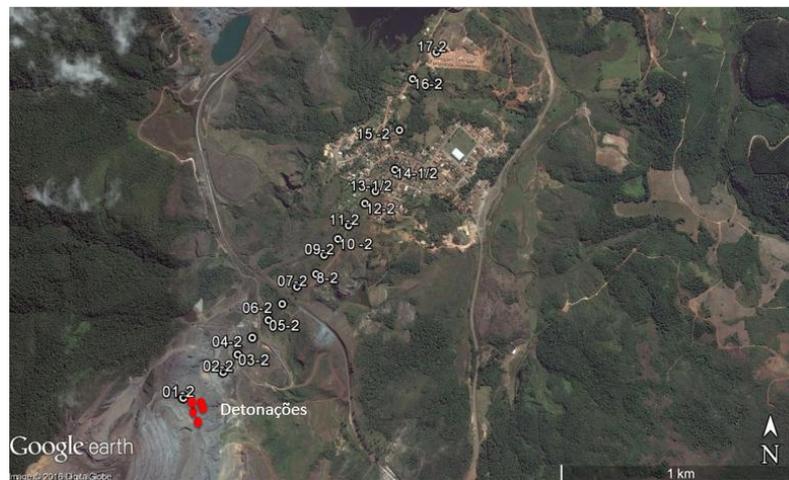
As campanhas de monitoramento dos níveis de VPP ocorreram durante a execução de 10 desmontes de rochas, no intervalo de 10 a 19 de maio de 2016, utilizando explosivos do tipo emulsão Fortis Advantadge, e com o auxílio de 20 sismógrafos GEOSONICS®, modelo SSU 3000 EZ + (Navarro Torres et al., 2018). Os pontos de monitoramento se

localizavam em parte da lavra, em área existente entre a lavra e a comunidade e na própria comunidade próxima à mina, conforme pode ser visto na Figura 2.

Após o tratamento dos *outliers* realizado por Silveira (2017), o banco de dados passou a ser composto por 132 observações. Cada observação apresenta dados de VPP (mm/s) e de distância do ponto de detonação ao ponto de monitoramento (D), assim como dos parâmetros de desmorte, incluindo carga máxima por espera (Q), afastamento (A), espaçamento (E), altura do furo (Hf), subperfuração (S), tampão (T), número de furos (Nf) e razão de carregamento (RC). Os parâmetros do plano de desmorte para cada um dos 10 desmortes realizados podem ser observados na Tabela 2.

Ao analisar dados multivariados é importante observar os valores extremos considerando todas as variáveis do banco de dados de maneira conjunta. Nesse estudo, a verificação da presença de *outliers* multivariados foi realizada considerando a distância de Mahalanobis ( $D^2$ ). A  $D^2$  é uma medida de distância entre as observações, que mostra o quão longe cada observação está em relação ao centro da distribuição das observações, levando em consideração todas as variáveis e suas covariâncias (Hair et al., 2005). Um valor elevado de distância de Mahalanobis para um dado pode indicar um possível *outlier* multivariado.

**Figura 2.** Localização dos sismógrafos durante os dois primeiros dias de monitoramento.



Fonte: Silveira (2017).

**Tabela 2.** Parâmetros do plano de desmorte.

Desmorte	Q (kg)	A (m)	E (m)	Hf (m)	S (m)	T (m)	Nf	RC (g/t)
1	1250	4,3	5	10,2	2,4	5	5	373,5
2	2000	4,2	5	12	0,7	5,8	8	352,5
3	1500	4,4	5,2	12	1	5,2	5	416,8
4	1750	4,3	5	11,5	1	5,5	6	410
5	1000	4,2	4,9	11,5	1	5,2	4	363,9
6	1400	4	4,6	12,4	1	5,2	4	506,3
7	1600	4	4,5	11	0,4	5,1	5	534,7
8	1350	4	4,6	11,5	0,5	5,1	6	534,7
9	2100	4,2	4,5	12,1	1,1	5,6	4	290,8
10	800	4,1	4,6	10,7	0,4	5,1	5	471,5

Fonte: Adaptado de Silveira (2017).

Em seguida, uma análise exploratória dos dados foi realizada. As estatísticas básicas dos dados, assim como suas distribuições e as correlações de Pearson existentes entre as variáveis do banco de dados, são apresentadas. Além disso, com o

intuito de verificar a existência de correlações significantes entre as variáveis, o teste de esfericidade de Bartlett (1951) foi aplicado.

Para a estimação dos diferentes modelos, o banco de dados foi, previamente, dividido em amostras de treino e teste por meio do método *hold-out*, também conhecido como validação simples (Burger, 2018). A divisão do banco foi realizada de maneira aleatória, considerando a prática comum para partição do banco de dados: 70% das observações para treino e 30% para teste.

A fim de evitar o problema de *overfitting* na rede neural, a amostra de treino foi utilizada para o treinamento da rede neural, enquanto a amostra de teste teve como objetivo validar o modelo gerado. Já nos modelos de regressão múltipla e nas equações empíricas, o conjunto de treinamento forneceu os coeficientes de regressão e as amostras de teste foram utilizadas apenas para comparação com a rede neural. Vale destacar que o conjunto de teste não foi apresentado às redes neurais na fase de treinamento, tampouco aos modelos empíricos e de regressão múltipla na fase de obtenção dos coeficientes de regressão.

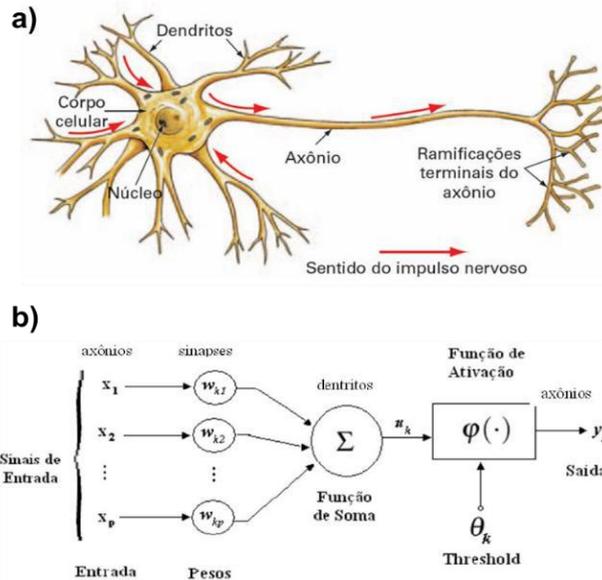
## 2.2 Redes Neurais Artificiais

As redes neurais artificiais, do inglês *artificial neural network* (ANN), são ferramentas inteligentes que permitem analisar problemas complexos e não-lineares. Essa técnica tem a capacidade de generalizar uma solução a partir de padrões presentes em uma amostra de treino. Uma vez que a rede é treinada a partir de um banco de dados com amostras suficientes, predições podem ser realizadas com base na aprendizagem adquirida.

As redes neurais são constituídas por neurônios artificiais, organizados hierarquicamente em camadas, que procuram simular a forma, o funcionamento e as funções de neurônios biológicos. Eles são responsáveis pelo processamento da informação em uma rede neural e seu funcionamento básico consiste em somar valores de entradas ponderados e aplicar uma função de ativação.

A Figura 3 demonstra a comparação entre um neurônio biológico e um neurônio artificial. As entradas do neurônio artificial (correspondentes aos dendritos dos neurônios biológicos) são representadas pelas variáveis  $x_p$ . Já as ligações sinápticas entre os axônios dos outros neurônios e os dendritos desse são representadas pelos pesos  $w_{k,p}$ . A função de ativação  $\varphi$  pode assumir várias formas no neurônio artificial, de forma a permitir a identificação das relações lineares e não-lineares entre as variáveis de entrada e saída, além de restringir a amplitude do intervalo de saída do neurônio (Haykin, 2001). Essas funções são responsáveis por processar o somatório das entradas ponderadas pelos seus respectivos pesos, para produzir a saída final do neurônio  $y_k$ . O valor dessa saída é enviado aos demais neurônios. Os pesos dos neurônios artificiais após o processo de aprendizagem armazenam o conhecimento adquirido pela rede (Santos, 2013).

**Figura 3.** Comparação entre a) um neurônio biológico e b) um neurônio artificial.



Fonte: a) DSA (2021); b) Santos (2013).

Existem diversas arquiteturas de redes neurais, incluindo as redes Perceptrons Multicamadas, do inglês *multilayer perceptron* (MLP). As redes MLP são redes do tipo *feed-forward*, em que a informação de entrada e os cálculos fluem em sequência linear até a saída (*forward calculation*). Dessa forma, a saída de uma camada é usada como entrada para a próxima camada, sem a presença de *loops*.

As redes MLP são formadas por múltiplas camadas. A primeira camada é a camada de entrada (*input*) que recebe as informações das variáveis explicativas, enquanto a última camada é a camada de saída (*output*) que recebe os resultados. As camadas intermediárias são denominadas ocultas e o número de neurônios que a constituem deve ser definido com base na complexidade do problema.

Antes de ser aplicada para interpretar novas informações, a rede precisa ser treinada por meio de algoritmos de aprendizagem. O procedimento de aprendizagem por retropropagação, do inglês *backpropagation*, pode ser aplicado para redes *feed-forward*. Esse algoritmo é baseado no gradiente descendente e o aprendizado é realizado por meio de ajuste iterativo dos pesos da rede com o intuito de minimizar as diferenças entre a saída atual e a saída esperada.

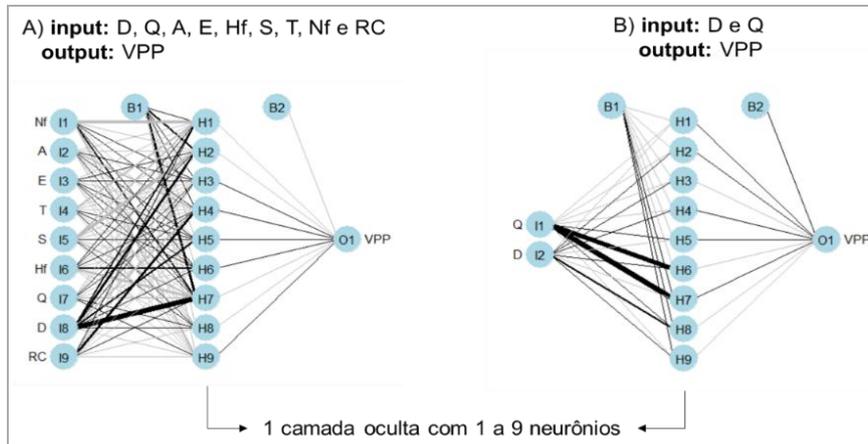
Diversos autores concordam que, dentre os diversos algoritmos para treinamento disponíveis, o *feed-forward backpropagation* se mostra como uma técnica versátil e robusta, comumente utilizada para a solução de problemas não-lineares (Khandelwal & Singh, 2009; Monjezi et al., 2011; Yan et al. 2020). Dessa forma, com o intuito de estimar redes neurais para predição de VPP, neste estudo optou-se por trabalhar com o pacote neuralnet no aplicativo R (Fritsch & Günther, 2008), que possui funções que permitem treinar redes neurais *feed-forward* a fim de aproximar correlações não-lineares complexas. Para estimar os modelos de redes neurais, o conjunto de treinamento, contendo 70% das observações do banco de dados, foi utilizado.

Selecionar adequadamente as variáveis para a estimação da rede neural é considerada uma boa prática a fim de reduzir a complexidade do modelo e evitar problemas como multicolinearidade e *overfitting*. Dessa forma, dois grupos de variáveis foram avaliados como dados *input* para as redes neurais nesta pesquisa. O grupo A é constituído por todas as variáveis do banco de dados disponibilizado por Silveira (2017), as quais são: D, Q, A, E, Hf, S, T, Nf e RC. Já o grupo B é constituído somente pelas variáveis D e Q que podem facilmente ser monitoradas em campo e que, há décadas, já são reconhecidas como variáveis significantes na estimação de VPP, sendo utilizadas nos modelos empíricos.

Tanto para o grupo A quanto para o grupo B de variáveis, os algoritmos de aprendizagem testados foram retropropagação resiliente com retrocesso de peso (*rprop+*, *resilient backpropagation with weight backtracking*) e

retropropagação resiliente sem retrocesso de peso (rprop-, *resilient backpropagation without weight backtracking*). Já as funções de ativação avaliadas foram a função sigmoide logística (*logistic*) e a tangente hiperbólica (*tanh, tangent hyperbolicus*). As estruturas das redes analisadas apresentavam 1 camada oculta, em que a quantidade de neurônios variava de 1 a 9 neurônios, conforme mostrado na Figura 4.

**Figura 4.** Diferentes estruturas de redes neurais avaliadas.



Fonte: Dados originais da pesquisa.

### 2.3 Regressão múltipla

A regressão múltipla tem como objetivo estabelecer a relação entre uma variável dependente (Y) e múltiplas variáveis predictoras (X) ao mesmo tempo (Hair et al., 2005). Quando a relação entre a variável Y e as k variáveis X é expressa linearmente, esta é chamada de regressão linear multivariada e pode ser representada como (Hair et al., 2005; Fávero & Belfiore, 2017):

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i \quad (1)$$

em que  $u_i$  é o termo de erro e  $\beta_0$  e  $\beta_k$  representam, respectivamente, o intercepto e os coeficientes de cada variável e podem ser obtidos a partir do método dos mínimos quadrados ordinários (Fávero & Belfiore, 2017).

No entanto, em situações em que a variável Y não seja expressa por um comportamento linear das variáveis X, modelos não-lineares devem ser avaliados. As relações entre variáveis podem ocorrer por meio de diversas formas funcionais não-lineares. Sendo assim, ao estimar os modelos de regressão, as diferentes formas funcionais devem ser consideradas, para que haja a descrição matemática mais aproximada do comportamento dos diferentes fenômenos.

Para obter a forma funcional mais adequada ao fenômeno em estudo, a transformação de Box-Cox foi aplicada nessa análise. Essa técnica tem como objetivo auxiliar no processo de estimação de regressões não-lineares por meio da transformação das variáveis. Para a transformação da variável dependente, utiliza-se a equação (Box e Cox, 1964):

$$y^\lambda = \begin{cases} \frac{y^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln y, & \lambda = 0 \end{cases} \quad (2)$$

em que  $\lambda$  é o parâmetro de Box-Cox, que pode variar entre  $-\infty$  e  $+\infty$ . O valor do parâmetro de Box-Cox será aquele que maximiza a aderência à normalidade da distribuição da nova variável transformada gerada a partir da variável dependente original (Fávero e Belfiore, 2017).

A fim de selecionar e eliminar do modelo de regressão as variáveis que não se mostram significantes para a determinação da VPP, utilizou-se o procedimento *stepwise*. Esse procedimento auxilia na seleção do modelo com base no *Akaike's Information Criterion* (AIC; Akaike, 1973) e se caracteriza como uma ferramenta que identifica o subconjunto útil de variáveis preditoras. Sistemáticamente, a variável mais significativa é adicionada ou a variável menos significativa é removida durante cada etapa.

Neste estudo, o conjunto de treinamento foi utilizado a fim de obter os parâmetros do modelo de regressão múltipla para a estimação das vibrações sísmicas induzidas por desmonte de rochas.

## 2.4 Equações empíricas

Diferentes modelos empíricos foram propostos ao longo do tempo por diversos pesquisadores para prever os níveis de velocidade de pico de partícula induzidos por desmonte de rochas (Tabela 3). Tais modelos, também chamados de lei de atenuação ou lei de propagação das vibrações, permitem analisar como as vibrações sísmicas são atenuadas à medida que se afastam de seu ponto de origem.

**Tabela 3.** Alguns modelos empíricos propostos por diferentes pesquisadores.

Pesquisadores	Modelos empíricos
Duvall e Petkof (1958)	$VPP = K(D/\sqrt{Q})^{-B}$
Langefors e Kihlstrom (1963)	$VPP = K(\sqrt{Q}/D^{2/3})^B$
Equação geral	$VPP = K D^{-B} Q^A$
Ambraseys-Hendron (1968)	$VPP = K(D/Q^{1/3})^{-B}$
Indian Standard (1973)	$VPP = K(Q/D^{2/3})^B$
Preditor CMRI (Roy, 1991)	$VPP = n + K(D/\sqrt{Q})^{-1}$

Fonte: Dados originais da pesquisa.

Os parâmetros K, n, B e A observados nas leis de atenuação apresentadas na Tabela 3 são constantes relativas à litologia local e aos parâmetros do desmonte de rochas. Essas constantes podem ser facilmente determinadas a partir de medidas de campo por meio de regressão linear ou não-linear. Nesta pesquisa, o conjunto de dados de treinamento foi aplicado para a obtenção das constantes locais.

## 2.5 Comparação entre modelos

Conforme detalhado anteriormente, todos os modelos gerados foram estimados a partir do banco de dados de treinamento. Os dados de teste, por sua vez, foram utilizados com o intuito de comparar os resultados dos modelos empíricos e de regressão múltipla com os resultados das redes neurais. Os parâmetros utilizados para a avaliação do desempenho dos diferentes modelos gerados foram o coeficiente de determinação ( $R^2$ ) entre os dados medidos e os dados previstos e o cálculo da raiz do erro quadrático médio, do inglês, *root mean square error* (RMSE).

O coeficiente de determinação ( $R^2$ ) representa a proporção da variação amostral da variável dependente que é explicada pelas variáveis preditoras. O  $R^2$ , que pode ser utilizado como uma medida do grau de ajuste do modelo proposto, varia de 0 a 1 e é determinado pela equação:

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n (u_i)^2} \quad (3)$$

em que  $\hat{Y}_i$  representa o valor estimado para cada observação  $i$  da amostra,  $\bar{Y}$  é a média de  $Y$  e  $u_i$  é o termo de erro. Quanto mais próximo de 1 for o  $R^2$ , maior será o grau de ajuste do modelo e maior a proporção da variação da variável dependente é descrita pelas variáveis explicativas.

A raiz do erro quadrático médio representa a magnitude típica do erro e é utilizada a fim de mensurar a precisão da previsão. O RMSE pode ser obtido por:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2} \quad (4)$$

em que  $Y_i$  equivale ao valor de  $Y$  de cada observação  $i$  e  $n$  se refere ao número de observações presentes na amostra. O RMSE pode variar de 0 a infinito, sendo que 0 representa o valor para a previsão perfeita.

### 3. Resultados e Discussão

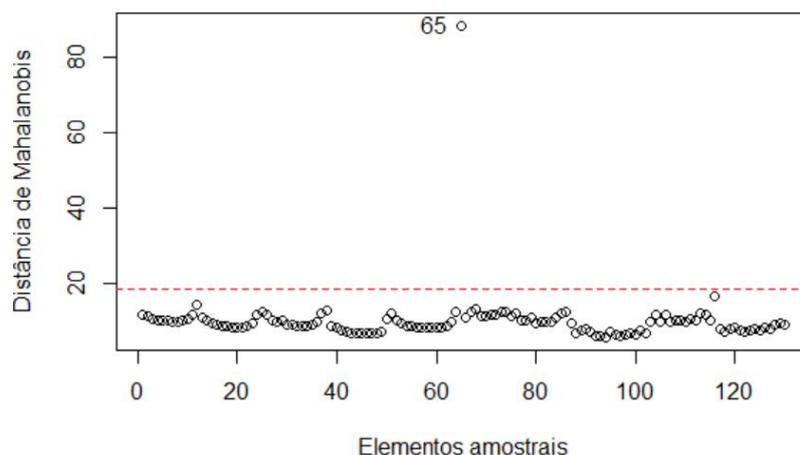
#### 3.1 Banco de dados

A partir da análise de *outliers* multivariados por meio da distância de Mahalanobis foi possível identificar a existência de um dado discrepante em relação ao restante do banco de dados. Conforme pode ser observado na **Erro! Fonte de referência não encontrada.**, o dado 65 apresenta uma distância de Mahalanobis significativamente grande em relação aos demais dados do banco de dados e foi identificado como um *outlier* multivariado.

A partir da Tabela 4, observa-se que o dado 65 é o ponto em que foi obtido o maior valor de vibração de pico de partícula (VPP = 15,88 mm/s). Tal fato se mostra coerente com a realidade, uma vez que o ponto se encontra à menor distância entre o ponto de monitoramento e o ponto de detonação ( $D = 100,96$  m), onde de fato são esperados maiores valores de VPP. No entanto, uma vez que o dado 65 é a única observação com VPP superior a 6,67 mm/s, enquanto todas as demais 131 observações são inferiores a esse valor, essa faixa de valores de VPP não é devidamente amostrada no banco de dados. Logo, o dado 65 foi excluído do banco de dados para a estimação dos modelos de predição de VPP.

A Tabela 5 indica as variáveis que compõem o banco de dados, assim como suas estatísticas básicas. Na **Erro! Fonte de referência não encontrada.**, é possível visualizar as distribuições de cada uma das variáveis, assim como as correlações lineares de Pearson entre elas. Um ponto de atenção a ser considerado ao analisar os modelos que serão gerados a seguir, no entanto, refere-se à alta correlação existente entre algumas variáveis preditoras (**Erro! Fonte de referência não encontrada.**). Correlações significativas entre variáveis independentes levam a multicolinearidade, podendo afetar negativamente as predições da variável dependente. Portanto, a adequada seleção de variáveis para a estimação de modelos se mostra como uma importante ferramenta.

**Figura 5.** Análise de outliers multivariados por meio da distância de Mahalanobis.



Fonte: Resultados originais da pesquisa.

**Tabela 4.** Observação 65.

Desmonte	VPP (mm/s)	D (m)	Q (kg)	A (m)	E (m)	Hf (m)	S (m)	T (m)	Nf	RC (g/t)
6	15,88	100,96	1400	4	4,6	12,4	1	5,2	4	506,3

Fonte: Resultados originais da pesquisa.

**Tabela 5.** Parâmetros de input e output dos modelos.

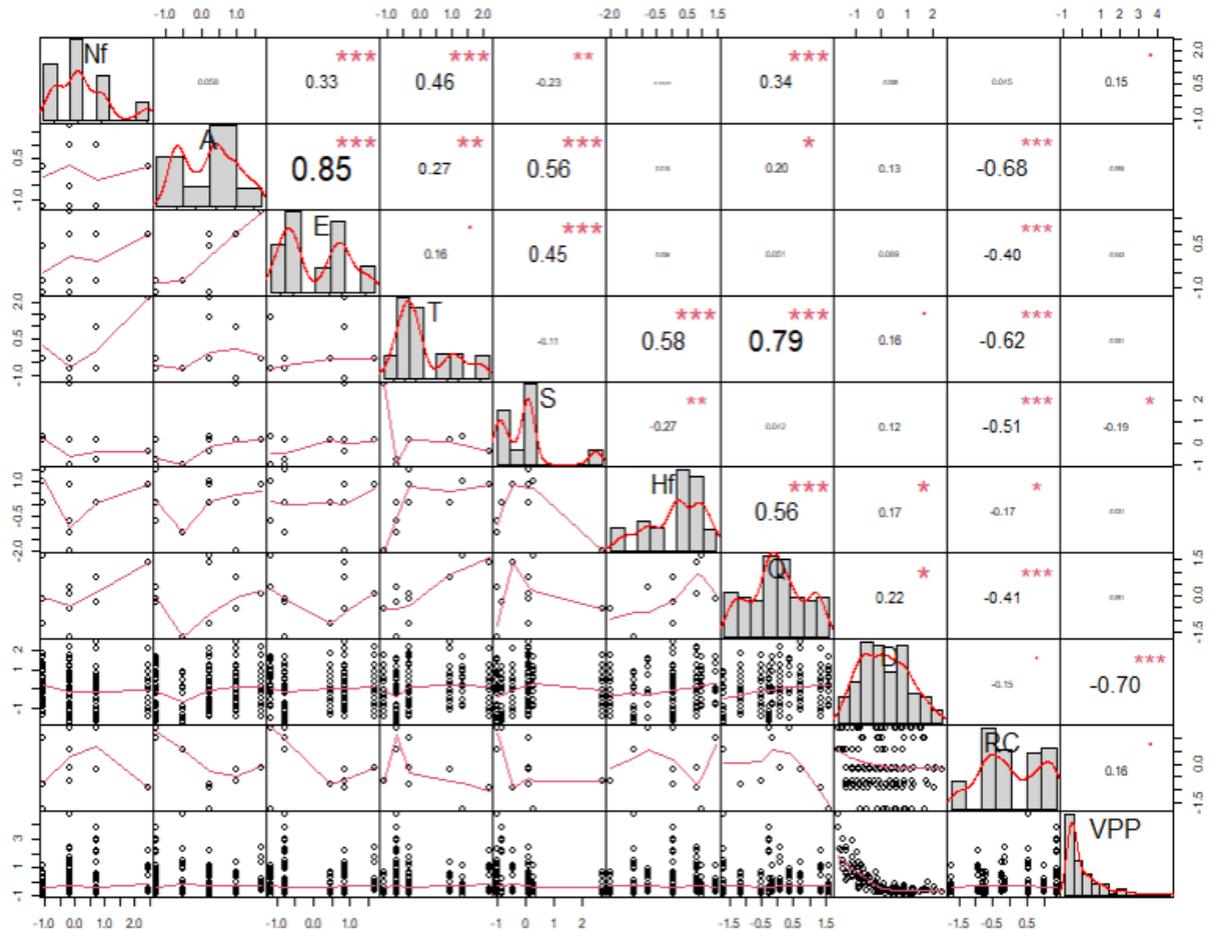
Parâmetros	Símbolo	Mín - Máx	Média	Desvio padrão	Unidade
Número de furos	Nf	4 - 8	5,21	1,14	-
Afastamento	A	4,00 - 4,40	4,17	0,14	m
Espaçamento	E	4,50 - 5,20	4,79	0,24	m
Tampão	T	5,00 - 5,80	5,27	0,24	m
Subperfuração	S	0,40 - 2,40	0,93	0,54	m
Altura do furo	Hf	10,20 - 12,40	11,48	0,64	m
Carga máxima por furo	Q	800 - 2100	1460	394,40	kg
Distância	D	239,6 - 1954,6	955,2	414,17	m
Razão de carregamento	RC	290,8 - 534,7	427,5	79,55	g/t
Velocidade de partícula de pico	VPP	0,19 - 6,67	1,23	1,16	mm/s

Fonte: Resultados originais da pesquisa.

A fim de verificar se o banco de dados multivariado em análise apresenta correlações significantes entre as variáveis, o teste de esfericidade de Bartlett (1951) foi utilizado. O resultado do teste, que consiste em comparar a matriz de correlação das variáveis a uma matriz identidade, é apresentado na Tabela 6. Uma vez que o p-valor se aproxima de zero, existe correlação suficiente entre os dados e conclui-se que o banco de dados é adequado para aplicação de técnicas de estatística multivariada.

Para a estimação dos diferentes modelos, dos 131 elementos constituintes do banco de dados em análise, 91 (70%) foram selecionadas aleatoriamente para constituir o conjunto de dados de treino. As demais 40 observações (30%) foram utilizadas como conjunto de teste.

**Figura 5.** Correlações lineares entre as variáveis.



Fonte: Resultados originais da pesquisa.

**Tabela 6.** Resultado do teste de Bartlett (1951).

Medida	Resultados
Qui-quadrado ( $\chi^2$ )	1107,546
Graus de liberdade (df)	45
p-valor	$1,32 \times e^{-202}$

Fonte: Resultados originais da pesquisa.

### 3.2 Redes Neurais Artificiais

A Tabela 7 apresenta os resultados obtidos para as diferentes arquiteturas de redes neurais avaliadas para o grupo A de variáveis de entrada (D, Q, A, E, Hf, S, T, Nf e RC), enquanto a Tabela 8 traz os resultados obtidos para o grupo B (D e Q).

Percebe-se que, quando o grupo A de variáveis é considerado como *input*, a arquitetura A4 apresentou desempenho superior às demais arquiteturas para o conjunto de teste com  $R^2$  de 0,80 e RMSE de 0,57. Ela conta com 4 neurônios na camada oculta e considerou a função de ativação sigmoide logística (*logistic*) e o algoritmo de aprendizagem de retropropagação resiliente com retrocesso de peso (*rprop+*).

**Tabela 7.** Resultados das redes neurais com o grupo A como variáveis de entrada.

Variáveis de entrada: Grupo A (D, Q, A, E, Hf, S, T, Nf e RC)					
Id	Algoritmo de	Função de	Neurônios na camada	Treinamento	Teste

	aprendizagem	Ativação	oculta	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE
A1	rprop+	logistic	1	0,83	0,47	0,75	0,65
A2	rprop+	logistic	2	0,86	0,43	0,77	0,62
A3	rprop+	logistic	3	0,86	0,43	0,77	0,62
A4	<b>rprop+</b>	<b>logistic</b>	<b>4</b>	<b>0,88</b>	<b>0,40</b>	<b>0,80</b>	<b>0,57</b>
A5	rprop+	logistic	5	0,90	0,37	0,72	0,65
A6	rprop+	logistic	6	0,96	0,24	0,20	4,25
A7	rprop+	logistic	7	0,95	0,26	0,42	1,11
A8	rprop+	logistic	8	0,96	0,24	0,29	2,01
A9	rprop+	logistic	9	0,98	0,18	0,17	2,07
A10	rprop+	tanh	1	0,83	0,47	0,75	0,65
A11	rprop+	tanh	2	0,84	0,47	0,76	0,63
A12	rprop+	tanh	3	0,84	0,46	0,75	0,64
A13	rprop+	tanh	4	0,87	0,42	0,79	0,57
A14	rprop+	tanh	5	0,89	0,38	0,55	0,94
A15	rprop+	tanh	6	0,92	0,33	0,62	0,89
A16	rprop+	tanh	7	0,92	0,32	0,58	0,91
A17	rprop+	tanh	8	0,97	0,20	0,17	1,57
A18	rprop+	tanh	9	0,97	0,19	0,10	2,42
A19	rprop-	logistic	1	0,83	0,47	0,75	0,65
A20	rprop-	logistic	2	0,86	0,43	0,77	0,61
A21	rprop-	logistic	3	0,84	0,46	0,75	0,65
A22	rprop-	logistic	4	0,88	0,40	0,73	0,65
A23	rprop-	logistic	5	0,95	0,27	0,19	2,75
A24	rprop-	logistic	6	0,89	0,38	0,71	0,64
A25	rprop-	logistic	7	0,95	0,26	0,33	1,36
A26	rprop-	logistic	8	0,97	0,21	0,17	1,52
A27	rprop-	logistic	9	0,97	0,21	0,33	1,85
A28	rprop-	tanh	1	0,83	0,47	0,75	0,65
A29	rprop-	tanh	2	0,84	0,46	0,77	0,61
A30	rprop-	tanh	3	0,84	0,46	0,75	0,64
A31	rprop-	tanh	4	0,86	0,43	0,72	0,65
A32	rprop-	tanh	5	0,88	0,39	0,69	0,74
A33	rprop-	tanh	6	0,87	0,42	0,69	0,69
A34	rprop-	tanh	7	0,90	0,36	0,57	0,85
A35	rprop-	tanh	8	0,96	0,24	0,25	1,94
A36	rprop-	tanh	9	0,97	0,20	0,06	2,09

Fonte: Resultados originais da pesquisa.

Para o grupo B de variáveis, B12 e B30 foram as arquiteturas que apresentaram o melhor desempenho em termos de coeficiente de determinação com R<sup>2</sup> de 0,92 e de raiz do erro quadrático médio com RMSE de 0,40. Ambas as arquiteturas possuíam 3 neurônios na camada oculta e função de ativação tanh. Já no que se refere a algoritmo de aprendizagem, a arquitetura B12 aplicou rprop+, enquanto a arquitetura B30 utilizou rprop-. No entanto, a partir da **Erro! Fonte de referência não encontrada.** nota-se que, de maneira geral, o grupo B de variáveis, que considera como variáveis *input* a carga máxima por espera e a distância entre o ponto de monitoramento e observação, apresentou resultados de R<sup>2</sup> e de RMSE satisfatórios em comparação ao grupo A.

**Tabela 8.** Resultados das redes neurais com o grupo B como variáveis de entrada.

**Variáveis de entrada: Grupo B**

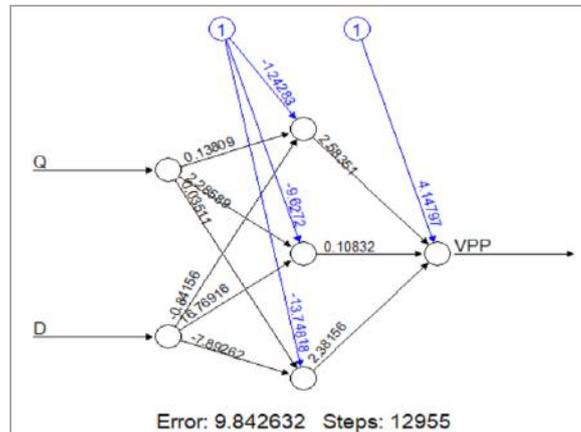
Id	Algoritmo de aprendizagem	Função de Ativação	Neurônios na camada oculta	(D e Q)			
				Treinamento		Teste	
				R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE
B1	rprop+	logistic	1	0,75	0,57	0,81	0,58
B2	rprop+	logistic	2	0,78	0,54	0,91	0,42
B3	rprop+	logistic	3	0,79	0,52	0,90	0,43
B4	rprop+	logistic	4	0,84	0,45	0,73	0,68
B5	rprop+	logistic	5	0,89	0,39	0,67	0,74
B6	rprop+	logistic	6	0,81	0,50	0,84	0,55
B7	rprop+	logistic	7	0,85	0,44	0,71	0,70
B8	rprop+	logistic	8	0,87	0,42	0,58	0,83
B9	rprop+	logistic	9	0,90	0,37	0,62	0,83
B10	rprop+	tanh	1	0,75	0,57	0,81	0,58
B11	rprop+	tanh	2	0,77	0,55	0,82	0,58
B12	<b>rprop+</b>	<b>tanh</b>	<b>3</b>	<b>0,78</b>	<b>0,54</b>	<b>0,91</b>	<b>0,40</b>
B13	rprop+	tanh	4	0,83	0,48	0,67	0,75
B14	rprop+	tanh	5	0,83	0,47	0,70	0,71
B15	rprop+	tanh	6	0,85	0,45	0,67	0,73
B16	rprop+	tanh	7	0,83	0,47	0,69	0,73
B17	rprop+	tanh	8	0,86	0,43	0,68	0,71
B18	rprop+	tanh	9	0,90	0,37	0,64	0,78
B19	rprop-	logistic	1	0,75	0,57	0,81	0,59
B20	rprop-	logistic	2	0,78	0,54	0,91	0,42
B21	rprop-	logistic	3	0,83	0,48	0,66	0,76
B22	rprop-	logistic	4	0,84	0,46	0,70	0,71
B23	rprop-	logistic	5	0,84	0,46	0,77	0,64
B24	rprop-	logistic	6	0,89	0,37	0,71	0,71
B25	rprop-	logistic	7	0,85	0,44	0,71	0,72
B26	rprop-	logistic	8	0,85	0,44	0,84	0,56
B27	rprop-	logistic	9	0,89	0,38	0,63	0,79
B28	rprop-	tanh	1	0,75	0,57	0,81	0,59
B29	rprop-	tanh	2	0,77	0,55	0,80	0,60
B30	<b>rprop-</b>	<b>tanh</b>	<b>3</b>	<b>0,78</b>	<b>0,54</b>	<b>0,91</b>	<b>0,40</b>
B31	rprop-	tanh	4	0,80	0,51	0,72	0,68
B32	rprop-	tanh	5	0,84	0,45	0,69	0,72
B33	rprop-	tanh	6	0,84	0,46	0,67	0,75
B34	rprop-	tanh	7	0,87	0,41	0,70	0,67
B35	rprop-	tanh	8	0,83	0,47	0,73	0,67
B36	rprop-	tanh	9	0,90	0,36	0,60	0,82

Fonte: Resultados originais da pesquisa.

Apesar de ser conhecido que diversos parâmetros influenciam nas vibrações sísmicas resultantes do desmonte de rochas (Zhou et al. 2020), os resultados obtidos se mostram coerentes com resultados obtidos por outros autores, tais como Khandelwal et al. (2011), Mohamed (2011), Mohamednejad et al. (2012) e Rajabi e Vafae (2019). Tais autores, mesmo considerando apenas as variáveis D e Q como *inputs*, também obtiveram modelos de redes neurais artificiais com bom desempenho para a predição de VPP. Dessa forma, é possível concluir que, para as arquiteturas de redes neurais analisadas e para o estudo de caso realizado, os parâmetros Q e D demonstraram potencial para prever os níveis de vibrações induzidas por desmonte de rochas por meio de redes neurais. Dessa forma, ressalta-se ainda a importância de se realizar uma adequada seleção de variáveis de entrada para a estimação de VPP por meio de redes neurais.

É, portanto, possível concluir que, dentre as arquiteturas analisadas, as redes neurais B12 e B30 foram aquelas que apresentaram o melhor desempenho na estimação dos níveis de vibrações sísmicas induzidas por desmontes de rochas. Como os desempenhos foram idênticos, para comparação de desempenho com os demais modelos analisados, optou-se por considerar a arquitetura B12, demonstrada na **Erro! Fonte de referência não encontrada.**

**Figura 7.** Rede neural B12.



Fonte: Resultados originais da pesquisa.

### 3.3 Regressão múltipla linear e não-linear

Um modelo de regressão linear multivariado foi desenvolvido considerando a variável dependente VPP em função das variáveis Nf, A, E, T, S, Hf, Q, D e RC. A fim de selecionar e eliminar do modelo as variáveis que não se mostram significantes para a determinação da variável dependente VPP, utilizou-se o procedimento *stepwise*. Por meio dessa técnica, somente a variável D se mostrou significativa. No entanto, uma vez que, a partir do teste Shapiro-Francia os resíduos do modelo não se mostraram aderentes à normalidade ( $p$ -valor =  $4,38 \times 10^{-5}$ , inferior a 0,05), concluiu-se que a forma funcional linear não é ajustada à nuvem de pontos.

Para buscar a forma funcional mais adequada ao modelo em análise, utilizou-se a transformação de Box-Cox da variável dependente em conjunto com o procedimento *stepwise* para garantir a significância dos parâmetros presentes no modelo. O parâmetro de Box-Cox que aumenta a probabilidade da nova variável VPP ser aderente à normalidade e, conseqüentemente, gerar resíduos aderentes à normalidade foi -0,27. O modelo estimado, que tem seus parâmetros apresentados na Tabela 19, pode ser escrito na forma:

$$\frac{VPP^{-0,27} - 1}{-0,27} = 0,72244 + 0,00039 Q - 0,00163 D \quad (5)$$

Nota-se que apenas as variáveis Q e D se mostraram significantes para a estimativa das vibrações sísmicas.

Os resultados do teste Shapiro-Francia mostraram que os resíduos do modelo não-linear, apresentado na eq. (5), são aderentes à normalidade ( $p$ -valor = 0,2284, superior a 0,05). Dessa forma, o modelo estimado demonstrou ser ajustado à nuvem de pontos, apesar de apresentar desempenho relativamente baixo de  $R^2$  e RMSE entre os valores de VPP medidos e preditos, conforme pode ser visto na Tabela 10. Na **Erro! Fonte de referência não encontrada.**, é possível observar a relação entre os valores de VPP medidos e preditos pela regressão múltipla para o conjunto de treinamento.

**Tabela 1.** Modelo de regressão multivariada com transformação de Box-Cox.

Coefficientes	Standard error	t stat	p-valor
---------------	----------------	--------	---------

<b>Intercepto</b>	0,72244	0.212660	3.397	0.00102
<b>Q</b>	0,00039	0.0001331	2.932	0.00429
<b>D</b>	-0,00163	0.0001280	-12.746	$<2 \times e^{-16}$

**Teste F: 81.33 p-valor:  $<2.2 \times e^{-16}$**

**Teste de normalidade de Shapiro-Francia: W: 0.98266 p-valor: 0.2284**

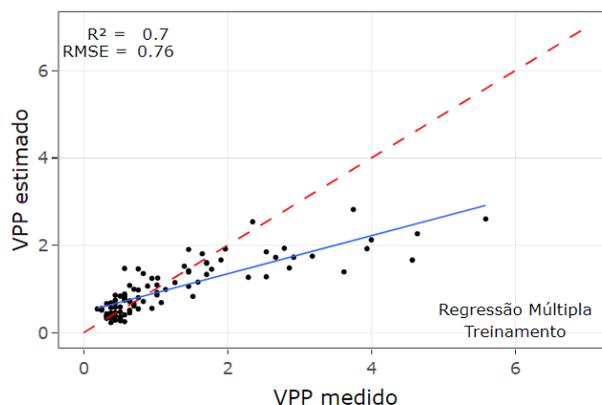
Fonte: Resultados originais da pesquisa.

**Tabela 10.** Resultados de  $R^2$  e RMSE obtidos para o modelo de regressão múltipla a partir do conjunto de treinamento.

Modelo	Treinamento	
	$R^2$	RMSE
<b>Regressão Múltipla</b>	0,7	0,76

Fonte: Resultados originais da pesquisa.

**Figura 8.** Comparação entre valores medidos e preditos de VPP por meio de regressão múltipla para o conjunto de treinamento.



Fonte: Resultados originais da pesquisa.

### 3.4 Equações empíricas

Na Tabela 11 são apresentadas as constantes locais dos modelos empíricos (Tabela) que foram determinadas a partir dos dados de treinamento. A partir dos resultados de  $R^2$  e RMSE obtidos entre os valores de VPP medidos e preditos pelos modelos empíricos para o conjunto de treinamento (Tabela 11 e

), nota-se que, em termos de  $R^2$ , o desempenho dos modelos USBM (Duvall e Petkof, 1958), equação geral (Nicholls et al., 1971) e Ambraseys-Hendron (1968) foi equivalente ( $R^2 = 0,76$ ). No entanto, no que se refere ao RMSE, a equação geral mostrou desempenho levemente superior, com um RMSE de 0,56. A equação empírica do Indian Standard (1973), por sua vez, foi aquela que apresentou o pior desempenho.

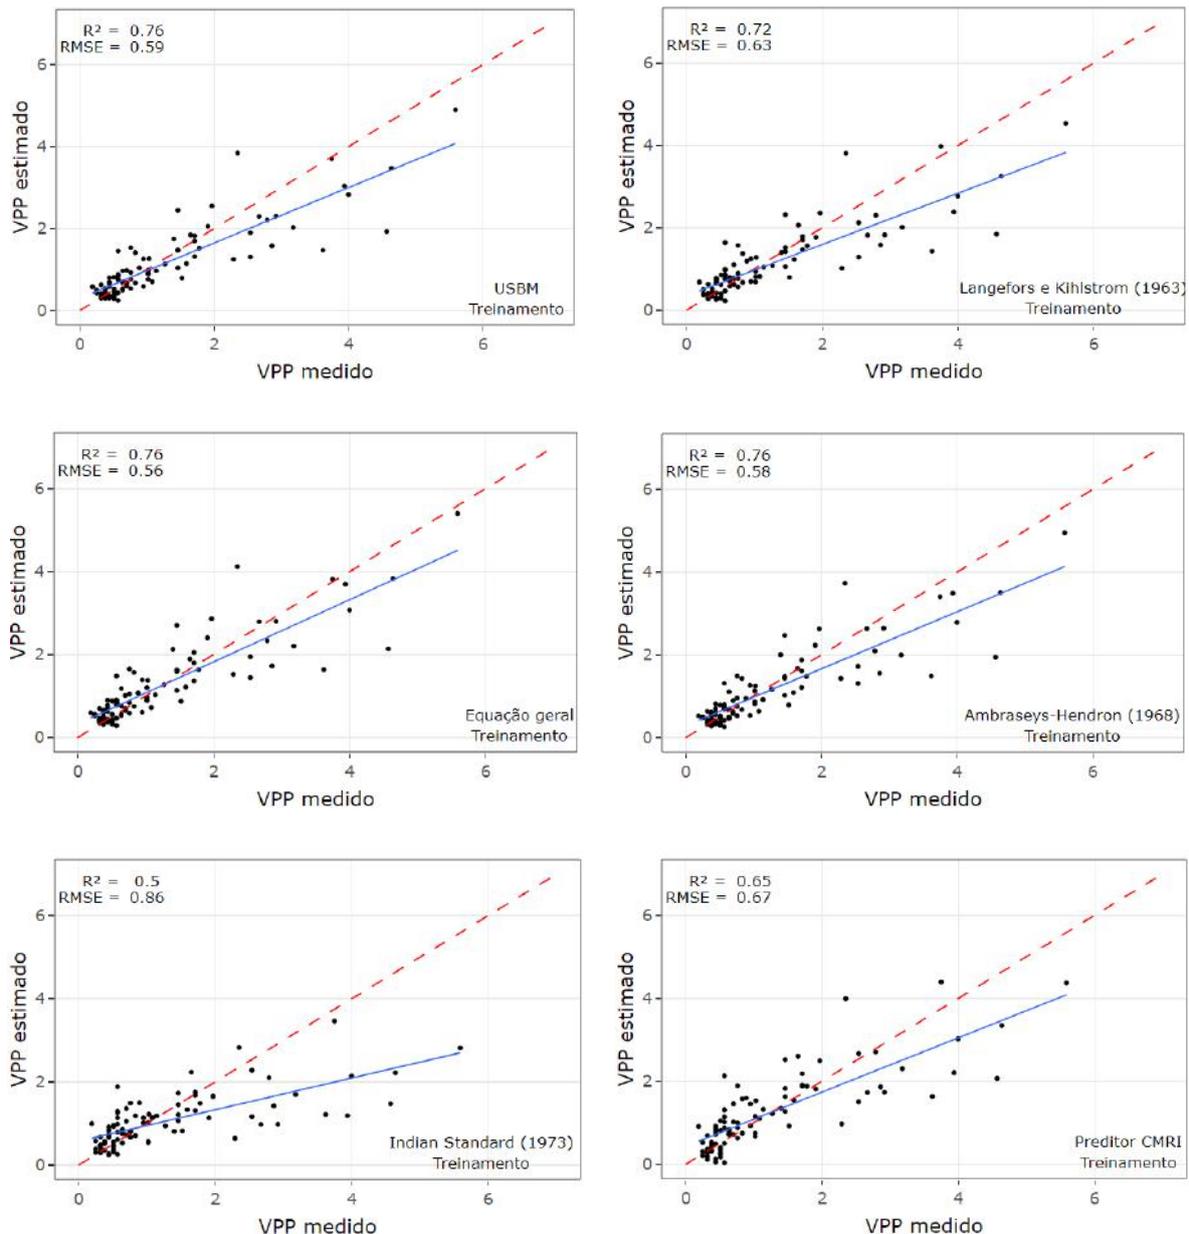
**Tabela 21.** Constante locais estimadas e resultados de  $R^2$  e RMSE obtidos para os para diferentes modelos empíricos a partir do conjunto de treinamento.

Modelo	Constantes locais				Treinamento	
	K	B	A	n	$R^2$	RMSE

<b>USBM (Duvall e Petkof, 1958)</b>	79,54	1,45		0,76	0,59
<b>Langefors e Kihlstrom (1963)</b>	5,32	2,10		0,72	0,63
<b>Equação geral (Nicholls et al., 1971)</b>	314,45	1,45	0,54	0,76	0,56
<b>Ambraseys-Hendron (1968)</b>	463,40	1,45		0,76	0,58
<b>Indian Standard (1973)</b>	0,013	1,52		0,50	0,86
<b>Preditor CMRI (Roy, 1991)</b>	0,90			-0,49	0,65

Fonte: Resultados originais da pesquisa.

**Figura 6.** Comparação entre valores de VPP medidos e preditos pelos modelos empíricos para o conjunto de treinamento.



Fonte: Resultados originais da pesquisa.

### 3.5 Comparação entre modelos

Na Tabela 12 são apresentados os valores dos parâmetros estatísticos  $R^2$  e RMSE dos modelos apresentados nessa pesquisa após o processo de estimação para o banco de dados de teste. Já a **Erro! Fonte de referência não encontrada.**

apresenta a relação entre os valores de vibrações sísmicas medidos em campo e os valores preditos pelos modelos empíricos, pela regressão múltipla e pela arquitetura de rede neural B12 para o mesmo banco de dados.

**Tabela 12.** Resultados de  $R^2$  e RMSE obtidos para os modelos analisados a partir do banco de dados de teste.

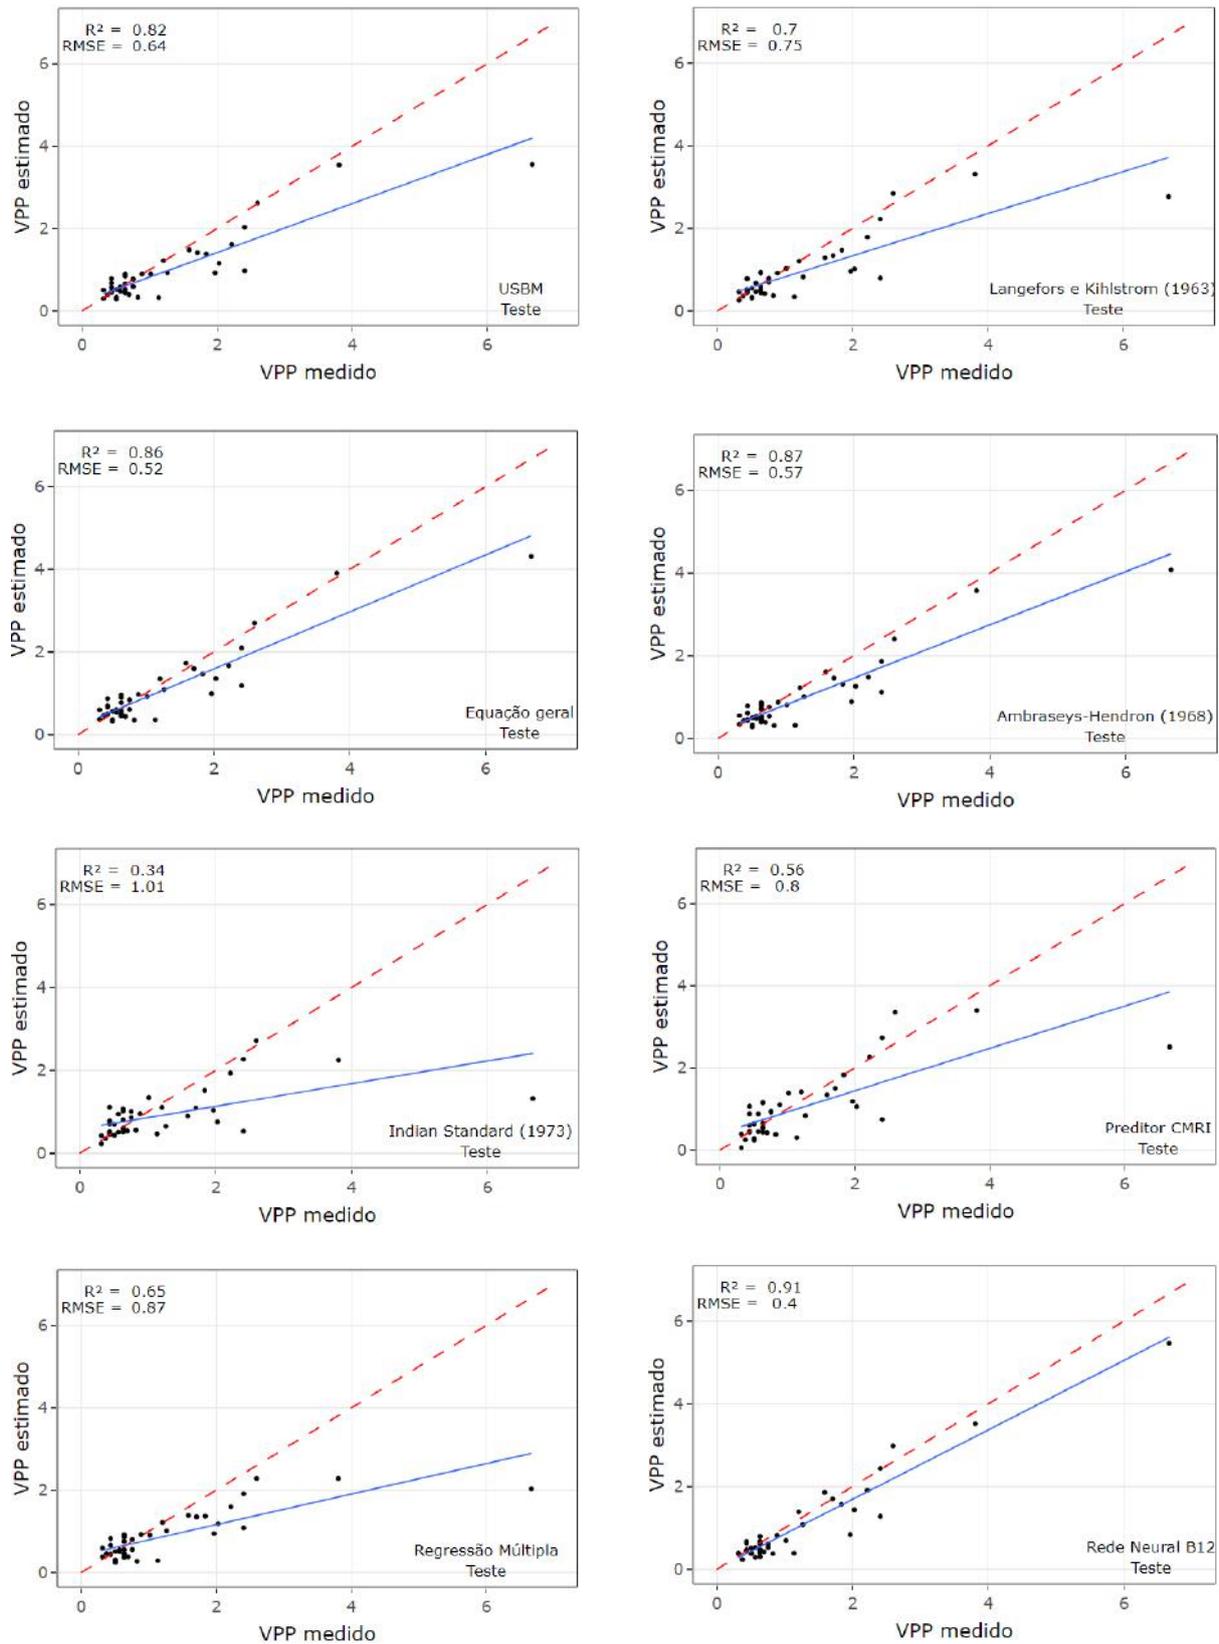
Modelo	Teste	
	$R^2$	RMSE
USBM (Duvall e Petkof, 1958)	0,82	0,64
Langefors e Kihlstrom (1963)	0,70	0,75
Equação geral	0,86	0,52
Ambraseys-Hendron (1968)	0,87	0,57
Indian Standard (1973)	0,34	1,01
Preditor CMRI (Roy, 1991)	0,56	0,80
Regressão Múltipla	0,65	0,87
Rede neural B12	0,92	0,40

Fonte: Resultados originais da pesquisa.

Nota-se que a rede neural B12 foi o modelo que apresentou melhor desempenho com o maior valor de  $R^2$  (0,91) e o menor valor de RMSE (0,40). Logo em seguida se destacam a equação proposta por Ambraseys-Hendron (1968) e a equação geral reconhecida por diversos autores (Nicholls et al., 1971; Dinis da Gama, 1998; Navarro Torres et al., 2018; outros) com  $R^2$  de 0,87 e 0,86, respectivamente. No entanto, em termos de RMSE, a equação geral obteve menor valor de RMSE (0,52) do que a equação empírica de Ambraseys-Hendron (1968). Já a equação empírica proposta pelo Indian Standard (1973) foi aquela que obteve os piores índices de  $R^2$  (0,34) e RMSE (1,01), assim como observado por Hosseini et al. (2019), Rajabi e Vafae (2019) em estudos de estimação de VPP. Dessa forma, a capacidade de estimação desse modelo se mostrou significativamente inferior aos demais modelos estimados.

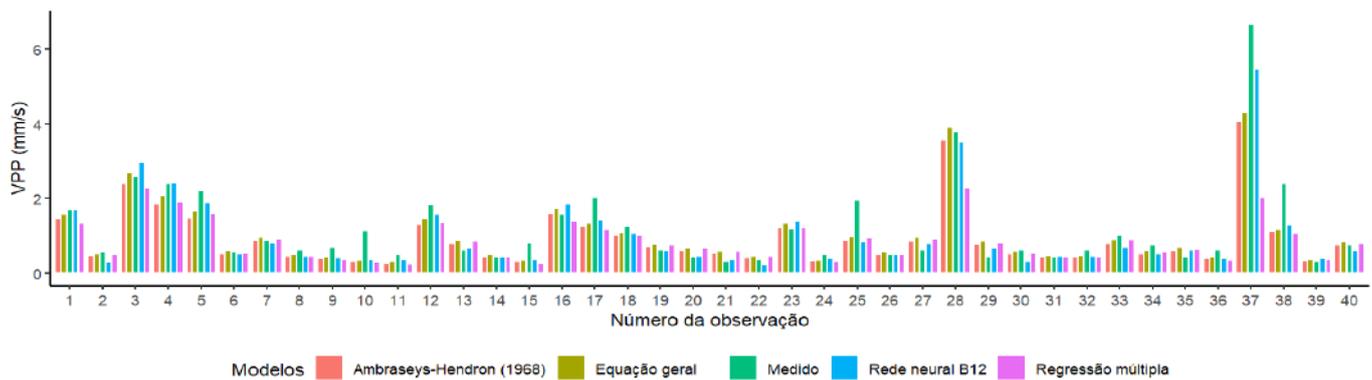
A **Erro! Fonte de referência não encontrada.** mostra a comparação entre as vibrações sísmicas medidas *in-situ* e estimadas pelos modelos empíricos que apresentaram melhor desempenho (Ambraseys-Hendron (1968) e equação geral), pela regressão múltipla e pela rede neural para o conjunto de teste. Nota-se que as predições realizadas pela ANN são, comumente, as mais próximas da VPP medida em campo, enquanto os valores estimados pelas equações empíricas e pela regressão múltipla, geralmente, subestimam ou superestimam o valor real.

**Figura 7.** Comparação entre valores medidos e preditos de PPV.



Fonte: Resultados originais da pesquisa.

**Figura 8.** Comparação entre os níveis de VPP medidos e estimados pelos modelos empíricos, pela regressão múltipla e pela rede neural.



Fonte: Resultados originais da pesquisa.

#### 4. Conclusão

A velocidade de pico de partícula é um parâmetro fundamental para o entendimento e o gerenciamento dos níveis de vibrações sísmicas induzidas por desmonte de rochas por explosivos e seus impactos. Nesse estudo, os níveis de VPP induzidos por desmontes em uma mina do Quadrilátero Ferrífero (Minas Gerais, Brasil) foram estimados a partir de redes neurais artificiais. Dois grupos de variáveis foram considerados como variáveis de entrada: A) distância entre o ponto de monitoramento e detonação, carga máxima por espera, afastamento, espaçamento, altura do furo, subperforação, altura do tampão, número de furos e razão de carga; B) distância entre o ponto de monitoramento e detonação e carga máxima por espera. Além disso, diferentes arquiteturas, funções de ativação e algoritmos de aprendizagem foram considerados. A título de comparação com a rede neural, modelos de regressão múltipla e equações empíricas também foram analisados na predição da VPP.

Dentre os modelos avaliados, o desempenho de uma rede neural MLP feed-forward com 1 camada oculta constituída de 3 neurônios, treinada pelo algoritmo de aprendizagem retropropagação resiliente com retrocesso de peso e considerando a função tangente hiperbólica como função de ativação, se destacou com coeficiente de determinação de 0,91 e raiz do erro quadrático médio de 0,40. Como variáveis de entrada para essa rede neural foram consideradas as variáveis distância entre o ponto de monitoramento e detonação e a carga máxima por espera. Os resultados demonstram a importância de se realizar a seleção das variáveis de entrada para a estimativa de vibrações sísmicas induzidas por desmonte de rochas por meio de redes neurais artificiais.

Como trabalhos futuros, sugere-se que sejam avaliadas diferentes arquiteturas de redes neurais para a predição dos níveis de VPP. Para esta análise, é possível considerar mais camadas ocultas com variados números de neurônios, assim como outros grupos de variáveis de entrada. Outra sugestão é desenvolver modelos de redes neurais que tenham como variável resposta não somente a velocidade de pico de partícula, como também a frequência de vibração.

#### Agradecimentos

Os autores gostariam de agradecer a CAPES, FAPEMIG, PPGEM/UFOP, UFOP, UNEMAT e a USP/ESALQ pelo apoio para a pesquisa. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. Agradecemos também ao Programa de Mestrado Profissional em Rede Nacional em Gestão e Regulação de Recursos Hídricos - Prof.Água, Projeto CAPES/ANA AUXPE Nº 2717/2015.

#### Referências

- Ainalis, D. et al. (2017). Modelling the source of blasting for the numerical Simulation of blast-induced ground vibrations: a review. *Rock Mech Rock Eng*, 50, 171-193.
- Akaike, H. (1973). Information theory and an extension of the maximum likelihood principle. In: *Second international symposium on information theory*, Budapest, 267–281.
- Ambraseys, N.R., & Hendron, A.J. 1968. *Dynamic behaviour of rock masses: rock mechanics in engineering practices*. Wiley, London.
- Armaghani, D. J., Momeni, E., Abad, S. V. A. N. K., & Khandelwal, M. (2015). Feasibility of ANFIS model for prediction of ground vibrations resulting from quarry blasting. *Environ Earth Sci*, 74:2845–2860.
- Associação Brasileira de Normas Técnicas (ABNT). (2018). *NBR 9653: Guia para avaliação dos efeitos provocados pelo uso de explosivos nas minerações em áreas urbanas – Procedimento*. Rio de Janeiro.
- Ataei, M., & Sereshki, F. (2017). Improved prediction of blast-induced vibrations in limestone mines using Genetic Algorithm. *Journal of Mining & Environment*, Vol.8, No.2, 291-304.
- Bartlett, M. S. (1951). The effect of standardization on a chi square approximation in factor analysis. *Biometrika*, 38, 337–344.
- Bayat, P., Monjezi, M., Rezakhah, M., & Armaghani, D. J. (2020). Artificial Neural Network and Firefly Algorithm for Estimation and Minimization of Ground Vibration Induced by Blasting in a Mine. *Natural Resources Research*, 29, 6: 4121-4132.
- Box, G.E.P., & Cox, D.R. (1964). An Analysis of Transformations. *Journal of the Royal Statistical Society. Series B (Methodological)*, 26, 2, 211-252.
- Burger, S.V. 2018. *Introduction to machine learning with R*. O'Reilly Media, Sebastopol, USA.
- Data Science Academy. (2021). O Neurônio, Biológico e Matemático. In: *Deep Learning Book*, <https://www.deeplearningbook.com.br/o-neuronio-biologico-e-matematico/>
- Dehghani, H., & Beirovand, H. (2019). Blasting pattern design for decreasing the ground vibration using genetic algorithm. *Journal of Mineral Resources Engineering*, 4, 2: 10 – 15.
- Dinis da Gama, C., & Bernardo, P.A.M. (2001). *Condições Técnicas para Uso de Explosivos na Escavação de Túneis Urbanos em Maciços Rochosos*. Curso sobre Túneis em Meios Urbanos (organizado por SPG e FCT-UC) – Coimbra.
- Duvall, W. I., & Petkof, B. 1959. *Spherical propagation of explosion generated strain pulses in rock*. USBM RI 5483.
- Fávero, L. P., & Belfiore, P. (2017). *Manual de análise de dados*. 1. ed. Elsevier, Rio de Janeiro, Brasil.
- Fritsch, S., & Günther, F. (2008). neuralnet: Training of Neural Networks. *R Foundation for Statistical Computing*, R package version 1.2.
- Ghoraba, S., Monjezi, M., Talebi, N., Armaghani, D.J., & Moghaddam, M. (2016). Estimation of ground vibration produced by blasting operations through intelligent and empirical models. *Environ Earth Sci*, 75, 1137.
- Hair, J., Black, W., Babin, B., Anderson, R., & Tathan, R. (2009). *Análise Multivariada de Dados*. 6. ed. Bookman, Porto Alegre, Brasil.
- Haykin, S. (2001). *Redes neurais: princípios e prática*. Bookman, Porto Alegre, Brasil.
- Hosseini, S. A., Tavana, A., Abdolahi, S. M., & Darvishmaslak, S. (2019). Prediction of blast-induced ground vibrations in quarry sites: a comparison of GP, RSM and MARS. *Soil Dynamics and Earthquake Engineering*, 119, 118–129.
- Indian Standard. (1973). *Criteria for safety and design of structures subjected to under ground blast*, ISI., IS-6922.
- Iphar, M., Yavuz, M., & Ak, H. (2008). Prediction of ground vibrations resulting from the blasting operations in an open-pit mine by adaptive neuro-fuzzy inference system. *Environ Geol*, 56:97–107.
- Khandelwal, M., Kumar, D. L., & Yellishetty, M. (2011). Application of soft computing to predict blast-induced ground vibration. *Eng Comput*, 27, 2, 117–125.
- Khandelwal, M., & Singh, T. N. (2009). Prediction of blast-induced ground vibration using artificial neural network. *Int J Rock Mech Min Sci*, 46:1214–22.
- Kovács, Z. L. (2002). *Redes neurais artificiais: fundamentos e aplicações*. 3. ed. Livraria da Física, São Paulo, Brasil.
- Langefors, U., & Kihlstrom, B. (1963). *The modern technique of rock blasting*. Wiley, New York.
- Li, D. T., Yan, J. L., & Zhang, L. (2012). Prediction of blast-induced ground vibration using support vector machine by tunnel excavation. *Appl Mech Mater*, 170:1414–8.
- Longjun, D., Xibing, L., Ming, X., & Qiyue, L. (2011). Comparisons of Random Forest and Support Vector Machine for Predicting Blasting Vibration Characteristic Parameters. *Procedia Engineering*, 26, 1772 – 1781.
- Mohamed, M. T. (2011). Performance of fuzzy logic and artificial neural network in prediction of ground and air vibrations. *Int J Rock Mech Min Sci*, 48, 5, 845.
- Mohamednejad, M., Gholami, R., & Ataei, M. (2012). Comparison of intelligence science techniques and empirical methods for prediction of blasting vibrations. *Tunn Undergr Space Technol*, 28, 238–244.

- Monjezi, M., Ghafurikalajahi, M., & Bahrami, A. (2011). Prediction of blast-induced ground vibration using artificial neural networks. *Tunn Undergr Space Technol*, 26: 46–50.
- Nicholls, H. R. Johnson, C. F., & Duvall, W. I. (1971). *Blasting vibrations and their effects on structures*. Pittsburgh: USBM, Bulletin 656.
- R Project. (2021). The R Project for Statistical Computing. <https://www.r-project.org/>
- Rajabi, A. M., & Vafae, A. (2019). Prediction of blast-induced ground vibration using empirical models and artificial neural network (Bakhtiari Dam access tunnel, as a case study). *Journal of Vibration and Control*, Vol 0 (0), p. 1-12.
- Rezaeineshat, A., Monjezi, M., Mehrdanesh, A., & Khandelwal, M. (2020). Optimization of blasting design in open pit limestone mines with the aim of reducing ground vibration using robust techniques. *Geomech. Geophys. Geo-energ. Geo-resour.* 6:40.
- Roy P. P. (1991). Vibration control in an opencast mine based on improved blast vibration predictors. *Min Sci Technol*, 12, 157–65.
- Santos, F. L. (2013). *Redes neurais artificiais ARTMAP-fuzzy aplicadas ao estudo de agitação marítima e ondas de lagos*. Tese de doutorado em Engenharia Elétrica. Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, Ilha Solteira, Brasil.
- Silveira, L. G. C. (2017). *Controle de vibrações e pressão acústica no desmonte de rochas com explosivos: estudo de caso em uma mina do quadrilátero ferrífero*. Dissertação (Mestrado em Engenharia Mineral) - Programa de Pós-Graduação em Engenharia Mineral, Universidade Federal de Ouro Preto, Ouro Preto.
- Tissot, H. C., Camargo, L. C., & Pozo, A. T. R. (2012). Treinamento de redes neurais feedforward: comparativo dos algoritmos backpropagation e differential evolution. In: *Encontro Brasileiro de Inteligência Artificial*, 2012, Porto Alegre, Curitiba, Brasil.
- Navarro Torres, V., Silveira, L. G., Lopes, P. F., & Lima, H. M. (2018). Assessing and controlling of bench blasting-induced vibrations to minimize impacts to a neighboring community. *Journal of Cleaner Production*, 187, 514–524.
- Trigueros, E., Cánovas, M., Muñoz, J.M., & Cospedal, J. (2017). A methodology based on geomechanical and geophysical techniques to avoid ornamental stone damage caused by blast-induced ground vibrations. *International Journal of Rock Mechanics & Mining Sciences*, 93, p. 196–200.
- Tuorini, J. B., & Mello, C. H. P. (2012). *Metodologia de pesquisa em engenharia de produção*. UNIFEI, Itajubá.
- Yan, Y., Hou, X., & Fei, H. (2020). Review of predicting the blast-induced ground vibrations to reduce impacts on ambient urban communities. *Journal of Cleaner Production*, 260, 121-135.
- Zhou, J., Asteris, P. G., Armaghani, D. J., & Pham, B. T. (2020). Prediction of ground vibration induced by blasting operations through the use of the Bayesian Network and random forest models. *Soil Dynamics and Earthquake Engineering*, 139, 106390