



INSTITUTO TECNOLÓGICO VALE



**Programa de Pós-Graduação em Instrumentação, Controle e  
Automação de Processos de Mineração (PROFICAM)  
Escola de Minas, Universidade Federal de Ouro Preto (UFOP)  
Associação Instituto Tecnológico Vale (ITV)**

**Dissertação**

**PREVISÃO DE VIBRAÇÕES USANDO REDES NEURAS ARTIFICIAIS NO  
CONTROLE DE DESMONTE DE ROCHAS**

**João Henrique Rodrigues Costa**

**Ouro Preto  
Minas Gerais, Brasil  
2019**

**João Henrique Rodrigues Costa**

**PREVISÃO DE VIBRAÇÕES USANDO REDES NEURAS ARTIFICIAIS NO  
CONTROLE DE DESMONTE DE ROCHAS**

Dissertação apresentada ao curso de Mestrado Profissional em Instrumentação, Controle e Automação de Processos de Mineração da Universidade Federal de Ouro Preto e do Instituto Tecnológico Vale, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador: Prof. D.Sc. Vidal Félix Navarro Torres

Coorientador: Prof. D.Sc. Alan Kardek Rêgo Segundo

Coorientador: Prof. D.Sc. Agnaldo José da Rocha Reis

Ouro Preto  
2019

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

C837p Costa, João Henrique Rodrigues .  
Previsão de vibrações utilizando redes neurais artificiais no controle de desmonte de rochas. [manuscrito] /  
João Henrique Rodrigues Costa. - 2019.  
91 f.: il.: color., gráf., tab., m..

Orientador: Prof. Dr. Vidal Félix Navarro Torres.

Coorientadores: Prof. Dr. Agnaldo José da Rocha Reis, Prof. Dr. Alan Kardek Rêgo Segundo.

Dissertação (Mestrado Profissional). Universidade Federal de Ouro Preto. Programa de Mestrado  
Profissional em Instrumentação, Controle e Automação de Processos de Mineração. Programa de  
Instrumentação, Controle e Automação de Processos de Mineração.

Área de Concentração: Engenharia de Controle e Automação de Processos Minerais.

1. Vibração - Medição. 2. Redes neurais (Computação). 3. Rochas - Controle de desmonte. 4. Acústica -  
Previsão de pressão. I. Costa, João Henrique Rodrigues . II. Reis, Agnaldo José da Rocha. III. Segundo, Alan  
Kardek Rêgo. IV. Torres, Vidal Félix Navarro. V. Universidade Federal de Ouro Preto. VI. Título.

CDU 681.5:622.2

Mestrado Profissional em Instrumentação, Controle e Automação de Processos  
de Mineração - PROFICAM

Previsões de Vibrações Usando Redes Neurais Artificiais no Controle de  
Desmante de Rochas

João Henrique Rodrigues Costa

Dissertação defendida e aprovada em 03 de junho de 2019 pela banca  
examinadora constituída pelos professores:



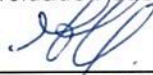
Ph.D. Vidal Félix Navarro Torres  
Orientador – Instituto Tecnológico Vale Mineração (ITV-MI)



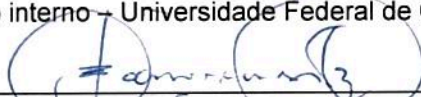
D.Sc. Alán Kardek Rêgo Segundo  
Coorientador – Universidade Federal de Ouro Preto (UFOP)



D.Sc. Agnaldo José da Rocha Reis  
Coorientador – Universidade Federal de Ouro Preto (UFOP)



Ph.D. Hernani Mota de Lima  
Membro interno – Universidade Federal de Ouro Preto (UFOP)



D.Sc. Carlos Enrique Arroyo Ortiz  
Membro interno – Universidade Federal de Ouro Preto (UFOP)



D.Sc. José Ildelfonso Gusmão Dutra  
Membro externo – Universidade Federal de Minas Gerais (UFMG)

*Dedico esta dissertação a minha  
amada esposa Rejane.*

# Agradecimentos

Agradeço primeiro a Deus por conservar minha saúde para que eu possa levantar todos os dias da cama. Agradeço a minha esposa Rejane pelo amor e companheirismo. À minha família, em especial meus pais José Alvimar e Lúgia pelo apoio. Aos meus gatos por proporcionar momentos felizes de descontração nos dias difíceis. Gratidão ao meu amigo Toninho (pão de queijo) por ter me recebido na república Os Bartira. Agradeço ao ITV e seus funcionários e professores. Em especial aos amigos da Lavra de Minas, Leonardo Soares Chaves, Leandro Geraldo Silveira Canaan e Gian Garcia. Aos colegas do Mestrado pelo companheirismo durante o programa. Aos professores da UFOP pelos ensinamentos e conhecimentos passados. Agradeço ao professor Alan Kardek por ter me recebido gentilmente no LABCAM. Gratidão ao professor Agnaldo por sua disposição em ajudar sempre. Agradeço ao meu orientador Vidal Félix Navarro Torres pelos ensinamentos, colaboração e orientação.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES); do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG); e da Vale SA. Por isso, reitero aqui os meus agradecimentos.

## Resumo

Resumo da Dissertação apresentada ao Programa de Pós Graduação em Instrumentação, Controle e Automação de Processos de Mineração como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

## PREVISÃO DE VIBRAÇÕES USANDO REDES NEURAS ARTIFICIAIS NO CONTROLE DE DESMONTE DE ROCHAS

João Henrique Rodrigues Costa

Junho/2019

Orientadores: Vidal Félix Navarro Torres  
Alan Kardek Rêgo Segundo  
Agnaldo José da Rocha Reis

É cada vez maior a preocupação da indústria da mineração com o meio ambiente, especialmente com o impacto que ela causa nas comunidades vizinhas à mina. Somado a essa preocupação, tem-se o aumento no rigor das leis ambientais e trabalhistas. Nesse contexto, uma grande preocupação diz respeito ao controle das vibrações e pressão acústica causadas pelo desmonte de rochas com explosivos na lavra de minas. Objetiva-se com este trabalho criar um modelo de previsão de vibrações e pressão acústica usando redes neurais artificiais. Para isso, foram treinadas várias configurações de arquitetura de rede usando uma base de dados proveniente de uma campanha de monitoramento *in situ*. O objetivo de treinar várias redes foi avaliar o desempenho das redes neurais com e sem a remoção de valores anômalos e assim selecionar a rede neural com melhor desempenho. Fez-se também a avaliação de sensibilidade das entradas da rede e dessa forma estabeleceu-se o impacto que cada entrada tem na estimativa da saída. Para avaliação dos níveis de vibração e pressão acústica, foi criada uma interface gráfica que possibilitou a estimativa desses valores utilizando os parâmetros do plano de fogo. A interface gráfica também foi capaz de mostrar no mapa o ponto de detonação e os valores de vibração associados a uma carga máxima por espera. O modelo de predição obteve coeficientes de determinação acima de 90%, índice esse, em média, acima daqueles obtidos com modelos de previsão tradicionais reportados na literatura. A rede neural também mostrou ser robusta à presença de valores anômalos na base inicial de dados, pois obteve-se maior coeficiente de determinação quando treinada com eles. Por fim, concluiu-se que o modelo de previsão e controle de vibrações mostrou-se eficaz

pois possibilitou a estimativa de vibrações usando dados do plano de fogo e o auxílio de uma interface gráfica, obtendo um bom desempenho com coeficientes de determinação altos.

**Palavras-chave:** Controle de Desmonte de Rochas; Previsão de Vibração; Previsão de Pressão Acústica; Redes Neurais Artificiais.

**Macrotema:** Desmonte de Rochas; **Linha de Pesquisa:** Tecnologias da Informação, Comunicação e Automação Industrial; **Tema:** Previsão e Controle de Vibrações.



## Abstract

Abstract of Dissertation presented to the Graduate Program on Instrumentation, Control and Automation of Mining Process as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

# VIBRATIONS PREDICTION USING ARTIFICIAL NEURAL NETWORK AT ROCK BLASTING CONTROL

João Henrique Rodrigues Costa

June/2019

Advisors: Vidal Félix Navarro Torres

Alan Kardek Rêgo Segundo

Agnaldo José da Rocha Reis

A growing mining industry's concern is the environment, especially the impact that mining has on neighboring communities to the mine. Added to this concern, the government have increased the severity of environmental and labor laws. In this context, a great concern is the respect for vibration control and airblast caused by rock removal with explosives at mining. This work aims to create a vibration and airblast prediction model using artificial neural networks. For this, have been trained multiple configurations of network architecture using a database from a *in situ* monitoring campaign. The goal was to train multiple networks and evaluate the performance with and without removing *outliers*, so select the best performance neural. The work also conducted the evaluation of sensitivity of the inputs of the network and thus established the impact that each input has on output estimate. For evaluation of vibration and airblast levels, was created a graphical interface to estimate these values by using the parameters of the blasting plan. The GUI is also capable of showing on a map the detonation points and the vibration values associated with the maximum charge per delay. The prediction model obtained a determination coefficient above 90%, which shows a good performance, on average, above those obtained with traditional forecast models reported in the literature. The neural network also was robust to the presence of *outliers* in database, as too obtained greater coefficient of determination when trained with *outliers*. Finally, it was concluded that the vibrations prediction model proved effectiveness because it made possible the estimation and control of vibrations using data from the blasting plan and the aid of a graphical interface, getting a good performance with high determination coefficients.

**Keywords:** Blasting Control; Vibration Prediction; Airblast Prediction; Artificial Neural Network

**Macrotheme:** Rock Blasting; **Research Line:** Information technology, Communication and Industrial Automation; **Theme:** Prediction and Vibration Control.

# Lista de Figuras

1.1	Impactos ambientais do desmonte de rochas. . . . .	2
3.1	Terminologias do Plano de Fogo. . . . .	5
3.2	VOD versus diâmetro do furo. . . . .	6
3.3	Ondas de compressão P, de cisalhamento S, Love e Rayleigh. . . . .	9
3.4	Análise das ondas sísmicas no tempo. . . . .	10
3.5	Movimento das partículas associado aos tipos de onda. . . . .	11
3.6	Análise da Frequência Dominante. . . . .	12
3.7	Comportamento da onda de pressão no tempo. . . . .	13
3.8	Faixa de frequência da onda. . . . .	14
3.9	Variação da Pressão Sonora. . . . .	15
3.10	Relação entre velocidade de vibração (mm/s) e frequência (Hz) para as diferentes classes de edifício de acordo com a Norma Alemã DIN 4150. . . . .	17
3.11	Representação gráfica dos limites de velocidade de vibração de partícula de pico por faixas de frequência. . . . .	19
3.12	Resposta humana as vibrações. . . . .	21
3.13	Diagrama representando os limites de velocidade máxima de vibração das partículas. . . . .	22
3.14	As partes do neurônio artificial genérico. . . . .	24
3.15	Funcionamento da Rede Neural na fase de treinamento. . . . .	24
3.16	Função Logística. . . . .	25
3.17	Função Tangente Hiperbólica. . . . .	25
3.18	Esquema da rede neural criada no Matlab <sup>®</sup> . . . . .	26
3.19	Rede Neural <i>Backpropagation</i> . . . . .	27
4.1	Metodologia para controle de vibrações causadas pelo desmonte de rochas. . . . .	31
4.2	Sismógrafo GEOSONICS <sup>®</sup> , modelo SSU 3000 EZ+. . . . .	32
4.3	Localização das detonações e sismógrafos do primeiro grupo . . . . .	33
4.4	Localização das detonações e sismógrafos do segundo grupo . . . . .	34
4.5	Remoção de valores anômalos de vibração . . . . .	36
4.6	Remoção de valores anômalos de pressão acústica . . . . .	36
4.7	Retirada manual dos valores anômalos de PVS . . . . .	37

4.8	Retirada manual dos valores anômalos de pressão acústica . . . . .	37
4.9	Histograma de Frequências Dominantes . . . . .	38
4.10	Parâmetros Geomecânicos. . . . .	39
4.11	Interface Gráfica para calculo do BI . . . . .	40
4.12	Arquitetura da Rede Neural . . . . .	42
5.1	PVS medido x PVS estimado (treinamento). . . . .	45
5.2	PVS medido x PVS estimado (validação). . . . .	45
5.3	PVS medido x PVS estimado (teste). . . . .	46
5.4	PVS medido x PVS estimado (todos os dados). . . . .	46
5.5	Pressão Acústica medida x Pressão Acústica estimada (treinamento). . . . .	48
5.6	Pressão Acústica medida x Pressão Acústica estimada (validação). . . . .	48
5.7	Pressão Acústica medida x Pressão Acústica estimada (teste). . . . .	49
5.8	Pressão Acústica medida x Pressão Acústica estimada (todos os dados). . . . .	49
5.9	PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (treinamento). . . . .	51
5.10	PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (validação). . . . .	51
5.11	PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (teste). . . . .	52
5.12	PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (todos os dados). . . . .	52
5.13	Arquitetura para a rede com valores anômalos. . . . .	53
5.14	PVS medido x PVS estimado (treinamento). . . . .	54
5.15	PVS medido x PVS estimado (validação). . . . .	54
5.16	PVS medido x PVS estimado (teste). . . . .	55
5.17	PVS medido x PVS estimado (todos os dados). . . . .	55
5.18	Pressão Acústica medida x Pressão Acústica estimada (treinamento). . . . .	56
5.19	Pressão Acústica medida x Pressão Acústica estimada (validação). . . . .	56
5.20	Pressão Acústica medida x Pressão Acústica estimada (teste). . . . .	57
5.21	Pressão Acústica medida x Pressão Acústica estimada (todos os dados). . . . .	57
5.22	PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (treinamento). . . . .	58
5.23	PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (validação). . . . .	58
5.24	PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (teste). . . . .	59
5.25	PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (todos os dados). . . . .	59

5.26 Estimador de vibração PVS, pressão acústica e frequência utilizando o plano de fogo. . . . .	63
5.27 Mapa de vibrações, pressão acústica e frequência. . . . .	64
5.28 Análise de Sensibilidade. . . . .	65

# Lista de Tabelas

3.1	Parâmetros controláveis e não controláveis que afetam a vibração . . . . .	4
3.2	Unidades de Pressão Acústica e seus efeitos e danos à seres humanos e estruturas.	16
3.3	Faixa de valores analisados pela norma alemã DIN 4150 para danos em edifícios.	17
3.4	Limite dos valores de vibração da partícula em mm/s. . . . .	18
3.5	Valores admissíveis das vibrações para pessoas localizadas em diferentes edifícios. . . . .	18
3.6	Valores máximos de velocidade em mm/s e suas frequências para prevenção de danos segundo a norma espanhola UNE 22-381-93. . . . .	19
3.7	Velocidades máximas de vibração de partículas de acordo com o horário dos eventos de detonação e a finalidade das construções. . . . .	20
3.8	Critérios de aceitação para velocidades de vibração do terreno (PVS) segundo a norma australiana. . . . .	20
3.9	Modelos para predição de PPV. . . . .	22
4.1	Dados dos desmontes monitorados . . . . .	33
4.2	Parâmetros de entrada e saída usados na rede. . . . .	35
5.1	Redes Neurais treinadas (PVS) . . . . .	44
5.2	Redes Neurais treinadas (Pressão acústica) . . . . .	47
5.3	Redes Neurais treinadas (PVS e Frequência Dominante) . . . . .	50
5.4	Coefficientes de Determinação com e sem valores anômalos . . . . .	60
5.5	PVS medido x PVS estimado . . . . .	61
5.6	Pressão Acústica medida x Pressão Acústica estimada . . . . .	61
5.7	Frequência Dominante medida x Frequência Dominante estimada . . . . .	62

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
<b>2</b>	<b>Objetivos</b>	<b>3</b>
2.1	Objetivo Geral . . . . .	3
2.2	Objetivos Específicos . . . . .	3
<b>3</b>	<b>Revisão Bibliográfica</b>	<b>4</b>
3.1	Variáveis que afetam as vibrações no desmonte de rochas . . . . .	4
3.1.1	Plano de Fogo . . . . .	4
3.1.2	Explosivos . . . . .	7
3.1.3	Propriedades das Rochas e Litologia . . . . .	8
3.2	Ondas Sísmicas . . . . .	9
3.2.1	Características das Vibrações . . . . .	10
3.2.2	Frequência Dominante . . . . .	12
3.3	Pressão Acústica . . . . .	13
3.4	Efeitos das vibrações: danos estruturais e incomodidade humana . . . . .	16
3.5	Estimadores de Vibração . . . . .	21
3.6	Redes Neurais Artificiais . . . . .	23
<b>4</b>	<b>Metodologia</b>	<b>30</b>
4.1	Estudo de Caso . . . . .	31
4.1.1	Campanha de Monitoramento . . . . .	32
4.1.2	Processamento dos Dados . . . . .	35
4.1.3	Blastability Index . . . . .	38
4.2	Entradas e arquitetura da rede neural . . . . .	40
<b>5</b>	<b>Resultados e Discussões</b>	<b>43</b>
5.1	Treinamento da Rede Neural utilizando a base de dados sem valores anômalos . . . . .	43
5.1.1	Treinamento das Redes Neurais para estimar vibração (PVS) . . . . .	43
5.1.2	Treinamento das Redes Neurais para estimar Pressão Acústica . . . . .	46

5.1.3	Treinamento das Redes Neurais para estimar PVS e Frequência Dominante . . . . .	49
5.2	Treinamento das Redes Neurais sem a remoção de valores anômalos . . . . .	53
5.2.1	Treinamento das Redes Neurais para estimar vibração (PVS) . . . . .	53
5.2.2	Treinamento das Redes Neurais para estimar Pressão Acústica . . . . .	55
5.2.3	Treinamento das Redes Neurais para estimar PVS e Frequência Dominante . . . . .	57
5.3	Interface Gráfica . . . . .	62
5.4	Análise de Sensibilidade . . . . .	64
<b>6</b>	<b>Conclusões e Trabalhos Futuros</b>	<b>66</b>
	<b>Referências Bibliográficas</b>	<b>67</b>
<b>7</b>	<b>Anexo</b>	<b>73</b>



# 1. Introdução

Quase todos os produtos presentes no nosso dia a dia possuem algum componente proveniente da indústria da mineração. Para que esses insumos possam ser extraídos da natureza, a lavra é o primeiro passo. O maior propósito das operações da lavra de minas consiste em reduzir o tamanho das rochas para que seja possível a manipulação por equipamentos de escavação, transporte e britagem (ARMSTRONG, 2001).

Os equipamentos de escavação não são capazes de escavar rochas duras, o que faz necessário o uso de explosivos para fragmentar e tornar possível a escavação. Na maioria dos casos, o uso de explosivos tem a vantagem de ser mais rápido e econômico quando comparado com os métodos mecanizados de desmonte. Apesar dos explosivos apresentarem o melhor custo benefício para o desmonte de rochas, uma grande energia é liberada em um curto espaço de tempo, o que gera ondas de choque que se propagam por terra e por ar afetando pessoas e edificações no seu percurso.


Segundo Dinis da Gama (1998), somente entre 5 a 15% da energia liberada pelos explosivos é aproveitada para o desmonte da rocha. O restante da energia liberada gera uma série de impactos ambientais, como vibrações, ruídos, produção de poeiras, a projeção de fragmentos, geração de pressão acústica e outros desmontes indesejados. A Figura 1.1 ilustra esses impactos no meio ambiente.

Dentre as consequências do desmonte de rochas com explosivos, a vibração pode causar maior impacto negativo nas comunidades vizinhas às minas e será objeto de estudo deste trabalho.

As detonações de cargas explosivas no desmonte de rochas podem gerar constantes reclamações por parte das comunidades próximas à mina. As empresas que trabalham com desmonte de rochas necessitam limitar os níveis de vibração, principalmente, para evitar possíveis danos estruturais e incômodo humano em comunidades vizinhas. Assim, a indústria de mineração necessita de ferramentas e metodologias para modelar e prever as vibrações causadas pelo desmonte de rochas.

Para realizar a predição e controle de vibrações e pressão acústica, segundo Nieble (2017), os parâmetros mais relevantes para analisar a vibração são a quantidade de explosivo em kg por retardo e a distância do local de detonação. Assim a velocidade de vibração de partículas tem uma relação direta com a carga explosiva por retardo e inversamente proporcional à distância entre o ponto de detonação da carga explosiva e o local de medição.

Figura 1.1: Impactos ambientais do desmante de rochas.



Fonte: Jimeno e Bermúdez (2017)

## 2. Objetivos

### 2.1 Objetivo Geral

Aplicar redes neurais artificiais para fins de predição de vibrações causadas pelo desmonte de rochas com explosivos e contribuir para a procura de técnicas alternativas no desmonte controlado e na previsão de possíveis danos a estruturas e incômodo humano.

### 2.2 Objetivos Específicos

- Desenvolver um modelo de predição para vibrações baseado nos parâmetros do desmonte de rochas, condições geológicas e litológicas locais, aplicando redes neurais artificiais;
- Estimar a vibração, frequência e pressão acústica com uma precisão satisfatória;
- Treinar diversas arquiteturas de redes neurais, com o objetivo de escolher o modelo com melhor desempenho;
- Utilizar a base de dados completa e com remoção de valores *anômalos* para treinar a rede neural e comparar seus desempenhos;
- Realizar uma análise de sensibilidade nas entradas da rede neural com o objetivo de ordenar o grau de importância de cada uma;
- Elaborar uma interface gráfica para previsão e controle de vibração utilizando o modelo de redes neurais que permita uma adequada avaliação do possível impacto físico e ambiental na comunidade circunvizinha à zona de lavra.

### 3. Revisão Bibliográfica

#### 3.1 Variáveis que afetam as vibrações no desmonte de rochas

Diversas variáveis são consideradas no projeto do desmonte de rochas. Essas variáveis podem ser divididas em variáveis não controláveis e controláveis. As primeiras dizem respeito as características das rochas e dos maciços rochosos que serão fragmentados pelos explosivos. Essas características são próprias do local do desmonte e não podem ser alteradas. Contudo, o conhecimento das propriedades das rochas é fundamental para um desmonte bem dimensionado e assim para o controle das vibrações. Já as variáveis controláveis, podem ser divididas em dois grupos: as variáveis do plano de fogo que envolvem as características geométricas do desmonte (diâmetro dos furos, espaçamento, afastamento, tampão, subperfuração, comprimento do furo e inclinação de furo etc) bem como carga explosiva de fundo e coluna e em outro grupo as variáveis associadas as características dos explosivos.

Para estabelecer um modelo que preveja as vibrações, primeiro deve-se conhecer todos os parâmetros controláveis e não controláveis que afetam a vibração. Estes parâmetros foram descritos por Ataei e Sereshki (2017) e estão listados na Tabela 3.1.

Tabela 3.1: Parâmetros controláveis e não controláveis que afetam a vibração

Variáveis Controláveis			Não Controláveis
Geométricas	Explosivo	Retardamento	
Diâmetro do Furo	Tipo de Explosivo	Ponto de Iniciação	Condições da Rocha Topografia Geologia Propriedades da Rocha Condições Climáticas
Espaçamento	Total de Explosivos	Sequência de Retardo	
Afastamento	Carga máxima por espera	Intervalos de Retardo	
Tampão	Energia da Explosão	Método de Detonação	
Inclinação do Furo	Velocidade de Detonação		
Sub-Furação	Confinamento		

Fonte: elaborado pelo autor

##### 3.1.1 Plano de Fogo


O dimensionamento do plano de fogo inclui o plano de perfuração, a distribuição de carga explosiva e temporização da sequência de saída no processo de detonação. A distância entre as filas é chamada de afastamento e a distância entre os furos de espaçamento. Os principais parâmetros considerados no planejamento do plano de fogo são:

- Diâmetro dos furos;
- Inclinação dos furos;

- Espaçamento;
- Afastamento;
- Altura da bancada;
- Altura da coluna de explosivos;
- Altura do tampão;
- Sub-perfuração;
- Consumo específico de explosivos.

Alguns dos parâmetros controláveis do plano de fogo estão ilustrados na Figura 3.1.

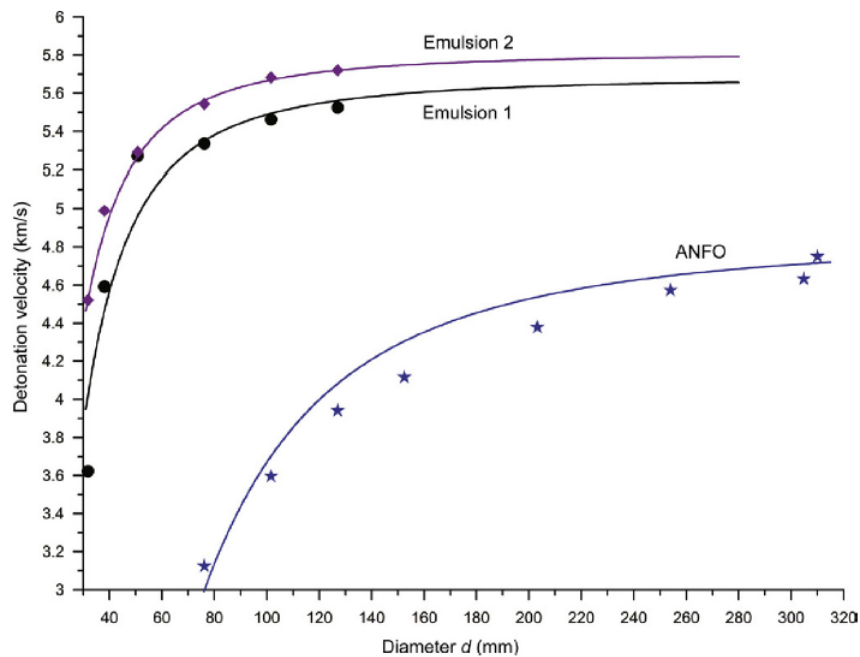
Figura 3.1: Terminologias do Plano de Fogo.



Fonte: Nobel (2010)

O diâmetro dos furos é afetado pelos seguintes fatores: características geotécnicas do maciço rochoso (resistência à compressão simples) e o tamanho de produção horária Navarro Torres e Dinis da Gama (2005). A família de descontinuidades presentes no maciço deve ser levada em consideração ao determinar o diâmetro do furo pois furos grandes podem prejudicar a fragmentação e formar blocos. O gráfico da Figura 3.2 mostra a relação entre o diâmetro do furo e o VOD para três tipos de explosivo: ANFO, Emulsão 1 e Emulsão 2. A relação entre o VOD e o diâmetro do furo não é linear, em uma faixa de valores há um grande aumento do VOD quando varia-se o diâmetro do furo Sun *et al.* (2001).

Figura 3.2: VOD versus diâmetro do furo.



Fonte: Sun *et al.* (2001)

A altura do banco é determinada pelo alcance da máquina de carga e pela fragmentação requerida, porém, bancos muito altos geram maiores vibrações e projeção de rochas. De uma forma geral, o aumento dos furos melhora a fragmentação e a produtividade de carregamento, entretanto pode gerar aumento da vibração.

A inclinação dos furos possui grandes vantagens, principalmente, com relação ao aumento da fragmentação e assim uma melhora no rendimento das máquinas carregadoras devido a melhor disposição da pilha de minério. O furos inclinados diminuem a sub-perfuração e dessa forma, diminuem o consumo específico de explosivo e melhoram o aproveitamento da energia do explosivo, diminuindo portanto os níveis de vibração produzidos (JIMENO, 1980).

Quando o afastamento é muito grande, os gases produzidos na detonação encontram grande resistência para fissurar a rocha, assim, parte da energia transforma-se em energia sísmica, aumentando a intensidade das vibrações. Desta forma, o afastamento está diretamente ligado aos níveis de vibração produzidos. Ou seja, quanto maior o afastamento, maiores serão os níveis de vibração (ZHANG, 2016). De acordo com Langefors e Kihlström (1978), uma boa relação entre o espaçamento  $S$  e o afastamento  $B$  é maior que 1,25.

O aumento da coluna de explosivos está ligado, conseqüentemente, ao aumento da quantidade de explosivos. Já o tampão que cobre a coluna de explosivos, tem a função de confinar e reter os gases da explosão até que a fragmentação esteja completa. Uma altura de tampão pequena pode gerar um escape antecipado dos gases, ocasionando um ultra lançamento de rochas e aumento da pressão acústica. Por outro lado, uma altura do tampão grande pode prejudicar

a fragmentação na parte superior do furo e também aumentar os níveis de vibração, devido ao grande confinamento dos gases da explosão (JIMENO e BERMÚDEZ, 2017).

A sub-perfuração é muito importante nos desmontes em mina de céu aberto. Essa técnica permite que as rochas próximas ao final do furo possam ser fragmentadas corretamente e assim evitar a formação de repés. O comprimento do furo deve avançar além do nível da bancada, assim, toda rocha acima do nível é arrancada permitindo a completa escavação pelas máquinas. Porém, o prolongamento do furo, aumenta a quantidade de explosivo e também o seu confinamento, o que provoca aumento nos níveis de vibração.

O consumo específico de explosivo diz respeito à quantidade de explosivo necessária para desmontar 1 t ou 1  $m^3$  de rocha. Essa característica está relacionada com o tipo de explosivo, bem como com a resistência da rocha que será desmontada e o grau de fragmentação requerida. Para rochas compactas e resistentes, o consumo específico pode variar entre 0,6 e 1,5  $kg/m^3$ . Para rochas de resistência média, entre 0,3 e 0,6  $kg/m^3$  e para rochas fraturadas entre 0,10 e 0,3  $kg/m^3$ . Um consumo específico de explosivos alto, melhora a fragmentação mas tende a aumentar também os níveis de vibração (CAVADAS *et al.*, 2012).

### 3.1.2 Explosivos

O objetivo principal da utilização de explosivos no desmonte de rochas consiste em utilizar a energia concentrada quimicamente e liberá-la de modo controlado, no tempo e espaço, com o objetivo de fragmentar o material rochoso. Um explosivo pode propagar energia a uma taxa de  $10^{10}$  watts por  $cm^2$  e produzir uma pressão de 20 GPa a uma temperatura de  $3000^\circ C$ , isso os torna uma fonte de energia muito poderosa e relativamente barata (FICKETT e DAVIS, 2001). Cada explosivo é caracterizado por propriedades diferenciadas que atendem a um tipo específico de detonação. A seleção correta das propriedades permite prever os resultados de fragmentação e vibração. As características mais importantes dos explosivos são:

- Energia do Explosivo;
- Velocidade de Detonação (VOD);
- Densidade;
- Relação entre o explosivo e o maciço rochoso.

A energia produzida pelo explosivo é obtida através de uma reação de oxidação. O correto balanço de oxigênio resulta em uma produção máxima de energia por unidade de peso do explosivo. Tipicamente, a energia de explosão dos explosivos é da ordem de 4 MJ/kg (ZHANG, 2016). Dessa forma, existem vários métodos práticos para ensaio em laboratório da potência e energia dos explosivos, descritos em Jimeno e Bermúdez (2017). Neste trabalho serão considerados os dados de energia do explosivo fornecidos pelo fabricante.

A velocidade de detonação ou *velocity of detonation*(VOD), diz respeito a velocidade com que a onda de detonação se propaga no explosivo, ou a taxa de propagação da energia. Os valores típicos de VOD estão entre 1.000 e 7.000 m/s. O VOD é influenciado, principalmente, pelo diâmetro da carga e a densidade do explosivo. Sendo que o VOD cresce proporcionalmente com o aumento desses (BLANCO, 2014). Assim, o valor do VOD depende da aplicação, porém, é fornecido pelo fabricante uma faixa de valores para a classe de explosivo. Também é possível realizar a medição do VOD em campo para um desmonte específico.

A densidade do explosivo é uma característica fundamental para o dimensionamento da quantidade de carga necessária para o desmonte. Da mesma forma que a velocidade de detonação, quanto maior a densidade, maior será a fragmentação da rocha. Valores típicos de densidade dos explosivos estão entre 0,8 e 1,6  $g/cm^3$  (TRUMPY, 2007). A densidade também é muito importante quando o desmonte tem a presença de água, pois determinará se o explosivo irá afundar ou flutuar. A densidade média do explosivo é fornecida pelo fabricante.

A principal relação estudada entre o explosivo e o maciço rochoso diz respeito à comparação entre a velocidade da onda *P-wave* na rocha e o VOD do explosivo. A onda *P-wave* é a principal onda nos corpos sólidos e está relacionada à rigidez das rochas através dos parâmetros: módulo de Young e coeficiente de Poisson e densidade. Nos casos em que VOD é igual ou maior que a velocidade da onda *P-wave*, o desmonte é favorecido segundo os experimentos de Mencacci e Farnfield (2003). Já nos casos em que VOD é menor que a velocidade da onda *P-wave*, o explosivo não detonado na frente de detonação pode ser comprimido pela onda *P-wave* e assim ter sua detonação prejudicada.

### **3.1.3 Propriedades das Rochas e Litologia**

Os materiais que constituem os maciços rochosos possuem características físicas provenientes de sua origem e formação geológica. Essas características produzem diversos tipos particulares de litologia, com a presença de rochas porosas ou fissuradas e também discontinuidades nas estruturas, como fraturas e planos de estratificação.

A resistência das rochas pode estar diretamente ligada, na maioria dos casos a sua densidade. Rochas com menor densidade fraturam com mais facilidade pois necessitam de uma quantidade menor de energia para romper. Já rochas mais densas precisam de mais energia para uma fragmentação satisfatória, o que pode gerar maior vibração.

A resistência a compressão e a resistência à tração são dois parâmetros muito importantes para medir a resistência das rochas. A relação resistência a compressão/resistência a tração, resulta em um índice muito importante para a avaliação da facilidade ou dificuldade de fragmentar a rocha. Quanto maior o índice, mais fácil é a fragmentação.



## 3.2 Ondas Sísmicas

As vibrações são ocasionadas por ondas sísmicas que se propagam, devido a natureza elástica das rochas, pelo maciço/terreno e são atenuadas com a distância (NETO, 2012). Estes eventos sísmicos são compostos por três tipos diferentes de ondas:

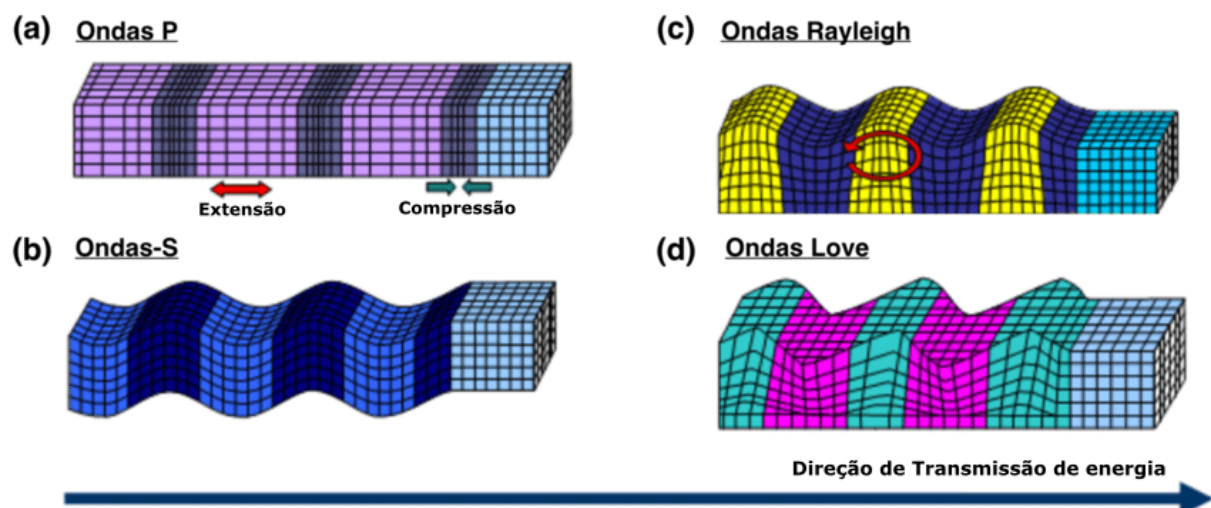
- Ondas primárias ou de Compressão P;
- Ondas secundárias S ou de cisalhamento;
- Ondas de superfície Rayleigh;
- Ondas Love.

As ondas P possuem maior velocidade e deformam a rocha na mesma direção de propagação da onda. Estas ondas fazem as partículas deslocarem radialmente ao furo de explosão, comportando-se como mola.

As ondas do tipo S possuem 50-60% da velocidade das ondas P e fazem as rochas vibrarem perpendicularmente à direção de propagação. O comportamento assemelha-se a uma onda propagando em uma corda, sendo que as partículas se deslocam em ângulos retos com relação ao movimento da onda.

As ondas P e S movimentam as partículas no corpo da rocha em três dimensões e podem ser vistas na Figura 3.3 a) e b) respectivamente. O movimento das ondas R e Love está ilustrado na Figura 3.3 c) e d) respectivamente .

Figura 3.3: Ondas de compressão P, de cisalhamento S, Love e Rayleigh.




Fonte: Jimeno e Bermúdez (2017)

As ondas R e Love se propagam mais lentamente e são ondas de superfície. Nas ondas R as partículas se movem no plano vertical de forma elíptica e acompanham a direção de propagação. Já nas ondas Love, as partículas se movem na direção transversal à propagação. A

primeira onda a chegar é a P, seguida da onda S, Love e depois da onda R que carrega maior parte da energia, entre 70 e 80% Vibration (2013), como pode ser visto na Figura 3.4

Figura 3.4: Análise das ondas sísmicas no tempo.



Fonte: Richart *et al.* (1970)

### 3.2.1 Características das Vibrações

Quando analisa-se o deslocamento das partículas ocasionado pelas ondas sísmicas, segundo Badal *et al.* (2010), deve-se levar em consideração quatro parâmetros:

- **Amplitude (A):** Pico máximo de um ponto ( $mm$ );
- **Velocidade da Partícula (v):** Velocidade que um ponto se desloca ( $mm/s$ );
- **Aceleração (a):** Variação da velocidade ( $mm/s^2$ );
- **Frequência (f):** Número completo de oscilações do ciclo por segundo ( $Hz$ ). É o inverso do período  $T_s$ .

O deslocamento é dado por:

$$y = A \cdot \text{sen}(\omega t) \quad (3.1)$$

Com:

$$\omega = 2 \cdot \pi \cdot f = 2 \cdot \pi \cdot \left(\frac{1}{T_s}\right) \quad (3.2)$$

Os valores máximos são:


$$v_{max} = A \cdot \omega = A \cdot 2 \cdot \pi \cdot f \quad (3.3)$$

$$a_{max} = A.\omega^2 = v_{max}.2.\pi.f \quad (3.4)$$

Vários estudos mostram que a velocidade das partículas é o parâmetro que está mais associado a causa de danos na vibração (BASU e SEN, 2005). Essa velocidade é medida nos seus pontos de máximo e mínimo e recebe o nome de Velocidade de Pico, ou *PVS*.

Como as ondas viajam com diferentes velocidades e devido aos tempos de atraso nas detonações, ocorrem sobreposições no tempo e espaço. Devido a essa complexidade do movimento das ondas, faz-se necessário sua análise em três direções: vertical, transversal e longitudinal como exemplificado na Figura 3.5.

Figura 3.5: Movimento das partículas associado aos tipos de onda.



Fonte: Richards e Moore (2012)

Com o uso do sismógrafo pode-se medir a magnitude, frequência das ondas e também as velocidades de pico de vibração das partículas nas três direções (transversal, vertical e longitudinal). A Soma Vetorial da Velocidade de Pico da Partícula ou *PVS* que também pode ser dada pelo sismógrafo da seguinte forma:

$$PVS = \sqrt{v_x^2 + v_y^2 + v_z^2}, \quad (3.5)$$

em que  $v_x$  é a componente longitudinal da velocidade,  $v_y$  a componente vertical e  $v_z$  a componente transversal.

Através da análise destes parâmetros pode-se avaliar o risco de ocorrência de danos a estruturas devido as vibrações. Então, é estabelecido um limite aceitável para a velocidade de

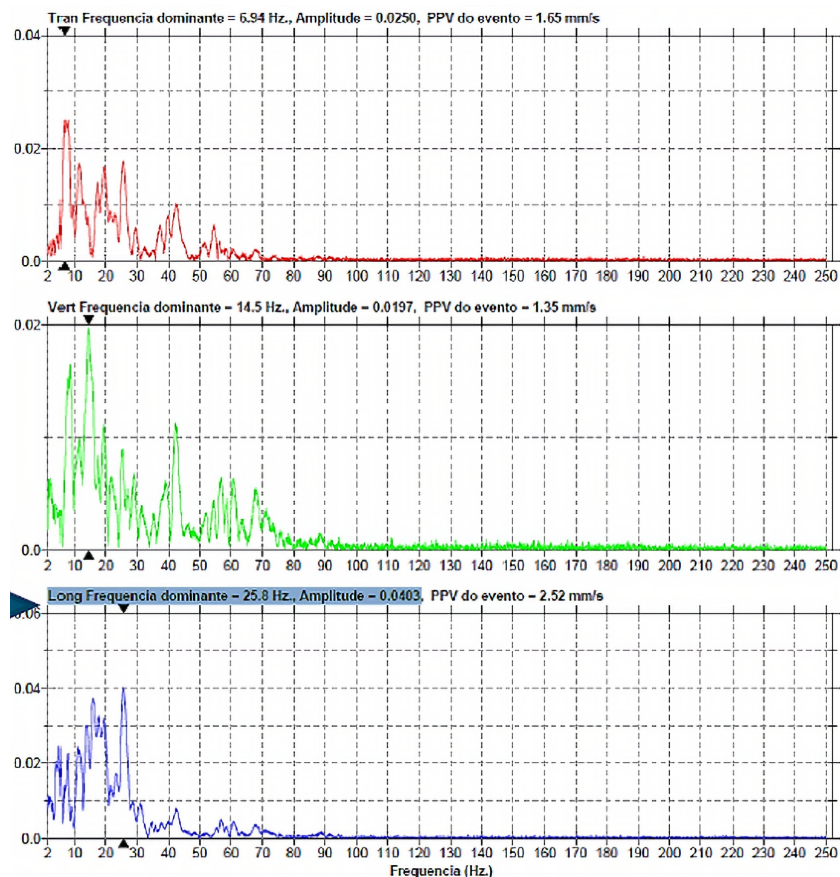
vibração de partícula de pico (mm/s), visto que cada tipo de edificação possui uma frequência natural de vibração (ROCHA, 2014).

### 3.2.2 Frequência Dominante

A análise da vibração causada por explosivos no desmonte de rochas, requer além da medida do pico de vibração, a medida da frequência de vibração. Como mostrado na figura 3.5, o sismógrafo através do transdutor de vibrações, mede a frequência das vibrações em três direções: longitudinal, transversal e vertical.

Em cada direção é apontada uma frequência dominante, a qual corresponde a frequência no momento de pico máximo da onda. Assim, determina-se qual frequência é a dominante entre as três analisando a frequência correspondente ao maior pico de vibração entre as três direções. A Figura 3.6 ilustra um exemplo de um evento de vibração nas direções transversal, vertical e longitudinal respectivamente.

Figura 3.6: Análise da Frequência Dominante.



Fonte: Bernardo (2017)

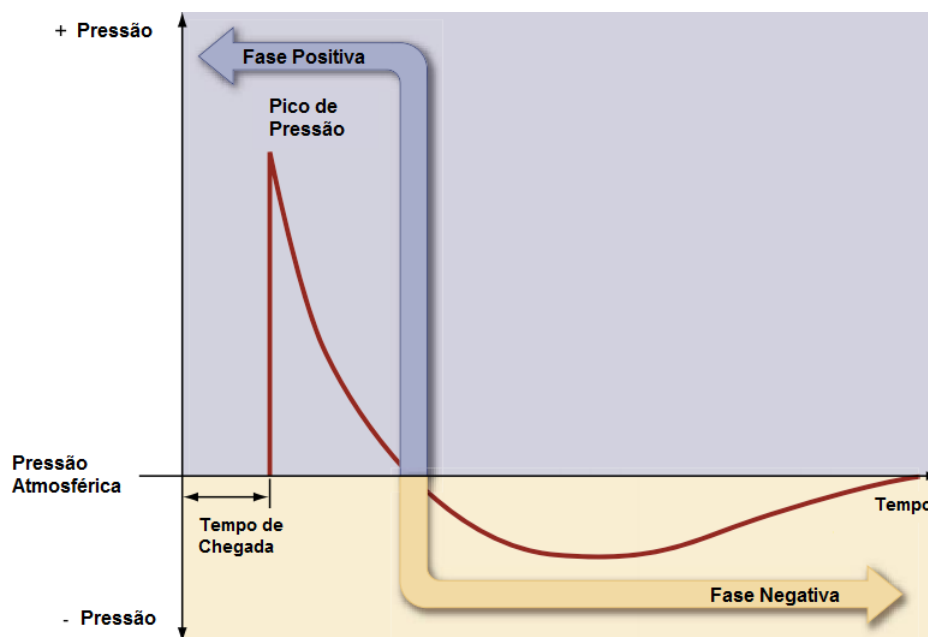
Pode-se ver que na direção longitudinal, a onda alcança sua maior amplitude em 0.0403 mm como destacado na Figura 3.6. Esse valor é o maior entre os valores de amplitude das três direções. Portanto, a frequência de 25.8 Hz é a frequência dominante neste caso.

A frequência dominante será muito importante durante a aplicação das normas que limitam a vibração, uma vez que a maioria das normas leva em consideração a frequência e o tipo de estrutura afetada pela vibração.

### 3.3 Pressão Acústica

No momento em que uma detonação é iniciada, uma grande quantidade de energia é desprendida através de uma reação exotérmica. A medida que essa reação ocorre, o material explosivo é transformado em um gás com alta pressão e temperatura. Inicialmente, o gás expande-se à altas velocidades causando o fraturamento da rocha mas também provoca uma onda de choque que atinge um pico de pressão máximo antes de alcançar equilíbrio com a pressão atmosférica. Um exemplo de comportamento da onda ao longo do tempo é mostrado na Figura 3.7.

Figura 3.7: Comportamento da onda de pressão no tempo.



Fonte: Agency (2003)

A Figura 3.7 caracteriza o comportamento da onda que parte de um valor de pressão atmosférica e atinge quase que de forma instantânea um pico de pressão. A medida que a frente da onda expande, a pressão cai até o nível da pressão atmosférica e depois tem uma fase negativa de menor intensidade que a positiva.

A pressão acústica pode ser expressa em Pascal (Pa) ou em Decibel (dB). Para obter-se a pressão em dB, é usada a Equação 3.6.

$$P_{dB} = 20 \log(P/P_0) \quad (3.6)$$

onde  $P$  é a pressão medida e  $P_0$  é a pressão atmosférica de referência  $2.10^{-5}$ .


A sobrepressão representa um efeito não desejável e inevitável do desmonte com explosivos. Os danos e distúrbios causados pela sobrepressão podem sofrer a influência de vários fatores como o plano de fogo, condições de clima e litologia. De acordo com Tiile (2016), a onda de sobrepressão possui geralmente quatro fontes principais:

- Pico de Pressão (ar): devido ao deslocamento de ar gerado pelo movimento de rocha na face livre do banco durante a detonação;
- Pico de Pressão (rocha): induzido pela vibração do solo;
- Pico de Pressão (gases): devido ao escape de gases pelas fraturas da rocha;
- Pico de Pressão (tampão): devido ao escape de gases quando o tampão é ejetado.

Os picos de pressão provenientes do deslocamento do ar e vibração do solo não podem ser evitados, mas os picos de pressão devido aos gases podem ser minimizados com um plano de fogo adequado. Os fatores que podem ser controlados e que afetam diretamente na sobrepressão são: carga máxima por espera, distancia da fonte de detonação, espaçamento, afastamento, tampão, comprimento da carga e direção de iniciação do fogo. Já os fatores que não podem ser controlados são: condições atmosféricas como ventos fortes e inversões de temperatura, sobrecarga de explosivos e propriedades da rocha.

A norma brasileira NBR 9653 (2018) define pressão acústica como a pressão provocada por uma onda de choque aérea com componentes na faixa audível (20 Hz a 20.000 Hz) e não audível, com duração menor que 1 segundo. A parte audível ou acústica da onda é considerada como ruído, ao contrário da parte infrassom que é chamada de choque ou sobrepressão e possui o maior impacto nas construções (NGUYEN *et al.*, 2018). A Figura 3.8 mostra a faixa de frequência que a onda abrange.


Figura 3.8: Faixa de frequência da onda.



Fonte: Aloui *et al.* (2016)

A frequência audível considerada ruído, manifesta-se em pequenas flutuações de pressão que são detectadas pelo ouvido humano e podem gerar desde um pequeno incômodo até grandes perturbações e até mesmo dor. Os níveis de pressão em Pa e dB e as atividades associadas são ilustrados na Figura 3.9 (FERREIRA e GUERREIRO, 2010).

Figura 3.9: Variação da Pressão Sonora.



Fonte: Noise (2001)

A Figura 3.9 mostra do lado esquerdo uma variação da pressão sonora que vai desde a pressão acústica de um ambiente silencioso até a pressão causada por uma turbina de avião. Já do lado direito, o nível da pressão sonora é mostrado em decibéis, incluindo a faixa de pressão geralmente encontrada nas atividades de mineração.

O United States Bureau of Mines (USBM) através do relatório 8485 “Structure Response and Damage Produced by Air blast From Surface Mining” recomenda uma pressão acústica máxima de segurança de 134 dB para registros de pressão em estruturas residenciais (SISKIND *et al.*, 1980). A Tabela 3.2 mostra a pressão acústica e seus efeitos nos seres humanos e estruturas.

Tabela 3.2: Unidades de Pressão Acústica e seus efeitos e danos à seres humanos e estruturas.

Pressão Acústica		Descrição
dB	Pa	
180	206842.71	Dano estrutural
170	6550.01	Quebra maioria das janelas
160	2068.42	
150	655	Quebra algumas janelas
140	206.84	Limite máximo para o pico
130	65.5	Limite máximo USBM*
120	20.68	Limite Seguro USBM*
110	6.55	Limiar da dor para efeito contínuo
100	20.684	Prováveis queixas
90	0.65	Limite máximo de 15 minutos (OSHA)*
80	0.2	Limite máximo de 8 minutos (OSHA)*

\* Occupational Safety and Health Administration

\* United States Bureau of Mines

Fonte: Aloui *et al.* (2016)

A Tabela 3.2 mostra os limites máximos de pressão para as unidades de dB e Pa. A agência OSHA (Occupational Safety and Health Administration) do departamento de trabalho dos Estados Unidos, estabelece limites máximos para a exposição contínua do ser humano a determinado nível de pressão acústica. Já a USBM trata também dos possíveis danos causados a estruturas.

### 3.4 Efeitos das vibrações: danos estruturais e incomodidade humana

Os efeitos das vibrações podem ser classificados em três grupos:

- Interrupção do funcionamento normal de equipamentos e instrumentos;
- Incomodidade humana nas regiões próximas a mina;
- Danos as estruturas (monumentos e edifícios) e aos maciços remanescentes.

A maior parte das normas que trata de danos estruturais, leva em consideração a velocidade e a frequência de vibração. Outras características como o período e a duração das vibrações também devem ser considerados. De acordo com Jorge *et al.* quando os impulsos dinâmicos causados pelas vibrações sobrepõe os impulsos estáticos, leva-se a uma condição



de ruptura da resistência da estrutura, causando danos aos edifícios. Algumas normas técnicas tratam deste problema estabelecendo critérios para controle dos danos causados por vibrações.


A norma Alemã DIN 4150 relaciona velocidade de vibração e frequência com três classes distintas de edifícios: edifícios estruturais, habitações e monumentos e construções delicadas. Isso pode ser visto na Tabela 3.3 e Figura 3.10.

Tabela 3.3: Faixa de valores analisados pela norma alemã DIN 4150 para danos em edifícios.

Tipos de estruturas	Fundação			Andar mais alto dos edifícios
	Frequência (Hz)			
	<10	10 - 50	50 - 100	Qualquer frequência
<b>Industrial</b>	20 mm/s	20 - 40 mm/s	40 - 50 mm/s	40 mm/s
<b>Habitações</b>	5 mm/s	5 - 15 mm/s	15 - 20 mm/s	15 mm/s
<b>Edifícios particularmente delicados</b>	3 mm/s	3 - 8 mm/s	8 - 10 mm/s	8 mm/s

Fonte: Bacci (2000)

Figura 3.10: Relação entre velocidade de vibração (mm/s) e frequência (Hz) para as diferentes classes de edifício de acordo com a Norma Alemã DIN 4150.



Fonte: Bacci (2000)

A norma portuguesa NP-2074 segue de forma geral, as diretrizes da norma DIN 4150. Os valores limites de vibração das partículas são estabelecidos de acordo com as classes de edificações, a frequência e o tipo de solo. O parâmetro utilizado para avaliar a vibração é a

soma vetorial das três componentes ortogonais como mostrado na equação 3.5. Um resumo da norma é mostrado na Tabela 3.4.

Tabela 3.4: Limite dos valores de vibração da partícula em mm/s.

Tipos de estruturas	Velocidade máxima de vibração de partículas - PVS (mm/s)		
	Frequência dominante, f		
	$f \leq 10Hz$	$10 Hz < f \leq 40Hz$	$f > 40 Hz$
Sensíveis	1,50	3,00	6,00
Comuns	3,00	6,00	12,00
Reforçadas	6,00	12,00	40,00

Fonte: Bacci (2000)

A norma internacional ISO 2631 é única norma no âmbito internacional e trata da incomodidade, da vibração de corpo inteiro e do grau de aceitabilidade de exposição à vibração Dinis da Gama e Paneiro (2006). Os valores limite admissíveis, segunda essa norma podem ser vistos na Tabela 3.5.

Tabela 3.5: Valores admissíveis das vibrações para pessoas localizadas em diferentes edifícios.

Tipos de locais	Período	Limiar de Incomodidade Humana às vibrações
Hospitais	Dia ou noite	0,10 mm/s
Residências	Dia	0,20 a 0,40 mm/s
	Noite	0,14 mm/s
Escritórios	Dia ou noite	0,40 mm/s
Oficinas	Dia ou noite	0,80 mm/s

Fonte: Dinis da Gama e Paneiro (2006)

A norma espanhola UNE 22-381-93 “Control de vibraciones producidas por voladuras” elaborada pela *Asociación Española de Normalización y Certificación* de Normalización e AENOR (1993) estabelece um procedimento de estudo e controle das vibrações causadas por desmontes. Os pontos relevantes da norma são descritos na Tabela 3.6.

A norma espanhola classifica os edifícios em três grupos:

- Grupo I: edifícios industriais feitos de concreto armado;
- Grupo II: edifícios de habitação, escritórios, centros comerciais e de entretenimento. Estruturas de valor arqueológico, arquitetônico ou histórico que não possuem sensibilidade especial à vibrações;

- Grupo III: estruturas de valor arqueológico, arquitetônico ou histórico sensíveis à vibrações.

Tabela 3.6: Valores máximos de velocidade em mm/s e suas frequências para prevenção de danos segundo a norma espanhola UNE 22-381-93.


Tipo de Estrutura	Frequência Principal		
	2 - 15	15 - 75	>75
I	Velocidade(mm/s) 20	Deslocamento(mm) 0,212	Velocidade(mm/s) 100
II	9	0,095	45
II	4	0,042	20

Fonte: Benjumea (2003)

A norma ABNT NBR 9653 NBR (2005) prevê que em uma faixa de frequência entre 4 Hz e 15 Hz pode-se ter velocidades de vibração entre 15 e 20 mm/s como mostrado na Figura 3.11.

A norma brasileira não leva em consideração o tipo de construção e o material utilizado e possui uma identificação maior com normas internacionais, não retratando assim os tipos de edificações presentes no Brasil. Comparando com outra referência brasileira a Companhia de Tecnologia de Saneamento Ambiental (CETESB) possui a norma D7.013 que possui valores mais rígidos para limite de vibração de partículas e ainda considera como o ser humano é afetado pelas vibrações (DE SANEAMENTO AMBIENTAL, 2005).

Figura 3.11: Representação gráfica dos limites de velocidade de vibração de partícula de pico por faixas de frequência.



Fonte: NBR (2005)

A norma britânica (BS 6472-2:2008) define velocidades de vibração limite com o objetivo de não causar incômodo humano, para um limite de até três eventos de detonação diários, classificando o tipo de construção quanto à sua finalidade e o horário das detonações (Tabela 3.7). Os valores utilizados na norma britânica se referem à velocidade de pico das partículas em cada uma das direções ortogonais (PPV) (STANDARD, 2008).

Tabela 3.7: Velocidades máximas de vibração de partículas de acordo com o horário dos eventos de detonação e a finalidade das construções.

<b>Local</b>	<b>Horário</b>	<b>Velocidade máxima de vibração de partículas - PVS (mm/s)</b>
	Dia	6,0 a 10,0
Residências	Noite	2,0
	Qualquer horário	4,5
Escritórios	Qualquer horário	14,0
Workshops	Qualquer horário	14,0

Fonte: STANDARD (2008)

A norma australiana do estado de Queensland, *Transport Noise Management Code*, estabelece critérios visando os limites de vibração de acordo com o tipo de construção, visando não causar incômodo humano. A Tabela 3.8 apresenta os valores limite de vibração para a norma (ROADS, 2016).

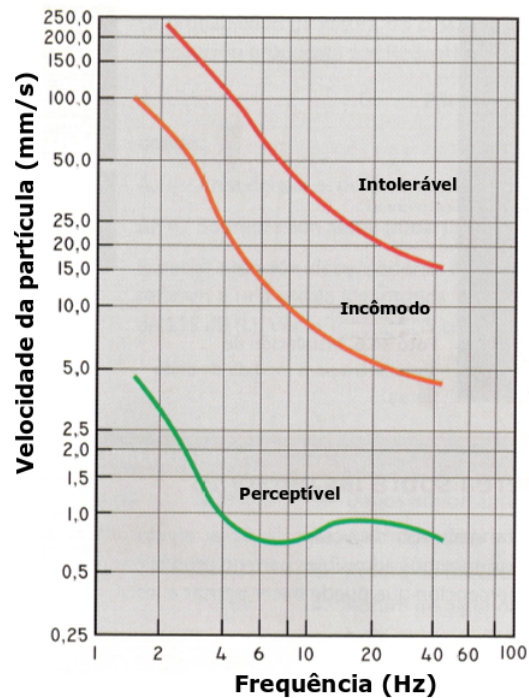
Tabela 3.8: Critérios de aceitação para velocidades de vibração do terreno (PVS) segundo a norma australiana.

<b>Localização</b>	<b>Limite de velocidade de vibração (PVS)</b>
Localização	Limite de velocidade de vibração (PVS)
Construções de valor especial como prédios históricos e monumentos	2mm/s
Áreas de uso sensível	Máximo de 5mm/s para 9 de cada 10 desmontes consecutivos, e máximo de 10mm/s para qualquer desmonte
Construções ocupadas não sensíveis, como áreas industriais, fábricas e estabelecimentos comerciais em geral	Consultar valores na norma australiana AS 2187.2:2006 (Tabela J4.5A do documento)

Fonte: Roads (2016)

Jimeno e Bermúdez (2017) definiram padrões que relacionam os níveis de incomodidade humana ao se analisar a frequência e a velocidade das partículas durante a vibração (Figura 3.12).

Figura 3.12: Resposta humana as vibrações.



Fonte: Jimeno e Bermúdez (2017)

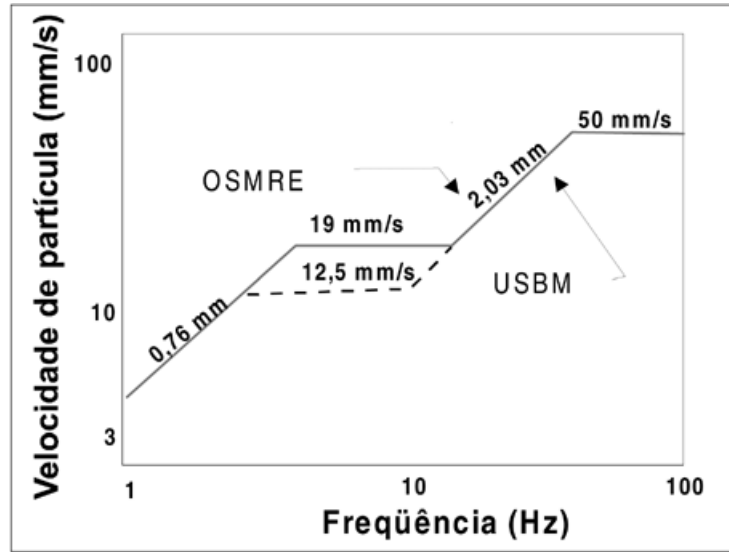
O *United States Bureau of Mines* (USBM) e o alemão *Office for Surface Mining Reclamation* (OSRME) são institutos importantes que também estabeleceram seus critérios, como mostrado na Figura 3.13.

### 3.5 Estimadores de Vibração

Os modelos para previsão de vibrações causadas por desmonte de rochas podem ser de três tipos: modelos empíricos, modelos de regressão estatística e os modelos de Redes Neurais Artificiais (RNA).

Ao longo de anos, vários cientistas e engenheiros propuseram equações que correlacionam estas medidas. Um resumo dos vários modelos empíricos encontrados na literatura pode ser visto na Tabela 3.9.

Figura 3.13: Diagrama representando os limites de velocidade máxima de vibração das partículas.



Fonte: Bacci (2000)

Tabela 3.9: Modelos para predição de PPV.

Modelos de Predição de PPV			
Preditor	Ano	Equação	Referência
USBM	1959	$PPV = K \left( \frac{D}{\sqrt{W}} \right)^{-B}$	Duval e Petkof (1958)
Langfors-Kihlstrom	1963	$PPV = K \left( \sqrt{\frac{W}{D^3}} \right)^B$	Kihlstrom e Wilkinson (1963)
General Predictor	1964	$PPV = KD^{-B}W^A$	Davies <i>et al.</i> (1964)
Ambrases-Hendron	1968	$PPV = K \left( \frac{D}{\sqrt[3]{W}} \right)^{-B}$	Ambraseys e Hendron (1968)
Bureau of Indian Standard	1973	$PPV = K \left( \frac{W}{D^3} \right)^B$	Standard (1973)
Ghosh-Daemen	1983	$PPV = K \left( \frac{D}{\sqrt{W}} \right)^{-B} \cdot e^{-\alpha D}$	Ghosh <i>et al.</i> (1983)
CMRI	1993	$PPV = n + K \left( \frac{D}{\sqrt{W}} \right)^{-1}$	Roy (1993)

Fonte: Kamali e Ataie (2010)

Alguns autores Torres *et al.* (2018), Hustrulid (1982) e Jimeno *et al.* (1995) reconhecem que atualmente a equação mais utilizada pela comunidade científica para descrever a lei de propagação das vibrações nos maciços causada pelo desmonte de rochas é a equação 3.7 a seguir:

$$v = aQ^b D^c, \quad (3.7)$$

onde  $v$  é a velocidade de vibração (mm/s),  $Q$  a carga máxima de explosivos por espera (kg),  $D$  a distância entre o sismógrafo e a detonação e  $a$ ,  $b$  e  $c$  são as constantes empíricas da equação.

O método proposto por Torres *et al.* (2018) para o controle de vibrações induzidas por desmonte de rochas é composto por quatro etapas:

- Monitoramento *in situ* das medições de vibração (PVS) e frequência (f) causadas por uma carga de explosivos por atraso (Q) a uma distância (D) entre o sismógrafo e a fonte de detonação.
- Obtenção da lei de atenuação de vibração pelo método de regressão linear múltipla, resultando como exemplo, na seguinte equação 3.8.

$$v = 900 * Q^{0,27} . D^{-1,29} \quad (3.8)$$

- Baseado na equação 3.8, foi obtida a equação 3.9 para estimar a carga máxima de explosivo por espera:

$$Q_{max} = \frac{\sqrt[b]{v_{lim} D^{-c}}}{a} \quad (3.9)$$

onde  $v_{lim}$  é o limite de vibração (PVS) causada por desmonte, segundo determinada legislação, para prevenção de danos e incomodidade humana.

Com o objetivo de melhorar o coeficiente de determinação dos modelos e incorporar à predição outros fatores do plano de fogo, litologia e geologia, métodos mais modernos propõem a utilização de redes neurais para estimar a vibração.

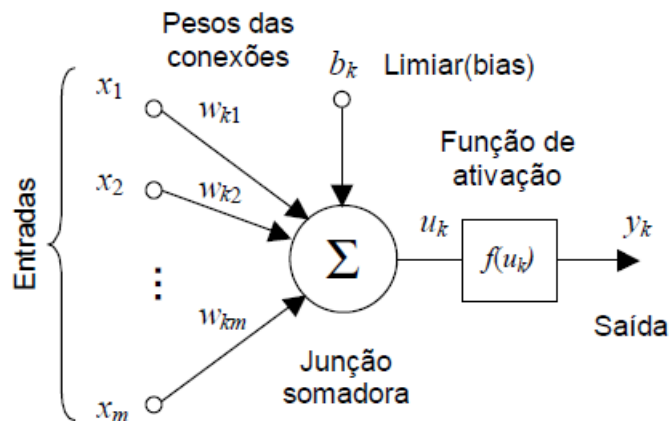
### 3.6 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são uma ramificação da área de Inteligência Artificial. São usadas, principalmente para processar informações de modo análogo ao funcionamento dos neurônios presentes no cérebro. As Redes são estruturas compostas por unidades básicas, os neurônios, altamente conectadas e processando paralelamente informação. As Redes Neurais podem ser treinadas para processar informações nas suas entradas e apresentar na sua saída a previsão de uma variável desejada, como por exemplo a vibração. O grande diferencial das RNA está em reconhecer padrões não previstos e tornar-se especialista na previsão quando comparada os outros métodos de predição.

O elemento principal na RNA é o neurônio artificial genérico. As principais partes (figura 3.14) que compõem o neurônio são:

- os pesos associados a cada entrada;
- a junção somatória;
- a função de ativação.

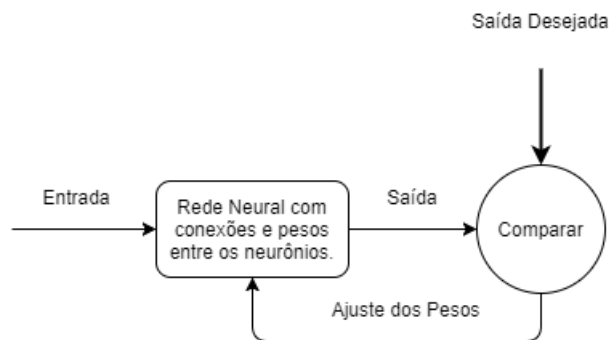
Figura 3.14: As partes do neurônio artificial genérico.



Fonte: Von Zuben *et al.* (1996)

A grande popularidade das RNA está na robustez de seu algoritmo de treinamento mais popular, o *back-propagation*, ou algoritmo de retroação. A ideia de funcionamento deste algoritmo pode ser vista na Figura 3.15.

Figura 3.15: Funcionamento da Rede Neural na fase de treinamento.



Fonte: elaborado pelo próprio autor

A *Back-Propagation Neural Network* (BPNN) é composta por três camadas: a camada de entrada, a camada oculta e camada de saída. Cada uma destas camadas é formada por neurônios que se conectam com as camadas seguintes através de pesos. Cada neurônio por sua vez, possui uma função de transferência e um peso constante associado denominado *bias*. As funções de ativação decidem se um neurônio será ativado ou não. Elas podem ser desde funções de grau até funções não lineares.


As principais funções de ativação são a logística e a tangente hiperbólica. A função logística comporta-se da seguinte forma:

$$f(u_k) = 1 \text{ se } pu_k \geq 1; pu_k \text{ se } 0 < pu_k < 1; 0 \text{ se } pu_k \leq 0$$

Sendo  $u_k$  o somatório ponderado das entradas mais o *bias* e  $f(u_k)$  a função de ativação do neurônio. O comportamento da função pode ser visto na Figura 3.16



Figura 3.16: Função Logística.




Fonte: Von Zuben e Attux (2001)

De modo análogo o funcionamento da função de ativação tangente é mostrado na Figura 3.17.

Figura 3.17: Função Tangente Hiperbólica.

$$y = f(\mathbf{u}_k) = \tanh(p\mathbf{u}_k) = \frac{e^{p\mathbf{u}_k} - e^{-p\mathbf{u}_k}}{e^{p\mathbf{u}_k} + e^{-p\mathbf{u}_k}} \quad \frac{\partial y}{\partial \mathbf{u}_k} = p(1 - \mathbf{u}_k^2) > 0$$

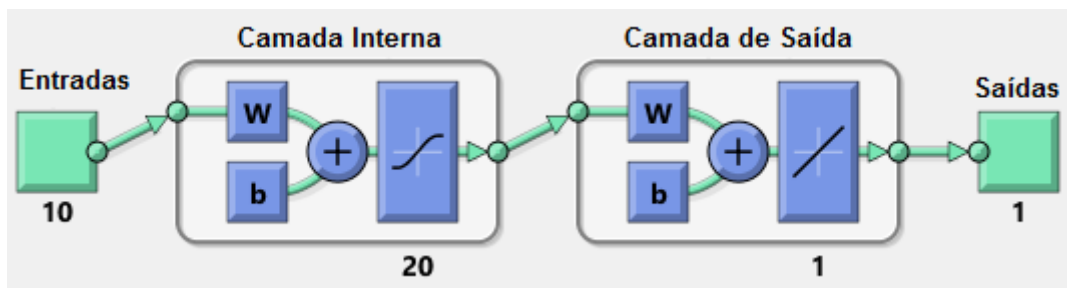


Fonte: Von Zuben e Attux (2001)

A Figura 3.18 mostra a arquitetura utilizada no software Matlab<sup>®</sup> para representar a RNA. A rede possui três camadas, a camada de entrada, sendo 10 entradas ( $X_i; i = 1, 2, 3, \dots, 10$ ), a camada interna ou oculta que possui 20 neurônios e a camada de saída, que possui um neurônio ( $Y_k; k = 1$ ). O neurônio  $j$  da camada interna está conectado com todos os neurônios da camada de entrada, como expresso na Equação 3.10:

$$X_i = (X_1, X_2, \dots, X_n). \quad (3.10)$$

Figura 3.18: Esquema da rede neural criada no Matlab®.



Fonte: gerada no software Matlab®.

Os valores de saída na camada de entrada da rede, são definidos pela Equação 3.11:

$$Net_j = \sum_{i=1}^n (X_i W_{ij} + \theta_j), \quad (3.11)$$

onde  $X_i$  é o valor de entrada,  $W_{ij}$  são os pesos da conexão entre o neurônio  $i$  da camada de entrada e o neurônio  $j$  da camada interna e  $\theta_j$  é o limiar de ativação (*bias*) do neurônio, que pode ser usado ou não.

Como saída da camada interna, cada neurônio da rede possui uma função de ativação, que nesse caso é uma função de ativação logística, expressa na Equação 3.12:

$$Out_j = f(Net_j) = \frac{1}{1 + e^{-(Net_j + \theta_j)}}. \quad (3.12)$$

A soma das entradas da unidade  $k$  da camada de saída é dada pela seguinte função expressa pela Equação 3.13:

$$Net_k = \sum_{j=1}^m (S_j W_{jk} + \theta_k), \quad (3.13)$$

onde  $S_j$  é o valor de entrada,  $W_{jk}$  são os pesos da conexão entre o neurônio  $j$  da camada de entrada e o neurônio  $k$  da camada de saída e  $\theta_k$  é o limiar de ativação (*bias*) fixo do neurônio.

Assim, a saída do neurônio  $k$  é dada pela Equação 3.14:

$$Out_k = f(N_k) = \frac{1}{1 + e^{-(N_k + \theta_k)}}. \quad (3.14)$$

Durante o processo de aprendizagem, a RNA é apresentada a um conjunto de dados que correspondem a uma entrada ou um conjunto de entradas e suas respectivas saídas. Usando os pesos entre as conexões e um limiar fixo para cada neurônio, a RNA calcula uma solução própria, comparando a solução obtida com a solução desejada. Dessa forma, um erro pode ser estabelecido pela equação 3.15:

$$e_k = t_k - Out_k, \quad (3.15)$$

onde  $t_k$  é o valor desejado.

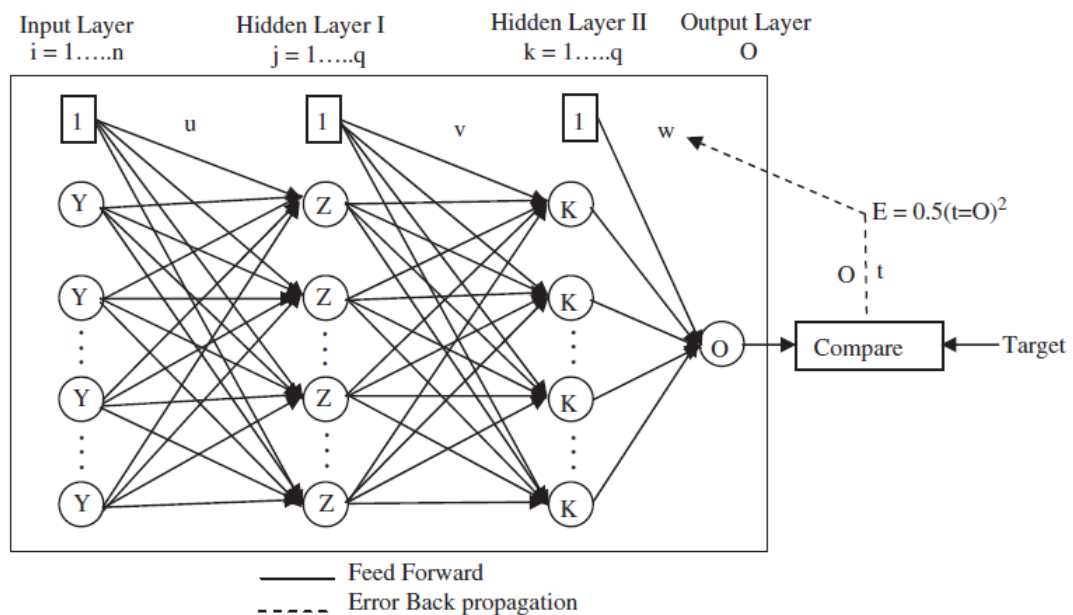
A função que determina o erro total é o Erro Quadrático Médio ou MSE expressa pela Equação 3.16:

$$E = \frac{1}{P} \sum_{k=1}^p (t_k - Out_k)^2, \quad (3.16)$$

onde  $p$  é o número de neurônios da camada de saída.

A Figura 3.19 mostra a camada de entrada, a camada interna e a camada de saída conectadas.

Figura 3.19: Rede Neural *Backpropagation*



Fonte: Neaupane e Achet (2004)

O treinamento da rede neural consiste no processo de otimização do vetor de pesos dos parâmetros de entrada. Em outras palavras, o treinamento deve identificar um mínimo global para a curva que representa o erro, como é apresentado na equação 3.17. Os principais algoritmos de treinamento são Levenberg-Marquardt (LM), Resilient Backpropagation (RP) e Bayesian Regularization (BR). Lourakis (2005), Prasad *et al.* (2013), Burden e Winkler (2008).

$$\nabla W_{jk} = -\gamma(\delta E / \delta W_{jk}) \quad (3.17)$$

Onde  $\gamma$  = a taxa de aprendizagem e  $E$  = ao erro da função. A função que descreve a atualização dos pesos no instante  $(n+1)$  é dada pela equação 3.18.

$$W_{jk}(n+1) = W_{jk}(n) + \nabla W_{jk}(n) \quad (3.18)$$

O processo é iterativo para cada par de valores a serem treinados (conjunto de entradas e

seus respectivos valores alvo) e é chamado de época ou período. O treinamento é interrompido quando a rede já foi treinada de modo satisfatório, por exemplo, quando o erro quadrático médio (MSE) ficar abaixo de um valor determinado ou quando o número de épocas ultrapassar um limite máximo.

Diversos estudos tem sido conduzidos usando redes neurais artificiais para estimar vibrações causadas por desmonte de rochas. Chakraborty *et al.* (2004) estudou o uso de redes neurais para estimar vibrações e comparou a rede com os modelos empíricos. Em os autores selecionaram alguns parâmetros mais importantes para serem utilizados como entrada da rede neural, são eles: diâmetro do furo, afastamento, espaçamento, subperfuração, carga máxima por espera e distância. Na comparação com os modelos tradicionais, o modelo que utiliza redes neurais obteve um coeficiente de determinação  $R^2$  de 0,822 frente à coeficientes abaixo de 0,5 para os modelos empíricos.

Singh (2004) aplicou uma rede neural de três camadas para predizer vibrações causadas por desmonte de rochas. Para treinar a rede, foi utilizado o algoritmo *back-propagation*. Como parâmetros de entrada foram usados: o diâmetro do furo, o número de furos, a profundidade do furo, o espaçamento, o afastamento e comprimento do tampão. A relação entre a vibração medida e estimada utilizando o modelo de redes neurais, obteve um coeficiente de determinação  $R^2$  de 0,834.

Khandelwal e Singh (2006) estimou a vibração e a sua frequência causadas pelo desmonte de rochas em minas à céu aberto usando RNA. Esse trabalho considerou em sua rede neural características da rocha, dos explosivos e do plano de fogo. Os parâmetros do plano de fogo usados como entrada da rede neural e que afetam a vibração e a frequência são: diâmetro do furo, profundidade do furo, afastamento, espaçamento, profundidade média das cargas, quantidade de explosivos por furo e a distância entre a detonação e o sismógrafo. Como características da rocha foram usados o *Blastability Index*, o Módulo de Young, o Coeficiente de Poisson e a velocidade P da onda. E por último, como características do explosivo foram usadas a *Velocity of Detonation* (VOD) e a densidade do explosivo. O coeficiente de determinação  $R^2$  obtido para o modelo foi de 0,99 para a vibração e 0,98 para a frequência.

Khandelwal e Singh (2007) comparou diversos modelos empíricos com o modelo proposto usando RNA para estimar vibração em uma mina de magnesita na Índia. Foi proposta uma rede neural de três camadas, com 5 neurônios na camada oculta e utilizando o algoritmo de treinamento *back-propagation*. Como parâmetros de entrada foram usados somente a carga máxima por espera e a distância. O coeficiente de determinação  $R^2$  obtido foi 0,913.

Além da estimativa da vibração, alguns autores fizeram uso de redes neurais para estimar ou predizer outros efeitos não desejáveis do desmonte de rochas como *back-break* e *flyrock*. Monjezi e Dehghani (2008) e Monjezi *et al.* (2014) avaliaram o efeito dos padrões do plano de fogo na ocorrência de *backbreak* ou quebra para trás usando RNA. Os autores utilizaram parâmetros do plano de fogo como espaçamento, afastamento, tampão, número de fileiras e fator de carga para estimar a ocorrência do desse fenômeno.

Outro uso análogo das redes neurais diz respeito a estimativa de fragmentação, que é um fator de extrema importância ao se planejar o desmonte. Kulatilake *et al.* (2010) usou redes neurais para estimar a fragmentação média causada pelo desmonte de rochas, baseando-se nos parâmetros do plano de fogo e das características geomecânicas das rochas.

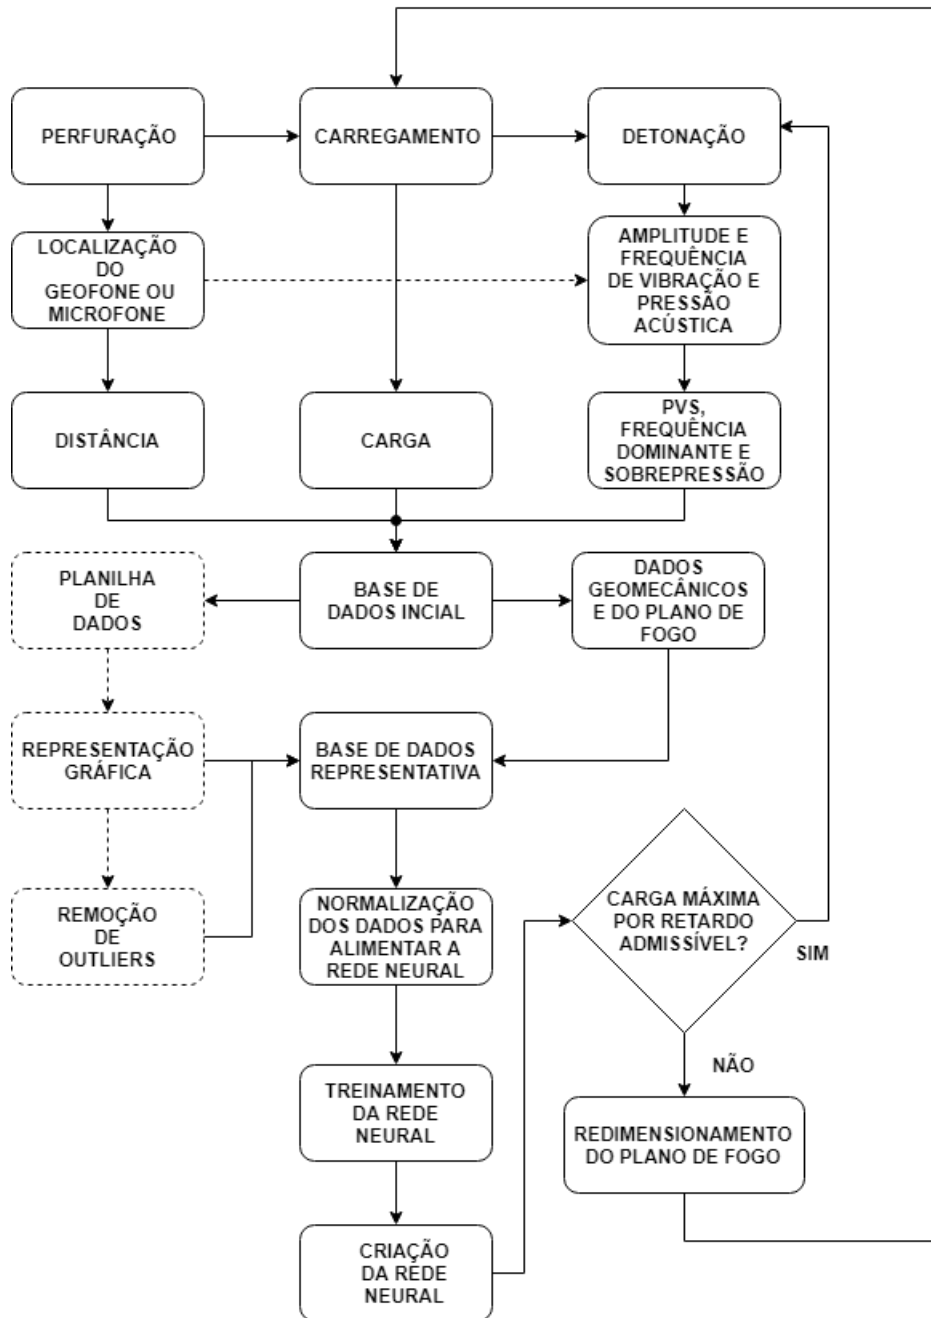
## 4. Metodologia

O presente trabalho foi realizado de acordo com as seguintes etapas:

- Utilizar a base de dados de uma campanha de monitoramento realizado num projeto de pesquisa do Instituto Tecnológico Vale numa mina de ferro de grande porte.
- Consolidar uma base inicial de dados, a qual foram considerados os parâmetros do plano de fogo, os valores de pico de vibração da partícula (PPV) e suas frequências nas direções vertical, longitudinal e transversal, a resultante PVS, e a pressão acústica.
- Treinar a Rede Neural com a totalidade dos dados, ou seja, sem a remoção dos valores anômalos e avaliar os resultados.
- Realizar a remoção dos valores anômalos através do uso do número modificado de Thomson e, posteriormente, analisar as variáveis graficamente com o uso de regressão linear.
- Realizar o treinamento de diversas Redes Neurais com arquiteturas diferentes a fim de obter a rede, com maior coeficiente de determinação  $R^2$  e menor erro quadrático médio (RMSE), ou seja, a rede que melhor estima o PVS, a Frequência Dominante e a Pressão Acústica.
- Avaliar a análise de sensibilidade das entradas da rede e mostrar quais entradas são mais determinantes na estimativa do valor de vibração;
- Desenvolver uma interface para o usuário conseguir montar um plano de fogo e visualizar a previsão de vibrações, frequência e pressão acústica. E assim, confrontar os valores obtidos com os valores máximos permitidos pela norma a ser utilizada.

A Figura 4.1 apresenta a metodologia utilizada no presente trabalho por meio de um fluxograma. Inicialmente, deve ser realizada a etapa de perfuração e carregamento obedecendo os critérios do plano de fogo para que o planejamento não seja diferente da execução. Em seguida, após uma detonação bem sucedida, os geofones e os microfones registram no sismógrafo a amplitude, frequência de vibração e pressão acústica. De posse desses valores, da localização geográfica dos geofones e microfones, dos valores do plano de fogo, segue-se para a etapa de processamento dos dados. Nessa etapa são removidos os valores anômalos e criada uma base de dados representativa para alimentar e treinar a rede neural. Um vez que a rede esteja treinada, é possível avaliar se o plano de fogo e a carga máxima por espera produzem níveis de vibração, pressão acústica e frequência aceitáveis, se não, o plano de fogo pode ser refeito e testado novamente.

Figura 4.1: Metodologia para controle de vibrações causadas pelo desmonte de rochas.



Fonte: Torres *et al.* (2018) adaptado pelo autor.

## 4.1 Estudo de Caso

O estudo de caso foi feito em uma mina de minério de ferro de grande porte a céu aberto localizada na parte leste do quadrilátero ferrífero, no estado de Minas Gerais. As operações da mina em questão estão a uma distância de aproximadamente 500 m da comunidade mais próxima, Morro da Água Quente, povoado pertencente a Catas Altas.

As campanhas de monitoramento ocorreram em pontos dentro da mina, em áreas exis-

tentes entre a mina e a comunidade e na própria comunidade. Um total de 163 eventos de vibração causados pelo desmonte foram usados para alimentar a rede neural. Um total de 10 fontes de vibração, usando explosivos do tipo emulsão da marca Fortis Advantage<sup>®</sup> foram usadas.

#### 4.1.1 Campanha de Monitoramento

O monitoramento foi realizado usando um total de 20 sismógrafos, modelo SSU 3000 EZ+ da marca GEOSONICS<sup>®</sup>(Figura 4.2). Cada sismógrafo possui a ele conectado um microfone para medição de diferentes níveis de pressão acústica e um geofone capaz de medir a vibração em três direções (vertical, longitudinal e transversal).

Figura 4.2: Sismógrafo GEOSONICS<sup>®</sup>, modelo SSU 3000 EZ+.



Fonte: Geosonics (2018)

A norma NBR 9653 (2018) que trata, entre outras coisas, dos procedimentos de fixação, instalação e programação dos sensores, foi usada para posicionar o geofone e o microfone de forma a captar principalmente o evento de detonação.

Um resumo dos 10 eventos de detonação, sua localização e o plano de fogo adotado pode ser visto na Tabela 4.1.




Tabela 4.1: Dados dos desmontes monitorados

ID	UTM			Q (kg)	A (m)	E (m)	L (m)	SF (m)	T (m)	RC (g/t)	Nº Furos	B.I
	X	Y	Z									
1	665775	7774221	1004	1250,0	4,3	5,0	10,2	2,4	5,0	373,5	5,0	44,11
2	665737	7774260	1004	2000,0	4,2	5,0	12,0	0,7	5,8	352,5	8,0	60,77
3	665747	7774230	1002	1500,0	4,4	5,2	12,0	1,0	5,2	416,8	5,0	53,90
5	665726	7774112	1006	1000,0	4,2	4,9	11,5	1,0	5,2	363,9	4,0	53,02
6	665712	7774251	1002	1400,0	4,0	4,6	12,4	1,0	5,2	506,3	4,0	31,37
7	665439	7774083	1091	1600,0	4,0	4,5	11,0	0,4	5,1	534,7	5,0	66,97
8	665470	7774117	1090	1350,0	4,0	4,6	11,5	0,5	5,1	534,7	6,0	73,75
9	665740	7774223	1001	2100,0	4,2	4,5	12,1	1,1	5,6	290,8	4,0	68,20
10	665718	7774215	1009	800,0	4,1	4,6	10,7	0,4	5,1	471,5	5,0	57,70

Q: carga máxima por espera, A: afastamento, E: espaçamento, L: altura do furo, SF: Subperfuração, T: tampão, RC: razão de carga, B.I: Blastability Index

Além dos parâmetros de entrada listados na tabela 4.1(Q: carga máxima por espera, A: afastamento, E: espaçamento, L: altura do furo, SF: Subperfuração, T: tampão, RC: razão de carga e B.I: Blastability Index), também é usada como entrada a distância do ponto de detonação ao geofone. A disposição geográfica das detonações e dos geofones durante a campanha de monitoramento podem ser vistas nas Figuras 4.3 e 4.4.

Figura 4.3: Localização das detonações e sismógrafos do primeiro grupo



Fonte: Silveira (2017)

Na Figura 4.3 representa-se o monitoramento das primeiras 5 detonações durante os dois primeiros dias usando um total de 17 sismógrafos posicionados em direção à comunidade de Morro da Água Quente.

Figura 4.4: Localização das detonações e sismógrafos do segundo grupo



Fonte: Silveira (2017)

Já na Figura 4.4 representa-se o monitoramento das últimas 5 detonações durante os outros dias usando um total de 20 sismógrafos, posicionados em diferentes pontos do povoado com o objetivo de avaliar os possíveis níveis de vibração.

Após a campanha de monitoramento, os valores de entrada caracterizados pelo plano de fogo, litologia e também os valores medidos de vibração (PVS), frequência e pressão acústica foram resumidos e são mostrados na Tabela 4.2.

Tabela 4.2: Parâmetros de entrada e saída usados na rede.

Parâmetros de Entrada e Saída	Limites	Média	Unidade
Distância	51 - 1955	845,5	m
Carga máxima por espera (MCPD)	800 - 2100	1463,5	kg
Afastamento	4,0 - 4,4	4,17	m
Espaçamento	4,5 - 5,2	4,79	m
Profundidade do furo	10,2 - 12,4	11,49	m
Subfuração	0,4 - 1,1	0,70	m
Altura do tampão	5 - 5,8	5,28	m
Razão de carga	290,8 - 534,7	418,6	g/t
Nº de Furos	4 - 8	5,2	-
Blastability Index (B.I)	31,3 - 73,7	54,54	-
PVS	0,2 - 74,9	3,7	mm/s
Pressão Acústica	89 - 142	113,2	dB
Frequência Dominante	0,8 - 16,1	4,4	Hz

#### 4.1.2 Processamento dos Dados

Os registros iniciais de vibração, frequência e pressão totalizavam 163 medidas. Porém, alguns valores observados parecem desviar-se consideravelmente dos outros membros da mesma medição. A essas observações dá-se o nome de valores anômalos (HODGE e AUSTIN, 2004). Já Barnett e Lewis (1974) define os valores *anômalos* como uma observação ou conjunto de observações que parece ser inconsistente em relação ao restante do conjunto de dados.

Para a análise e remoção de possíveis valores anômalos será utilizado um procedimento conhecido como teste modificado de Thompson Tau, descrito por (THOMPSON, 1985). O processo se dá da seguinte forma:

- Primeiro, a média e o desvio padrão (S) de um conjunto de dados é determinada;
- Em seguida, o desvio absoluto  $\delta_i$  entre cada ponto de dados é determinado;
- Em terceiro lugar, uma região de rejeição é determinada usando a fórmula:

$$\tau = \frac{t_{\alpha/2}(n-1)}{\sqrt{n}\sqrt{n-2+t_{\alpha/2}^2}}, \quad (4.1)$$

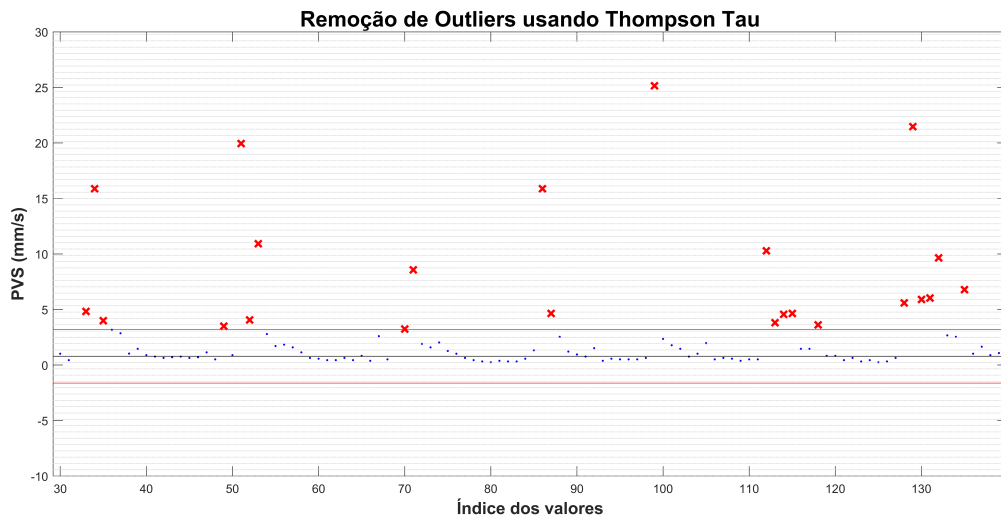
onde  $t_{\alpha/2}$  é o valor crítico da distribuição t de Student com n-2 graus de liberdade, n é o tamanho da amostra, e S é o desvio padrão da amostra.

Em seguida, utiliza-se o seguinte critério:

- Se  $\delta_i \geq \tau S$  o dado está na região de rejeição e é considerado um valor *anômalo*
- Se  $\delta_i \leq \tau S$  o dado está fora da região de rejeição e não é considerado um valor *anômalo*

Após o teste de verificação de valores anômalos, pode-se verificar o conjunto total dos dados e os valores que serão removidos na Figura 4.5

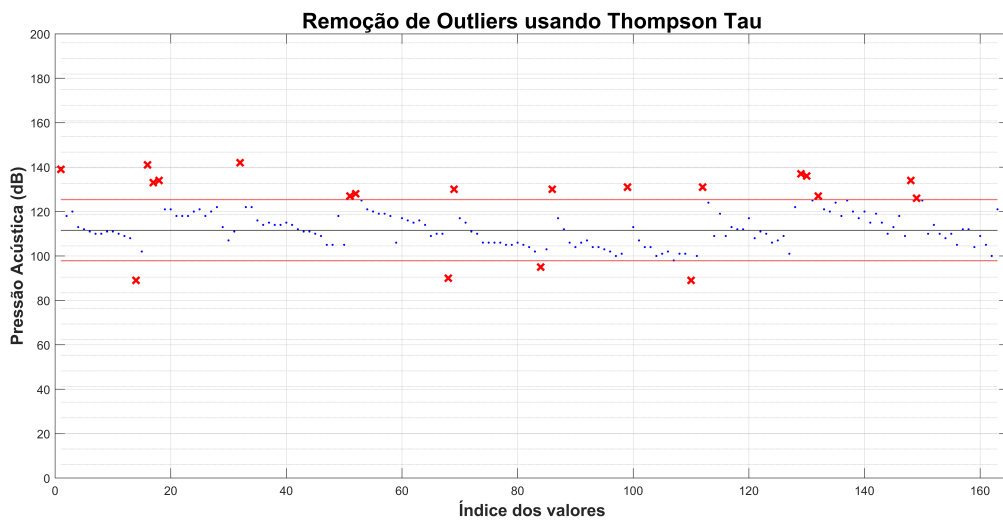
Figura 4.5: Remoção de valores anômalos de vibração



Fonte: elaborado pelo autor

Na Figura 4.5, no eixo das abscissas tem-se o índice dos valores de PVS e no eixo das ordenadas o valor de PVS em mm/s. Os azuis são os valores que não são anômalos segundo o critério de Thompson e as cruzeiros vermelhos são os valores anômalos.

Figura 4.6: Remoção de valores anômalos de pressão acústica

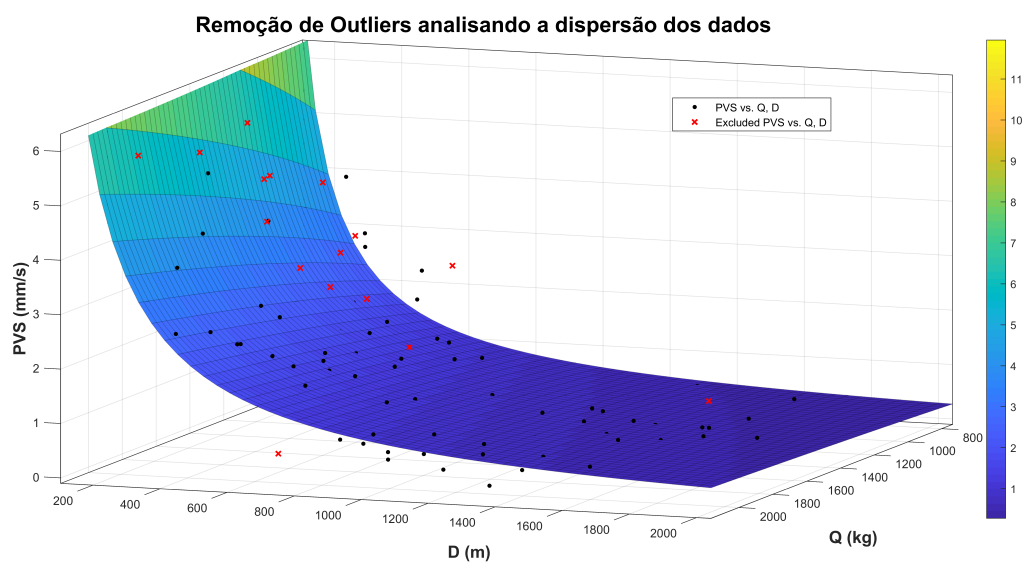


Fonte: elaborado pelo autor

Na Figura 4.6, no eixo das abscissas tem-se o índice dos valores de pressão acústica e no eixo das ordenadas o valor de pressão acústica em dB. Os pontos azuis são os valores que não são anômalos segundo o critério de Thompson e as cruces vermelhas são os valores anômalos.

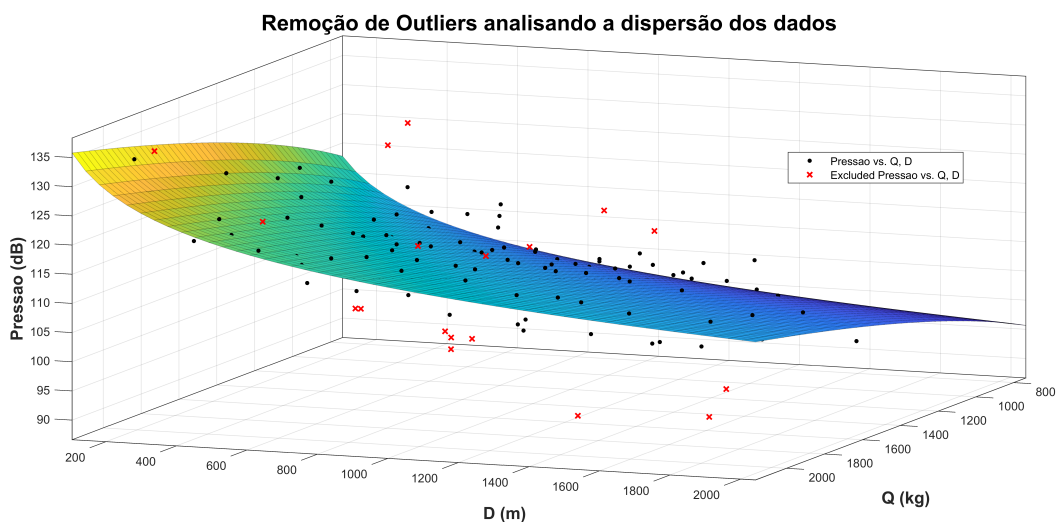
Mesmo após o uso do critério de Thompson para a remoção de valores anômalos, pode-se notar alguns pontos anômalos na dispersão dos dados. Dessa forma, foi “plotada” uma curva de regressão que relaciona as variáveis independentes Q (carga máxima por espera) e D (distância) com a variável dependente PVS 4.7. O mesmo foi feito para a variável dependente pressão acústica 4.8.

Figura 4.7: Retirada manual dos valores anômalos de PVS



Fonte: elaborado pelo autor.

Figura 4.8: Retirada manual dos valores anômalos de pressão acústica



Fonte: elaborado pelo autor.

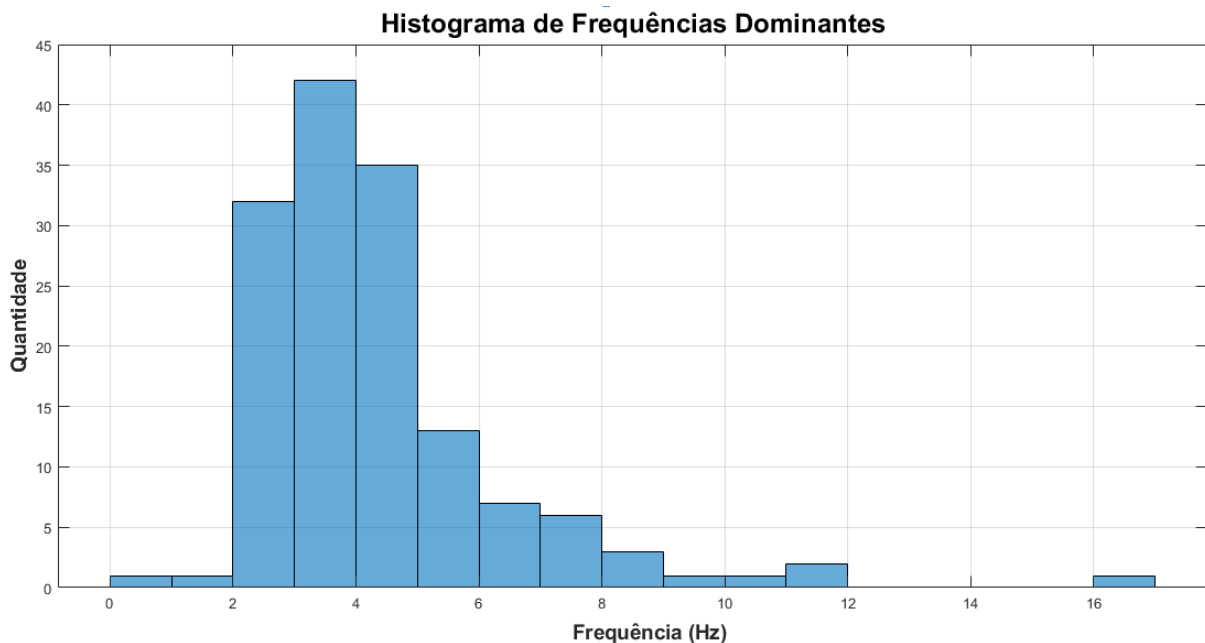
As curvas multicoloridas das Figuras 4.7 e 4.8 são as curvas de regressão obtidas ao utilizar-se a equação clássica 3.7 da lei de atenuação. Os pontos vermelhos no gráfico estão em certa medida afastados da curva, por isso são considerados anômalos. Já os pontos pretos não são considerados anômalos pois apresentam pouca dispersão.

Após a remoção dos valores anômalos, com o uso do critério de Thompson e através da remoção manual, restaram ao final 135 medições de PVS e 143 medições de pressão acústica. O peso da remoção desses valores anômalos e se eles afetam o desempenho da rede neural é discutido no Capítulo 5.

O tratamento dos dados relativos a frequência seguiu o mesmo critério de remoção de valores anômalos do PVS, uma vez que eles fazem parte da medição do mesmo sensor.

Uma análise do valor de pico da vibração e sua respectiva frequência foi feita para as três direções (vertical, transversal e longitudinal). Assim, como explicado na subseção 3.2.2. As frequências dominantes são apresentadas em formato de histograma na Figura 4.9.

Figura 4.9: Histograma de Frequências Dominantes



Fonte: elaborada pelo autor

Na Figura 4.9 apresenta-se um histograma da frequência dominante em Hz. Nota-se que a frequência dominante associada aos desmonte está concentrada entre 2 e 5 Hz.

### 4.1.3 Blastability Index

Para determinação do *Blastability Index* ou Índice de Arranque, mostrado por Lilly (1986) é proposto um método para qualificar as informações geológicas e descrever o comportamento geológico das estruturas e assim melhorar os níveis de fragmentação e desmonte de

rocha. O índice é composto por cinco características geomecânicas como mostrado na Equação 4.2 (KULATILAKE *et al.*, 2010):

$$BI = 0,5 \times (RMD + JPS + JPO + SGI + RSI), \quad (4.2)$$

onde RMD é a descrição do maciço rochoso, JPS é o espaçamento entre planos de descontinuidade, JPO é a orientação dos planos de descontinuidade (inclinação e direção), SGI é a influência da densidade do material e RSI é a influência da dureza da rocha.

Na Figura 4.10 apresenta-se uma tabela com os valores dos parâmetros para se determinar o Índice de Arranque. A determinação das propriedades físico-mecânicas das rochas seguiram os padrões da ISRM (ULUSAY, 2014).

Figura 4.10: Parâmetros Geomecânicos.

Parâmetros Geomecânicos	Classificação
<b>RMD - Descrição do maciço rochoso</b>	
Friável/ pouco consolidado	10
Diaclasado em Blocos	20
Pouco Massivo	50
<b>JPS - Espaçamento entre planos</b>	
Pequeno (<0,1m)	10
Médio (0,1 a 1m)	20
Grande (>1m)	50
<b>JPO - Orientação dos planos</b>	
Horizontal	10
Inclinação normal à frente livre	20
Direção normal à frente livre	30
Inclinação coincidente com a frente livre	40
<b>SGI - Influência da densidade</b>	
(SG - densidade do material em t/m <sup>3</sup> )	SGI = 25*SG-50
<b>RSI - Dureza da Rocha</b>	
(RC- Resistência à compressão simples em Mpa)	RSI = 0,05*RC

Fonte: adaptado de Cavadas *et al.* (2012)

Para facilitar o cálculo do BI foi criada uma interface gráfica com o usuário ou GUI (*Graphical User Interface*) no software Matlab<sup>®</sup> (Figura 4.11). Essa interface utiliza as classificações descritas na Figura 4.10 e a Equação 4.2 para calcular o BI.

Figura 4.11: Interface Gráfica para calculo do BI

Monitoramento e Controle de Vibrações

### Controle de Vibrações ITV

Plano de Fogo (Ash) | Tab | Mapa de Vibrações | Plano de Fogo | Blastability Index | Explosivos

**Descrição do Maciço Rochoso**

Friável ou pouco friável

Diaclasado em blocos

Massivo

10

**Espaçamento entre Planos**

Pequeno (< 1m)

Médio (0,1 a 1m)

Grande (> 1m)

10

**Orientação dos Planos**

Horizontal

Inclinação normal à frente livre

Direção normal à frente livre

Inclinação coincidente com a frente livre

10

Densidade (t/m<sup>3</sup>) 3.31

Resistência à Compressão (MPa) 300

Calcular

**Blastability Index (BI) = 38.88**

Fonte: elaborado pelo autor

## 4.2 Entradas e arquitetura da rede neural

Os parâmetros utilizados como entrada da rede neural a ser treinada são:

- D(m): Distância;
- Q(kg): Carga máxima por espera;
- B(m): Afastamento;
- S(m): Espaçamento;
- H(m): Altura do furo;
- SD(m): Sub-furação;
- SL(m): Altura do tampão;
- RC(kg/m<sup>3</sup>): Razão de carga;
- N<sup>o</sup> de furos;

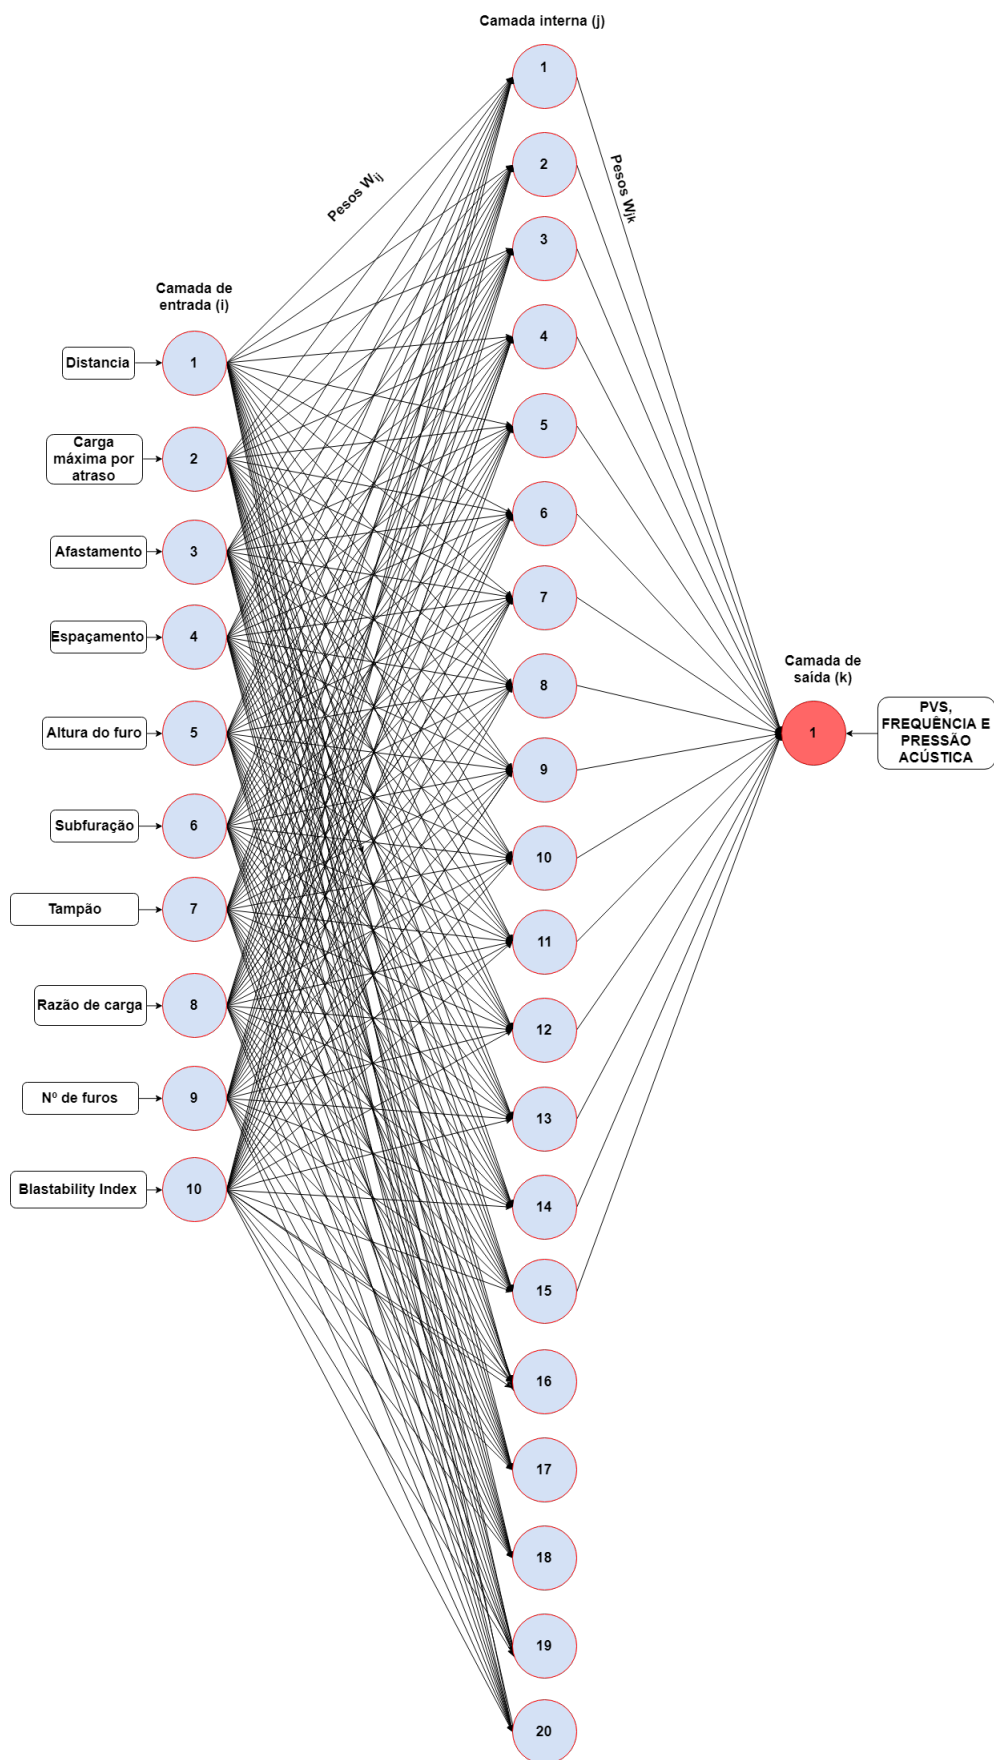


- BI: Índice de arranque.

Três redes neurais *feedforward back-propagation* de três camadas foram projetadas para estimar o PVS, a Pressão Acústica e a Frequência. Cada rede com uma única saída (PVS, pressão acústica ou frequência) para que o desempenho fosse analisado separadamente. A camada de entrada possui 10 parâmetros, a camada interna, 15 ou 20 neurônios e a camada de saída, 1 ou 2 neurônios. Como função de ativação dos neurônios foram usadas a função logística ou tangente hiperbólica. Para treinar a rede foram usados os algoritmos de Levenberg-Marquardt (LM), Resilient Backpropagation (RP) e Bayesian Regularization (BR), todos utilizando como critério de parada para o treinamento, o erro médio quadrático (MSE).

Antes do treinamento, os dados de entrada e saída da rede neural passaram por um pré-processamento. Nesse processo foi feita a normalização dos dados por meio da análise dos valores máximos e mínimos para que eles ficassem dentro de um intervalo específico. Na Figura 4.12 mostra-se a arquitetura da rede proposta.

Figura 4.12: Arquitetura da Rede Neural



Fonte: elaborada pelo autor

## 5. Resultados e Discussões

O desempenho da rede neural pode ser afetado por muitos fatores, os principais são:

- O número de dados utilizados para treinar a rede;
- A função de ativação associada aos neurônios da rede;
- A estrutura da rede (número de camadas e neurônios);
- O algoritmo de aprendizagem, ou treinamento.

Por isso, com o objetivo de avaliar o desempenho de diversas redes e escolher a melhor configuração, foram testadas diversas possibilidades.

### 5.1 Treinamento da Rede Neural utilizando a base de dados sem valores anômalos

O treinamento da rede neural para estimar valores de vibração (PVS) foi realizado com um conjunto total de 135 dados e para estimar a Pressão Acústica foram usados 143 dados de entrada. Já excluídos os possíveis valores anômalos, foram testadas várias configurações de redes neurais para a predição do PVS, Pressão Acústica e do par PVS e Frequência Dominante.

#### 5.1.1 Treinamento das Redes Neurais para estimar vibração (PVS)

As funções de ativação usadas foram tangente hiperbólica e logística, sendo que na camada de saída sempre foi usada uma função linear de ativação. A camada interna foi testada com 15 ou 20 neurônios. Nos algoritmos de aprendizagem, foram usados: o algoritmo de *Levenberg-Marquardt*, o algoritmo *Resilient Backpropagation* e o *Bayesian Regularization*.

Como métricas para avaliar o desempenho foram usados o coeficiente de determinação  $R^2$  e o *Root-Mean-Squared Error* (RMSE) ou Raiz Quadrada do Erro Médio. O coeficiente de determinação  $R^2$  ou *R-squared* é o principal indicador para avaliar a RNA. O  $R^2$  é uma medida estatística de quão próximo os dados estão do ajuste por regressão linear. O  $R^2$  mostra a relação entre a variação explicada e a variação total do preditor. Os valores estão entre 0 e 100% e dizem o quão bem o modelo se ajusta aos dados (DRAPER e SMITH, 1998). Já RMSE é usado para medir a diferença entre um valor medido e o valor estimado por um modelo.

Com o objetivo de testar diversas configurações, foram treinadas 12 redes neurais diferentes. A rede que obteve o melhor desempenho, ou seja maior  $R^2$  (0,9490) e menor RMSE (0,36) foi a rede da configuração 8 (ID=8). Essa rede possui a função de ativação logística, 20 neurônios na camada interna e foi treinada usando o algoritmo de *Levenberg-Marquardt*. A Tabela 5.1 resume as demais redes treinadas

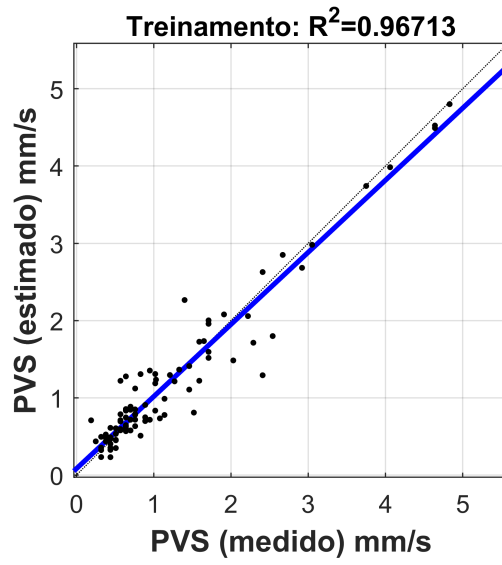
Tabela 5.1: Redes Neurais treinadas (PVS)

ID	Função de ativação	Estrutura	Algoritmo de Aprendizagem	$R^2$	RMSE
1	TAN-PL	10-15-1	LM	0,9461	0,37
2	TAN-PL	10-20-1	LM	0,9403	0,39
3	TAN-PL	10-15-1	RP	0,8624	0,58
4	TAN-PL	10-20-1	RP	0,8786	0,54
5	TAN-PL	10-15-1	BR	0,9475	0,40
6	TAN-PL	10-20-1	BR	0,9469	0,37
7	LOG-PL	10-15-1	LM	0,9208	0,44
8	LOG-PL	10-20-1	LM	0,9490	0,36
9	LOG-PL	10-15-1	RP	0,8529	0,60
10	LOG-PL	10-20-1	RP	0,8913	0,51
11	LOG-PL	10-15-1	BR	0,9459	0,37
12	LOG-PL	10-20-1	BR	0,9474	0,36

Para a rede com melhor desempenho, as Figuras 5.1, 5.2, 5.3 e 5.4 mostram uma comparação entre a PVS medida e a PVS estimada para os quatro estágios de construção da rede neural: treinamento, validação, teste e para todo o conjunto de dados.

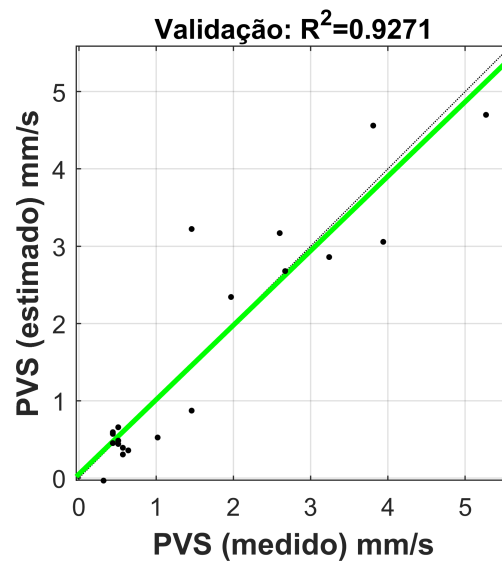
Na etapa de treinamento, Figura 5.1, 70% do conjunto total de dados foram usados para treinar a rede neural e, assim, foi obtido um coeficiente de determinação  $R^2 = 0,96713$ . Na etapa de validação, Figura 5.2, 15% do conjunto total de dados foram usados para validar a rede neural e, assim, foi obtido um coeficiente de determinação de  $R^2 = 0,9271$ . Já na etapa de teste, Figura 5.3, 15% do conjunto total de dados foram usados para testar a rede neural, obtendo-se um coeficiente de determinação  $R^2 = 0,85823$ . Utilizando o conjunto total de dados para avaliar o comportamento da rede neural, Figura 5.4, foi obtido um coeficiente de determinação de  $R^2 = 0,94904$ .

Figura 5.1: PVS medido x PVS estimado (treinamento).




Fonte: elaborada pelo autor

Figura 5.2: PVS medido x PVS estimado (validação).



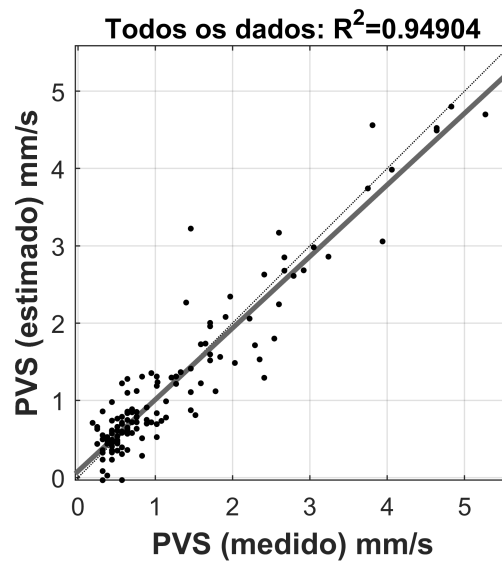
Fonte: elaborada pelo autor

Figura 5.3: PVS medido x PVS estimado (teste).



Fonte: elaborada pelo autor

Figura 5.4: PVS medido x PVS estimado (todos os dados).



Fonte: elaborada pelo autor

### 5.1.2 Treinamento das Redes Neurais para estimar Pressão Acústica

Aqui também foram treinadas 12 redes neurais diferentes. A rede que obteve o melhor desempenho, ou seja, maior  $R^2$  (0,9097) e menor RMSE (2,79), foi a rede da configuração 14 (ID=14). Essa rede possui a função de ativação tangente hiperbólica, 20 neurônios na camada interna e foi treinada usando o algoritmo de *Levenberg-Marquardt*. A tabela 5.2 resume as demais redes treinadas.

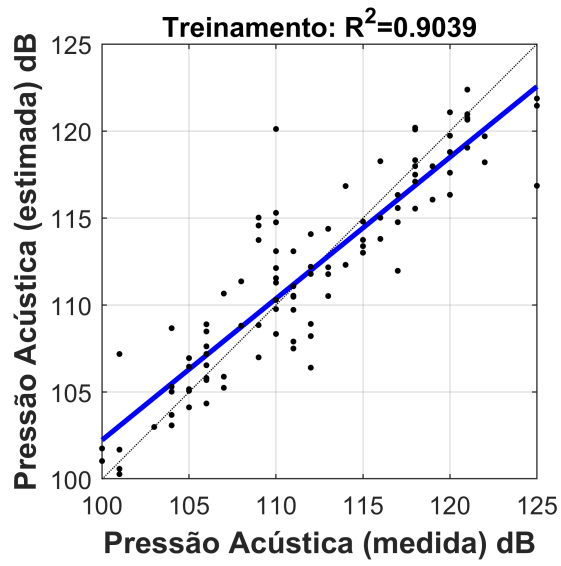
Tabela 5.2: Redes Neurais treinadas (Pressão acústica)

ID	Função de ativação	Estrutura	Algoritmo de Aprendizagem	$R^2$	RMSE
13	TAN-PL	10-15-1	LM	0,8769	3,24
14	TAN-PL	10-20-1	LM	0,9097	2,79
15	TAN-PL	10-15-1	RP	0,8708	3,23
16	TAN-PL	10-20-1	RP	0,8340	3,75
17	TAN-PL	10-15-1	BR	0,8854	3,13
18	TAN-PL	10-20-1	BR	0,8838	3,15
19	LOG-PL	10-15-1	LM	0,8734	3,27
20	LOG-PL	10-20-1	LM	0,9067	2,83
21	LOG-PL	10-15-1	RP	0,8920	3,04
22	LOG-PL	10-20-1	RP	0,8816	3,17
23	LOG-PL	10-15-1	BR	0,8940	3,01
24	LOG-PL	10-20-1	BR	0,8907	3,05

As Figuras 5.5, 5.6, 5.7 e 5.8 mostram uma comparação entre a Pressão Acústica medida e a Pressão Acústica estimada.

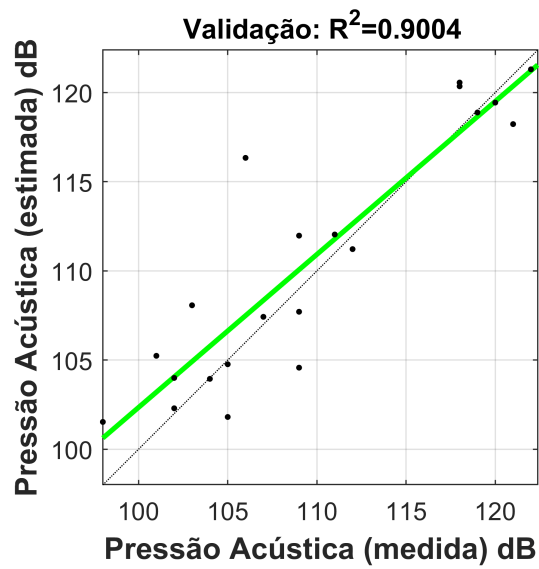
Na etapa de treinamento, Figura 5.5, 70% do conjunto total de dados foram usados para treinar a rede neural e, assim, foi obtido um coeficiente de determinação  $R^2 = 0,9039$ . Na etapa de validação, Figura 5.6, 15% do conjunto total de dados foram usados para validar a rede neural e, assim, foi obtido um coeficiente de determinação de  $R^2 = 0,9004$ . Já na etapa de teste, Figura 5.7, 15% do conjunto total de dados foram usados para testar a rede neural, obtendo-se um coeficiente de determinação  $R^2 = 0,9500$ . Utilizando o conjunto total de dados para avaliar o comportamento da rede neural, Figura 5.8, foi obtido um coeficiente de determinação de  $R^2 = 0,9096$ .

Figura 5.5: Pressão Acústica medida x Pressão Acústica estimada (treinamento).



Fonte: elaborada pelo autor

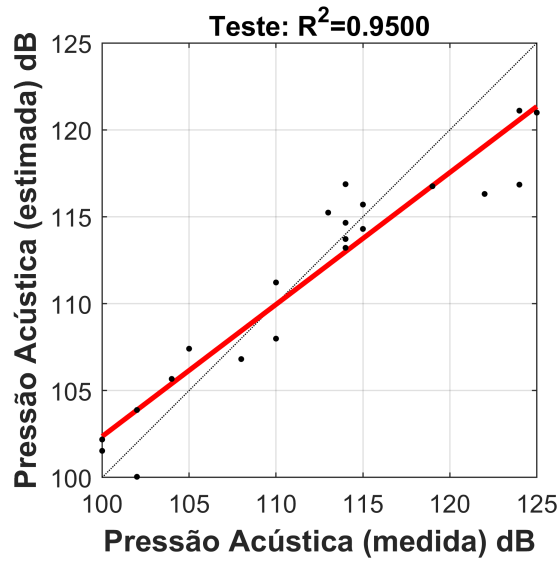
Figura 5.6: Pressão Acústica medida x Pressão Acústica estimada (validação).



Fonte: elaborada pelo autor

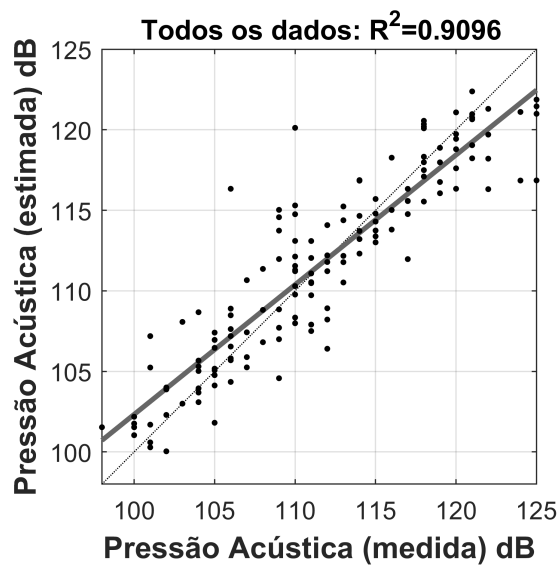


Figura 5.7: Pressão Acústica medida x Pressão Acústica estimada (teste).



Fonte: elaborada pelo autor

Figura 5.8: Pressão Acústica medida x Pressão Acústica estimada (todos os dados).



Fonte: elaborada pelo autor

### 5.1.3 Treinamento das Redes Neurais para estimar PVS e Frequência Dominante

Aqui também foram treinadas 12 redes neurais diferentes. A rede que obteve o melhor desempenho, ou seja, maior  $R^2$  (0,8360) e menor RMSE (1,73), foi a rede da configuração 32 (ID=32). Essa rede possui a função de ativação logística, 20 neurônios na camada interna e

foi treinada usando o algoritmo de *Levenberg-Marquardt*. A tabela 5.3 resume as demais redes treinadas.


Tabela 5.3: Redes Neurais treinadas (PVS e Frequência Dominante)

ID	Função de ativação	Estrutura	Algoritmo de Aprendizagem	$R^2$	RMSE (PVS)	RMSE (frequência dominante)
25	TAN-PL	10-15-2	LM	0,8145	0,48	1,82
26	TAN-PL	10-20-2	LM	0,8307	0,44	1,76
27	TAN-PL	10-15-2	RP	0,7901	0,68	1,88
28	TAN-PL	10-20-2	RP	0,7888	0,74	1,86
29	TAN-PL	10-15-2	BR	0,8102	0,46	1,86
30	TAN-PL	10-20-2	BR	0,7866	0,69	1,89
31	LOG-PL	10-15-2	LM	0,8346	0,47	1,76
32	LOG-PL	10-20-2	LM	0,8360	0,40	1,73
33	LOG-PL	10-15-2	RP	0,7515	0,73	2,02
34	LOG-PL	10-20-2	RP	0,7869	0,66	1,90
35	LOG-PL	10-15-2	BR	0,7807	0,70	1,91
36	LOG-PL	10-20-2	BR	0,7786	0,74	1,91

As Figuras 5.9, 5.10, 5.11 e 5.12 mostram uma comparação entre o PVS e a Frequência Dominante medidos e o PVS e a Frequência Dominante estimados


Na etapa de treinamento, Figura 5.9, 70% do conjunto total de dados foram usados para treinar a rede neural e, assim, foi obtido um coeficiente de determinação  $R^2 = 0,89991$ . Na etapa de validação, Figura 5.10, 15% do conjunto total de dados foram usados para validar a rede neural e, assim, foi obtido um coeficiente de determinação de  $R^2 = 0,81522$ . Já na etapa de teste, Figura 5.11, 15% do conjunto total de dados foram usados para testar a rede neural, obtendo-se um coeficiente de determinação  $R^2 = 0,62522$ . Utilizando o conjunto total de dados para avaliar o comportamento da rede neural, Figura 5.12, foi obtido um coeficiente de determinação de  $R^2 = 0,83461$ .

Figura 5.9: PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (treinamento).



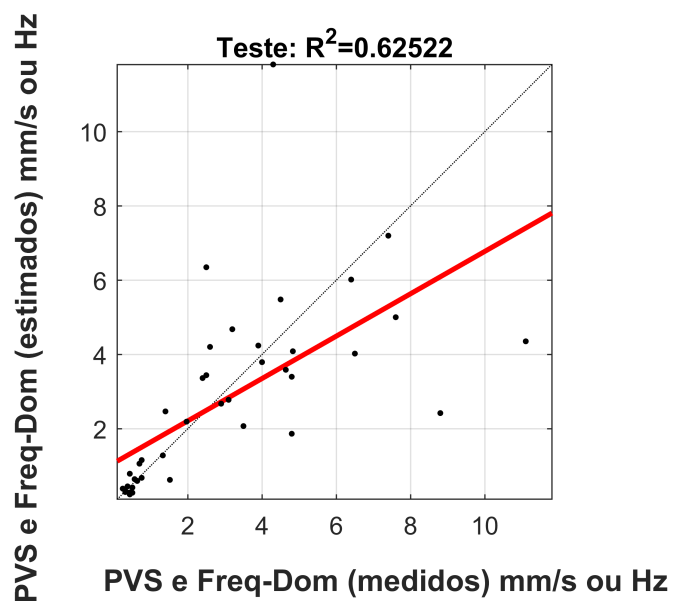
Fonte: elaborada pelo autor

Figura 5.10: PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (validação).



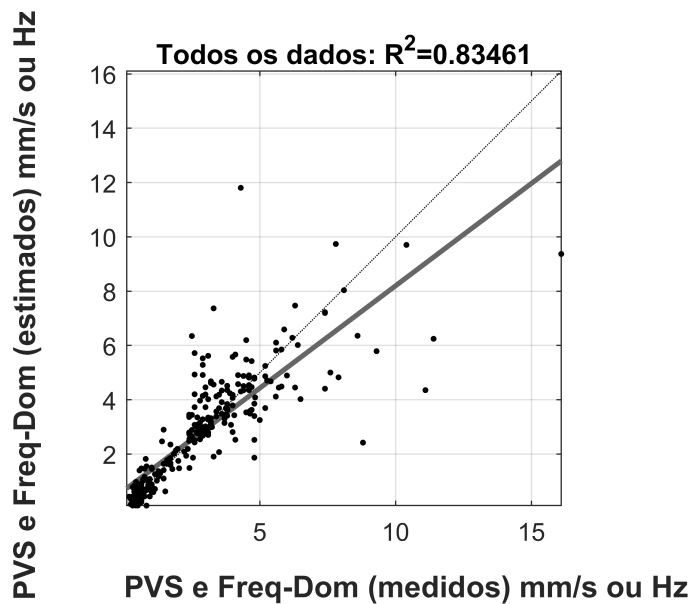
Fonte: elaborada pelo autor

Figura 5.11: PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (teste).



Fonte: elaborada pelo autor

Figura 5.12: PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (todos os dados).

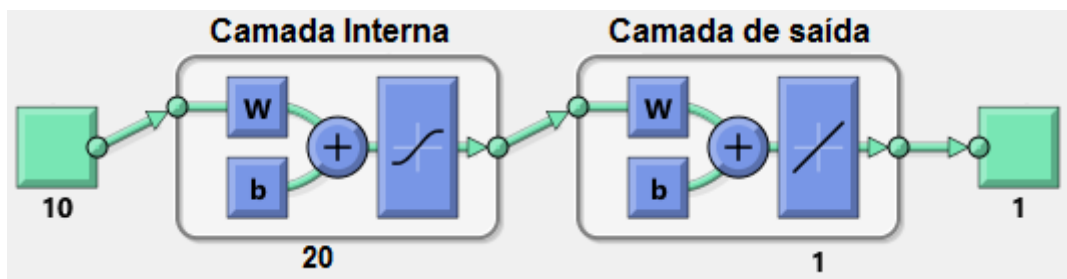


Fonte: elaborada pelo autor

## 5.2 Treinamento das Redes Neurais sem a remoção de valores anômalos

Com o objetivo de avaliar o desempenho das redes neurais quando treinadas sem a remoção dos valores anômalos, a base de dados total foi utilizada (163 dados). A melhor arquitetura encontrada para a rede neural pode ser vista pela Figura 5.13. Nessa figura observa-se a camada interna utilizando como função de ativação a função tangente hiperbólica e possuindo um total de 20 neurônios. O algoritmo de aprendizado utilizado foi o de *Levenberg-Marquardt*.

Figura 5.13: Arquitetura para a rede com valores anômalos.

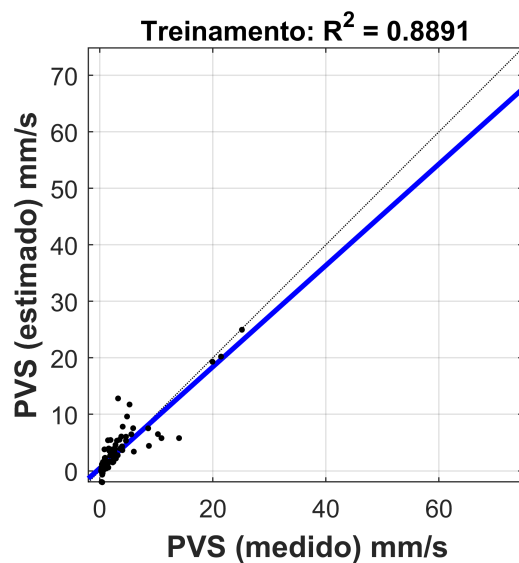


Fonte: figura gerada pelo Matlab®

### 5.2.1 Treinamento das Redes Neurais para estimar vibração (PVS)

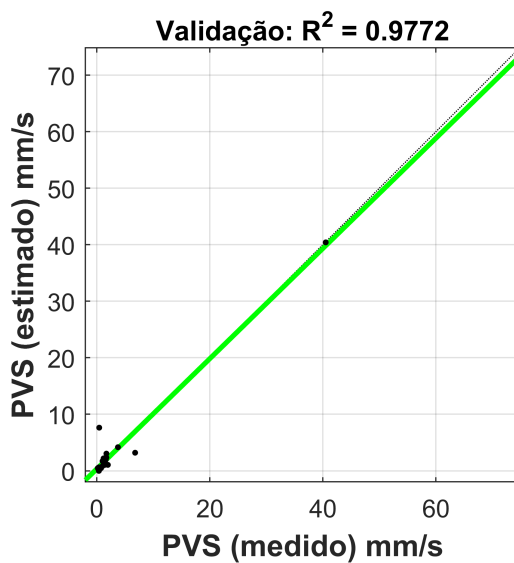
Na etapa de treinamento, Figura 5.14, foi obtido um coeficiente de determinação  $R^2 = 0,89991$ . Na etapa de validação, Figura 5.15, foi obtido um coeficiente de determinação de  $R^2 = 0,9772$ . Já na etapa de teste, Figura 5.16, obteve-se um coeficiente de determinação  $R^2 = 0,9799$ . Utilizando o conjunto total de dados para avaliar o comportamento da rede neural, Figura 5.17, foi obtida uma determinação de  $R^2 = 0,96725$ .

Figura 5.14: PVS medido x PVS estimado (treinamento).



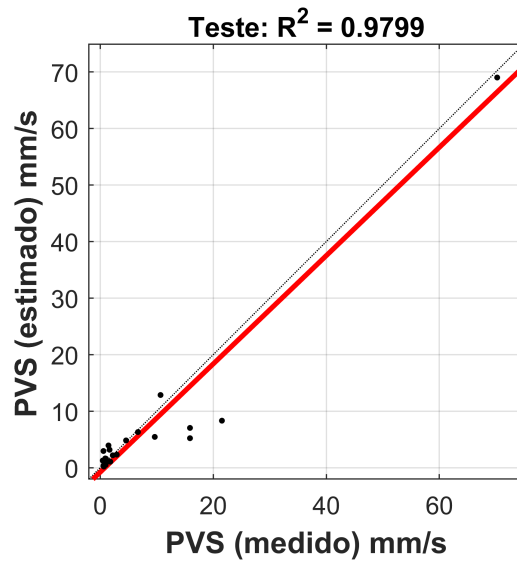
Fonte: elaborada pelo autor

Figura 5.15: PVS medido x PVS estimado (validação).



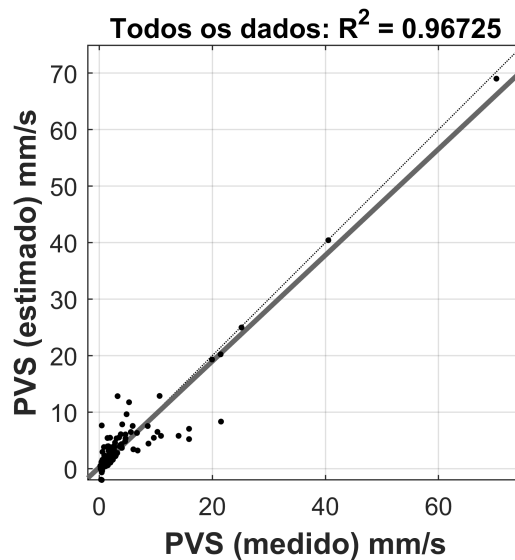
Fonte: elaborada pelo autor

Figura 5.16: PVS medido x PVS estimado (teste).



Fonte: elaborada pelo autor

Figura 5.17: PVS medido x PVS estimado (todos os dados).

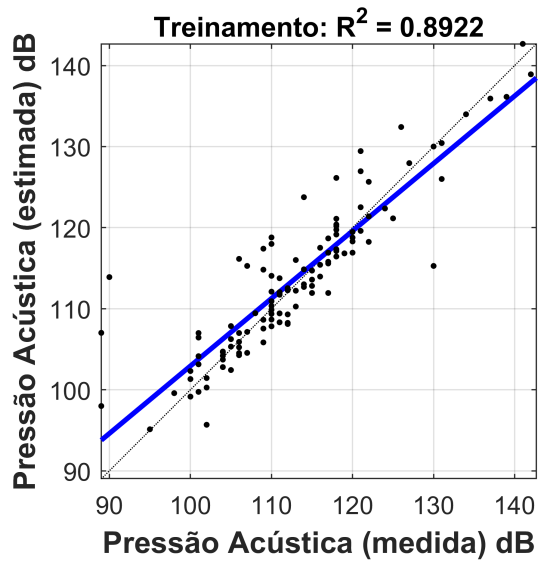


Fonte: elaborada pelo autor

## 5.2.2 Treinamento das Redes Neurais para estimar Pressão Acústica


Na etapa de treinamento, Figura 5.18, foi obtido um coeficiente de determinação  $R^2 = 0,8922$ . Na etapa de validação, Figura 5.19, foi obtido um coeficiente de determinação de  $R^2 = 0,9089$ . Já na etapa de teste, Figura 5.20, obteve-se um coeficiente de determinação  $R^2 = 0,9446$ . Utilizando o conjunto total de dados para avaliar o comportamento da rede neural, Figura 5.21, foi obtida uma determinação de  $R^2 = 0,9003$ .

Figura 5.18: Pressão Acústica medida x Pressão Acústica estimada (treinamento).



Fonte: elaborada pelo autor

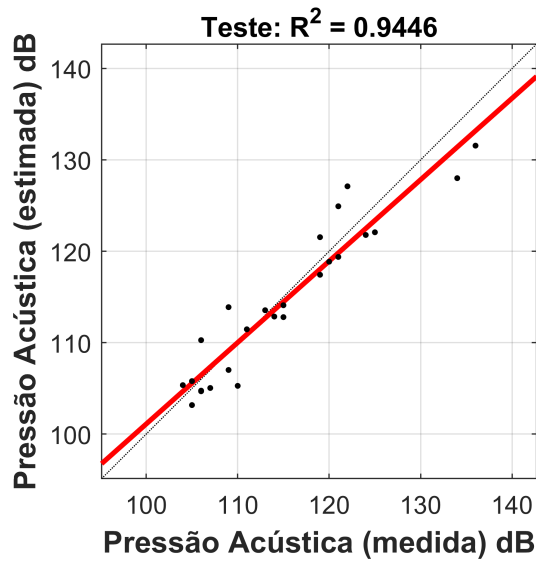
Figura 5.19: Pressão Acústica medida x Pressão Acústica estimada (validação).



Fonte: elaborada pelo autor

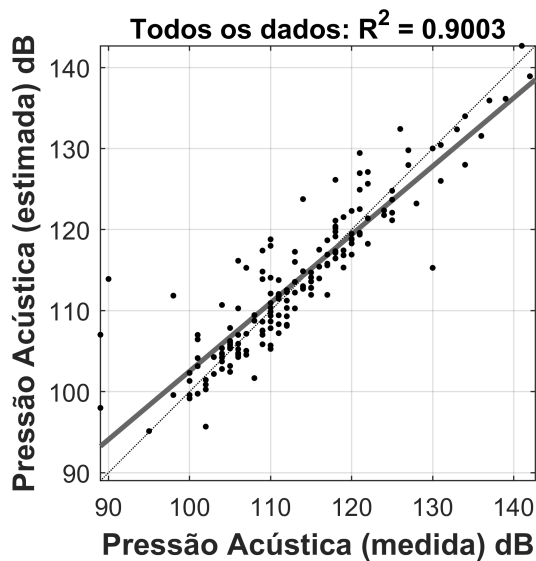


Figura 5.20: Pressão Acústica medida x Pressão Acústica estimada (teste).



Fonte: elaborada pelo autor

Figura 5.21: Pressão Acústica medida x Pressão Acústica estimada (todos os dados).



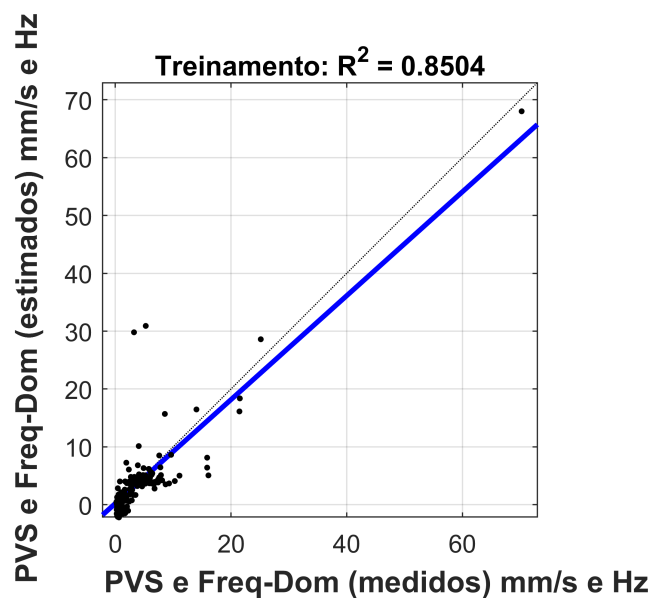
Fonte: elaborada pelo autor

### 5.2.3 Treinamento das Redes Neurais para estimar PVS e Frequência Dominante

Na etapa de treinamento, Figura 5.22, foi obtido um coeficiente de determinação  $R^2 = 0,8504$ . Na etapa de validação, Figura 5.23, foi obtido um coeficiente de determinação de  $R^2 = 0,9682$ . Já na etapa de teste, Figura 5.24, obteve-se um coeficiente de determinação


$R^2 = 0,8558$ . Utilizando o conjunto total de dados para avaliar o comportamento da rede neural, Figura 5.25, foi obtida uma determinação de  $R^2 = 0,9015$ .

Figura 5.22: PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (treinamento).



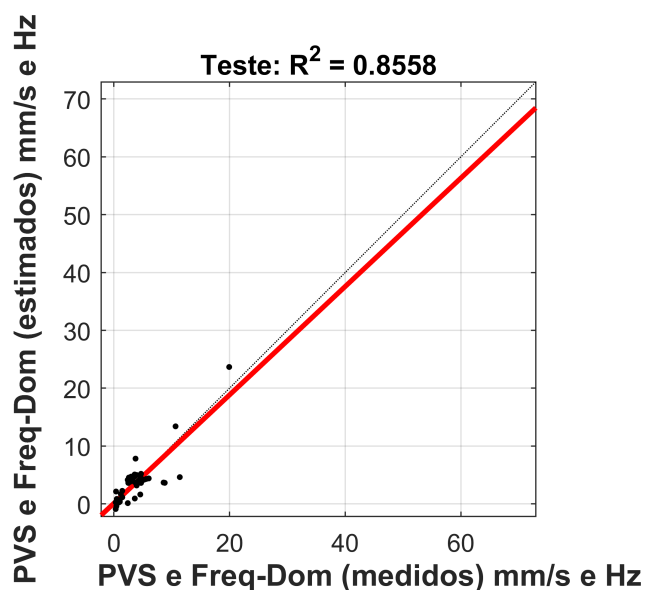
Fonte: elaborada pelo autor

Figura 5.23: PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (validação).




Fonte: elaborada pelo autor

Figura 5.24: PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (teste).



Fonte: elaborada pelo autor

Figura 5.25: PVS e Frequência Dominante medidos x PVS e Frequência Dominante estimados (todos os dados).



Fonte: elaborada pelo autor

As Figuras 5.17, 5.21 e 5.25 mostram que a vibração PVS, a pressão acústica e a frequência dominante previstas pelas redes neurais são muito próximas da vibração PVS, pressão acústica e frequência medidas quando consideramos todo o conjunto de dados. Os valores de coeficiente de determinação de  $R^2 = 0.9672$ ,  $R^2 = 0.9003$  e  $R^2 = 0.9015$  indicam que em porcentagens

96,72%, 90,03% e 90,15% o quanto o modelo consegue explicar os valores observados e dessa forma mostra uma boa confiabilidade do modelo.

Para comparar o desempenho dos modelos deve-se usar o coeficiente de determinação ajustado  $R_a^2$ , pois as amostras possuem tamanhos diferentes. Esse coeficiente é dado pela Equação 5.1 (LEACH e HENSON, 2007):

$$R_a^2 = 1 - \left( \frac{n-1}{n-(p+1)} \right) (1 - R_p^2), \quad (5.1)$$

onde  $R_a^2$  é o coeficiente de determinação ajustado,  $p$  é o número de coeficientes,  $n$  é o número de amostras e  $R_p^2$  é o coeficiente de determinação.

Uma comparação entre os coeficientes de determinação ajustados obtidos pelas redes treinadas com e sem valores anômalos pode ser vista na Tabela 5.4.

Tabela 5.4: Coeficientes de Determinação com e sem valores anômalos

$R_a^2(ajustado)$	<b>PVS (mm/s)</b>	<b>Pressão (dB)</b>	<b>PVS e Frequência</b>
<b>SEM VALORES ANÔMALOS</b>	0,9486	0,9090	0,8347
<b>COM VALORES ANÔMALOS</b>	0,9669	0,8995	0,9008

Pode-se observar que as redes treinadas para estimar PVS e frequência dominante sem a remoção dos valores anômalos possuem desempenhos ligeiramente melhor que as redes treinadas com a remoção de valores anômalos. Já as redes treinadas para estimar a pressão acústica possuem praticamente o mesmo desempenho. Esse fato, possivelmente, deve-se à:

- ao retirar os valores anômalos, o número de dados para alimentar e treinar a rede neural diminui e assim o modelo de estimação pode ficar menos robusto ou menos generalista;
- o algoritmo de treinamento da rede neural pondera através de pesos as entradas, dessa forma, uma entrada esporádica ou anômala seria minimizada;
- o sistema de pesos funciona como um filtro, possibilitando diluir valores anômalos;
- a presença de valores anômalos nas entradas da rede neural, durante o treinamento, torna a rede mais generalista e assim melhor em suas estimativas.

Para testar o modelo de estimação de vibração, pressão acústica e frequência utilizando redes neurais, foram separadas 10 amostras dados que estavam fora da base de treinamento. Assim, para cada amostra, a rede neural foi executada e obteve-se os valores estimados. A Tabela 5.5 mostra uma comparação entre o PVS medido e o estimado, bem como o erro da estimativa. Já a Tabela 5.6 mostra a pressão acústica medida em comparação com a estimada e seu erro. Por último, a Tabela 5.7 mostra uma comparação entre a frequência dominante medida e estimada. Pode-se ver que os valores medidos e estimados estão bem próximos, assim, o erro de estimação é pequeno, o que mostra a qualidade do modelo de estimação.

Tabela 5.5: PVS medido x PVS estimado

<b>PVS (medido)(mm/s)</b>	<b>PVS (estimado)(mm/s)</b>	<b>Erro (mm/s)</b>
3,05	2,98	0,07
0,44	0,33	0,11
2,22	2,06	0,16
0,89	0,70	0,19
0,76	0,63	0,13
2,03	1,48	0,55
1,27	1,31	0,04
2,54	1,80	0,74
1,02	0,69	0,33
0,51	0,45	0,06

Tabela 5.6: Pressão Acústica medida x Pressão Acústica estimada

<b>Pressão Acústica (medida)(dB)</b>	<b>Pressão Acústica (estimada)(dB)</b>	<b>Erro (dB)</b>
118,00	117,49	0,51
121,00	119,04	1,96
110,00	111,55	1,55
117,00	114,76	2,24
113,00	110,52	2,48
118,00	120,19	2,19
105,00	104,77	0,23
106,00	104,34	1,66
107,00	107,42	0,42
109,00	107,00	2,00

Tabela 5.7: Frequência Dominante medida x Frequência Dominante estimada

<b>Frequência Dominante (medida)(Hz)</b>	<b>Frequência Dominante (estimada)(Hz)</b>	<b>Erro (Hz)</b>
4,80	4,78	0,02
6,40	6,02	0,38
5,60	5,81	0,21
3,00	3,73	0,73
3,70	3,30	0,40
4,70	3,63	1,07
8,10	8,03	0,07
4,10	5,67	1,57
6,30	4,45	1,85
10,40	9,70	0,70

### 5.3 Interface Gráfica

Uma vez que as redes neurais foram treinadas e escolheu-se a rede com melhor desempenho, o software Matlab<sup>®</sup> gera uma função pela qual é possível estimar os valores de PVS, pressão acústica e frequência, tendo como entradas os valores do plano de fogo. Para possibilitar a escolha dos parâmetros do plano de fogo e avaliar os os efeitos de vibração e pressão acústica, foi criada uma interface gráfica para essa tarefa 5.26.

Figura 5.26: Estimador de vibração PVS, pressão acústica e frequência utilizando o plano de fogo.

Monitoramento e Controle de Vibrações

**Controle de Vibrações ITV**

Plano de Fogo (Ash) | Tab | Mapa de Vibrações | Plano de Fogo | Blastability Index | Explosivos | Dados Geotécnicos

**Distância**  m

**Carga máxima por espera**  kg

**Afastamento**  m

**Espaçamento**  m

**Profundidade dos Furos**  m

**Subfuração**  m

**Tampão**  m

**Razão de Carga**  g/t

**Nº de Furos**

**Constantes do Local de Desmonte**

a

b

c

**Lei de Atenuação**

**PVS (tradicional)**  mm/s

**PVS (RNA)**  mm/s

**Pressão Acústica**  dB

**Frequência Dominante**  Hz

**Calcular PVS**

**Calcular PVS e Frequência**

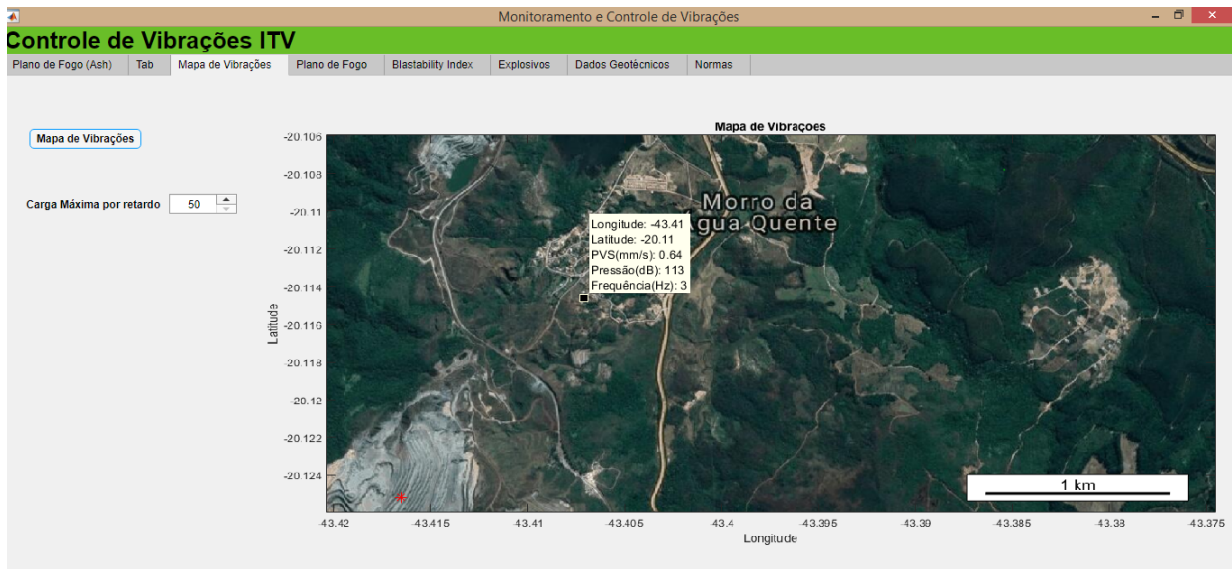
**Calcular Pressão Acústica**

Fonte: elaborada pelo autor

Na Figura 5.26 as caixas da esquerda recebem os valores de entrada e as caixas da direita mostram os valores de estimativa de PVS, pressão acústica e frequência. Também é mostrado o valor calculado de PVS utilizando a lei tradicional de atenuação.

Uma vez fixados os parâmetros do plano de fogo, é possível alterar a carga máxima por espera e avaliar o comportamento da vibração e pressão acústica ao longo da distância entre a carga e um ponto de interesse. Para isso, foi desenvolvida uma interface gráfica que permite, através de um mapa de satélite, determinar um ponto de detonação e com o ponteiro do mouse escolher um ponto de interesse para as estimativas de vibração e pressão acústica. A Figura 5.27 mostra a tela com a funcionalidade dessa interface gráfica.

Figura 5.27: Mapa de vibrações, pressão acústica e frequência.



Fonte: elaborada pelo autor


Outro ponto importante, é que através da interface gráfica é possível identificar no mapa características importantes dos locais de monitoramento das vibrações. Por exemplo, antes da detonação é possível estimar qual serão os níveis de vibração, frequência e pressão acústica em edifícios de interesse como hospitais, igrejas, museus, escolas etc. Dessa forma, o nível de vibração estimado pode ser comparado ao nível máximo permitido pela norma.

## 5.4 Análise de Sensibilidade

Para identificar quais parâmetros de entrada são críticos e qual o grau de influência que cada um tem na saída, foi realizada uma análise de sensibilidade. Entre os diversos métodos para avaliar a importância relativa das variáveis de entrada nas redes neurais, pode-se citar: o método “PaD” (*Partial Derivatives*) ou derivadas parciais que consiste no cálculo das derivadas parciais das saídas de acordo com as variáveis de entrada (SHOJAEEFARD *et al.*, 2013a); o método dos pesos (*weights*) que analisa os pesos das conexões (WANG *et al.*, 2000); o método “Profile” que varia uma variável enquanto mantém as demais constantes (SHOJAEEFARD *et al.*, 2013b) e o método “backward stepwise” que observa a mudança no erro quando o passo e retroalimentação das entradas é executado (GEVREY *et al.*, 2003). O método utilizado no presente trabalho é o método “Profile” pela sua simplicidade de implementação e a facilidade de visualizar os resultados. A análise é apresentada na Figura 5.28.



Figura 5.28: Análise de Sensibilidade.



Fonte: elaborada pelo autor

Concluiu-se que a carga máxima por espera e a distância são os dois fatores que mais influenciam o PVS, seguidos do espaçamento e afastamento. Já era esperado que os fatores que mais afetam a vibração fossem a carga máxima por espera e a distância, visto que a vibração é diretamente proporcional a quantidade de explosivos detonada no mesmo retardo e inversamente proporcional a distância de monitoramento. Os parâmetros de afastamento e espaçamento formam a malha do plano de fogo, a qual a vibração é muito sensível.

## 6. Conclusões e Trabalhos Futuros

A metodologia proposta para previsão e controle de vibrações utilizando redes neurais artificiais mostrou-se eficaz uma vez que, depois de treinada, as redes obtiveram coeficientes de determinação altos (maiores que 90%) para vibração, pressão acústica e frequência. Como o treinamento das redes neurais divide os dados aleatoriamente entre as fases de treinamento, validação e teste, o modelo já começa a ser validado e testado na sua concepção.

Mostrou-se interessante a comparação entre as redes treinadas com a remoção de valores anômalos e sem a remoção de valores anômalos. Viu-se que as redes podem ser robustas quanto ao treinamento com bases de dados com a presença de valores anômalos, uma vez que as redes dessa configuração apresentaram melhor coeficiente de determinação ajustado,  $R_a^2$ . Assim, uma base de dados completa e sem tratamento estatístico, dependendo da característica dos dados, pode ser melhor para treinar o modelo de redes neurais, além de ser mais fácil de ser trabalhada.

As estimativas de vibração e pressão acústica são dependentes de diversas características do plano de fogo, explosivos, litologia e geo-mecânica. Dessa forma, em alguns casos, quanto mais parâmetros de entrada possuir a rede treinada, melhor será o modelo de estimação usando redes neurais. Porém, algumas entradas possuem pouco ou quase nenhum efeito na saída, o que demanda uma análise de sensibilidade para escolher as entradas com maior influência no modelo. Essa análise foi feita e como já era intuitivamente esperado, a carga máxima por espera e distância são os parâmetros que mais contribuem para a vibração.

A possibilidade de estimativa de vibrações através da configuração do plano fogo possibilita uma flexibilidade no controle das mesmas, pois pode-se variar, além da carga máxima por espera, parâmetros geométricos como afastamento x espaçamento, tampão e subperfuração. Além disso, atrelada a previsão vibrações, a estimativa de frequência dominante é fundamental para a avaliação de possíveis danos à estruturas e incomodo a seres humanos.

A interface gráfica desenvolvida no Matlab<sup>®</sup> permite a visualização em mapa de satélite do ponto de detonação e dos níveis de vibração e pressão acústica. Assim, pode-se variar os parâmetros da rede e analisar as vibrações.

O presente trabalho contribui para melhorar a precisão da estimativa de vibração utilizando redes neurais, além de possibilitar a inclusão de parâmetros do plano de fogo no modelo e visualizar, por meio de uma interface gráfica, essas estimativas. Como contribuição científica, o trabalho possibilitou a criação de um artigo que foi apresentado no *Mine Planning and Equipment Selection - MPES 2018* e publicado em *Proceedings of the 27th International Symposium on Mine Planning and Equipment Selection* (TORRES *et al.*, 2019). O artigo pode ser visto no Capítulo 7 (Anexo).

Como trabalho futuro, ou uma próxima etapa deste trabalho, sugere-se a validação do modelo de estimativa de vibrações utilizando redes neurais em campo. Dessa forma, será possível montar um plano de fogo e confrontar os valores medidos e estimados de vibração.

## Referências Bibliográficas

- AGENCY, F. E. M. “Reference manual to mitigate potential terrorist attacks against buildings”, *FEMA-426*, 2003.
- ALOUI, M., BLEUZEN, Y., ESSEFI, E., et al.. “Ground vibrations and air blast effects induced by blasting in open pit mines: Case of Metlaoui Mining Basin, South western Tunisia”, *Journal of Geology and Geophysics*, v. 5, n. 3, 2016.
- AMBRASEYS, N., HENDRON, A. “Dynamic Behaviour of Rock Masses. Rock Mechanics in Engineering Practice. Stagg, F., Zienkiewicz, OC”. 1968.
- ARMSTRONG, L. W. “Evaluation of parameters effecting blast induced vibrations”, 2001.
- ATAEI, M., SERESHKI, F. “Improved prediction of blast-induced vibrations in limestone mines using Genetic Algorithm”, *Journal of Mining and Environment*, v. 8, n. 2, pp. 291–304, 2017.
- BACCI, D. D. L. C. *Vibrações geradas pelo uso de explosivos no desmonte de rochas: avaliação dos parâmetros físicos do terreno e dos efeitos ambientais*. Tese de Doutorado, Instituto de Geociências e Ciências Exatas da Universidade Estadual Paulista., 2000.
- BADAL, K., OTHERS. *Blast vibration studies in surface mines*. Tese de Doutorado, 2010.
- BARNETT, V., LEWIS, T. *Outliers in statistical data*. Wiley, 1974.
- BASU, D., SEN, M. “Blast induced ground vibration norms—a critical review”. Em: *National Seminar on Policies, Statutes & Legislation in Mines*, pp. 112–113, 2005.
- BENJUMEA, J. M. “Vibraciones Causadas Por Actividad Humana: caracterización, efectos y manejo en la Ingeniería Civil”, *Universidad del Valle*, 2003.
- BERNARDO, P. *A utilização da norma NP 2074*. Relatório técnico, Orica, Penamacor, 2017.
- BLANCO, J. A. S. “Rock Fragmentation by Blasting: Proceedings of the 9th Int. Symp. on Rock Fragmentation by Blasting-Fragblast 9, Sept. 2009, Granada Spain”, 2014.
- BURDEN, F., WINKLER, D. “Bayesian regularization of neural networks”. Em: *Artificial neural networks*, Springer, pp. 23–42, 2008.

- CAVADAS, P. M. M., OTHERS. “Optimização do desmonte numa mina a céu aberto com aplicação de air decks”, 2012.
- CHAKRABORTY, A., GUHA, P., CHATTOPADHYAY, B., et al.. “A fusion neural network for estimation of blasting vibration”. Em: *International Conference on Neural Information Processing*, pp. 1008–1013. Springer, 2004.
- DAVIES, B., FARMER, I., ATTEWELL, P. “Ground vibration from shallow sub-surface blasts”, *Engineer*, v. 217, n. 5644, 1964.
- DE NORMALIZACION, A. E., AENOR, C. “Control de vibraciones producidas por voladuras”, *Norma UNE*, pp. 22–381, 1993.
- DE SANEAMENTO AMBIENTAL, C. D. T. “CETESB-Companhia de Tecnologia de Saneamento Ambiental”. Em: *CETESB-Companhia de Tecnologia de Saneamento Ambiental*, CETESB, 2005.
- DINIS DA GAMA, C. “Ruídos e vibrações ligados à utilização dos explosivos e equipamentos”, *Comunicações do 1º Seminário de Auditorias Ambientais Internas. Divisão de Minas e Pedreiras do Instituto Geológico e Mineiro, Portugal*, 1998.
- DINIS DA GAMA, C., PANEIRO, G. “A Incomodidade Humana perante as Vibrações e sua Caracterização Absoluta e Relativa”, 2006.
- DRAPER, N. R., SMITH, H. “Applied regression analysis 3rd edition”. 1998.
- DUVALL, W. I., PETKOF, B. *Spherical propagation of explosion-generated strain pulses in rock*. Relatório técnico, Bureau of Mines, 1958.
- FERREIRA, N., GUERREIRO, H. “O ruído e a indústria extractiva”, *Boletim de Minas*, pp. 3–17, 2010.
- FICKETT, W., DAVIS, W. “Detonation Theory and Experiment, chap. 2”. 2001.
- GEOSONICS. “Sismógrafo Geosonics”. 2018. Disponível em: <<http://www.geosonicsvibratech.com/>>.
- GEVREY, M., DIMOPOULOS, I., LEK, S. “Review and comparison of methods to study the contribution of variables in artificial neural network models”, *Ecological modelling*, v. 160, n. 3, pp. 249–264, 2003.
- GHOSH, A., DAEMEN, J. J., OTHERS. “A simple new blast vibration predictor (based on wave propagation laws)”. Em: *The 24th US Symposium on Rock Mechanics (USRMS)*. American Rock Mechanics Association, 1983.

- HODGE, V., AUSTIN, J. “A survey of outlier detection methodologies”, *Artificial intelligence review*, v. 22, n. 2, pp. 85–126, 2004.
- HUSTRULID, W. A. “Underground mining methods handbook”, 1982.
- JIMENO, C. L., BERMÚDEZ, P. G. *Manual de perforación, explosivos y voladuras: minería y obras públicas*. Universidad Politécnica de Madrid, Grupo de Proyectos de Ingeniería, 2017.
- JIMENO, E. L., JIMINO, C. L., CARCEDO, A. *Drilling and blasting of rocks*. CRC Press, 1995.
- JIMENO, L. “Parametros Criticos en la Fragmentacion de Rocas con Explosivos”, *VI Jornadas Minerometalurgicas*, 1980.
- JORGE, L., NUNES, R., MIGUEL, P. “Controlo de Vibrações provocadas pela utilização de Explosivos na Indústria Extractiva próximo de Áreas Urbanas – Análise das Principais Normas Europeias – Control of Vibrations produced by the use of Explosives in the Quarry – Analysis of the Main Europe”, pp. 783–786.
- KAMALI, M., ATAEI, M. “Prediction of blast induced ground vibrations in Karoun III power plant and dam: a neural network”, *Journal of the Southern African Institute of Mining and Metallurgy*, v. 110, n. 8, pp. 481–490, 2010.
- KHANDELWAL, M., SINGH, T. “Prediction of blast induced ground vibrations and frequency in opencast mine: a neural network approach”, *Journal of sound and vibration*, v. 289, n. 4-5, pp. 711–725, 2006.
- KHANDELWAL, M., SINGH, T. “Evaluation of blast-induced ground vibration predictors”, *Soil Dynamics and Earthquake Engineering*, v. 27, n. 2, pp. 116–125, 2007.
- KIHLSTROM, B., WILKINSON, J. H. *The modern technique of rock blasting*. 1963.
- KULATILAKE, P., QIONG, W., HUDAVERDI, T., et al.. “Mean particle size prediction in rock blast fragmentation using neural networks”, *Engineering Geology*, v. 114, n. 3-4, pp. 298–311, 2010.
- LANGFORS, U., KIHLSSTRÖM, B. *The modern technique of rock blasting*. Wiley, 1978.
- LEACH, L. F., HENSON, R. K. “The use and impact of adjusted R2 effects in published regression research”, *Multiple Linear Regression Viewpoints*, v. 33, n. 1, pp. 1–11, 2007.
- LILLY, P. A. “An empirical method of assessing rock mass blastability”, *The Aus*, 1986.

- LOURAKIS, M. I. “A brief description of the Levenberg-Marquardt algorithm implemented by levmar”, *Foundation of Research and Technology*, v. 4, n. 1, pp. 1–6, 2005.
- MENCACCI, S., FARNFIELD, R. “The measurement and analysis of near-field pressure transients in production blasting”. Em: *2nd European Federation of Explosives Engineers World Conference On Explosives and Blasting, Prague*, 2003.
- MONJEZI, M., DEHGHANI, H. “Evaluation of effect of blasting pattern parameters on back break using neural networks”, *International Journal of Rock Mechanics and Mining Sciences*, v. 45, n. 8, pp. 1446–1453, 2008.
- MONJEZI, M., RIZI, S. H., MAJD, V. J., et al.. “Artificial neural network as a tool for back-break prediction”, *Geotechnical and Geological Engineering*, v. 32, n. 1, pp. 21–30, 2014.
- NAVARRO TORRES, V., DINIS DA GAMA, C. “Underground Environmental Engineering and Applications”, *CETEM/CNpq Rio de Janeiro*,(2005), p. 550, 2005.
- NBR, A. “9653-Guia para avaliação dos efeitos provocados pelo uso de explosivos nas minerações em áreas urbanas”, *Rio de Janeiro*, 2005.
- NBR 9653, A. “9653-Guia para avaliação dos efeitos provocados pelo uso de explosivos nas minerações em áreas urbanas”, *Rio de Janeiro*, 2018.
- NEAUPANE, K. M., ACHET, S. H. “Use of backpropagation neural network for landslide monitoring: a case study in the higher Himalaya”, *Engineering Geology*, v. 74, n. 3-4, pp. 213–226, 2004.
- NETO, E. C. H. G. J. “2-ESCAVAÇÕES DE TÚNEIS”, *Obras Civis*, 2012.
- NGUYEN, H., BUI, X.-N., BUI, H.-B., et al.. “A comparative study of artificial neural networks in predicting blast-induced air-blast overpressure at Deo Nai open-pit coal mine, Vietnam”, *Neural Computing and Applications*, pp. 1–17, 2018.
- NIEBLE, C. M. *Desmontes cuidadosos com explosivos: aspectos de engenharia e ambientais*. São Paulo, Oficina de Textos, 2017.
- NOBEL, D. *Blasting and Explosives Quick Reference Guide-2010*. Relatório técnico, REF0110/0210/AZZAUS, 2010.
- NOISE, E. “Brüel&Kjær Sound & Vibration Measurement A”, *S, Denmark Naerum*, 2001.
- PRASAD, N., SINGH, R., LAL, S. P. “Comparison of back propagation and resilient propagation algorithm for spam classification”. Em: *2013 Fifth International Conference on Computational Intelligence, Modelling and Simulation*, pp. 29–34. IEEE, 2013.

- RICHARDS, A., MOORE, A. “Blast vibration course: measurement, assessment, control”, *Terrock Consulting Engineers (Terrock Pty Ltd). Australia*, 2012.
- RICHART, F. E., HALL, J. R., WOODS, R. D. “Vibrations of soils and foundations”, 1970.
- ROADS, M. “Transport Noise Management Code of Practice : Volume 2 – Construction Noise and Vibration”, v. 2, n. March, 2016.
- ROCHA, P. E. D. T. E. *Estudo de caso escavação e tratamento para emboque de túnel em rocha utilizando o método nat-região portuária*. Tese de Doutorado, Universidade Federal do Rio de Janeiro, 2014.
- ROY, P. “Putting ground vibration predictions into practice”, *Colliery Guardian*, v. 241, n. 2, pp. 63–7, 1993.
- SHOJAEFARD, M. H., AKBARI, M., TAHANI, M., et al.. “Sensitivity analysis of the artificial neural network outputs in friction stir lap joining of aluminum to brass”, *Advances in Materials Science and Engineering*, v. 2013, 2013a.
- SHOJAEFARD, M. H., BEHNAGH, R. A., AKBARI, M., et al.. “Modelling and Pareto optimization of mechanical properties of friction stir welded AA7075/AA5083 butt joints using neural network and particle swarm algorithm”, *Materials & Design*, v. 44, pp. 190–198, 2013b.
- SILVEIRA, L. G. C. “Controle de vibrações e pressão acústica no desmonte de rochas com explosivos: estudo de caso em uma mina do Quadrilátero Ferrífero.” 2017.
- SINGH, T. “Artificial neural network approach for prediction and control of ground vibrations in mines”, *Mining Technology*, v. 113, n. 4, pp. 251–256, 2004.
- SISKIND, D. E., STACHURA, V. J., STAGG, M. S., et al.. *Structure response and damage produced by airblast from surface mining*, v. 8485. Citeseer, 1980.
- STANDARD, B. “Guide to evaluation of human exposure to vibration in buildings”, 2008.
- STANDARD, I. “Criteria for safety and design of structures subjected to under ground blast”, *ISI, IS-6922*, 1973.
- SUN, C., LATER, D. W., CHEN, G. “Analysis of the effect of borehole size on explosive energy loss in rock blasting”, *Fragblast*, v. 5, n. 4, pp. 235–246, 2001.
- THOMPSON, R. “A note on restricted maximum likelihood estimation with an alternative outlier model”, *Journal of the Royal Statistical Society: Series B (Methodological)*, v. 47, n. 1, pp. 53–55, 1985.

- THILE, R. N. “Artificial neural network approach to predict blast-induced ground vibration, airblast and rock fragmentation”, 2016.
- TORRES, N., REIS, J., LUIZ, P., et al.. “Neural Network Applied to Blasting Vibration Control Near Communities in a Large-Scale Iron Ore Mine”. Em: *Proceedings of the 27th International Symposium on Mine Planning and Equipment Selection-MPES 2018*, pp. 81–91. Springer, 2019.
- TORRES, V. N., SILVEIRA, L. G., LOPES, P. F., et al.. “Assessing and controlling of bench blasting-induced vibrations to minimize impacts to a neighboring community”, *Journal of Cleaner Production*, v. 187, pp. 514–524, 2018.
- TRUMPY, A. J. “National Park Service”, *Green Culture: An A-to-Z Guide*, 2007. doi: 10.4135/9781412975711.n90. Disponível em: <[https://www.nps.gov/parkhistory/online\\_books/npsg/explosives/contents.htm](https://www.nps.gov/parkhistory/online_books/npsg/explosives/contents.htm)>.
- ULUSAY, R. *The ISRM Suggested Methods for Rock Characterization , Testing and Monitoring* .: 2014. ISBN: 9783319077123.
- VIBRATION, C. “Transportation and Construction Vibration Guidance Manual”, 2013.
- VON ZUBEN, F. J., OTHERS. “Modelos paramétricos e não-paramétricos de redes neurais artificiais e aplicações”, 1996.
- VON ZUBEN, I.-P. F. J., ATTUX, R. R. “Redes Neurais com Funções de Ativação de Base Radial”, *DCA/FEEC/Unicamp*, 2001.
- WANG, W., JONES, P., PARTRIDGE, D. “Assessing the impact of input features in a feed-forward neural network”, *Neural Computing & Applications*, v. 9, n. 2, pp. 101–112, 2000.
- ZHANG, Z.-X. *Rock fracture and blasting: theory and applications*. Butterworth-Heinemann, 2016.



## **7. Anexo**

Abaixo, um cópia do artigo apresentado no *Mine Planning and Equipment Selection - MPES 2018* e publicado em *Proceedings of the 27th International Symposium on Mine Planning and Equipment Selection* (TORRES *et al.*, 2019).

# Neural Network Applied to Blasting Vibration Control Near Communities in a Large-Scale Iron Ore Mine



N. Torres, J. A. Reis, P. L. Luiz, J. H. R. Costa and L. S. Chaves

## 1 Introduction

The growing demand for minerals results in increased use of explosives for blasting in open pit mining [1]. Blasting is usually the main method used in hard rock mining to achieve rock breakage and fragmentation [2]. Blasting and fragmentation directly affects operational activities such as loading, hauling and mineral processing. Nevertheless, only 20–30% of the explosive energy is efficiently used in fragmentation and the remaining energy generates collateral effects that has potential environmental impacts such as ground vibration, air overpressure, dust generation, back break and fly rock [3].

Shi and Chen [4] considered the maximum charge per delay and the waveform interference by the delay blasting as important factors influencing the ground vibration and the final pit walls stability. Armaghani et al. [2] and Khandelwal and Singh [3] have obtained the maximum charge per delay as one of the main influencing factors on the resultant vibration velocity.

Several studies have been conducted using Artificial Neural Network (ANN) to predict blast-induced ground vibrations. Chakraborty et al. [5] studied multilayer perceptron networks to predict ground vibrations and compared it with different empirical models. Singh [6] applied feed-forward back propagation neural network to predict and control ground vibrations in mines. Khandelwal and Singh [7] predicted blast-induced ground vibration and frequency in open pit mines using ANN models and later [8] compared and evaluated ground vibration predictors using ANN models. Monjezi and Dehghani [9] applied ANN to evaluate the effects of blasting

---

N. Torres (✉) · J. H. R. Costa · L. S. Chaves  
Instituto Tecnológico Vale (ITV), Belém, Brazil  
e-mail: [vidal.torres@itv.org](mailto:vidal.torres@itv.org)

J. A. Reis · P. L. Luiz  
Vale S.A., Rio de Janeiro, Brazil

© Springer Nature Switzerland AG 2019  
E. Widzyk-Capehart et al. (eds.), *Proceedings of the 27th International Symposium on Mine Planning and Equipment Selection - MPES 2018*,  
[https://doi.org/10.1007/978-3-319-99220-4\\_7](https://doi.org/10.1007/978-3-319-99220-4_7)

pattern parameters on backbreak occurrence. Monjezi et al. [10] predicted backbreak formation using ANN.

The parameters that determine blast-induced ground vibrations can be divided into three groups: (1) Blast design parameters; (2) explosive parameters and (3) rock mass parameters [11]. Burden, spacing, hole depth, stemming, sub-drilling, maximum charge per delay and hole diameter are all blast design parameters. Explosive type, velocity of detonation (VOD), density, strength and specific charge are explosive parameters, and these are controllable. The third group consists of the rock mass parameters, such as Young's modulus, Poisson's ratio, P-wave velocity and Blastability Index, which are uncontrollable [11].

The Blastability Index, BI suggested by Lilly [12] can be calculated according to Eq. (1):

$$BI = 0.5 \times (RMD + JPS + JPO + RDI + S) \quad (1)$$

where: RMD is the rock mass description (powdery or friable = 10, blocky = 20 and massive = 50); JPS is the joint plane spacing (<0.1 m = 10, 0.1–1.0 m = 20, >1.0 m = 50); JPO is the joint plane orientation (horizontal = 10, dip out of face = 20, strike normal to face = 30, dip into face = 40); RDI is the rock density influence which is equal to  $25d - 50$ , where  $d$  is density; and  $S$  is the rock strength, equals to 0.05 times UCS, where UCS is the uniaxial compressive strength [12].

In the mining industry, the ground vibrations caused by blasting operations commonly have negative effect on adjacent populations, relative to possible infrastructure damage and human discomfort. Several countries have established limits for ground vibration to minimize infrastructure damage and human discomfort, including Brazil [13], Germany [14], Portugal [15], and the United States [16]. Therefore, it is essential to evaluate and control vibrations to avoid these undesirable effects.

This paper shows the development and application of an ANN to predict and control blast-induced vibrations at a community close to a large-scale open pit iron mine. The ANN was trained to predict the peak vector sum (PVS) using measured data obtained from mine blasting operations. The communities are frequently facing blast-induced ground vibration issues, therefore, ANN may be highly suitable to relate the blasting parameters and the vibration level.

## 2 Vibration Control Methodology

The method proposed by Navarro Torres et al. [17] involves the prediction of blast-induced ground vibrations through mathematical models and the vibration control through the adjustment of the maximum charge per delay by using delay blasting. The adapted method for the present work (Fig. 1) uses ANN to predict vibration velocity and the adequacy of the maximum charge per delay in a blast by the use of delay blasting to control the maximum resultant vibration, and is summarized in four steps:

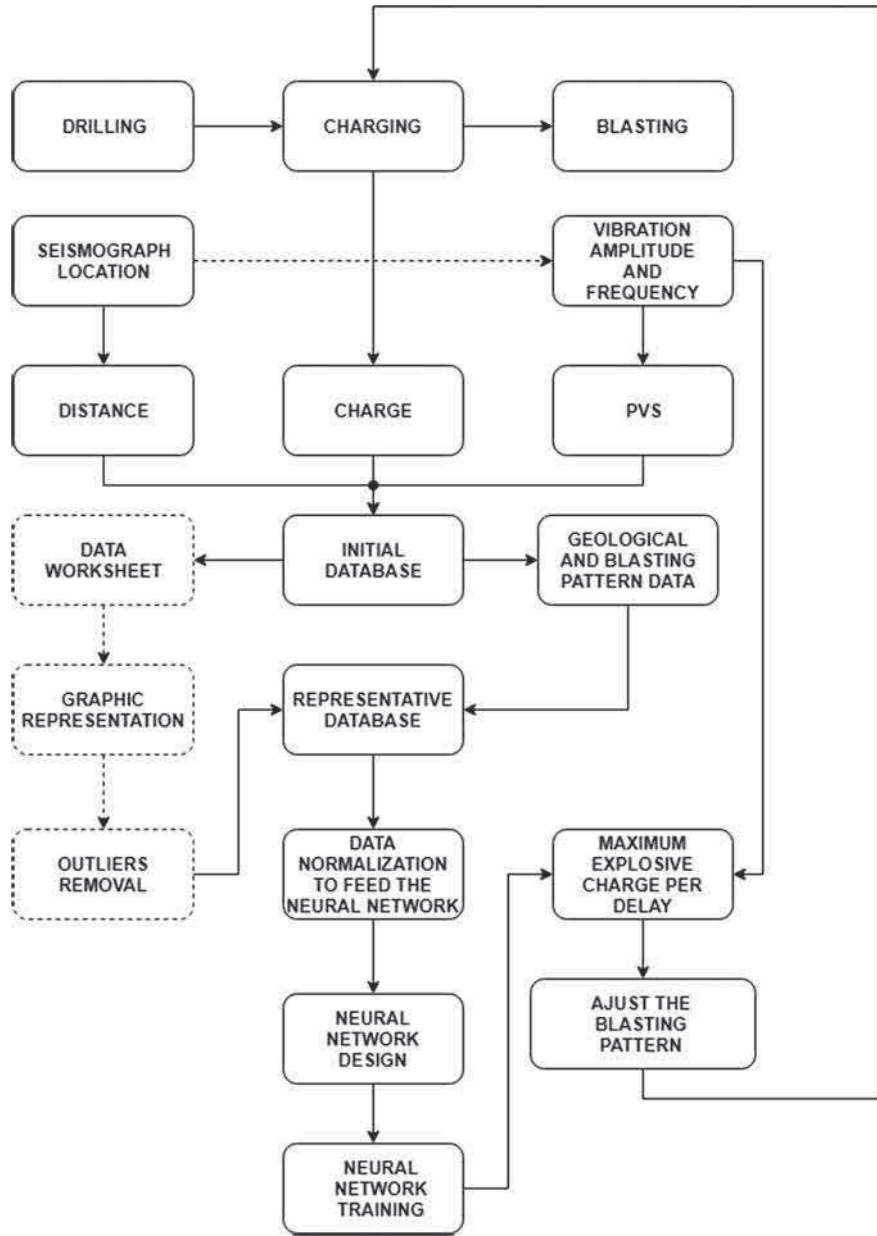


Fig. 1 Methodology proposed for blast-induced vibration and their control

- (1) In situ blasting vibration monitoring to measure the PVS and the frequency ( $f$ ) caused by blasting, considering the maximum charge per delay ( $Q$ ), the

- distance between the blasting source and the position of the geophone ( $D$ ), the blast design parameters (burden, spacing, hole depth, stemming, sub-drilling and powder factor), an explosive parameter (VOD) and rock mass parameters (blastability index, P-wave velocity, Young's modulus and Poisson's);
- (2) Obtain the blasting vibration predictor by training an ANN with the monitoring data;
  - (3) Validate and test the ANN performance using new blasting data, and check the predictor's performance using all data set;
  - (4) Feed the ANN predictor with the data for a planned blasting in order to predict the expected vibration in a point and evaluate the adequacy of the planned maximum charge per delay to the desired vibration limits.

### 3 Artificial Neural Network

ANNs are computational techniques, which present a mathematical model inspired by the neural structure of intelligent organisms to acquire knowledge through experience. An artificial neural network consists of several processing units. These processing units are usually connected through communication channels associated with the given weight. These units are only operating on its local data, which are received by connections. The intelligent behavior of an ANN comes from the interactions between the network processing units [18].

The ability to "learn" associated with a neural network is one of the most important qualities of these structures. It is considered "learning" process that adapts the behavior and results in a performance improvement. In the context of ANNs, learning or training corresponds to the adjustment process of the free parameters of the network through a mechanism of presentation of environmental stimuli, known as standards (or data) input or training.

Figure 2 shows the network used in the Matlab® software to represent the ANN. The network has three layers, in which the hidden one has 15 neurons, the output layer has one neuron ( $Y_k; k = 1$ ) and the input layer has 11 neurons ( $X_i; i = 1, 2, 3 \dots, 13$ ). The ANN architecture is showed in Fig. 3 and the connections are explained by Eqs. (4) to (10) [19]. The neuron  $j$  from the hidden layer is connected with all neurons from the input layer expressed by Eq. (2).

$$X_i = (X_1, X_2, \dots, X_n) \quad (2)$$

The input values to the Net network's input layer are as defined in Eq. (3).

$$\text{Net}_j = \sum_{i=1}^n (X_i W_{ij} + \theta_j) \quad (3)$$



Fig. 2 Architecture of Neural Network in Matlab®




Fig. 3 Back-propagation neural network

where:  $X_i$  is the input value,  $W_{ij}$  is the weight of the connection between the neuron  $i$  from the input layer and the neuron  $j$ , from the hidden layer,  $\theta_j$  is the fixed activation threshold of the neuron (bias) which may be used or not. As output from the hidden layer, each neuron from this network has a logistic activation function as Eq. (4).

$$Out_j = f(Net_j) = \frac{1}{1 + e^{-(Net_j + \theta_j)}} \quad (4)$$

The sum of the inputs of the  $k$  unit of the output layer is given by the following function expressed by Eq. (5).

$$\text{Net}_k = \sum_{j=1}^m S_j W_{jk} + \theta_k \quad (5)$$

where:  $S_j$  is the input value,  $W_{jk}$  is the weight of the connection between the neuron  $j$  from the input layer and the neuron  $k$  from the output layer,  $\theta_k$  is the fixed activation threshold of the neuron (*bias*) which may be used or not. Therefore, the output of the  $k$  neuron is provided by the function (6).

$$\text{Out}_k = f(N_k) = \frac{1}{1 + e^{(N_k + \theta_k)}} \quad (6)$$

In the learning process, the ANN is presented to a data set corresponding to the input and the respective output. Using the weight of each connections and the fixed threshold from each neuron, the ANN calculates its' own solution comparing the obtained solution to the desired one. Thus, an error could be established as the Eq. (7).

$$e_k = t_k - \text{Out}_k \quad (7)$$

where:  $t_k$  is the target value. The function that determines the total error is the Mean Squared Error expressed by Eq. (8).

$$E = \frac{1}{P} \sum_{k=1}^p (t_k - \text{Out}_k)^2 \quad (8)$$

where:  $p$  is the number of neurons in the output layer. Figure 3 shows how the Input layer, Hidden Layer and Output Layer are connected. The ANN training consists in the process of optimizing the weight vector of the parameters. In other words, the training should identify a local or global minimum value. The steepest descent error surface is calculated using the following rule:

$$\nabla W_{jk} = -\gamma(\delta E / \delta w_{jk}) \quad (9)$$

where:  $\gamma$  = learning rate parameter, and  $E$  = error function. The update of weights for the  $(n + 1)$  pattern is given as Eq. (10):

$$W_{jk}(n + 1) = W_{jk}(n) + \nabla W_{jk}(n) \quad (10)$$

The process is iterative for each pair of training values (set of input data and the target output values) and it is the same for the connections between the hidden and output layers. Each step of this iterative training process is called epoch. As long as the error not achieve the user specified goal, the number of epochs will increase until the network be trained [20].

**Table 1** Input and output parameters for development of ANN

Input parameters	Range	Mean	Unit
Maximum charge per delay (MCPD)	800–2100	1463.5	kg
Distance	100–2000	954.3	m
Burden	4–4.4	4.17	m
Spacing	4.5–5.2	4.79	m
Hole depth	10.2–12.4	11.49	m
Stemming	5–5.8	5.28	m
Sub-drilling	0.4–1.1	0.70	m
Powder factor	0.96–1.76	1.34	kg/m <sup>3</sup>
Velocity of detonation of explosive (VOD)	4000–6500	5315	m/s
Blastability index	58–63	60.6	–
P-wave	1600–3600	2552	m/s
Young's modulus	40–80	63.5	GPa
Poisson ratio	0.25–0.40	0.28	–
Peak vector sum (PVS)	0.19–15.8	1.34	mm/s

#### 4 Case Study in Large Iron Ore Mine from Brazil

The case study was a large open pit iron mine located at the eastern portion of the Quadrilátero Ferrífero, at Minas Gerais state, Brazil, where the community was located about 500 m from the mining operation.

Monitoring systems were installed in different locations which includes: the vicinity of the open pit, the area between mining and the community, and in the community itself. The sum of 133 blast vibration events were used to feed the Neural Network. Vibration sources were from 10 production blasts using emulsion-type of explosive. The monitoring was performed using 20 geophones with natural frequency of 10 Hz and response on the range of 2–250 Hz, distributed in the monitoring area with distances from 100 to 2000 m from the vibration source. The determination of rock physic and mechanical properties follow the ISRM standards [21]. The vibration value used was the PVS that is the peak instant velocity of the vector sum of all the components.

Parameters, such as maximum charge per delay, burden, spacing, hole depth, stemming, sub-drilling, powder factor and velocity of detonation (VOD) were collected from the blast design. The distance was measured according to geophone's locations. A list of the parameters used as input and output to the network training is presented at Table 1.

A three-layer feedforward back-propagation neural network was design to estimate the PVS. The input layer has 13 neurons, the hidden layer has 15 neurons and the output layer has one neuron illustrated in Fig. 4. It was used logistic function as



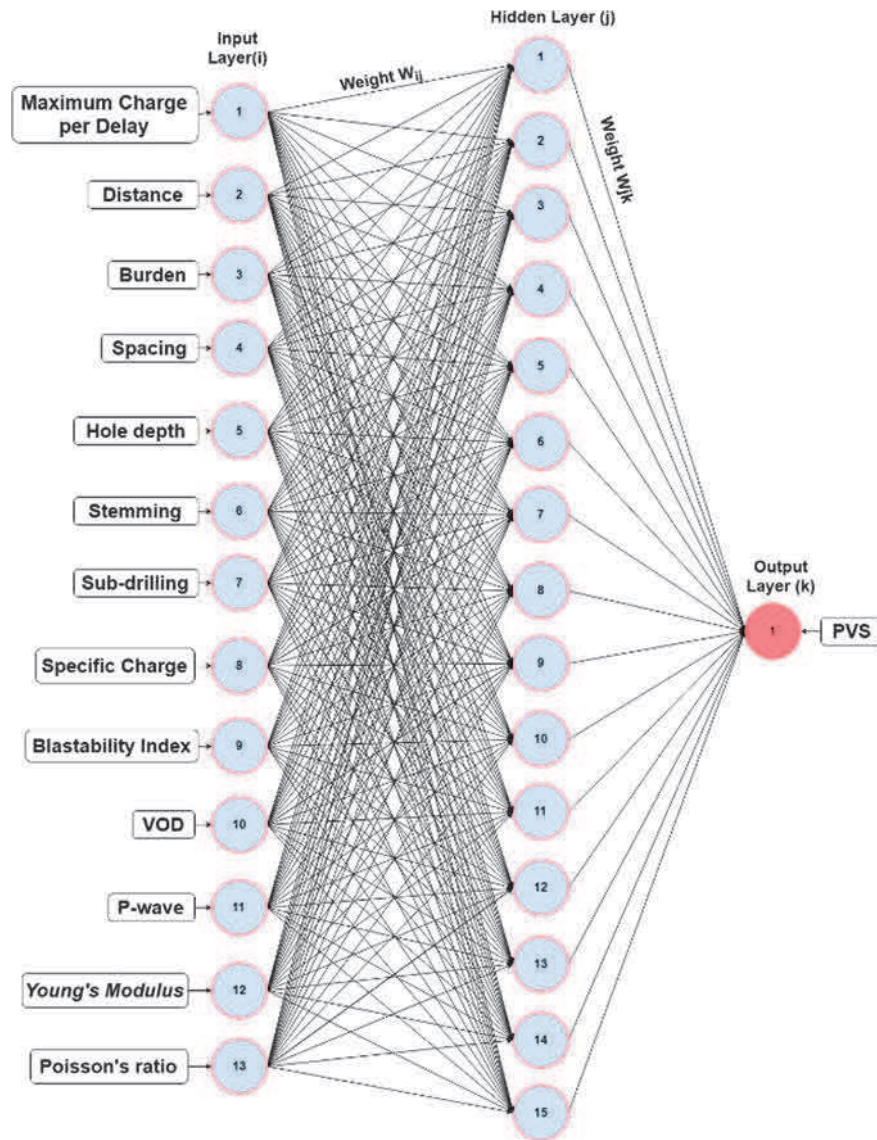


Fig. 4 Artificial neural network architecture

transfer function of the neurons and the Levenberg-Marquardt algorithm to train the network [22].

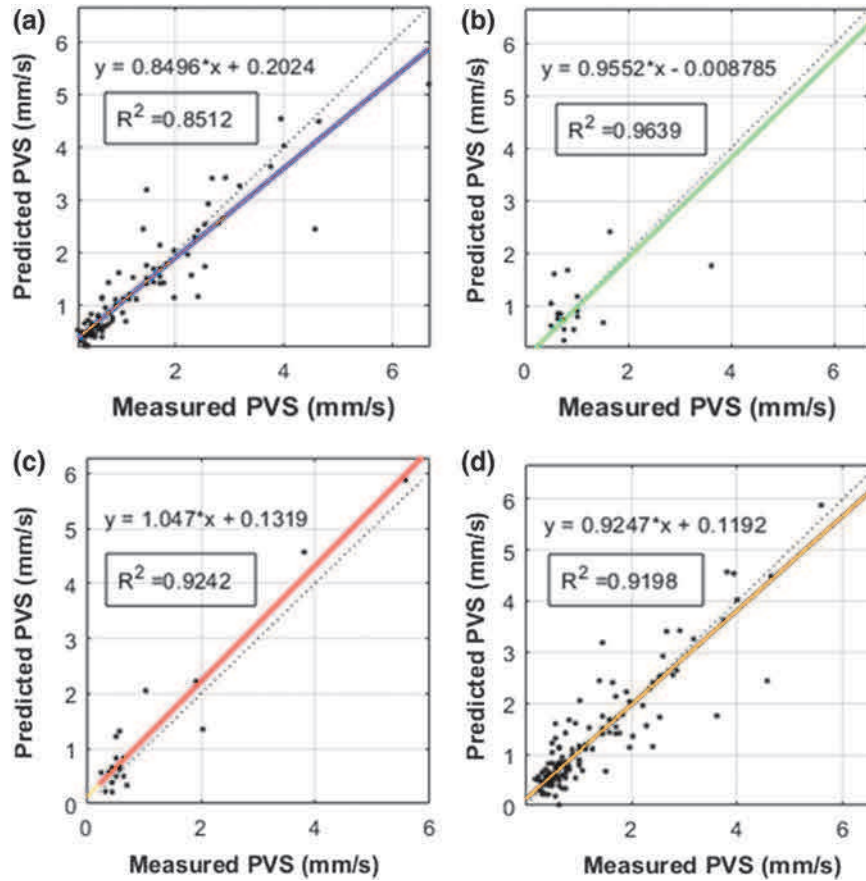


Fig. 5 Measured versus ANN predicted PVS a test stage, b all data set stage

## 5 Results and Discussion

The ANN was trained using 70% of the registered and measured data set, validated with 15% and tested with the remaining 15%. Figure 5 shows the comparison between the measured and the predicted PVS, in mm/s, for the data used at the three stages and for the entire data set. At the training stage, Fig. 5a, the resulting  $R$  squared ( $R^2$ ) was 0.8512, at the validation stage, Fig. 5b, the  $R^2$  obtained was 0.9639, at the test stage, Fig. 5c, the resulting  $R^2$  was 0.9242 and considering the entire data set, Fig. 5d, the resulting  $R^2$  was 0.9198.

$R^2$  is the main performance indicator to evaluate the ANN.  $R^2$  is a statistical measure of how close the data are to the fitted regression line. It is also known as the coefficient of determination. The  $R^2$  gives the relationship between the explained

variation and the total variation, and it ranges from 0 to 100%, providing a number to evaluate how well the model fits the data [23].

As illustrated by Fig. 5d, the vibration velocity (PVS) predicted by ANN is very close to the measured vibration when considering all data set, the  $R^2$  of 0.9198 means a correlation of 91.98%, which indicates the reliability of the model. The developed ANN model has therefore a satisfying reliability on the prediction of blast-induced ground vibration. It may be used as an auxiliary tool for planning and controlling blasts for the mine located nearby the community in order to avoid infrastructure damage and neighborhood discomfort, assessing the environmental impacts caused by blasting by controlling the resultant ground vibrations. By predicting the vibration velocity in the community limits, the model provides more information for the blaster to take decisions related to the maximum charge to be detonated per delay.

## 6 Conclusions

A specific ANN was proposed to predict blast-induced ground vibration at a community near a large iron ore mine in the Quadrilátero Ferrífero region in Brazil. The specialty of the neural network consists of the use of blast design elements and rock properties in contrast with conventional predictors that are only based on maximum charge per delay and the distance between blasting and monitoring point. The conventional empirical predictors do not consider other influencing parameters.

Despite the complex correlation between input and output, the ANN obtained a good performance, showed by the high value of  $R^2$ . The ANN model can learn other hidden patterns that are not clear at the original data set. As long as the data set increases, the ANN can be updated and trained again to obtain better correlation results.

The ANN model may be used to predict the blast-induced ground vibration (PVS) before blasting, representing a valuable tool for evaluating the possible environmental effects of a blast in the surroundings of the mine. The model allows the blaster to establish the maximum charge per delay and the amount of explosive to be used in order to control the ground vibrations, hence avoiding human discomfort and damage to nearby infrastructures from neighboring communities.

## References

1. Álvarez-Vigil, A.E., Gonzalez-Nicieza, C., Gayarre, F.L., Álvarez-Fernández, M.I.: Predicting blasting propagation velocity and vibration frequency using artificial neural networks. *Int. J. Rock Mech. Min. Sci.* **55**, 108–116 (2012)
2. Armaghani, D.J., Hajihassani, M., Mohamad, E.T., Marto, A., Noorani, S.A.: Blasting-induced flyrock and ground vibration prediction through an expert artificial neural network based on particle swarm optimization. *Arab. J. Geosci.* **7**(12), 5383–5396 (2014)

3. Khandelwal, M., Singh, T.N.: Prediction of blast-induced ground vibration using artificial neural network. *Int. J. Rock Mech. Min. Sci.* **46**(7), 1214–1222 (2009)
4. Shi, X.Z., Chen, S.R.: Delay time optimization in blasting operations for mitigating the vibration-effects on final pit walls' stability. *Soil Dyn. Earthq. Eng.* **31**(8), 1154–1158 (2011)
5. Chakraborty, A.K., Guha, P., Chattopadhyay, B., Pal, S., Das, J.: A fusion neural network for estimation of blasting vibration. In: *International Conference on Neural Information Processing*, pp. 1008–1013. Springer, Berlin, Heidelberg (2004)
6. Singh, T.N.: Artificial neural network approach for prediction and control of ground vibrations in mines. *Min. Technol.* **113**(4), 251–256 (2004)
7. Khandelwal, M., Singh, T.N.: Prediction of blast induced ground vibrations and frequency in opencast mine: a neural network approach. *J. Sound Vib.* **289**(4–5), 711–725 (2006)
8. Khandelwal, M., Singh, T.N.: Evaluation of blast-induced ground vibration predictors. *Soil Dyn. Earthq. Eng.* **27**(2), 116–125 (2007)
9. Monjezi, M., Dehghani, H.: Evaluation of effect of blasting pattern parameters on back break using neural networks. *Int. J. Rock Mech. Min. Sci.* **45**(8), 1446–1453 (2008)
10. Monjezi, M., Rizi, S.H., Majd, V.J., Khandelwal, M.: Artificial neural network as a tool for backbreak prediction. *Geotech. Geol. Eng.* **32**(1), 21–30 (2014)
11. Kulatilake, P.H.S.W., Qiong, W., Hudaverdi, T., Kuzu, C.: Mean particle size prediction in rock blast fragmentation using neural networks. *Eng. Geol.* **114**(3–4), 298–311 (2010)
12. Lilly, P.A.: An empirical method of assessing rock mass blastability. *The AusIMM* (1986)
13. ABNT. NBR 9653. Guia para avaliação dos efeitos provocados pelo uso de explosivos nas minerações em áreas urbanas. Norma de Procedimento 13 (Guide for assessing the blasting effects in urban areas) (2005)
14. DEUTSCHE NORM (DIN 4150). Structural Vibration in Buildings e Effects on Structures (1986)
15. NP 2074-2015. Avaliação da influência de vibrações impulsivas em estruturas (Impulsive blasting-induced vibration in structures). Portugal, 17 (2015)
16. USBM (United States Bureau of Mines). Bureau of Mines report, 59. RI 8507 (1980)
17. Torres, V.N., Silveira, L.G., Lopes, P.F., de Lima, H.M.: Assessing and controlling of bench blasting-induced vibrations to minimize impacts to a neighboring community. *J. Clean. Prod.* **187**, 514–524 (2018)
18. Amnieh, H.B., Mozdianfard, M.R., Siamaki, A.: Predicting of blasting vibrations in Sarcheshmeh copper mine by neural network. *Saf. Sci.* **48**(3), 319–325 (2010)
19. Neaupane, K.M., Achet, S.H.: Use of backpropagation neural network for landslide monitoring: a case study in the higher Himalaya. *Eng. Geol.* **74**(3–4), 213–226 (2004)
20. Hudaverdi, T., Kuzu, C., Fisne, A.: Investigation of the blast fragmentation using the mean fragment size and fragmentation index. *Int. J. Rock Mech. Min. Sci.* **56**, 136–145 (2012)
21. Ulusay, R.: *The ISRM Suggested Methods for Rock Characterization, Testing and Monitoring* (2014)
22. Lourakis, M.I.: A Brief Description of the Levenberg-Marquardt Algorithm Implemented by Levmar. In: *Matrix*, vol. 3, no. 2 (August 2005)
23. Draper, N.R., Smith, H.: *Applied Regression Analysis*, vol. 326. Wiley, Hoboken (2014)