



**CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS UNIDADE
ARAXÁ**

LAURA ADRIELE MOURA DA SILVA

**DETERMINAÇÃO DO RMR POR MEIO DA UTILIZAÇÃO DE
REDES NEURAIS ARTIFICIAIS**

ARAXÁ-MG

2022

LAURA ADRIELE MOURA DA SILVA

**DETERMINAÇÃO DO RMR POR MEIO DA UTILIZAÇÃO DE
REDES NEURAIS ARTIFICIAIS**

Trabalho de Conclusão de Curso apresentado ao Centro Federal de Educação Tecnológica de Minas Gerais – Campus Araxá, como requisito parcial para obtenção do grau de Bacharel em Engenharia de Minas.

Orientador: Dr. Allan Erlikhman Medeiros Santos.

ARAXÁ-MG

2022

DETERMINAÇÃO DO RMR POR MEIO DA UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS

Trabalho de Conclusão de Curso apresentado ao Centro Federal de Educação Tecnológica de Minas Gerais - Unidade Araxá, como requisito parcial para obtenção do grau de Bacharel em Engenharia de Minas.

Araxá, 02 de dezembro de 2022.



Prof. Dr. Allan Erlichman Medeiros Santos, Engenheiro de Minas
Centro Federal de Educação Tecnológica de Minas Gerais



Prof. Me. Guilherme Alzamora Mendonça, Engenheiro de Minas
Centro Federal de Educação Tecnológica de Minas Gerais



Prof. Me. Fernando Brandão Rodrigues da Silva, Engenheiro de Minas
Centro Federal de Educação Tecnológica de Minas Gerais

DEDICO ESTE TRABALHO

Aos meus avós Antônio e Maria Aparecida,

À minha irmãzinha Maria Clara.

À Ana e Andressa minhas mães emprestadas.

Ao meu parzinho dessa vida Gustavo Vieira.

*E por fim dedico à minha mãe Gele Adriana que
hoje me assiste do céu.*

AGRADECIMENTOS

À Deus pela força que me move dia após dia e não me permite desistir. Pela coragem em persistir diante de tantos obstáculos e pela superação de todas as dificuldades.

Aos meus avós pelas virtudes com as quais me educaram, por me ensinarem o valor das pequenas conquistas e por serem os pilares que me sustentam.

Às minhas mães (Andresa e Ana Patricia) que sempre estiveram comigo quando mais precisei, com palavras doces nos momentos mais difíceis.

À minha companhia da vida (Gustavo Vieira), por sempre me incentivar, apoiar e torcer por mim.

Às minhas amigas que sempre me impulsionam, quanto orgulho eu tenho de vocês meninas.

Ao meu orientador pela confiança e auxílio durante toda minha jornada acadêmica, obrigada por acreditar em minha capacidade.

À todos os professores do CEFET-MG, pelo empenho e dedicação na construção de nosso conhecimento.

“ A sabedoria é resplandecente, não murcha, mostra-se facilmente para aqueles que a amam. Ela se deixa encontrar por aqueles que a buscam. Ela se antecipa, revelando-se espontaneamente os que a desejam...”

RESUMO

O estudo das condições de estabilidade em taludes de mina é de grande relevância para o planejamento da lavra. O sistema de classificação conhecido como Rock Mass Rating (RMR), é atualmente uma das formas de identificar a qualidade de maciços rochosos, permitindo estimativas adequadas dos parâmetros de resistência do maciço rochoso. O objetivo da pesquisa foi de aplicar este sistema de classificação em um banco de dados da literatura, organizado por Zaré Naghadehi et al. (2013), e nesse contexto avaliar e quantificar o RMR dos maciços rochosos deste banco de dados. A metodologia se divide em: o estudo prévio do banco de dados; determinação do RMR de cada maciço; determinação de modelos preditivos do tipo Redes Neurais Artificiais relacionando as variáveis presentes no banco de dados e as classificações RMR dos maciços. O banco de dados em estudo é composto pelas variáveis condições hidráulicas, propriedades das descontinuidades, RQD, resistência da rocha intacta, tipo de rocha, alteração, regime tectônico, geometria do talude, método de desmonte, histórico de instabilidade e condições de estabilidade. O estudo resultou na adição de duas novas variáveis compondo o banco de dados, são elas as classes de RMR 1 e RMR 2 que representa respectivamente os valores mínimas e máximas nos intervalos, ainda um modelo que permite relacionar a qualidade do maciço em classes de RMR e às variáveis do banco de dados. O modelo de rede neural artificial apresentou bons resultados referentes à aprendizagem de máquina sob o método de classificação por classes de RMR. Observou-se que o banco de dados se limita em Classe II, III e IV, visto que, não apresenta valores compreendidos em Classe I e V, dessa forma, o modelo também é limitado. Nota-se ainda que a maioria dos dados está compreendida na Classe III, dessa forma, a Classe III apresenta menores valores de acurácia, sensibilidade e especificidade na análise dos dados em comparação aos mesmos parâmetros para as Classes II e IV.

Palavras-chave: RMR, Redes Neurais Artificiais, Classes, Maciço

ABSTRACT

The study of stability conditions in mine slopes is of great relevance for mine planning. The classification system known as Rock Mass Rating (RMR) is currently one of the ways to identify the quality of rock masses, allowing adequate estimates of rock mass strength parameters. The aim of the research was to apply this classification system to a literature database, organized by Zaré Naghadehi et al. (2013), and in this context to evaluate and quantify the RMR of the rock masses in this database. The methodology is divided into: the previous study of the database; determination of the RMR of each rock mass; determination of predictive models of the Artificial Neural Networks type relating the variables present in the database and the RMR classifications of the rock masses. The database under study is composed of the variables hydraulic conditions, discontinuity properties, RQD, intact rock strength, rock type, alteration, tectonic regime, slope geometry, blasting method, instability history, and stability conditions. The study resulted in the addition of two new variables to the database, namely the maximum and minimum RMR classes and a model that allows relating the rock mass quality in RMR classes to the variables in the database. The artificial neural network model showed good results regarding machine learning under the RMR class classification method. It was observed that the database is limited in Class II, III and Class IV, not presenting values of Class I and Class V. It is also noted that the largest amount of data is comprised in Class III, thus, Class III presents lower values of accuracy, sensitivity and specificity in the analysis of the data compared to the same parameters analyzed for Classes II and IV.

Keywords: RMR, Artificial Neural Networks, Classes, Massif

LISTA DE QUADROS E TABELAS

Tabela 1: Descrição dos espaçamentos médios. Adaptado de (ISMR, 1983)	21
Tabela 2: Classificação da persistência segundo seu tamanho. Adaptado de (ISMR, 1983).	22
Tabela 3: Classificação em relação aos tamanhos de abertura. Adaptado de (Barton, 1978).	25
Tabela 4: Descrição do material presente no preenchimento de uma junta. Adaptado de (Barton, 1978).	26
Tabela 5: Correlação entre o grau de alteração e as condições visuais de uma rocha: Adaptado de (ISMR, 1981).	26
Tabela 6: Relação entre o valor de RQD e a qualidade da rocha. Adaptado de (Brown, 1981)	30
Tabela 7: Classificação de campo da resistência dos materiais rochosos e correlação com a resistência à compressão uniaxial. Adaptado de (Brown, 1981).	31
Tabela 8: Relação entre os parâmetros e seus pesos. Adaptado de (Bieniawski, 1973).	33
Tabela 9: Classificação das condições das discontinuidades. Adaptado de (Bieniawski, 1989).	34
Tabela 10: Classificação dos maciços rochosos segundo o RMR de acordo com Bieniawski (1989).	35
Tabela 11: Representação de uma matriz de confusão.	41
Tabela 12: Descrição do banco de dados de Naghadehi et al. (2013).	43
Tabela 13: Descrição das variáveis presentes no banco de dados de Naghadehi et al. (2013).	44
Tabela 14: Descrição da divisão entre máximo e mínimo dos parâmetros dispostos em intervalos	46
Tabela 15: Nomenclatura adotada para tratativa no software R Studio.	47
Tabela 16: Amostra do banco de dados final representando os resultados de RMR.	52
Tabela 17: Estatísticas Tabuladas: RMR 1 valores mínimos no intervalo (Linhas); RMR 2 valores máximos nos intervalos (Colunas).	53

LISTA DE FIGURAS

Figura 1: Representação de camadas setorizadas representando a resistência e o grau de fraturamento da rocha pela profundidade. Adaptado de (Deere & Patton, 1971).	18
Figura 2: Representação das características das descontinuidades. Modificado de (Hoek e Bray, 1981).	19
Figura 3: Representação da orientação de uma descontinuidade no espaço. Adaptado de (Hoek e Bray, 1981.)	20
Figura 4: Influência das irregularidades nas paredes das descontinuidades com a resistência. Adaptado de (Hoek e Bray, 1981.)	23
Figura 5: Tipos de rugosidades	23
Figura 6: Classificação dos tipos de rugosidade por medidas visuais segundo o coeficiente de rugosidade JRC. Adaptado de (Barton e Choubey, 1977).	24
Figura 7: Representação visual do cálculo do RQD pelo furo de sonda. Adaptado de DEERE & DEERE (1988).	29
Figura 8: Diagrama ilustrativo do efeito escala. Adaptado de Hoek (2002).	32
Figura 9: Representação de um neurônio biológico. Adaptado de SHANMUGANATHAN & SAMARASINGHE, 2016).	37
Figura 10: Representação do neurônio por McCulloch e Pitts.	38
Figura 11: Representação dos tipos de articulação de redes neurais artificiais.	39
Figura 12: Representação gráfica da função threshold . Adaptado de (Santos, 2021)	40
Figura 13: Representação gráfica da função Sigmóide. Adaptado de (Santos, 2021)	40
Figura 14: Representação gráfica da função Tanh. Adaptado de Santos (2021)	41
Figura 15: Fluxograma completo da metodologia proposta.	49
Figura 16: Gráfico representando a dispersão entre os valores de RMR máximo e mínimo.	53
Figura 17: Distribuição das classes referentes aos valores de RMR máximos.	54
Figura 18: Distribuição das classes referentes aos valores de RMR mínimos	55
Figura 19: Comparação de escalas entre as variáveis mínimas.	56
Figura 20: Comparação de escalas entre as variáveis máximas.	56
Figura 21: Testes feitos para determinação do número de neurônios no treino.	57
Figura 22: Distribuição dos dados de RMR 1 para valores mínimos nos intervalos antes do balanceamento.	58
Figura 23: Distribuição dos dados de RMR 1 para valores mínimos nos intervalos depois do balanceamento.	58

Figura 24: Arquitetura dos neurônios utilizando as três camadas referentes às classes de RMR 1 para valores mínimos nos intervalos.	59
Figura 25: Gráfico relacionando a acurácia entre os treinos e testes referentes ao RMR 1 para valores mínimos nos intervalos.	60
Figura 26: Resultados do treino para os valores mínimos da classe II.	60
Figura 27: Resultados do teste para valores mínimos da classe II.	61
Figura 28: Resultados do treino para valores mínimos classe III.	62
Figura 29: Resultados teste para valores mínimos classe III.	62
Figura 30: Resultados treino para valores mínimos classe IV.	63
Figura 31: Resultados teste para valores mínimos classe IV.	63
Figura 32: Distribuição das classes de RMR 2 para valores máximos nos intervalos antes do balanceamento.	64
Figura 33: Distribuição das classes de RMR 2 para valores máximos nos intervalos depois do balanceamento.	65
Figura 34: Arquitetura dos neurônios utilizando as três camadas referentes às classes de RMR 2 para valores máximos nos intervalos.	66
Figura 35: Representação gráfica da acurácia dos testes envolvendo os dados de RMR 2 para valores máximos nos intervalos.	67
Figura 36: Resultados treino para valores máximos classe II.	67
Figura 37: Resultados teste para valores máximos classe II.	68
Figura 38: Resultados treino para valores máximos de classe III.	69
Figura 39: Resultados teste para valores máximos de classe III.	69
Figura 40: Resultados treino para valores máximos de classe IV.	70
Figura 41: Resultados teste para valores máximos de classe IV.	70

LISTA DE EQUAÇÕES

Equação 1: Frequência das descontinuidades	20
Equação 2: Espaçamento médio das descontinuidades.	20
Equação 3: Cálculo do RQD a partir de um testemunho.	28
Equação 4: Cálculo de RQD de acordo com a frequência das descontinuidades.	29
Equação 5: Cálculo do RQD a partir do índice Jv.	29
Equação 6: Cálculo do índice Jv.	30
Equação 7: Função de ativação primordial.	38
Equação 8: Função de ativação do tipo Threshold.	39
Equação 9: Função de ativação do tipo Sigmoidal.	40
Equação 10: Função de ativação do tipo Tanh.	41
Equação 11: Derivação da função 10.	41
Equação 12: Cálculo da acurácia a partir da matriz de confusão.	42
Equação 13: Cálculo da sensibilidade a partir da matriz de confusão.	42
Equação 14: Cálculo da especificidade a partir da matriz de confusão.	42
Equação 15: Cálculo da acurácia balanceada ou eficiência.	42

SUMÁRIO

1. INTRODUÇÃO	15
2. REFERENCIAL TEÓRICO	17
2.1 Maciço Rochoso	17
2.2 Descontinuidades	18
2.2.1 Orientação:	19
2.2.2 Espaçamento:	20
2.2.3 Persistência:	21
2.2.4 Rugosidade:	22
2.2.5 Abertura de juntas:	24
2.2.6 Preenchimento	25
2.3 Alteração da Rocha	26
2.4 Rock Quality Designation (RQD)	28
2.5 Resistência da rocha intacta	30
2.6 Efeito escala	32
2.7 Rock Mass Rating (RMR)	32
2.8 Inteligencia artificial	35
2.81 Redes Neurais Artificiais “RNAs”	36
2.82 As funções de ativação	39
2.83 Validação para modelos de classificação	41
2.9 Banco de dados de Zaré Naghadehi	43
3. METODOLOGIA	45
3.1 Considerações iniciais	46
3.2 Materiais	46
3.3 Análise do banco de dados	46
3.4 Tratamento dos dados	47
3.5. Treinamento das redes neurais	50
3.6 Validação dos resultados	51
4. RESULTADOS E DISCUSSÃO	51
4.1 Cálculo de RMR Intervalos Máximo e Mínimo.	51
4.2 Análise preliminar do banco de dados	52
4.3 Treinamento do modelo	55
4.4 Resultados RMR 1 valores de intervalo mínimo.	57
4.5 Resultados RMR 2 valores de intervalo máximo.	64

	14
5. CONCLUSÕES	71
6. REFERÊNCIAS	73
Anexo 1	76
Anexo 2	83
Anexo 3	85

1. INTRODUÇÃO

Com o surgimento das aberturas de lavra e dos projetos de engenharia civil envolvendo cortes em rochas, houve a necessidade de se conhecer mais sobre a estabilidade dos taludes gerados em função dos possíveis acidentes envolvendo rupturas. Observa-se que neste momento surge a importância das classificações geomecânicas, que são preliminares à análise de estabilidade, permitindo avaliar as condições dos maciços rochosos, estimar parâmetros de resistência, dimensionar suportes, tornando o estudo de grande relevância ao campo da mineração e da construção civil.

O sistema de classificação Rock Mass Rating (RMR), é um dos mais conhecidos atualmente. Esse sistema atribui pesos aos parâmetros utilizados em sua análise, dessa forma evidenciando os parâmetros com mais influência nas condições de estabilidade do maciço em análise. É uma ferramenta muito utilizada que leva em consideração parâmetros como a resistência a rocha intacta e o RQD, e ainda parâmetros referentes as descontinuidades como o espaçamento, a persistência, a rugosidade, a abertura, o preenchimento, o grau de alteração e a condição de água local.

O projeto em questão utiliza como base os dados coletados e doados por ZARE NAGHADEHI *et al.* (2013). O banco de dados é composto por: Tipo de Rocha e Precipitação; Resistência à compressão da rocha intacta; RQD (Rock Quality Designation) e Alterações; Regime Tectônico; Condições hidráulicas: Condições de água subterrânea; Propriedades das descontinuidades: Número de Sets, persistência, espaçamento, orientação, abertura, rugosidade e preenchimento; Geometria do talude: Ângulo do talude e altura do talude; Construção: Métodos de desmonte; Histórico: Instabilidades anteriores. O autor ainda dispõe de informações específicas da estabilidade de cada maciço do seu banco de dados, se o maciço é estável ou instável.

O projeto propõe a aplicação do sistema de classificação RMR no banco de dados cedidos por ZARE NAGHADEHI *et al.* (2013), dessa forma permitindo a compreensão das características geotécnicas dos maciços. Partindo dessa análise será possível relacionar as classificações com as características dos maciços, como a geometria e as condições de estabilidade. Nesse contexto torna-se importante ressaltar que o modelo é limitado aos taludes compreendidos no banco de dados, ou seja, compreende apenas as classificações de RMR correspondentes a esses dados em específico.

Ao final o banco de dados inicial terá a inserção das novas atribuições, como a classe em RMR, valores do RMR mínimo e máximo, considerando que o banco

apresenta variáveis dispostas em intervalos. Com esses novos parâmetros será obtido uma correlação entre eles e as demais variáveis que inicialmente compunham o banco de dados.

Na atualidade a inteligência artificial está sendo utilizada em diversos processos como aprimoramento dos sistemas de análises. Pesquisas no ramo da inteligência artificial estão em uso por pesquisadores do ramo da geotecnia com base na aplicação em métodos de classificação. O presente trabalho segue a linha de aplicação de métodos da inteligência artificial do tipo redes neurais artificiais (RNAs) que são fundamentadas no conceito de redes neurais biológicas.

O objetivo geral deste trabalho consiste em propor um modelo que determina e classifica um banco de dados em função do RMR e, para atingir tal propósito será utilizado a técnica de inteligência artificial do tipo rede neural artificial e com o auxílio das estatísticas multivariadas realizar uma análise de viabilidade do modelo proposto. O trabalho ainda permite a complementação do banco de dados base com a adição do parâmetro de classificação RMR e ainda permite a análise da distribuição de Classes RMR na qual está compreendido.

A estruturação da proposta compreende na análise preliminar do banco de dados e a distribuição do mesmo conforme a necessidade para a determinação do RMR, ressaltando a estruturação dos parâmetros em valores máximos e mínimos quando dispostos em intervalos. Dispondo da classificação dos dados, estrutura-se o modelo de rede neural artificial analisando os fatores determinísticos para o modelo, como o número de nós, número de camadas, o algoritmo, a função de ativação que mais se adequa aos dados. Por fim, dispondo do modelo funcional, e com o auxílio da estatística multivariada, realiza-se às análises de viabilidade e assertividade do modelo proposto.

De acordo com Santos (2021) o uso de estatística multivariada e técnicas baseadas em inteligência artificial tem recebido considerável atenção em estudos relacionados às propriedades geomecânicas, mecânica das rochas e estabilidade de taludes. Em relação ao problema de obtenção de parâmetros geomecânicos e determinação da classificação do maciço rochoso, destacam-se os estudos realizados por Meulenkamp & Grima (1999), Singh *et al.* (2001), Gokceoglu *et al.* (2004), Liu & Chen (2006), Pantelidis (2009), Monjezi *et al.* (2010), Zare Naghadehi *et al.* (2011), Nejati *et al.* (2014), Pinheiro *et al.* (2015) e Barham *et al.* (2020), usando diferentes técnicas. Em relação à análise de estabilidade de encostas por meio de técnicas de inteligência artificial, destacam-se os estudos de Sakellariou & Ferentinou (2005), Zare Naghadehi *et al.* (2013), Melchiorre *et al.* (2011), Samui & Kothari (2011), Li *et al.* (2015) e Ahour *et*

al. (2020).

2. REFERENCIAL TEÓRICO

2.1 Maciço Rochoso

O maciço rochoso pode ser classificado como um conjunto de blocos de rocha intacta e suas descontinuidades, somando a esse conceito as condições hidrológicas e as tensões aplicadas ao maciço como adiciona Jaques (2014), características resultantes de formação geológica e condições situacionais.

Conceitua-se rocha intacta como um agregado de grãos minerais sólidos podendo estar mais compactados diminuindo assim o volume de vazios ou menos compactados, a rocha pode ter grãos mais arredondados obtendo um volume maior de vazios. Observam-se, portanto, que as descontinuidades em uma rocha intacta caracterizam-se em planos de fraqueza que interrompem a continuidade da rocha tornando-a menos resistente conforme dito por Fiori e Carmignani. (2015) .

O grau de alteração da rocha é um fator importante para a resistência de um maciço o processo refere-se a modificação das características físicas e químicas de um maciço em função de atividades dos agentes intempéricos, a alteração é variável de acordo com a litologia e o tempo no qual o maciço esteve sob influência de intemperismo seja ele químico, físico ou biológico. O intemperismo físico está diretamente relacionado ao tamanho e o grau de fraturamento da rocha, o intemperismo químico é elevado com a percolação de água por entre as descontinuidades. O intemperismo biológico menos frequente na alteração das rochas consiste na movimentação de raízes e microorganismos ao longo do tempo.

A Figura 1 retrata uma representação proposta por Deere & Patton (1971), onde apresenta uma sequência de camadas setorizando de acordo com as características de resistência e fraturamento de rochas do tipo granito e gnaiss. A ilustração mostra a diferença entre o grau de alteração de cada setor, conforme desce na imagem aumenta a profundidade.

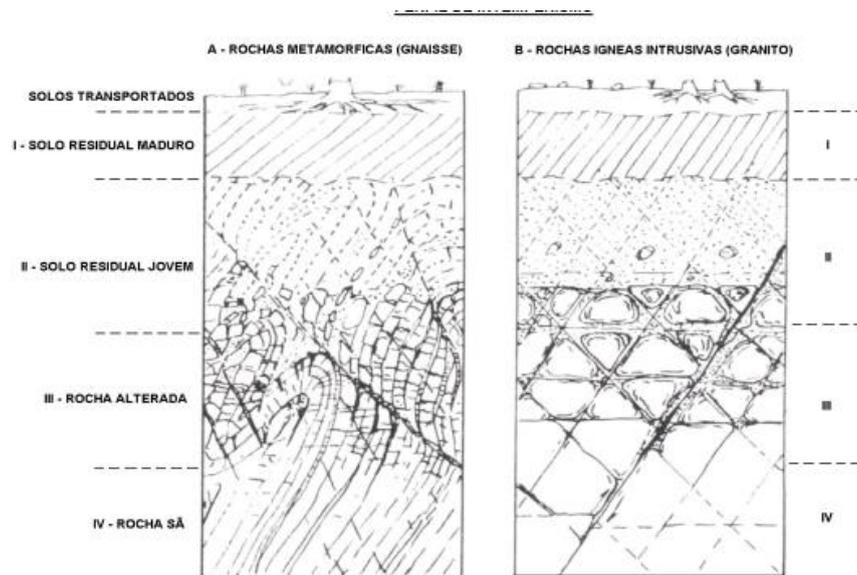


Figura 1: Representação de camadas setorializadas representando a resistência e o grau de fraturamento da rocha pela profundidade. Adaptado de (Deere & Patton, 1971).

2.2 Descontinuidades

Segundo Fiori e Carmignani (2015) descontinuidades são planos de fraqueza que podem ser derivados de diversos ambientes, são elas descritas como falhas, planos de acamamento, laminações, juntas, fendas de tração, diques e veios, zonas de cisalhamento ou planos de foliações.

Ainda segundo Fiori e Carmignani (2015), quando se observa a influência das descontinuidades na resistência do maciço deve-se levar em conta as características das descontinuidades, tais como: a natureza da descontinuidade, tamanho da abertura, espaçamento, frequência, orientação, rugosidade, persistência, preenchimento, grau de alteração e presença de água, a Figura 2 representa graficamente alguns dos parâmetros citados acima .

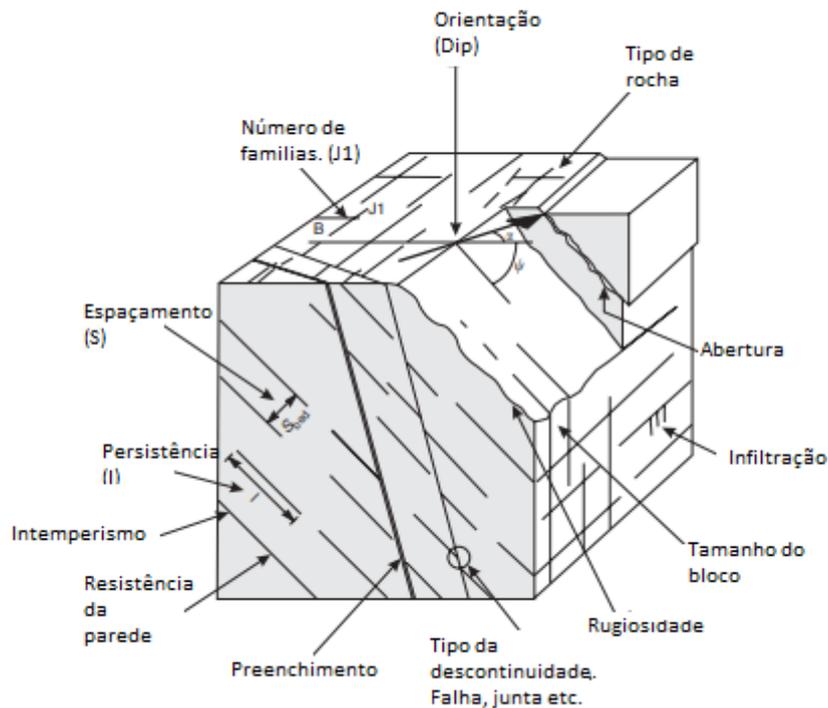


Figura 2: Representação das características das descontinuidades. Modificado de (Hoek e Bray, 1981).

As descontinuidades que pertencem a um maciço rochoso podem ser descritas e mensuradas da seguinte forma como proposto por Fiori e Carmignani. (2015) .

2.2.1 Orientação:

Cada descontinuidade de um maciço possui direção (dip) e mergulho (dip direction) mensuráveis e estas características são em sua grande maioria medidas utilizando uma bússola. A orientação das descontinuidades tem grande influência na estabilidade de um talude, visto que, conforme sua direção e mergulho junto a outras características poderá facilitar o mecanismo de deslizamento ocasionando em grandes movimentos de massa. A Figura 3 representa graficamente a estruturação dos termos utilizados na identificação da orientação em um bloco rochoso.

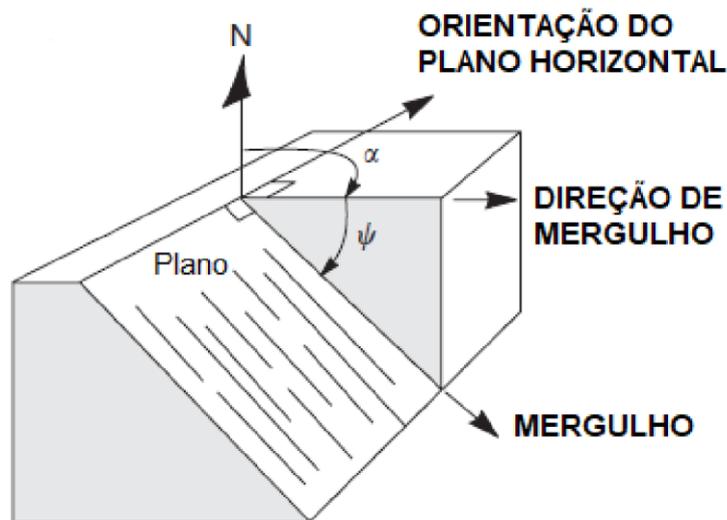


Figura 3: Representação da orientação de uma descontinuidade no espaço. Adaptado de (Hoek e Bray, 1981.)

2.2.2 Espaçamento:

Para determinar o espaçamento de descontinuidades geralmente traça-se linhas de varredura perpendiculares às famílias de descontinuidade ao longo de todo talude em estudo, posteriormente mede-se a distância entre cada descontinuidade ao longo dessa linha. Com os dados de distância média entre as descontinuidades e o tamanho da linha de varredura proposta ao talude calcula-se a frequência das descontinuidades que pode ser descrita pela Equação 1.

Equação 1

$$F = \frac{N}{L}$$

Onde, N é o número de descontinuidades ao longo da linha de varredura e L é o comprimento total dessa linha.

Segundo Fiori e Carmignani. (2015) o espaçamento médio pode ser descrito pelo inverso da frequência conforme a Equação 2.

Equação 2

$$E = \frac{1}{F}$$

A alta frequência de descontinuidades ao longo de um talude afeta diretamente sua resistência, independentemente de sua competência. A percolação de água é outra característica que pode ser influenciada pelo espaçamento. Fiori e Carmignani. (2015) ainda aponta que a condutividade hidráulica de um sistema é inversamente proporcional ao espaçamento quando há aberturas comparáveis, ou seja, quanto menor o espaçamento entre as descontinuidades maior será sua capacidade de percolação de água (permeabilidade) e mais propício o maciço estará para grandes deformações.

A Tabela 1 propõe uma relação descritiva dos espaçamentos médios observando o tamanho (cm) em relação a denominação apresentada, que se compreende entre muito afastadas á muito próximas (ISMR, 1983).

Tabela 1: Descrição dos espaçamentos médios. Adaptado de (ISMR, 1983)

Termo	Espaçamento (cm)	Denominação
E1	>200	Muito afastadas
E2	60 E 200	Afastadas
E3	20 E 60	Medianamente afastadas
E4	6 A 20	Próxima
E5	< 6	Muito próximas

Muitos fatores influenciam no espaçamento das descontinuidades presentes em um maciço como o tipo litológico, as movimentações tectônicas e a profundidade.

2.2.3 Persistência:

Para Fiori e Carmignani. (2015) a persistência possui três componentes básicos a serem considerados, o segmento separado ou sem coesão, áreas com proporções de rocha intacta e áreas de segmentos enfraquecidos. Esses componentes têm grande efeito no cálculo da resistência mecânica da rocha.

A persistência pode ser proposta como uma continuidade ininterrupta ao longo de uma extensão, nesse caso há uma grande influência do efeito escala na leitura em um

talude ou afloramento, observa-se também que essa característica tem significativa interferência na estruturação de taludes de mina ou barragens principalmente quando a mesma é orientada em sentido desfavorável ao talude.

Essa característica pode modificar consideravelmente as características de um maciço, além disso, deve-se levar em conta a dificuldade de analisar esse parâmetro em certas situações onde o efeito escala é determinante. Em alguns afloramentos a persistência não se mostra por inteiro tornando a situação difícil de analisar e quantificar.

A Tabela 2 descreve e classifica a persistência de acordo com o tamanho mensurado conforme proposto por (ISMR, 1983).

Tabela 2: Classificação da persistência segundo seu tamanho. Adaptado de (ISMR, 1983).

Termo	Persistência (m)
Persistência muito pequena	< 1
Persistência pequena	1 < 3
Persistência média	3 < 10
Persistência grande	10 < 20
Persistência muito grande	> 20

2.2.4 Rugosidade:

O comportamento das paredes das discontinuidades em relação a rugosidade influencia diretamente na resistência ao cisalhamento do maciço. A ondulação da superfície é observada em pequena e grande escala irregulares de primeira e segunda ordem e foram definidas por Deere *et al.* (1967).

A Figura 4 simboliza como as irregularidades agem na superfície de uma discontinuidade, onde i é o ângulo da feição superficial da discontinuidade e a a inclinação da vertente (rugosidade), σ é a tensão normal e τ a cisalhante.

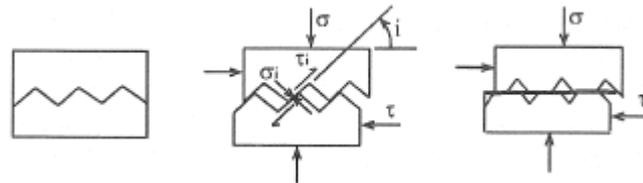


Figura 4: Influência das irregularidades nas paredes das discontinuidades com a resistência. Adaptado de (Hoek e Bray, 1981.)

Dessa forma é notório que quanto mais lisa se encontra as paredes de uma descontinuidade menor é sua resistência ao cisalhamento, desse modo o contrário também é verdade, quanto mais rugosa se apresenta a parede da descontinuidade maior a dificuldade de deslocamento entre uma e outra, ou seja, maior a resistência ao cisalhamento. A Figura 5 apresenta os tipos de rugosidades que podem ocorrer nas paredes de uma descontinuidade conforme sua geometria.

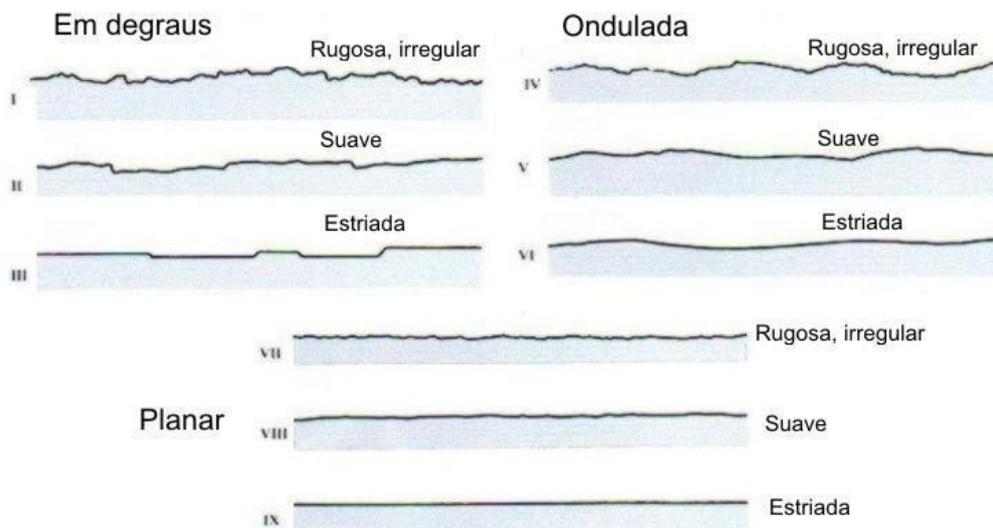


Figura 5: Tipos de rugosidades

A Figura 6 classifica os tipos de rugosidade por medidas visuais segundo o coeficiente de rugosidade JRC proposto por (Barton e Choubey, 1977).

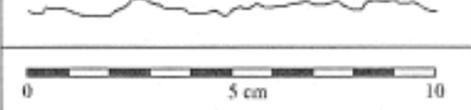
	JRC = 0-2
	JRC = 2-4
	JRC = 4-6
	JRC = 6-8
	JRC = 8-10
	JRC = 10-12
	JRC = 12-14
	JRC = 14-16
	JRC = 16-18
	JRC = 18-20
	

Figura 6: Classificação dos tipos de rugosidade por medidas visuais segundo o coeficiente de rugosidade JRC. Adaptado de (Barton e Choubey, 1977).

2.2.5 Abertura de juntas:

Essa abertura pode ser descrita como a distância média entre blocos ou como a distância entre as paredes de uma descontinuidade. Elas podem ser totalmente fechadas, preenchidas e pode haver abertura que facilita a percolação de água, as mesmas são provenientes dos esforços tectônicos. Esse espaçamento se torna menor à medida que aumenta a profundidade pois junto ao terreno os esforços provocam um relaxamento na rocha, já em profundidade esse relaxamento se torna bem menor por não ter o mesmo espaço da superfície.

O espaço entre as paredes pode estar vazio, parcialmente preenchido e totalmente preenchido, as mínimas aberturas que permitem o contato entre as paredes provocam uma influência a resistência por cisalhamento, conforme for a rugosidade presente na abertura. A medição dessa característica em campo pode ser feita por uma trena e/ou uma régua graduada.

A Tabela 3 apresenta uma classificação em relação aos possíveis tamanhos de abertura de acordo com (Barton, 1978).

Tabela 3: Classificação em relação aos tamanhos de abertura. Adaptado de (Barton, 1978).

Termo	Abertura
Cerrada	Zero
Extremamente fechada	>0 - 2 mm
Muito fechada	2 - 6 mm
Fechada	6 - 20 mm
Moderadamente Fechada	20 - 60 mm
Moderadamente aberta	60 - 200 mm
Aberta	>200 mm

2.2.6 Preenchimento

O espaço entre as descontinuidades pode estar preenchido com outro material resultado da fragmentação ao longo do plano. Segundo Fiori e Carmignani. (2015), em geral esse material possui baixa resistência ao cisalhamento. Em determinadas zonas é frequente encontrar material argiloso como preenchimento, o que traz sérios danos a resistência do maciço, quando preenchidos por sílica a resistência se torna alta em comparação ao material argiloso de acordo com as características de resistência individuais dos mesmos.

A resistência do material presente no preenchimento pode ser descrita de acordo com a classificação proposta por (Barton, 1978) descrita na Tabela 4.

Tabela 4: Descrição do material presente no preenchimento de uma junta. Adaptado de (Barton, 1978).

Classificação	Descrição	Identificação de campo	Valor aproximado da resistência à compressão uniaxial (Mpa)
S1	Argila muito mole	Facilmente penetrável em algumas polegadas com o pulso	< 0,025
S2	Argila mole	Facilmente penetrável em algumas polegadas com o dedo polegar	0,025 - 0,05
S3	Argila firme	Pode ser penetrável em algumas polegadas porém penetrável somente com grande esforço.	0,05 - 0,10
S4	Argila rígida	Facilmente amolgada com o dedo polegar porém penetrável somente com grande esforço.	0,10 - 0,25
S5	Argila muito rígida	Facilmente recortada com a unha.	0,25 - 0,50
S6	Argila dura	Recortada com dificuldade com a unha.	>0,50

2.3 Alteração da Rocha

As ações intempéricas do ambiente podem modificar a resistência de uma rocha, essa alteração é visivelmente marcada de acordo com o tempo de exposição e aos tipos de intemperismos na qual estão expostas. Essa alteração pode ser caracterizada de acordo com ISRM (1981). A Tabela 5 estabelece uma correlação entre o grau de alteração e as condições visuais da rocha em análise.

Tabela 5: Correlação entre o grau de alteração e as condições visuais de uma rocha: Adaptado de (ISMR, 1981).

Sigla	Denominação	Descrição

W1	Sem alteração (rocha sã)	Alteração mineralógica nula ou incipiente. Os minerais preservam brilho original, cor e clivagem. Foliação visível e selada. Resistência original da rocha não afetada pela alteração.
W2	Pouca alteração	Leve descoloração e oxidação na matriz e ao longo das descontinuidades. Foliação visível e selada. Juntas fechadas, paredes descontinuidades. Foliação visível e selada. Juntas fechadas, paredes ligeiramente alteradas. Resistência original da rocha parcialmente afetada.
W3	Alteração moderada	Matriz descolorida, com evidências de oxidação. Juntas abertas (< 1.0 mm) e oxidadas, podendo ocorrer material mais alterado ao longo das descontinuidades. Foliação realçada pelo intemperismo. Resistência afetada.
W4	Muita alteração	Alteração acentuada, alguns minerais parcialmente decompostos. Matriz totalmente oxidada e cores muito modificadas. Fraturas abertas (2 < e < 5 mm) e oxidadas. Foliação realçada pelo intemperismo. Desplacamentos ao longo da foliação.
W5	Alteração extrema	Material completamente alterado para solo estruturado. Extremamente descolorido, minerais resistentes quebrados e outros transformados em argilominerais. Foliação preservada. Juntas não discerníveis.
W6	Solo residual	Material totalmente transformado em solo.

2.4 Rock Quality Designation (RQD)

O RQD é um dos principais parâmetros utilizados pelo RMR. De acordo com Cunha (2019) o testemunho de sondagem utilizado para obtenção do RQD deve ser obtido de maneira contínua contemplando todas as descontinuidades do corpo de minério e desconsidera-se qualquer fratura pelo método da sondagem.

O índice RQD elaborado por Deere (1964, 1968), representa o espaçamento do qual se encontram as descontinuidades, geralmente sendo determinado no distanciamento entre os pedaços de rocha em um furo de sonda. Disposto do testemunho de perfuração, o cálculo de RQD pode ser feito de acordo com a Equação 3:

Equação 3

$$RQD = \frac{100\sum X_i}{L}$$

Nesse contexto X_i corresponde ao tamanho dos fragmentos inteiros do testemunho, e L o comprimento total do testemunho. A Figura 7 representa um furo de sonda fragmentado onde a somatória de X_i totaliza 118 e o comprimento total L compreende em 200, resultando em um RQD de 54%.

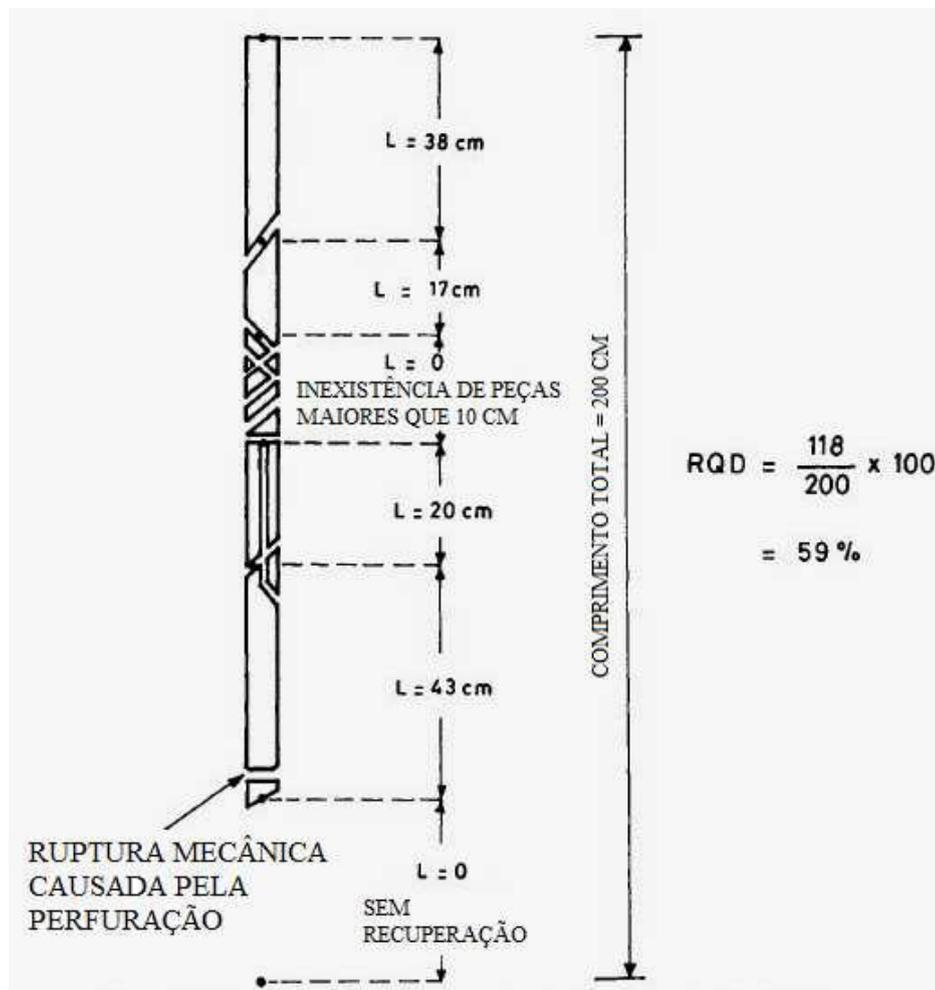


Figura 7: Representação visual do cálculo do RQD pelo furo de sonda. Adaptado de DEERE & DEERE (1988).

O RQD pode ser definido utilizando a frequência das descontinuidades, esse método foi proposto por PALMSTRÖM (1982) e HUDSON & HARRISON (1997).

As Equações 4 e 5 definem o RQD em função das descontinuidades:

Equação 4

$$RQD = 100(\lambda t + 1)e^{-\lambda t}$$

Equação 5

$$RQD = 115 - 3,3Jv$$

Na Equação 4 o λ representa a frequência das descontinuidades e t o tamanho do pedaço da rocha intacta considerada. Já na Equação 5, Jv retrata o contador volumétrico de juntas que por sua vez é calculado conforme descrito na Equação 6.

Equação 6

$$Jv = \sum 1/Si$$

Nesse contexto, Si representa o espaçamento em metros das famílias de descontinuidades.

A Tabela 6 abaixo representa a relação entre os valores de RQD em porcentagem e a qualidade da rocha.

Tabela 6: Relação entre o valor de RQD e a qualidade da rocha. Adaptado de (Brown, 1981)

RQD (%)	Qualidade da rocha
<25	A – Muito ruim
25 – 50	B – Ruim
50 – 75	C – Razoável
75 – 90	D – Bom
90 – 100	E – Excelente

2.5 Resistência da rocha intacta

A resistência da rocha intacta pode ser determinada por ensaios de compressão de tipos uniaxial e triaxial, nesses casos as amostras são prensadas até se romperem. Quando não há a possibilidade de aplicação dos métodos laboratoriais preditos acima, métodos indiretos podem ser utilizados, dentre eles o teste do martelo de geólogo.

O teste do martelo de geólogo é muito utilizado em trabalhos de campo devido sua facilidade e determinação de resultados de forma rápida. Compreende em golpes do martelo em um material rochoso e de acordo com o resultado deixado na rocha relacionando-se com a resistência e seus resultados são apresentados em faixa de valores.

A Tabela 7 compreende as possibilidades de identificação em campo e sua correlação com a resistência em (MPa).

Tabela 7: Classificação de campo da resistência dos materiais rochosos e correlação com a resistência à compressão uniaxial. Adaptado de (Brown, 1981).

Grau Resistência	Descrição	Identificação de campo	Resistência (MPa)
R0	Rocha extremamente fraca.	Marcada pela unha.	0,25-1,0
R1.	Rocha muito fraca.	Esmigalha-se sob o impacto do martelo de geólogo, pode ser raspada por canivete.	1,0-5,0
R2.	Rocha fraca.	Pode ser raspada por canivete com dificuldade, marcada por forte pancada c/ a ponta do martelo.	5,0-25
R3	Rocha com resistência média.	Não pode ser raspada por canivete, amostras podem ser fraturadas com um único golpe do martelo.	25-50
R4	Rocha resistente.	As amostras requerem mais de um golpe de martelo para fraturar-se.	50-100
R5.	Rocha muito resistente.	Amostras requerem muitos golpes de martelo para fraturar-se.	100-250
R6	Rocha extremamente resistente.	Amostras podem somente ser lascadas com o martelo de geólogo.	>250

2.6 Efeito escala

É relevante ressaltar que muitos estudos de maciços rochosos e a determinação da resistência do maciço depende da proporção do talude no qual está sendo analisado. Observa-se que na Figura 8 quando a escala de análise aumenta, aumenta também o número de descontinuidades no campo em estudo, portanto ao aumentar gradativamente a proporção na qual está sendo analisado a resistência se torna a resistência do maciço que é diferente da resistência da rocha intacta. Para que se minimize esse empecilho é necessário realizar testes laboratoriais em escalas diferentes.

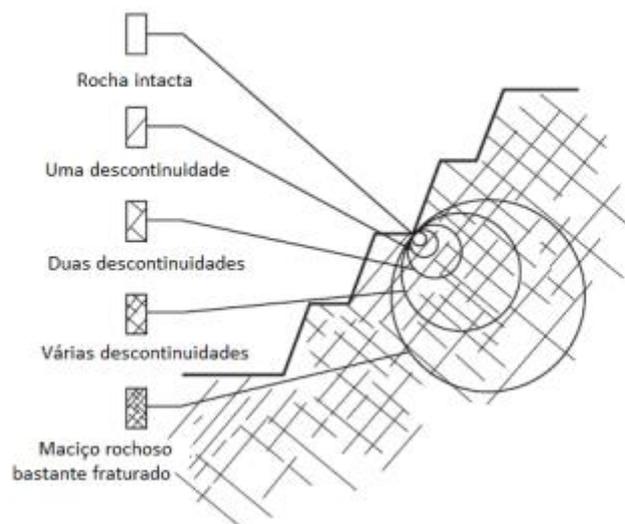


Figura 8: Diagrama ilustrativo do efeito escala. Adaptado de Hoek (2002).

Quando a estrutura geológica é composta em uma grande escala em função de falhamento e fraturas e a escala amostral para estudo foi menor que o espaçamento das descontinuidades, pode resultar erroneamente em uma resistência ao cisalhamento é maior que a do maciço rochoso quando na verdade as complexidades geológicas influenciaram negativamente nessa resistência.

2.7 Rock Mass Rating (RMR)

Em 1973 Bieniawski propôs a primeira versão do sistema de classificação RMR e o mesmo autor buscou aperfeiçoar a técnica revelando então em 1979 sua versão

final. O sistema compreende a atribuição de pesos a fatores que influenciam a estabilidade de um maciço. Quanto melhor as condições do maciço, maior o valor final imposto a ele. A Tabela 8 compreende a relação entre os parâmetros de influência no RMR e seus respectivos pesos.

São 6 os parâmetros que para Bieniawski influenciam na resistência do maciço, são eles: a resistência a compressão, o RQD do maciço, o espaçamento das descontinuidades, as condições das descontinuidades, as condições de água subterrânea e a orientação das descontinuidades em relação ao corte do talude em análise.

Tabela 8: Relação entre os parâmetros e seus pesos. Adaptado de (Bieniawski, 1973).

Parâmetros			Coeficientes						
1	Resistência da rocha intacta	Point load	>10Mpa	4-10Mpa	2-4Mpa	1-2Mpa	Ver compressão		
		Compressão Uniaxial	>250Mpa	100-250Mpa	50-100Mpa	25-50Mpa	5-25Mpa	1-5Mpa	<1Mpa
	Pesos	15	12	7	4	2	1	0	
2	R.Q.D		90-100%	75-90%	50-75%	25-50%	<25%		
	Pesos		20	17	13	8	3		
3	Espaçamento médio		>2mm	2-0,6m	0,6-0,2m	0,2-0,06m	<0,06m		
	Pesos		20	15	10	8	5		
4	Condição das descontinuidades		Superfícies muito rugosas, não contínuas, sem separação, paredes de rocha não	Superfícies ligeiramente rugosas, separação <1mm, paredes	Superfícies ligeiramente rugosas, separação <1mm, paredes muito alteradas	Superfícies polidas ou enchiemento com espessura <5mm ou juntas contínuas com	Enchimento mole com espessura >5mm ou juntas contínuas com separação >5mm.		

		alteradas	ligeiramente alteradas.		separação 1-5mm.	
Pesos	30	25	20	10	0	

As descontinuidades presentes nos maciços rochosos possuem características específicas que modificam a resistência do mesmo, para cada uma delas Bieniawski condiciona um peso de acordo com as suas características conforme a Tabela 9, estes atributos incluem-se no parametro condições das descontinuidades disposto na tabela 8.

Tabela 9: Classificação das condições das descontinuidades. Adaptado de (Bieniawski, 1989).

Comprimento da descontinuidade (persistência)	< 1 m	1 - 3 m	3 - 10 m	10 - 20 m	> 20 m
Peso	6	4	2	1	0
Separação (abertura)	Nenhuma	< 0,1 mm	0,1 - 1,0 mm	1 - 5 mm	> 5 mm
Peso	6	5	4	1	0
Rugosidade	Muito rugoso	Rugoso	Ligeiramente rugoso	Quase liso	Liso
Peso	6	5	3	1	0
Preenchimento	Nenhum	Duro com espessura < 5 mm	Duro com espessura > 5 mm	Mole com espessura < 5 mm	Mole com espessura > 5 mm

Peso	6	4	2	2	0
Grau de alteração	Não alteradas	Ligeiramente alteradas	Moderadamente alteradas	Muito alteradas	Em decomposição
Peso	6	5	3	1	0

De posse dos valores finais da somatória de todos os pesos de cada parâmetro definido por Bieniawski, tem-se o valor final de RMR, esse valor é atribuído a uma classe. A seguir a Tabela 10 representa a divisão das classes segundo o valor de RMR atribuído. A relação também apresenta uma breve descrição da rocha de acordo com sua classificação, essa descrição vai de rocha muito boa até a rocha muito pobre.

Tabela 10: Classificação dos maciços rochosos segundo o RMR de acordo com Bieniawski (1989).

Valor	100-81	80-61	60-41	40-21	< 21
Classe	I	II	III	IV	V
Descrição da rocha	Muito boa	Boa	Razoável	Pobre	Muito pobre

O sistema de classificação do tipo RMR, apresenta grande aceitação no campo das ciências geológicas, uma de suas maiores vantagens está na facilidade no uso do método e em seu âmbito de aplicações, seu uso abrange problemas de engenharia em fundações, galerias em minas subterrâneas, túneis e taludes no geral.

Ao longo dos anos surgiram diversas atribuições ao sistema, porém, sem nenhuma mudança no sentido básico do método, as atribuições surgiram para o aperfeiçoamento do sistema nas diversas aplicações.

2.8 Inteligencia artificial

Atualmente as IA's são a grande aposta para evolução tecnológica em diversos meios como na medicina, nas engenharias. Em um primeiro momento a criação e desenvolvimento da IA era no objetivo de criar robôs tão inteligentes como seres humanos, com o passar do tempo essa expectativa foi se assentando quando

observaram que esse objetivo continha impossibilidades que os impediam de obter sucesso. Por esse motivo o objetivo passou a ser mais realista e dessa forma as pesquisas passaram a desenvolver métodos de resolução de problemas baseados na capacidade do cérebro humano.

Segundo Nicoli (2017) os principais modelos que utilizam da inteligência artificial são: Sistemas Especialistas (SE) baseado em conhecimento e regras, Raciocínio básico em casos levando como base o aprendizado pela vivência, Redes Semânticas explorando a associação de conceitos, Lógica nebulosa que expressa a incerteza da realidade, Redes neurais artificiais que tenta reproduzir as capacidades do cérebro humano e os Algoritmos genéricos que utiliza a mecânica da seleção natural e genética. O software RStudio desenvolvido por JJ Allaire, utiliza a linguagem R com o intuito de realização de estudos estatísticos incluindo geração de gráficos, a linguagem possui bibliotecas próprias incluindo o pacote neuralnet (GÜNTHER & FRITSCH, 2010), que é utilizada para o treinamento das multicamadas nas análises de regressão.

2.81 Redes Neurais Artificiais “RNAs”

A criação de redes neurais artificiais teve como embasamento o desempenho dos neurônios biológicos do sistema nervoso. Esse método surgiu em 1943 com o trabalho de Warren McCulloch e Walter Pitts denominado “A logical calculus of the ideas Immanent in Nervous Activity”. Para Nicoli (2017) a arquitetura de uma rede neural artificial conta com números de camadas, número de nós por camadas, tipo de conexão entre nós e a topologia. A rede neural é organizada por entrada, camadas e saída .

Um neurônio biológico é composto por quatro partes, os dendritos, o corpo celular, o axônio e as terminações do axônio A Figura 9 ilustra um neurônio biológico que é a base de entendimento para os neurônios artificiais (ver Figura 10).

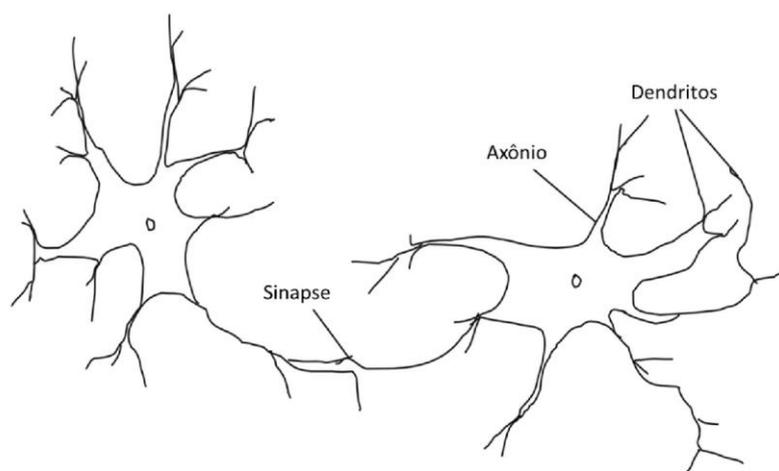


Figura 9: Representação de um neurônio biológico. Modificado de SHANMUGANATHAN & SAMARASINGHE, 2016)

A sinapse é responsável de transportar o conhecimento de um neurônio a outro, a informação chega até os dendritos, são levados ao corpo celular onde a informação é processada, depois é transportada pelo axônio e chega às terminações. Em analogia ao sistema de um neurônio biológico as redes artificiais seguem o mesmo raciocínio, as entradas são por similaridade aos dendritos e os pesos são a sinapse.

Inicialmente a rede neural passa por um momento de aprendizagem, amostras de um sistema é apresentadas a rede como exemplos e a rede estuda e retém as informações necessárias para reproduzir o conhecimento adquirido. Segundo BRAGA et al. (2000) O atrativo principal do uso das RNAs é a capacidade de aprender com conjuntos reduzidos de amostras e apresentar resultados coerentes posteriormente para dados não conhecidos.

A Figura 10 representa o neurônio proposto por McCulloch e Pitts. Os campos indicados com $X_1, X_2 \dots X_n$ são as entradas dos dados que fazem alusão aos dendritos no sistema neural biológico, já $W_1, W_2 \dots W_n$ correspondem aos pesos impostos a cada entrada, o que reflete a sinapse no neurônio biológico.

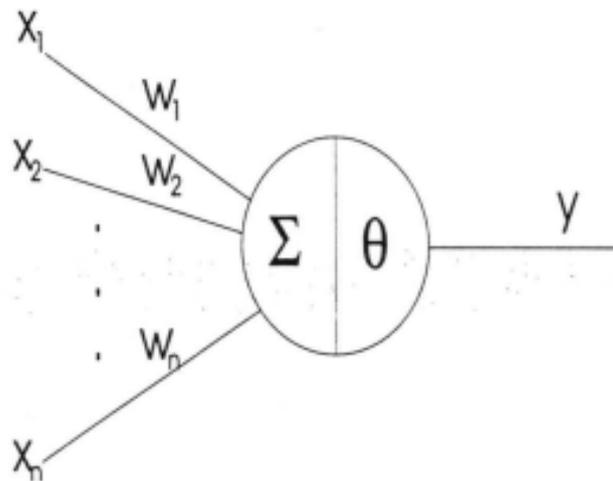


Figura 10: Representação do neurônio por McCulloch e Pitts.

Para BRAGA *et al.* (2000) um neurônio biológico dispara quando a soma dos impulsos que recebe ultrapassa o seu limiar de excitação (*threshold*). Em um neurônio artificial esse papel é feito por uma função de ativação. Quando a somatória do produto entre o peso e a entrada for maior ou igual a zero o neurônio ativa uma saída. A função apresentada por BRAGA *et al.* (2000) mostra que a função de ativação é dada pelo descrições da Equação 7:

Equação 7

$$\sum_{i=1}^n x_i w_i \geq 0$$

O modelo acima descrito é segundo Santos (2021) limitado a aplicações somente no âmbito linear.

A estruturação de uma rede neural artificial ocorre conforme a sua aplicação, essa estrutura corresponde a designação de parâmetros específicos como por exemplo, número de camadas, número de nós e função de ativação. Para Nicoli (2017), os parâmetros mais importantes para uma rede neural artificial são o número de camadas, o número de nós por camada, o tipo de conexão entre nós e a composição da rede neural artificial. A organização compreende níveis de entrada, camadas, e níveis de saída.

As camadas de entrada são responsáveis pela recepção dos dados, as camadas intermediárias extraem através de seus neurônios as características do processo em análise e já as camadas de saída reproduzem o resultado final da rede. Dentre as arquiteturas mais conhecidas estão as redes de camada única, múltiplas, recorrentes e

articuladas, a Figura 11 representa a estruturação das redes citadas..

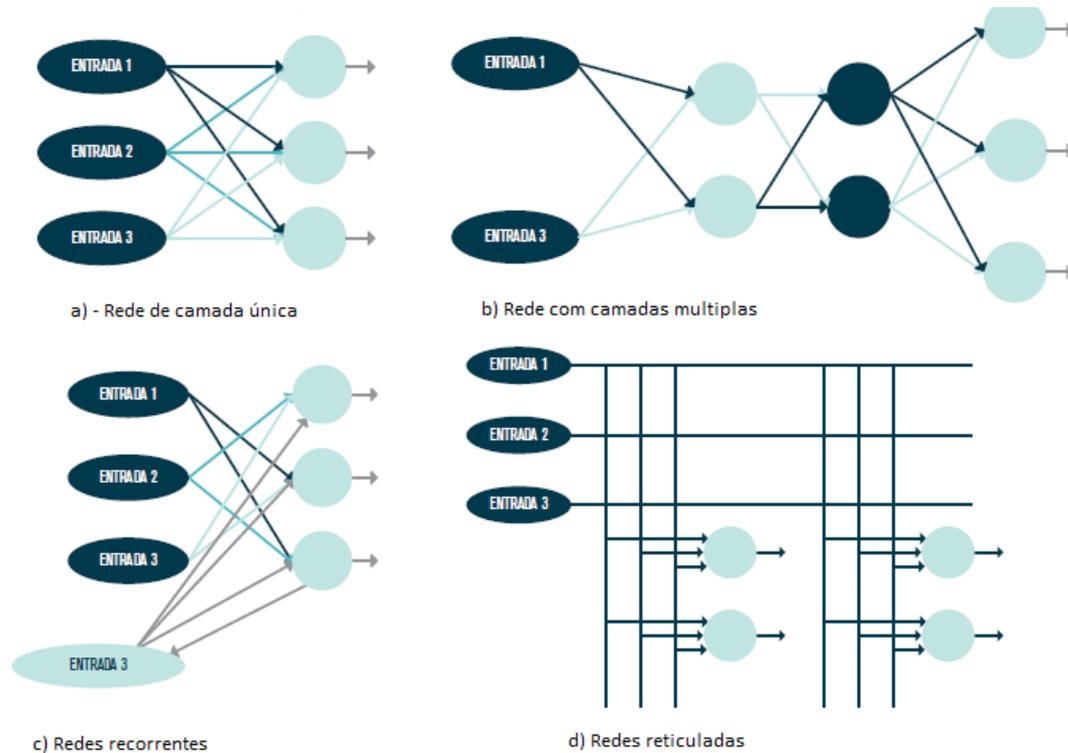


Figura 11: Representação dos tipos de articulação de redes neurais artificiais.

2.82 As funções de ativação

A seguir dispõe-se algumas funções de ativação em uso na atualidade. São elas a função threshold, sigmóide, tangente hiperbólica, a função threshold historicamente foi o primeiro modelo a ser utilizado no âmbito das redes neurais.

Conforme descrito por Santos (2021) , se a saída do neurônio assume o valor 1 significa que o campo local induzido é positivo, se essa saída assume o valor de 0, diz-se que o campo local induzido pode ser negativo, ou seja, a função limiar restringe a saída da RNA em valores binários de (0, 1).

Esse modelo pode ser descrito de acordo com a equação abaixo e posteriormente representada conforme o gráfico da figura 12.

Equação 8:

$$f(x) = \begin{cases} 0 & \text{if } x \geq 0 \\ 1 & \text{if } x < 0 \end{cases}$$

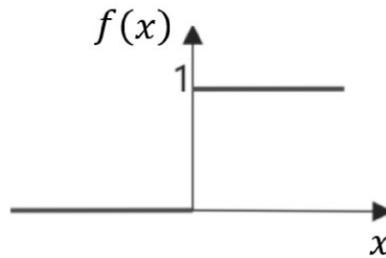


Figura 12: Representação gráfica da função threshold . Adaptado de (Santos, 2021).

A função Sigmóide mais comumente usada pode ser descrita como uma função crescente, que varia equilibradamente entre comportamento linear e não linear em um intervalo de 0 a 1. Essa função porém possui algumas ressalvas conforme dito por Santos (2021), a função pode relatar mínimos locais e não o mínimo absoluto, esses problemas de propagação do gradiente podem causar dificuldades no treinamento.

A função Sigmóide pode ser descrita de acordo com a função abaixo onde β é o parâmetro crescente da função.

Equação 9

$$F(x) = \frac{1}{1 - \exp(-\beta x)}$$

A figura 13 representa a função de ativação do tipo Sigmoide evidenciando o parâmetro crescente da função.

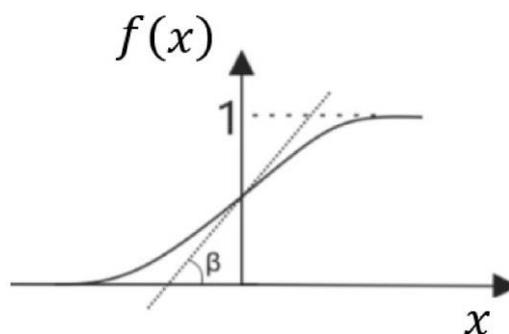


Figura 13: Representação gráfica da função Sigmóide. Adaptado de (Santos, 2021)

A função tangente hiperbólica possui grande similaridade com a função sigmóide, porém sua variação ocorre de 1 a -1. Para Santos (2021) a função Tanh como é comumente conhecida apresenta ativação em camadas ocultas o que a torna mais atrativa trazendo consigo maiores benefícios analíticos. As equações abaixo representam a derivação de onde surge a função Tanh assim como o gráfico disposto na figura 14.

Equação 10:

$$f(x) = \frac{1 - e^{-\beta x}}{1 + e^{-\beta x}}$$

Equação 11

$$\tanh'(x) = 1 - \tanh^2(x)$$

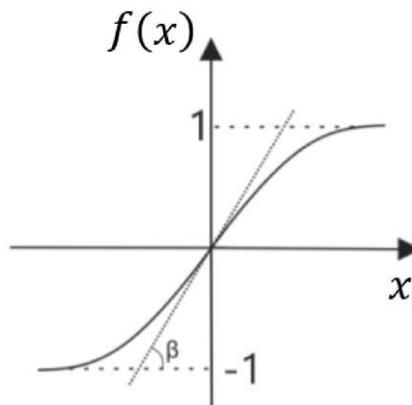


Figura 14: Representação gráfica da função Tanh. Adaptado de Santos (2021)

2.83 Validação para modelos de classificação

A forma mais comum para validação de um modelo de classificação *a priori* é por meio das matrizes de confusão. Uma matriz de confusão pode ser descrita como uma tabela quadrada que expressa a relação do número de previsões corretas e previsões erradas, essa propriedade é base de diversas análises de diferentes pontos. De forma generalizada, a Tabela 11 ilustra uma matriz de confusão.

Tabela 11: Representação de uma matriz de confusão.

	Referência	
Previsto	Positivo	Negativo
Positivo	A	B
Negativo	C	D

Dispondo dos dados na tabela 11, pode-se analisar os dados de acordo com

alguns parâmetros, são eles acurácia, sensibilidade, especificidade. As equações abaixo mostram a forma na qual esses parâmetros são calculados a partir da análise da matriz de confusão.

A acurácia calcula o número de acertos sobre todos os dados, pode ser descrita como a probabilidade média de acertos do total. A Equação 12 representa o cálculo da acurácia.

Equação 12

$$\text{Acurácia} = \frac{(A + D)}{A + B + C + D}$$

A sensibilidade é descrita como a quantidade de verdadeiros reais sob a quantidade de verdadeiros totais, real e aparente, ou seja, a capacidade do método de detectar os resultados classificados como positivos e pode ser descrita de acordo com a Equação 13.

Equação 13:

$$\text{Sensibilidade} = \frac{A}{(A + C)}$$

A especificidade mostra a quantidade de verdadeiros negativos sobre a quantidade total de negativos, ou seja, a capacidade do método de determinar os resultados ditos negativos conforme descrito na Equação 14.

Equação 14:

$$\text{Especificidade} = \frac{D}{(B + D)}$$

A eficiência do modelo ou a acurácia balanceada pode ser descrita como a média entre os valores de sensibilidade e especificidade, conforme descrito conforme a Equação 15.

Equação 15:

$$\text{Acurácia balanceada} = \frac{\text{sensibilidade} + \text{especificidade}}{2}$$

Utilizando das equações descritas acima, tem-se uma análise robusta do teste na qual será aplicado a matriz de confusão.

2.9 Banco de dados de Zaré Naghadehi

A presente pesquisa se baseia no banco de dados reunido por Zaré Naghadehi *et al.* (2013), em seus trabalhos publicados acerca de estudos sobre estabilidade de taludes. Segundo eles os parâmetros presentes em seu banco de dados foram levantados de acordo com as literaturas anteriores propunham. O Anexo 1 compreende aos pesos adotados para os parâmetros utilizados do banco de dados de Naghadehi *et al.* (2013) que anteriormente se compreendia em diversos arquivos separados cada um de um local, neste anexo os dados estão dispostos em um único arquivo unificado.

A tabela 12 compreende um resumo dos dados presentes nos banco de dados original precedendo a localidade, o bem mineral, o nome da mina e a quantidade de taludes analisados.

Tabela 12: Descrição do banco de dados de Naghadehi *et al.* (2013).

BEM MINERAL/LOCALIDADE	MINA	Nº DE TALUDES ANALISADOS
MINA DE FERRO/ BRASIL	ÁGUAS CLARAS	5
MINA DE COBRE/ SUÉCIA	AITIK	6
MINA DE CHUMBO E ZINCO /IRÃ	ANGOORAN	4
MINA DE COBRE/ SUÉCIA	AZNALCOLLAR	5
MINA DE OURO/ EUA	BETZEPOST	5
MINA DE OURO E COBRE /AUSTRÁLIA	CADIA HILL	5
MINA DE FERRO/ IRÃ	CHADORMALOU	4
MINA DE COBRE/ IRÃ	CHOGHART	5

MINA DE COBRE/ CHILE	CHUQUICAMATA	5
MINA DE COBRE/ CHILE	ESCONDIDA	7
MINA DE COBRE/ USA	ESPERANZA	1
MINA DE FERRO/ IRÃ	GOLEGOHAR	4
MINA DE ARGILAS/ ESPANHA	LAYESA	2
MINA DE OURO E COBRE/ GUINÉ	OKTED	3
MINA DE DIAMANTE/ CANADÁ	PANDA	1
MINA DE PLATINA/ ÁFRICA DO SUL	SANDSLOOT	6
MINA DE COBRE/ IRÃ	SARCHESHMEH	4
MINA DE COBRE/ IRÃ	SUNGUN	4
MINA DE COBRE/ CHILE	UJINA	1
MINA DE DIAMANTE/ ÁFRICA DO SUL	VENETIA	7
TOTAL		84

O banco de dados é composto por 19 parâmetros, estes parâmetros descrevem tanto o local em si e os taludes analisados como também descreve minuciosamente as condições das descontinuidades. As variáveis estão dispostas no banco conforme dispostas na Tabela 13.

Tabela 13: Descrição das variáveis presentes no banco de dados de Naghadehi et al. (2013).

Variáveis presentes no banco de dados	Unidades de medida
Local	-

Tipo de rocha	-
Regime tectônico	-
Número de famílias	-
ângulo do talude	Graus
Altura do talude	Metros
Método de desmonte	-
Chuva	mm/y (Milímetros/ano)
Instabilidade anterior	-
Grau de alteração	-
Resistência a rocha intacta	Pa
RQD (%)	%
Condições de percolação de água	-
Persistência da descontinuidade	Metros
Espaçamento da descontinuidade	Metros
Abertura da descontinuidade	Metros
Orientação das descontinuidades	Graus
Rugosidade da descontinuidade	-
Preenchimento da descontinuidade	-

Além dos parâmetros dispostos anteriormente, o autor ainda dispõe de dados da estabilidade do talude se o mesmo se encontra estável ou não.

3. METODOLOGIA

3.1 Considerações iniciais

A metodologia utilizada neste trabalho originou-se de estudos preliminares do banco de dados e dos softwares a serem utilizados e realizou também análises estatísticas da determinação fatores referentes a qualidade do banco de dados.

3.2 Materiais

Para unir, analisar e organizar o banco de dados e prosseguir com as demais análises estatísticas e classificações, utilizou-se o Microsoft Excel. Para estruturação da rede neural, balanceamento dos dados, equacionamento das variáveis e para análises estatísticas utilizou-se a linguagem R de programação por meio da interface R Studio, uma ferramenta gratuita e disponível no laboratório de geoprocessamento do CEFET-MG.

3.3 Análise do banco de dados

O banco de dados em estudo originou-se do compilado de dados proposto por Zaré Naghadehi *et al.* (2013). Para iniciar o projeto foi primordial organizar o banco de dados de 84 taludes em um banco unificado, sendo que, ele é constituído de 19 variáveis, qualitativas e quantitativas. Essas variáveis são, neste estudo exposto, aplicadas na construção de dois novos fatores denominados RMR1 para valores mínimos e RMR2 para valores máximos, que são somados ao banco de dados inicial.

Durante o processamento inicial dos dados observou-se que algumas variáveis possuíam valores dispostos em intervalos e, para que esses intervalos não tornassem os resultados imprecisos, foi necessário a separação em colunas de valores máximo e valores mínimos, conforme apresentado na Tabela 14.

Tabela 14: Descrição da divisão entre máximo e mínimo dos parâmetros dispostos em intervalos

Divisão das variáveis dispostas em intervalos	
RQD (%)	RQD (%) (Mínimo)
	RQD (%) (Máximo)
Persistência da descontinuidade	Persistência da descontinuidade (Mínimo)

	Persistência da descontinuidade (Máximo)
Espaçamento da descontinuidade	Espaçamento da descontinuidade (Mínimo)
	Espaçamento da descontinuidade (Máximo)
Abertura da descontinuidade	Abertura da descontinuidade (Mínimo)
	Abertura da descontinuidade (Máximo)

Ao organizar o banco de dados, utilizando das planilhas de peso dispostas por Bieniawski, conforme visto anteriormente, foi atribuído os pesos a cada variável do banco de dados e ao final somados resultando no valor de RMR. Os valores foram classificados de acordo com as cinco classes, Classe I, Classe II, Classe III, Classe IV e Classe V, conforme a tabela 10 disposta no tópico 2.7 Rock Mass Rating (RMR), contudo, os 84 taludes estão compreendidos apenas entre as Classes II, III e IV.

3.4 Tratamento dos dados

A segunda etapa da metodologia proposta neste trabalho compreende em do selecionar as variáveis no banco de dados a serem utilizadas nas etapas subsequentes, partiu-se para o pré-processamento dos dados. A Tabela 15 corresponde a nomenclatura adotada aos parâmetros que foram utilizados para treino e teste do modelo da rede neural artificial em construção.

Tabela 15: Nomenclatura adotada para tratativa no software R Studio.

Variável	Nomenclatura adotada
Número de famílias de descontinuidades	V1
Resistência da rocha intacta	V2
RQD (%) (Mínimo)	V3
Espaçamento mínimo das descontinuidades	V4

Persistência Mínima	V5
Abertura	V6
Rugosidade Mínima	V7
Preenchimento Mínima	V8
Grau de alteração Mínima	V9
Condições da água	V10
Classes de RMR1	rmr

O tratamento inicial dos dados conta com a verificação da escala e a distribuição dos dados. Para o banco de dados atual observou-se a necessidade de balanceamento e escalonamento dos dados, visto que, existe uma desproporção na quantidade de dados correspondentes à classe III de RMR indicadas. O balanceamento das variáveis foi aplicado ao banco de dados por meio do algoritmo *Smote*, essa função é apropriada para tratar de dados classificatórios desbalanceados, dessa forma a função assume o papel de reduzir a classe dominante dos dados e aumentar as outras.

O escalonamento das variáveis foi realizada com base na função *Scale*, disponível na R, essa ferramenta padroniza uma matriz subtraindo os valores de sua média e dividindo pelo desvio padrão. Dessa maneira ocorre o escalonamento dos dados ao serem pré-processados no *script*.

Após os dados serem balanceados e escalonados foi realizada a etapa de separação de amostras, onde, parte dos dados foram direcionados para o treino e parte direcionados para o teste. A quantidade referente a cada amostra foi pré determinada pelo tamanho do banco de dados e por testes preliminares do tipo tentativa e erro.

A próxima etapa diz respeito à metodologia a ser empregada e, neste caso, optou-se pela utilização de redes neurais artificiais para o processamento dos dados. Por meio de testes, foi determinado o número de nós ideal assim como a função de ativação na qual mais representa os dados. Ao determinar todos os parâmetros necessários para estruturação da rede neural, partiu-se para etapa de treino, onde, a rede aprendeu com os dados enviados para essa etapa.

Após a aprendizagem inseriu-se os dados referentes ao teste para a rede aplicar o conhecimento adquirido na etapa anterior e posteriormente classificou esses dados. A validação foi feita com base nos resultados dispostos em matrizes de confusão

resultantes da etapa de treino, posteriormente para analisar os resultados dos testes utilizou-se das matrizes de confusão dispostas nas etapas de testes, podemos observar o passo a passo na figura 15, que representa um fluxograma das principais etapas desse trabalho.

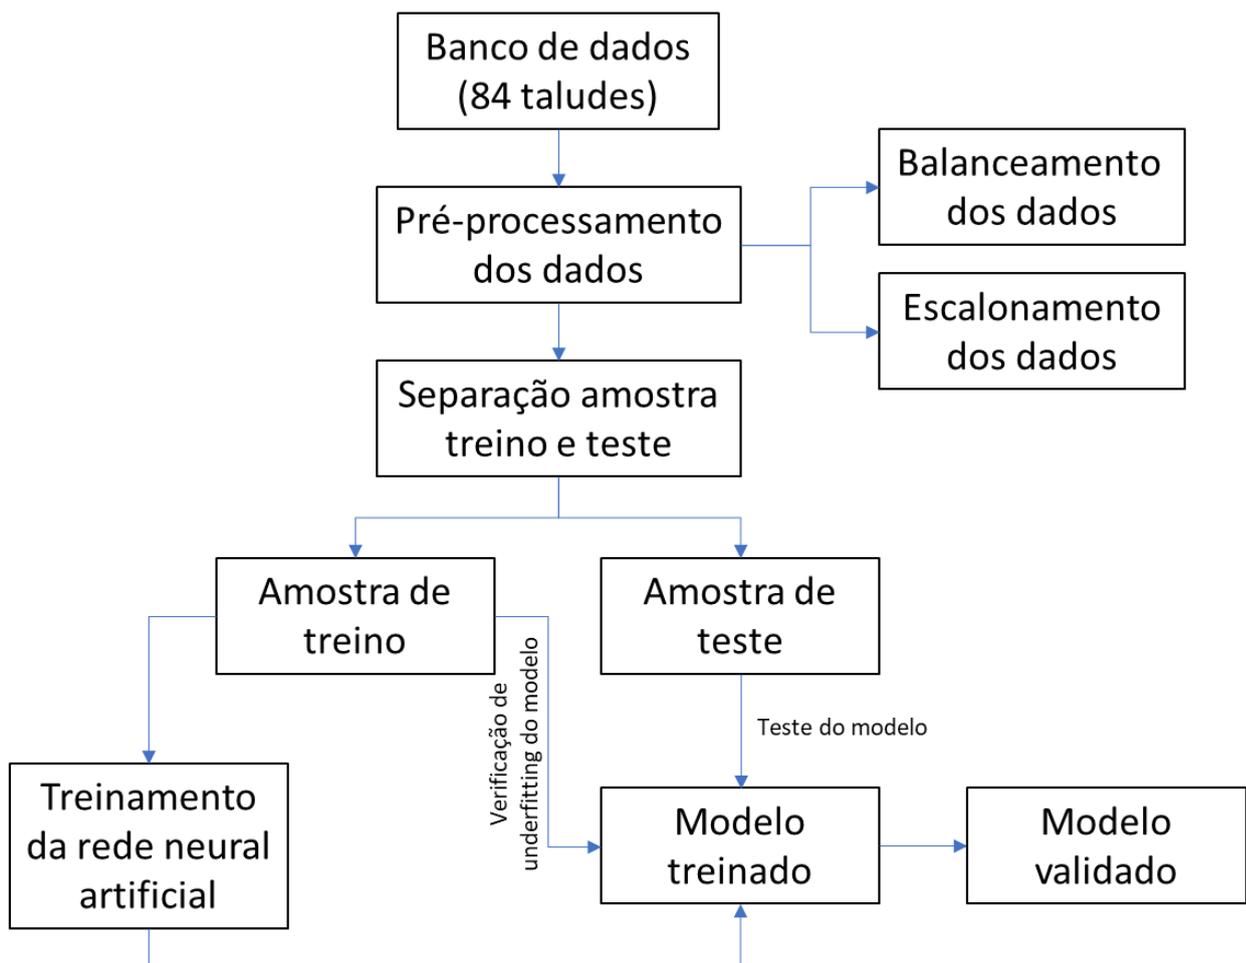


Figura 15: Fluxograma completo da metodologia proposta.

A amostra de treino tem o objetivo neste trabalho de ajustar os pesos e conexões de acordo com o que representa um melhor resultado e menor erro. Já a amostra teste utiliza uma amostra desconhecida pelo modelo para verificar suas capacidades de assertividade em dados desconhecidos. Para determinar se a metodologia foi eficaz utilizou-se de parâmetros estatísticos para verificação.

A estruturação da rede neural artificial é realizada conforme a sua utilização, ou seja, a rede segue a estruturação específica para cada tipo de problema. A estruturação que melhor compreendia os dados em questão contou com uma rede neural com 3 camadas, sendo a de entrada, uma oculta e a de saída.

Para a determinação do número ideal de nós foram feitos testes com números de nós dispostos de um a dez, dispondo de resultados referentes à acurácia do modelo para cada número de nós apresentado.

A função de ativação na qual melhor se adequa aos dados em análise corresponde a função a tangente hiperbólica, conhecida como função tanh. O algoritmo de aprendizagem utilizado está disposto no Anexo 3 ao final deste trabalho.

3.5. Treinamento das redes neurais

O tema atual desse trabalho se baseia na interface de programação em R denominada Rstudio desenvolvido por JJ Allaire, com o intuito de realização de estudos da aplicação das redes neurais artificiais e de estudos estatísticos incluindo geração de gráficos. Esta linguagem possui bibliotecas próprias como auxílio para o embasamento necessário neste trabalho, incluindo o pacote neuralnet (GÜNTHER & FRITSCH, 2010), que é utilizada para o treinamento das multicamadas nas análises de regressão.

Varias bibliotecas foram utilizadas no processo de tratamento e análise dos dados como segue abaixo.

Gmodels: para ajuste de modelos (Warnes *et-al.* 2022), com o intuito de para acelerar o processo de criação de modelos preditivos utilizou-se o conjunto de funções.

Caret: (Kuhn *et. al.* 2022), o pacote plyr foi utilizado no intuito de tratar os dados como dividir, combinar e aplicar dados (Wickham, 2011).

MultiROC que é aplicado para calcular e visualizar curvas de ROC e PR em multiclassses (Runmin *et. al.* 2018).

PROC para exibir e analisar curvas ROC (Xavier *et. al.* 2011) .

UBL que representa a implementação de abordagens de reamostragem para aprendizado baseado em utilidade para tarefas de classificação e regressão (Branco *et. al.* 2016).

Para desenvolver um modelo com o melhor desempenho possível foi necessário o ajuste de todos os parâmetros e o treino do modelo para que se desenvolvesse o cenário ideal, determinando os parâmetros mais adequados no modelo como a função de ativação e número de camadas. Para esse treino foi desenvolvido uma rede com função de ativação do tipo tangente hiperbólica, com três camadas, entrada, camada oculta e saída. Essa estruturação foi definida pelo treino esse cenário remete ao modelo do qual apresentou os melhores resultados.

O Anexo 3 remete ao código criado na linguagem R que utiliza das bibliotecas

descrita nos parágrafos anteriores para a criação do modelo ideal para a análise classificatória dos dados, observa-se que a camada de entrada possui 10 nós representando os 10 parâmetros de entrada, a camada oculta e a camada de saída ambas possuem 3 nós em sua estrutura, visto que a saída remete a classificação dos dados que neste caso está limitada em Classe II, Classe III e Classe IV.

3.6 Validação dos resultados

Após a estruturação das redes neurais utilizou-se da matriz de confusão para determinar alguns resultados, esse resultados são analisados com algumas técnicas estatísticas, a análise parte do conhecimento dos parâmetros acurácia, sensibilidade especificidade e acurácia balanceada.

Utilizou-se técnicas para cálculos dos determinados parâmetros descritos acima de acordo com o especificado no texto disposto no item, 2.83 Validação para modelos de classificação. Ao determinar todos esses parâmetros para o teste e para o treino dos 10 testes feitos no modelo, utilizou-se de uma análise gráfica para comparar os resultados e determinar a qualidade do modelo. Para realizar tal comparação montou-se uma tabela com os resultados de cada parâmetro para o treino e para o teste, e os parâmetros são observados para cada uma das classes, sendo assim um resultado que pode explicar algumas características entre classes.

O cálculo de tais parâmetros dependem exclusivamente da análise da matriz de confusão, foram dispostas matrizes para treino e teste de valores referentes aos fatores máximos e aos mínimos. Observa-se que foi realizada a reunião todas as 10 matrizes de confusão determinadas anteriormente como forma de validação do modelo, essas matrizes podem ser melhores observadas no anexo III ao final dessa pesquisa

4. RESULTADOS E DISCUSSÃO

4.1 Cálculo de RMR Intervalos Máximo e Mínimo.

Conforme proposto por Bieniawski (1989), O calculo de RMR para o banco de dados foi realizado com base nos pesos atribuidos aos parâmetros correspondentes a classificação. A soma dos pesos determinados resultou no valor bruto de RMR, e posteriormente classificou-se os valores de acondo com o valor da somatória dos pesos.

Quatro novas colunas foram adicionadas ao banco de dados após os cálculos citados no parágrafo acima. São eles RMR 1 nomenclatura adotada para refenciar os

valores mínimos nos intervalos, RMR 2 referenciando aos valores máximos nos intervalos, Classes Máximas para valores Máximos e Classes Mínimas para valores mínimas. A Tabela 16 representa 10 dos 84 taludes do banco de dados primordial para demonstrar as adições citadas.

Tabela 16: Amostra do banco de dados final representando os resultados de RMR.

<i>Local</i>	<i>RMR 1 Mínimo</i>	<i>Classes Mínimas</i>	<i>RMR 2 Máximo</i>	<i>Classes Máximas</i>
ÁGUAS CLARAS -BRASIL	48,00	Classe III	43,00	Classe III
MINA DE COBRE - SUÉCIA	59,00	Classe III	57,00	Classe III
MINA DE CHUMBO E ZINCO - IRÃ	42,00	Classe III	42,00	Classe III
MINA DE OURO - EUA	58,00	Classe III	60,00	Classe III
MINA DE FERRO - IRÃ	41,00	Classe III	47,00	Classe III
MINA DE COBRE - CHILE	48,00	Classe III	48,00	Classe III
MINA DE COBRE - CHILE	40,00	Classe IV	41,00	Classe III
MINA DE COBRE - EUA	38,00	Classe IV	47,00	Classe III
MINA DE FERRO -IRÃ	64,00	Classe II	69,00	Classe II
MINA DE ARGILA - ESPANHA	51,00	Classe III	53,00	Classe III

4.2 Análise preliminar do banco de dados

Ao calcular o RMR dos valores do intervalo referentes a máximo e mínimo para os taludes do banco de dados, analisou-se estatisticamente por meio de uma matriz de confusão e gráfico de dispersão a variação entre classes dos resultados iniciais conforme a tabela abaixo. Na Tabela 17 mostra que a variação das classes compreendem entre a Classe II, III e IV, não ocorrendo nenhum resultado nas classes I e V, essa delimitação ocorre pois o trabalho está restrito ao banco de dados de Zare Naghadehi et (2013), e o banco por si compreende apenas taludes dos quais se

classificam como Classes II, III e IV.

Tabela 17: Estatísticas Tabuladas: RMR 1 valores mínimos nos intervalos(Linhas); RMR 2 valores máximos nos intervalos (Colunas).

	Classe II	Classe III	Classe IV	Todos
Classe II	6	3	0	9
Classe III	1	47	1	49
Classe IV	0	14	12	26
Todos	7	64	13	84

A diferença entre as classes resultantes dos RMRs para valores máximos e mínimos dos intervalos seguem a lógica de que não há salto de classe de um extremo para outro sem passar pela classe central. Nesse caso pode-se dizer que uma Classe I não salta para uma Classe IV na análise dos dados. Esse fenômeno ocorre pois as diferenças entre os intervalos das variáveis não são suficientes para tal fato. No entanto, essa diferença que se dá entre as classes calculadas é o que torna necessário a divisão entre RMR 1 e 2.

A Figura 16 ilustra conforme apresentado na Tabela 17, a necessidade da determinação do RMR 1 e RMR 2, o primeiro para valores mínimos em intervalos e o segundo para valores máximos, observa-se que os resultados são visivelmente dispersos.

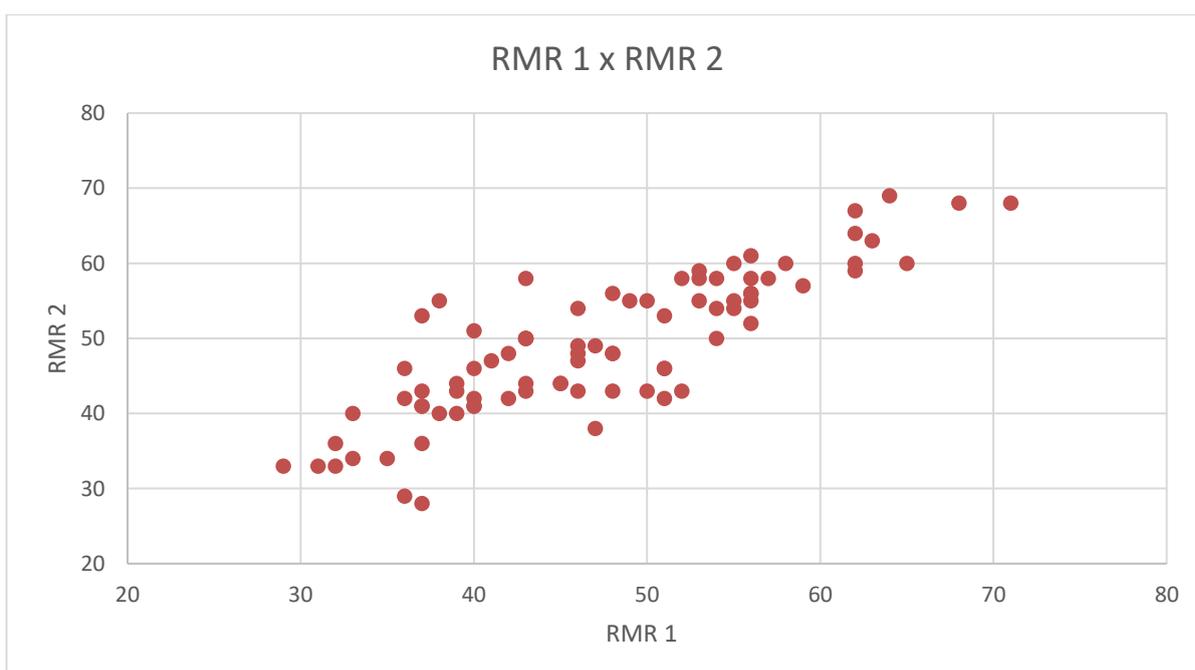


Figura 16: Gráfico representando a dispersão entre os valores de RMR 1 e RMR 2

Ao todo somam-se 84 taludes, os resultados obtidos de RMR foram dispostos nos

gráficos abaixo, e eles mostram a irregularidade do banco de dados com uma concentração da maioria dos taludes em Classe III . Esse desbalanceamento conforme afirma as Figuras 17 e 18 torna-se necessário o balanceamento para as etapas subsequentes. Observa-se que o banco de dados compreende apenas Classes RMR II, III e IV, e dessa forma o modelo na qual se baseia esse projeto não abrange as Classes I e V.

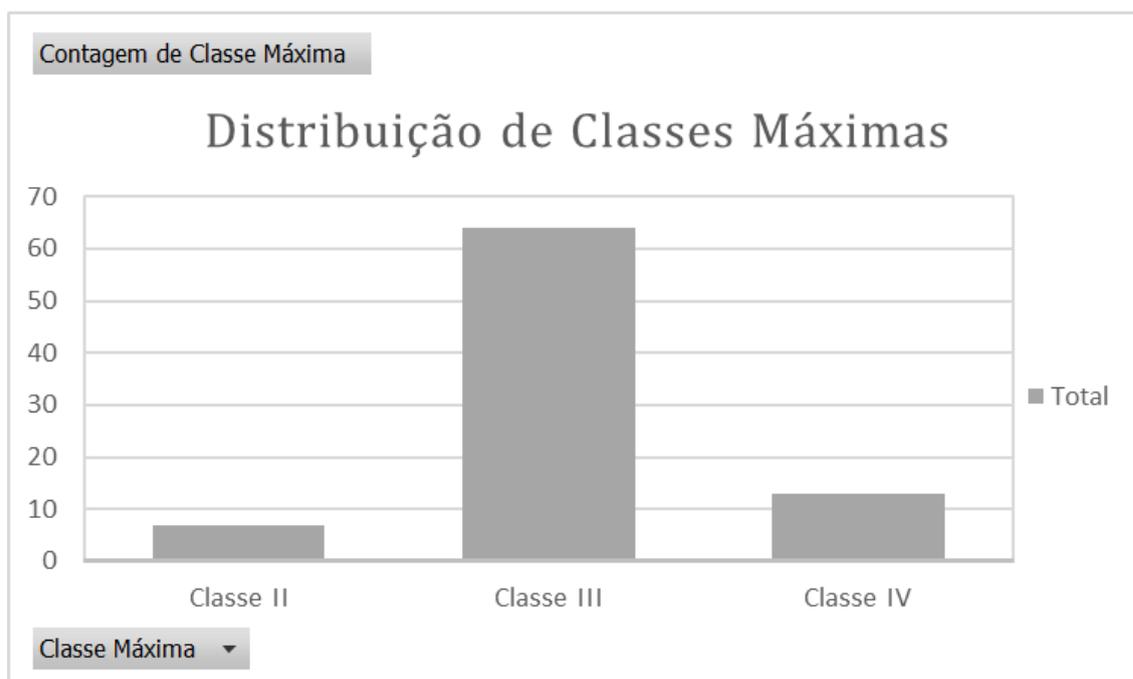


Figura 17: Distribuição das classes referentes aos valores de RMR 2 valores máximos nos intervalos.

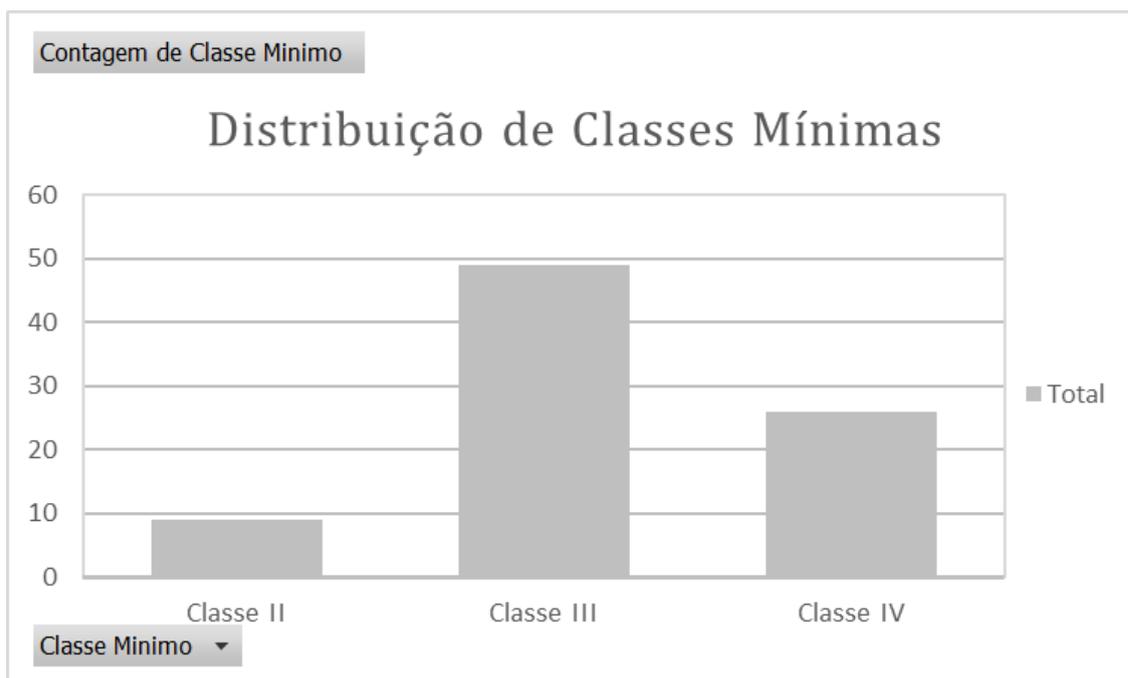


Figura 18: Distribuição das classes referentes aos valores de RMR 1 valores mínimos nos intervalos.

4.3 Treinamento do modelo

Ao criar o banco de dados para utilização no software R Studio, houve a necessidade de uma análise mais detalhada das variáveis a serem utilizadas. Comparando as escalas dessas variáveis conforme os gráficos das Figuras 19 e 20, conclui-se que é necessário escalonar as variáveis.

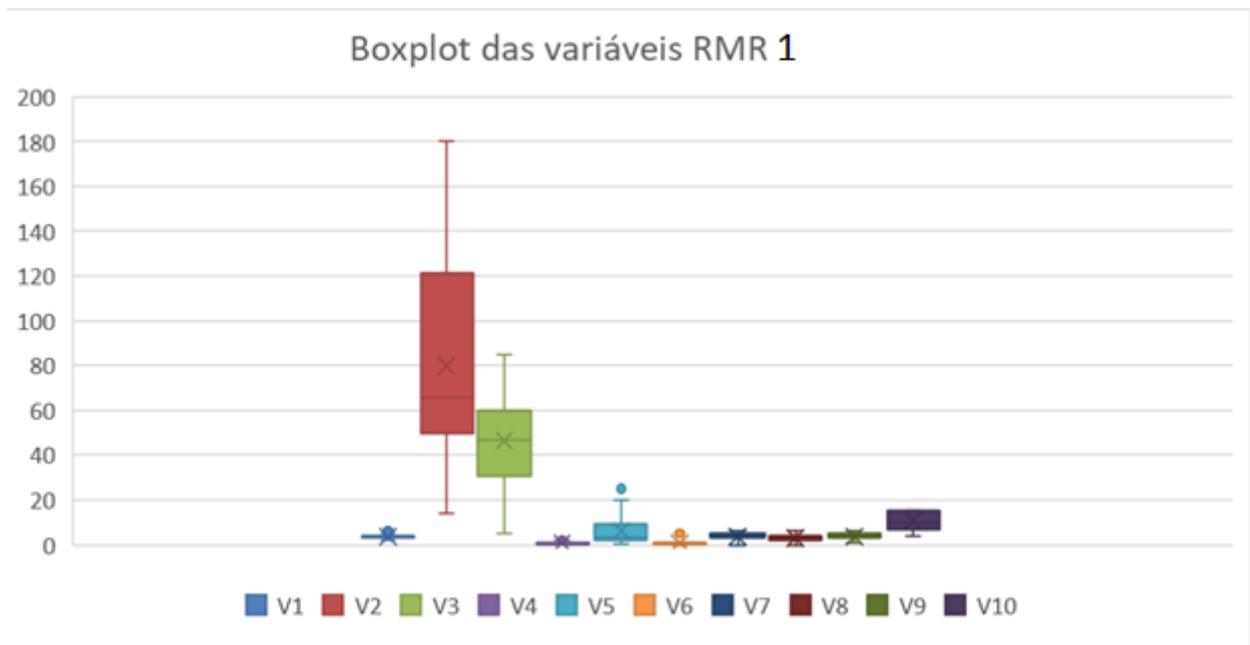


Figura 19: Comparação de escalas entre as variáveis mínimas.

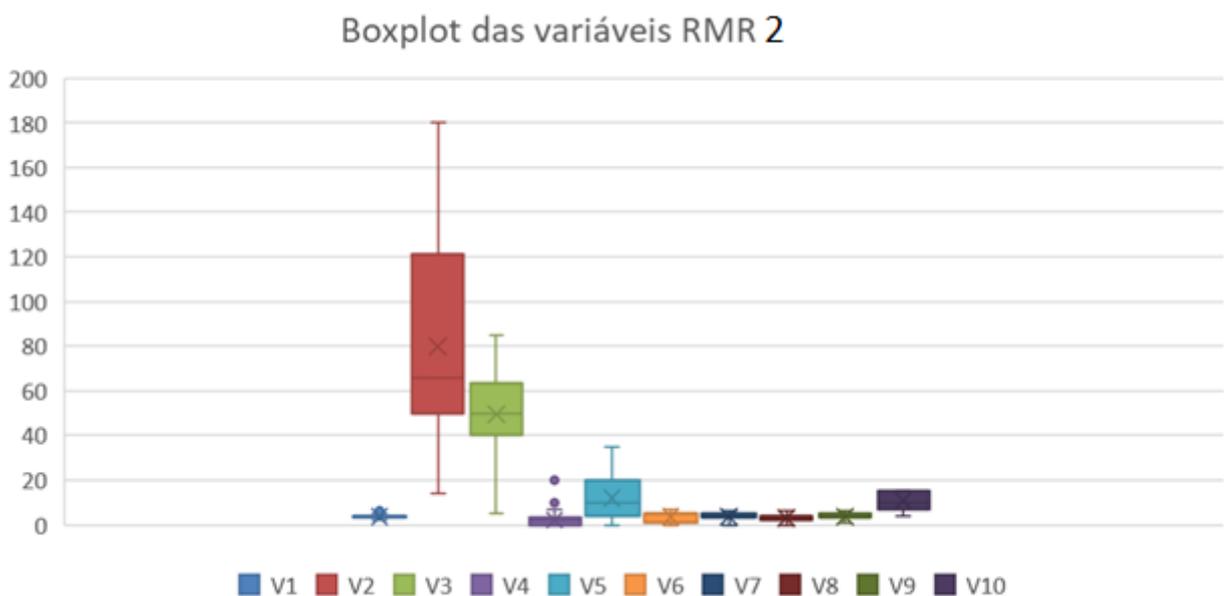


Figura 20: Comparação de escalas entre as variáveis máximas.

As variáveis V5, V6, V7, V8, V9 e V10 assumiu-se os valores de seus pesos (somatórias utilizadas no cálculo de RMR), V2 (Resistência da rocha intacta), V3 (RQD (%)) (Mínimo) e V4 (Espaçamento mínimo das descontinuidades), foram adicionados os valores de suas atribuições normais.

Para determinação de alguns parâmetros utilizados pelo R Studio na formação da rede neural artificial foi preciso realizar alguns testes, na determinação do tamanho das amostras para treino e teste e também para a determinação do número de nós a

serem utilizados. Visando o tamanho do banco de dados optou-se por dividi-lo em um terço para o teste e dois terços para treino, ou seja, 56 taludes para o treino e 28 para o teste.

O gráfico a seguir apresentado na Figura 21, representa os testes feitos para determinação da quantidade ideal de nós para a RNA.

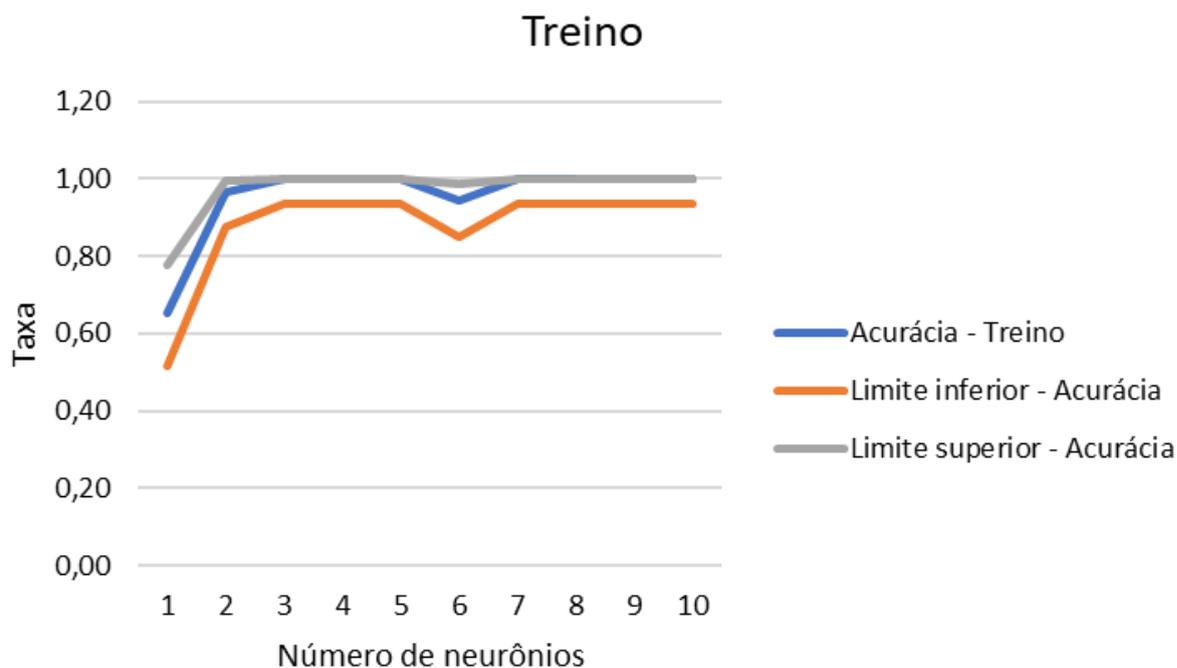


Figura 21: Testes feitos para determinação do número de neurônios no treino.

Ressalta-se que a mesma rede utilizada para o treino também foi utilizada no teste. Observa-se no gráfico que a utilização de 3 neurônios é a opção ideal, pois, a acurácia nesse ponto foi a que mais se destacou positivamente tanto no treino quanto no teste.

Para identificar a eficácia do modelo para cada classe utilizou-se os parâmetros sensibilidade, especificidade e acurácia balanceada conforme descrito no item 2.83 matriz de confusão.

4.4 Resultados RMR 1 valores de intervalo mínimo.

Como esclarecido anteriormente sobre a necessidade do balanceamento dos dados, adicionou-se ao script que anterior à realização da divisão entre amostras treino e teste, seria necessário o balanceamento dos dados, conforme pode-se comparar nos

gráficos abaixo representados pelas Figuras 22 e 23.

A utilização de um banco de dados balanceado minimiza a possibilidade de problemas de overfitting durante o treinamento, dado que a concentração de dados na classe III é visivelmente maior como na Figura 22, enquanto nos dados balanceados essa diferença se minimiza consideravelmente Figura 23.

O balanceamento dessas variáveis feitas no script, utilizando a técnica Smote que reduz a classe predominante e aumenta as outras, formando assim um banco de dados mais equiparado.

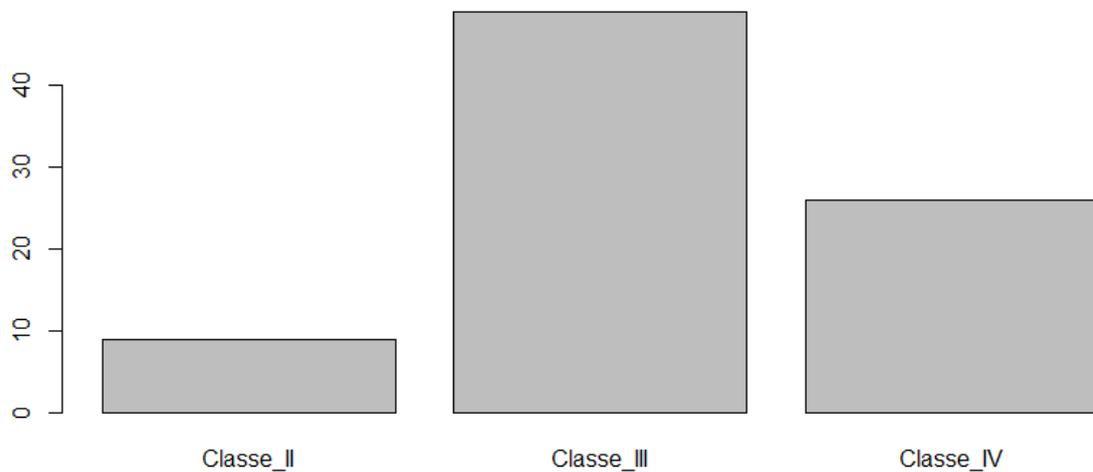


Figura 22: Distribuição dos dados de RMR 1 (parâmetros mínimos) antes do balanceamento.



Figura 23: Distribuição dos dados de RMR 1 (parâmetros mínimos) depois do balanceamento.

Ao realizar o treino com os 3 neurônios e 3 camadas foi obtida a seguinte arquitetura evidenciada na Figura 24.

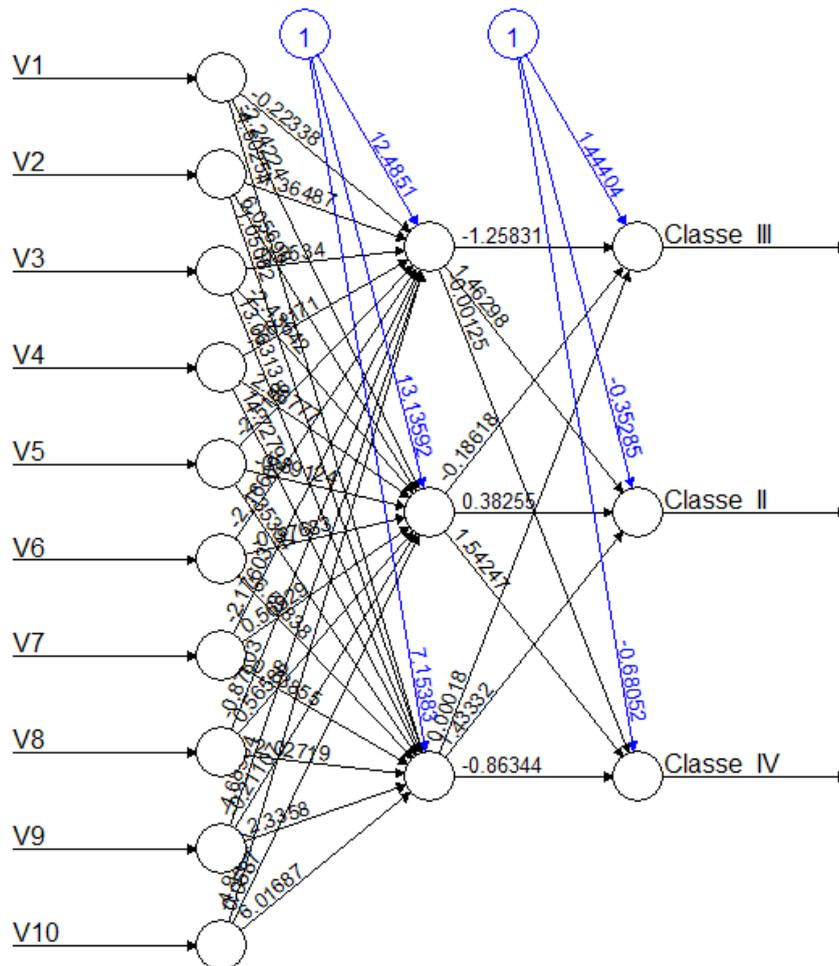


Figura 24: Arquitetura dos neurônios utilizando as três camadas referentes às classes de RMR 1 com com valores mínimos do intervalo.

Para validar os testes, o modelo foi utilizado por dez vezes no banco de dados utilizando amostras aleatórias e distintas. Durante a validação registrou-se os valores de acurácia a fim de pontuar graficamente uma relação na qual se torna possível verificar com maior precisão a assertividade do modelo.

A Figura 25 representa os dez testes feitos na validação do modelo para os valores mínimos dos intervalos RMR 1, os valores de acurácia no treino estão dispostos em torno da média de 92,73% e no treino no entorno de 80%.

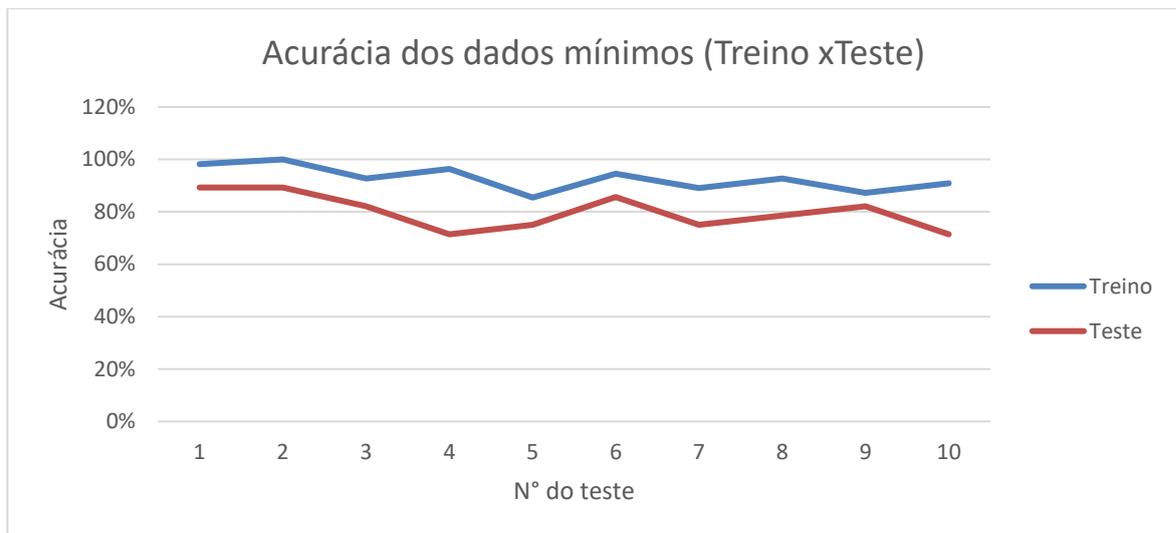


Figura 25: Gráfico relacionando a acurácia entre os treinos e testes referentes ao RMR 1 para valores mínimos nos intervalos.

As Figuras 26 e 27 representam os resultados obtidos nos dez testes feitos quanto a sensibilidade, especificidade e acurácia balanceada. Observa-se que no treino os valores estão mais próximos do máximo de 100%, diferenciando-se apenas em alguns dos testes.

A média referente aos valores de sensibilidade, especificidade e acurácia balanceada em relação ao treino é de respectivamente, 96%, 99% e 98% enquanto que os mesmos parâmetros têm valores de 99%, 94% e 96% para os testes, dessa forma observamos que para a classe II o modelo tem uma precisão semelhante entre o treino e o teste, observando-se que quanto mais próximo de 100% mais assertivo é o modelo.

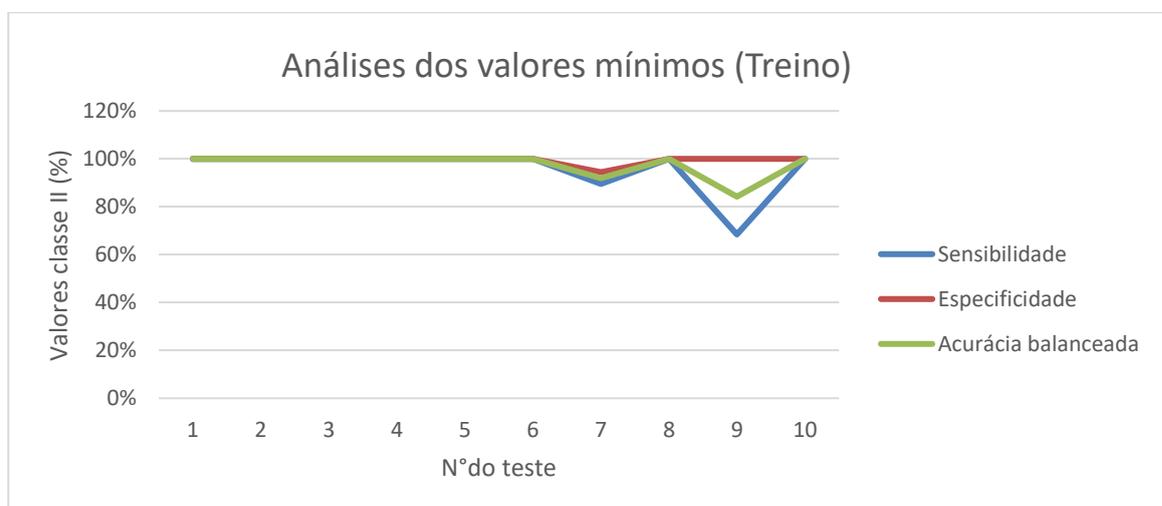


Figura 26: Resultados do treino para os valores mínimos da classe II.

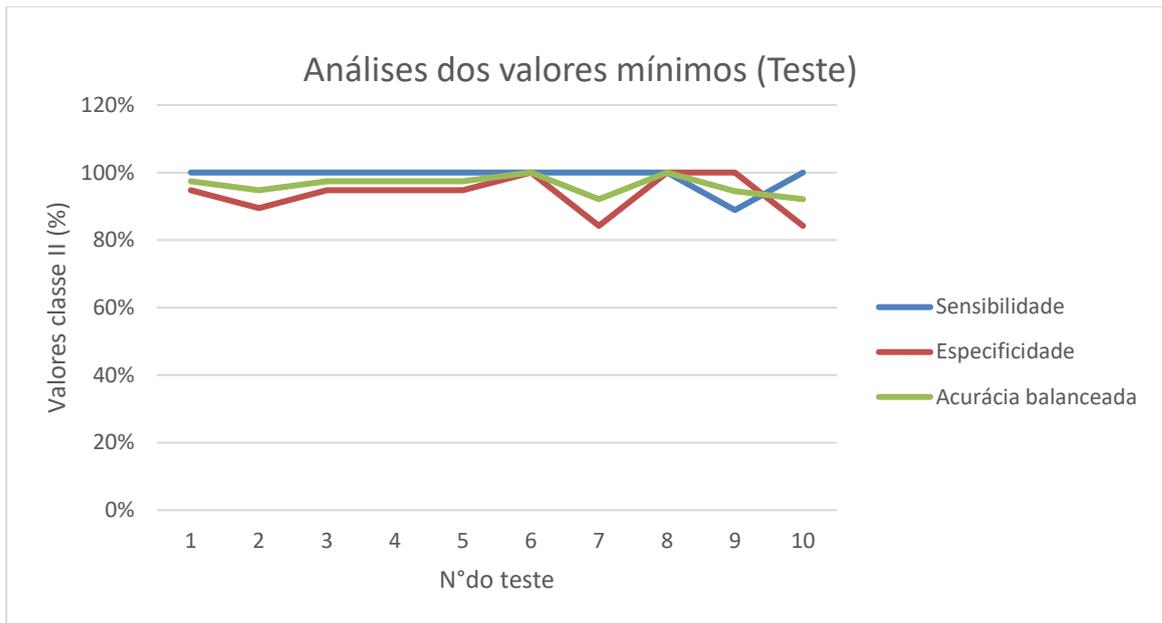


Figura 27: Resultados do teste para valores mínimos da classe II.

Para os parâmetros correspondentes à classe III, temos os dois gráficos abaixo referentes ao treino e ao teste. Observa-se que há uma diferença significativa entre o treino e teste da classe II, citados acima, e o treino e teste da classe III explicitados nas Figuras 28 e 29. Os valores médios de sensibilidade, especificidade e acurácia balanceada para o treino seguem os valores, 88%, 96% e 92%, enquanto os mesmos valores são 54%, 91% e 72% para o teste, respectivamente.

Conclui-se então que a classe III tem menor sensibilidade na classificação que a classe I. Lembrando que a maioria dos resultados de classificação do banco de dados tem classificação em classe III de RMR, tornando a quantidade dessa variável maior que as classes II e IV, sendo assim um erro nas Classes II e IV se torna mais representativo nas análises que na Classe III.

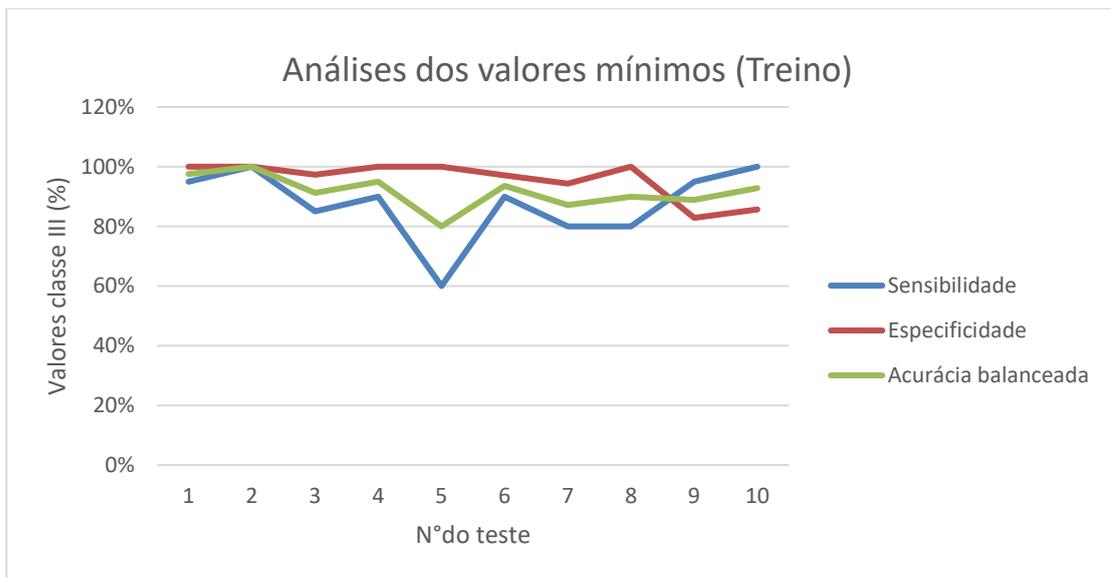


Figura 28: Resultados do treino para valores mínimos classe III.

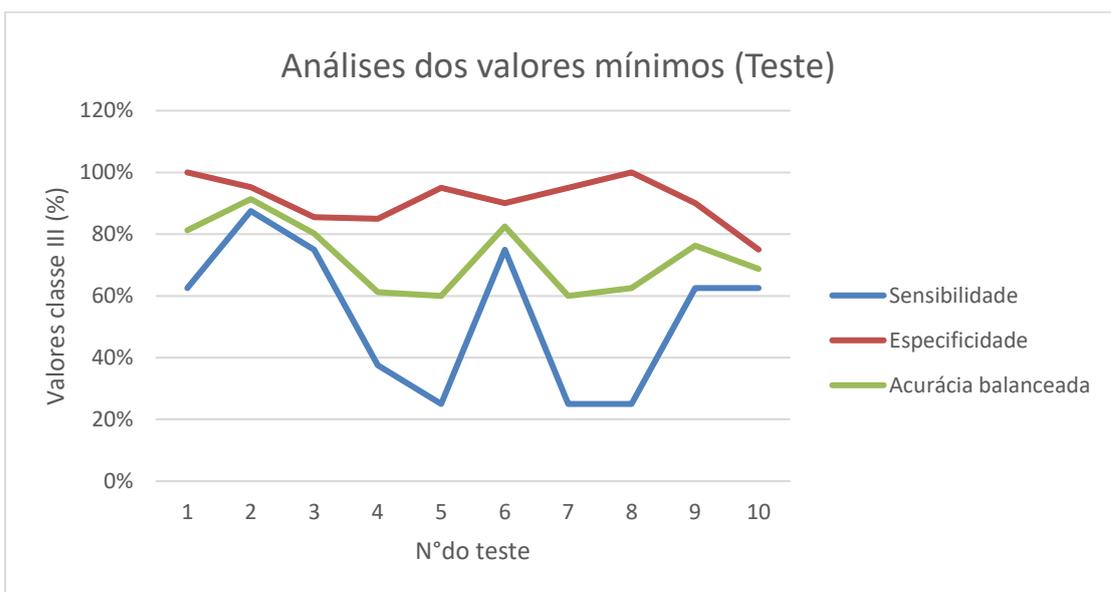


Figura 29: Resultados teste para valores mínimos classe III.

A classe IV tem resultados mais homogêneos que a classe III e mais diversificados que a classe II anteriormente apresentada, como apontam os gráficos descritos nas Figuras 30 e 31 referentes a treino e teste. As médias entre os valores de sensibilidade, especificidade e acurácia balanceada seguem a ordem de 96%, 94% e 95% para o treino enquanto para o testes os valores discorrem em torno de 84%, 85% e 84%.

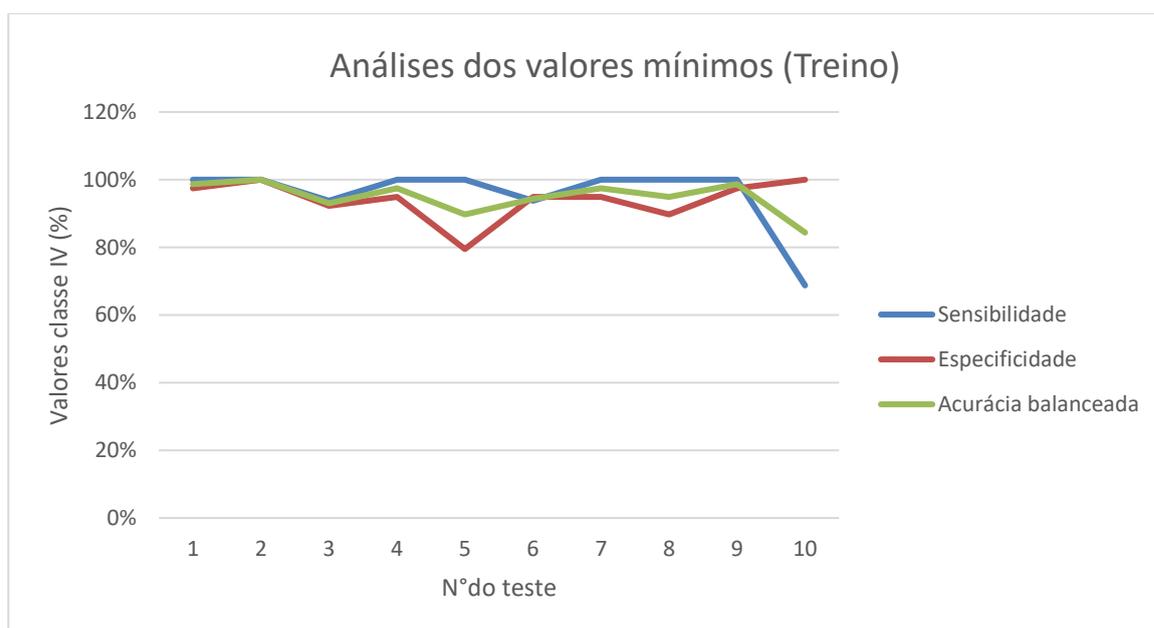


Figura 30: Resultados treino para valores mínimos classe IV.

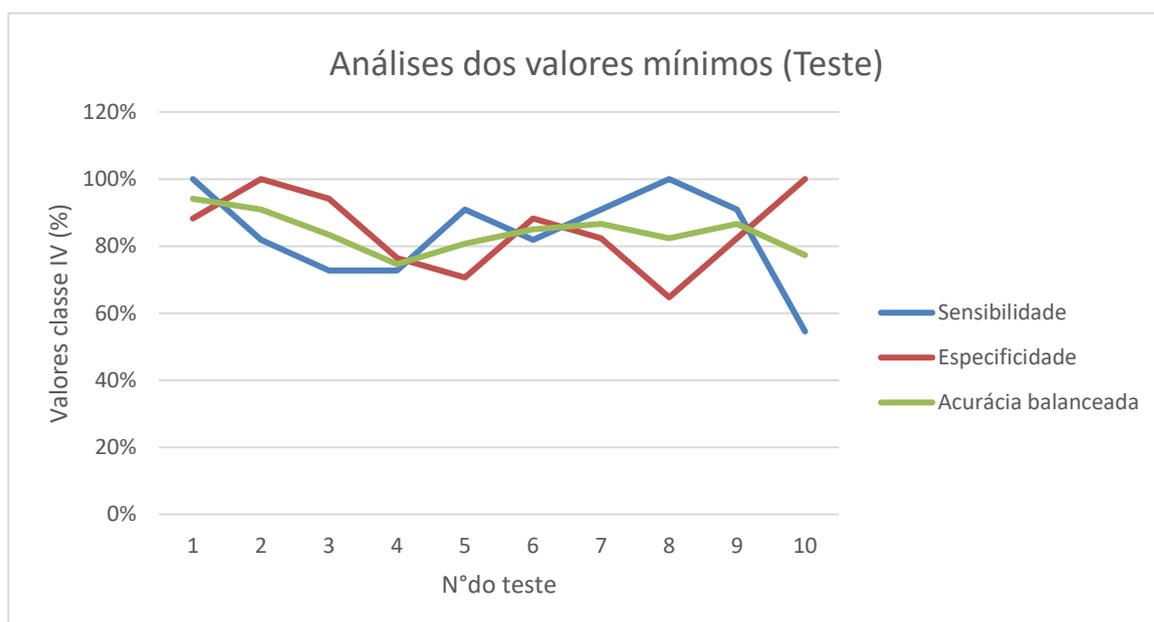


Figura 31: Resultados teste para valores mínimos classe IV.

Observa-se que a Classe III pode variar entre Classe II e Classe IV, sua sensibilidade é expressiva, enquanto a Classe II apenas erra para a classe acima e a Classe IV apenas erra para a classe abaixo.

A média das acurácias balanceadas provam que o modelo é válido e consideravelmente eficaz, visto que, o mesmo apresentou o valor de acurácia balanceada acima de 80%. As matrizes de confusão utilizadas para os cálculos dos parâmetros discutidos neste trabalho está disponibilizada no Anexo 2 ao final.

4.5 Resultados RMR 2 valores de intervalo máximo.

Assim como foi feito para os valores de RMR mínimos, optou-se pelo balanceamento dos dados referentes a classe para os valores de RMR 2 valores máximos nos intervalos. Observa-se no gráfico abaixo (Figura 32), que a distribuição das classes também se encontram desbalanceadas com uma concentração maior de valores em classe III, portanto, para utilizar os dados de forma a amenizar resultados tendenciosos utilizou-se a técnica do balanceamento conforme feito anteriormente nos dados de RMR 1 valores mínimos nos intervalos.

Pode-se comparar os resultados do balanceamento observando os valores prévios na Figura 32 e posteriormente balanceados na Figura 33. A diferença entre os dados se torna consideravelmente menor nos dados balanceados em comparação aos dados precedentes.

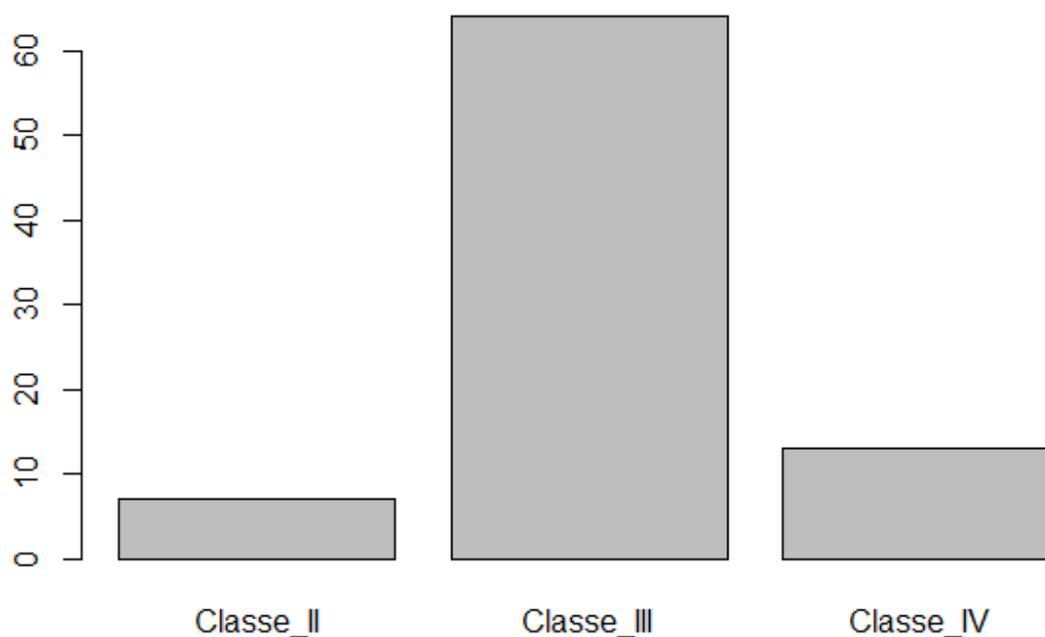


Figura 32: Distribuição das classes de RMR máximo antes do balanceamento.

A técnica aplicada para o balanceamento dos dados conforme os resultados da figura 33, compreende da técnica Smote que reduz a classe dominante e equipara as classes inferiorizadas.

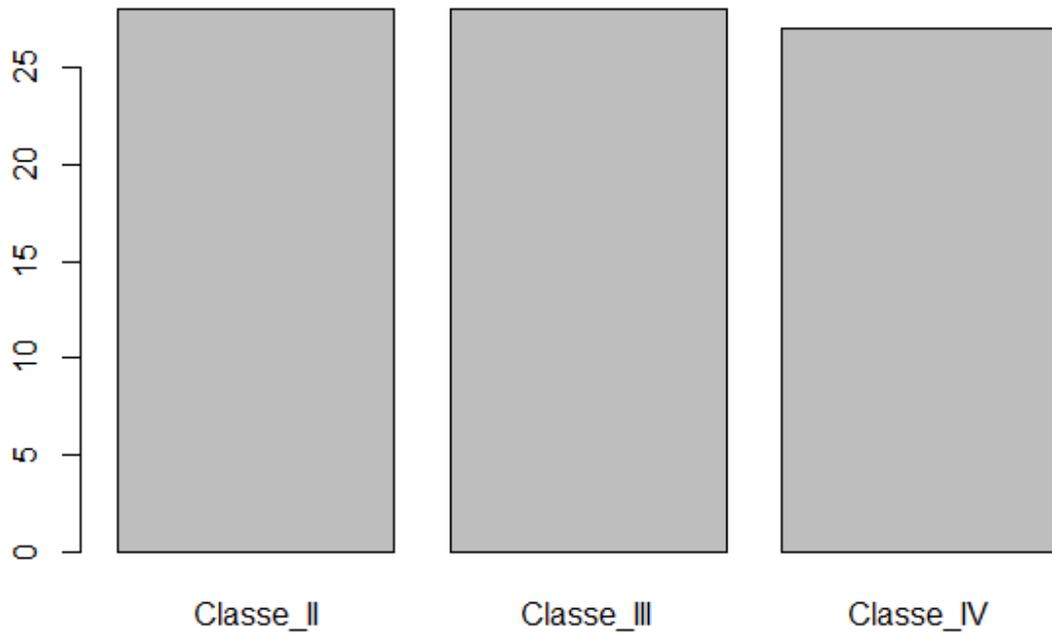


Figura 33: Distribuição das classes de RMR máximo depois do balanceamento.

Utilizando das três camadas e dos três neurônios do modelo anteriormente apresentado, a figura 34, nos apresenta o modelo aplicado aos dados máximos avaliados. A Figura 34 representa de forma ilustrativa a arquitetura de um dos testes feitos no modelo.

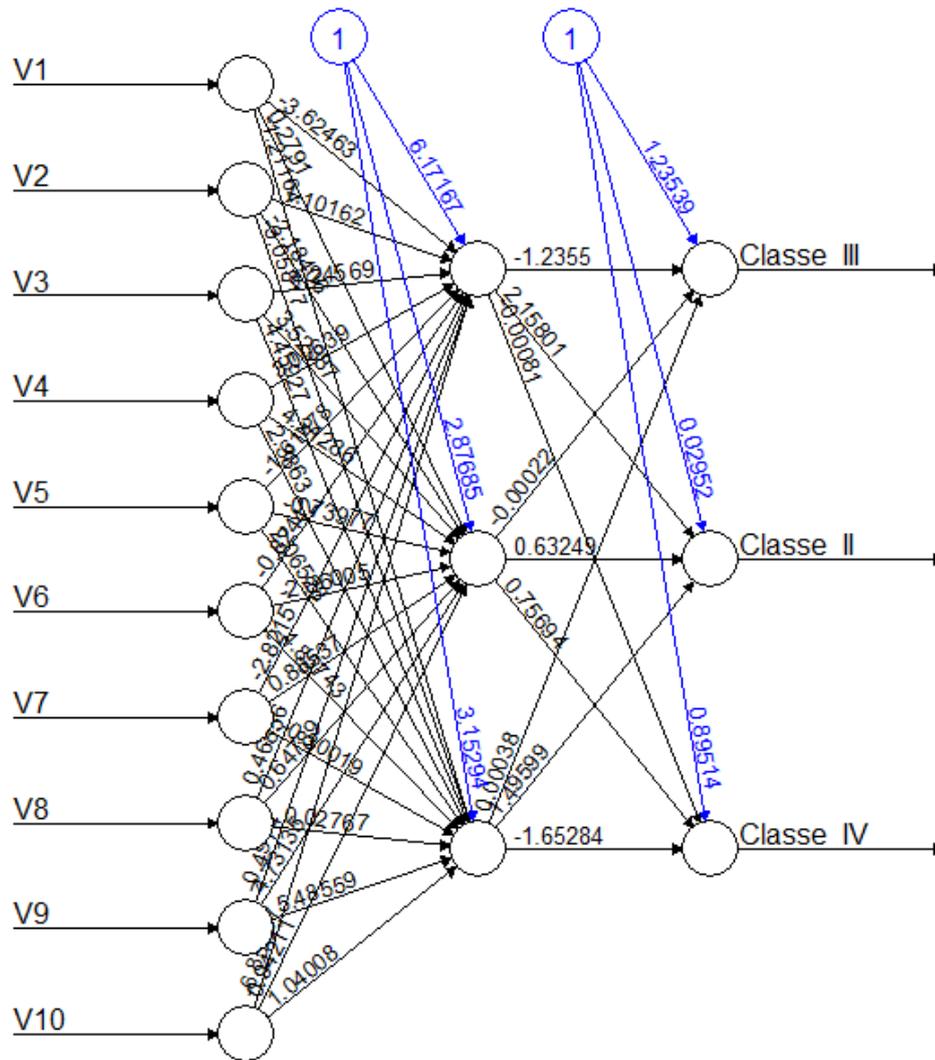


Figura 34: Arquitetura dos neurônios utilizando as três camadas referentes às classes de RMR máximo.

Conforme feito anteriormente nos dados referentes ao RMR mínimo, a validação do modelo foi feita em função dos dez testes aleatórios com a mesma amostra de dados. Os resultados de acurácia dos dez testes foram registrados.

A Figura 335 representa graficamente a distribuição da acurácia dos testes de validação. Observa-se também que os valores de acurácia estão dispostos em torno da média com o valor de 95,64% para treino, e 80% para teste.

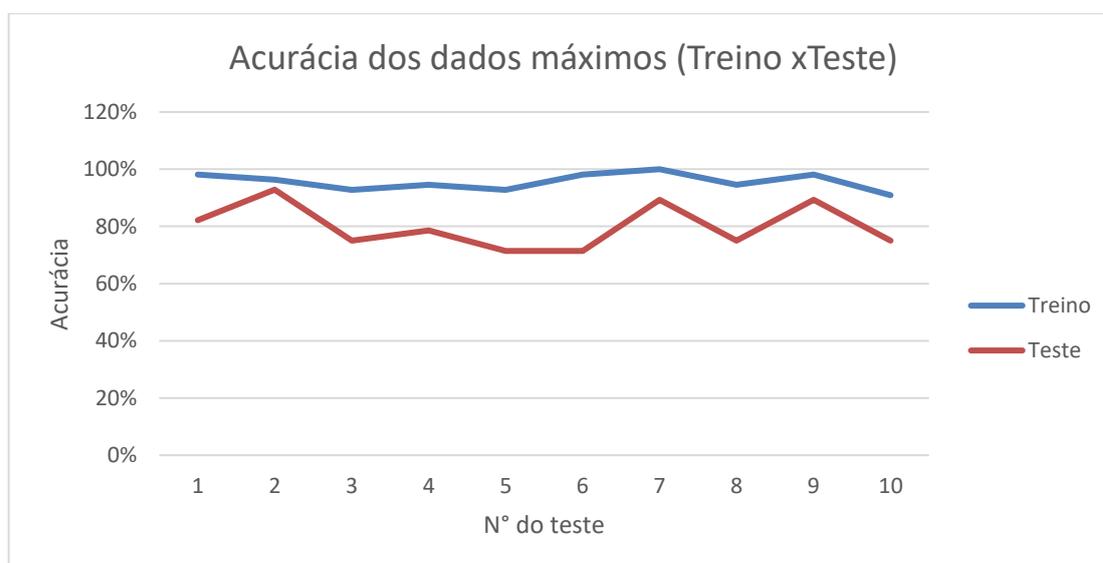


Figura 35: Representação gráfica da acurácia dos testes envolvendo os dados de RMR máximos.

Os valores de sensibilidade, especificidade e acurácia balanceada para os valores máximos de RMR, estão distribuídos de acordo com os gráficos apresentados a seguir. Comparando as Figuras 36 e 37 observa-se que os resultados entre treino e teste não se diferem representativamente, pode-se observar que para a Classe II os valores não se diferenciam em relação aos mesmos parâmetros observados nos resultados anteriores para os valores mínimos nos intervalos.

As médias referentes aos parâmetros sensibilidade, especificidade e acurácia balanceada, são respectivamente, 98%, 99% e 98% enquanto para o teste esses valores variam de 94%, 93% e 94%.

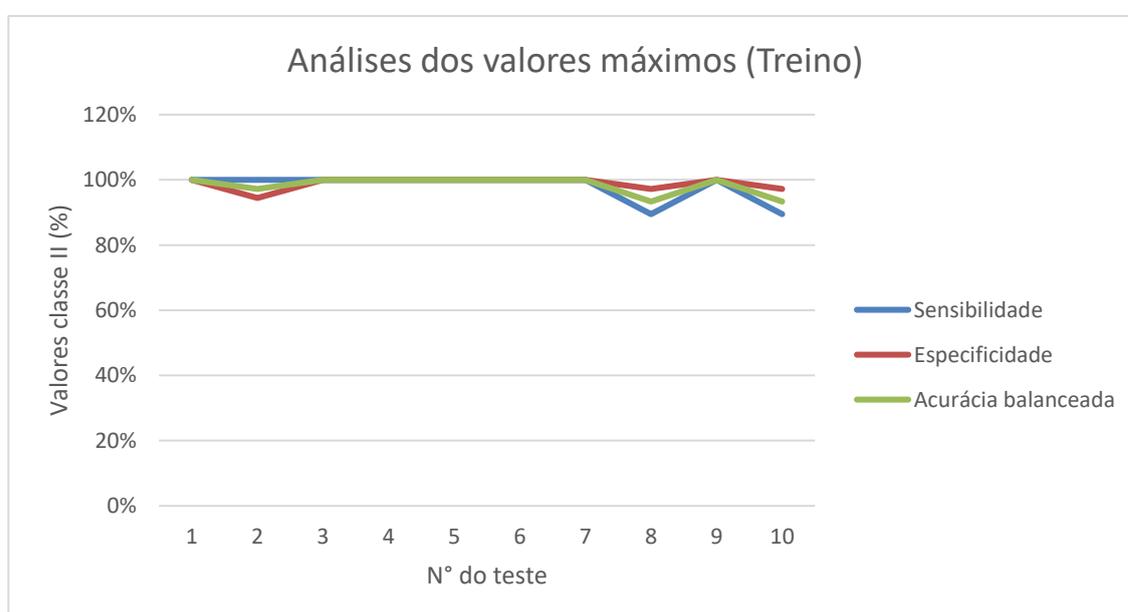


Figura 36: Resultados treino para valores máximos classe II.

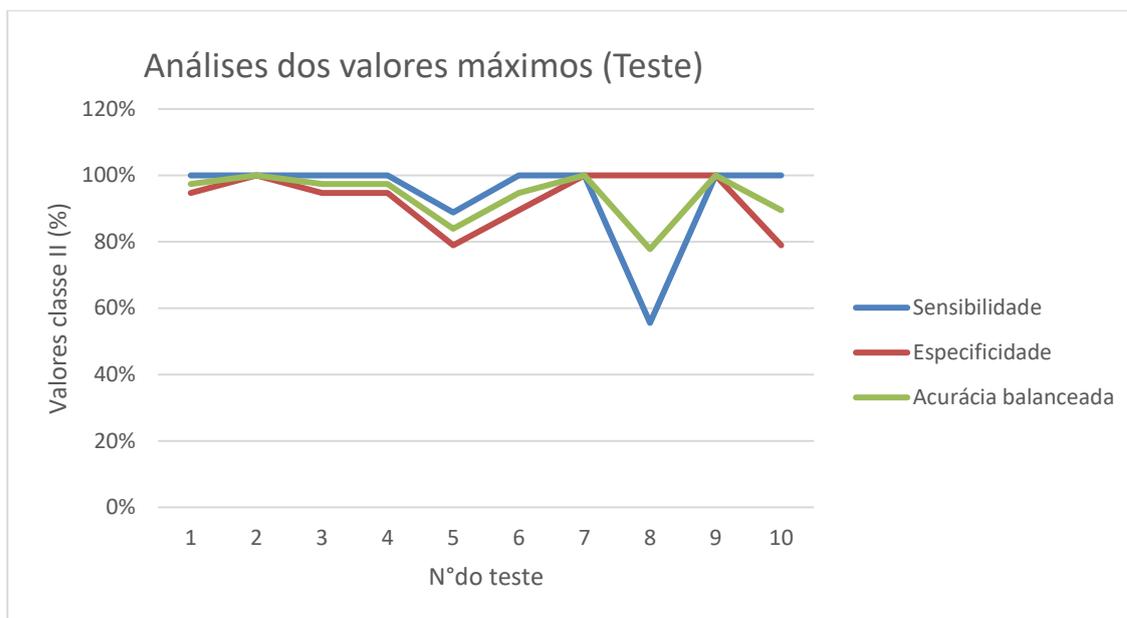


Figura 37: Resultados teste para valores máximos classe II.

Em relação aos valores máximos referente a classe III os resultados são pouco divergentes em relação aos mesmos parâmetros referentes aos resultados para os valores mínimos nos intervalos apresentados anteriormente.

As Figuras 38 e 39 manifestam a mesma variação resultante da quantidade de dados compreendidos em classe III nos dados referência. Observa-se que os valores médios estão dispostos como 90%, 99% e 94% para treino e 51%, 91% e 71% para o teste em relação aos parâmetros sensibilidade, especificidade e acurácia balanceada.

Do mesmo modo no qual o modelo tem menor sensibilidade ao erro para a classe III nos valores mínimos (RMR 1), o modelo também tem essa menor sensibilidade aos valores de classe III do dados máximos (RMR 2).

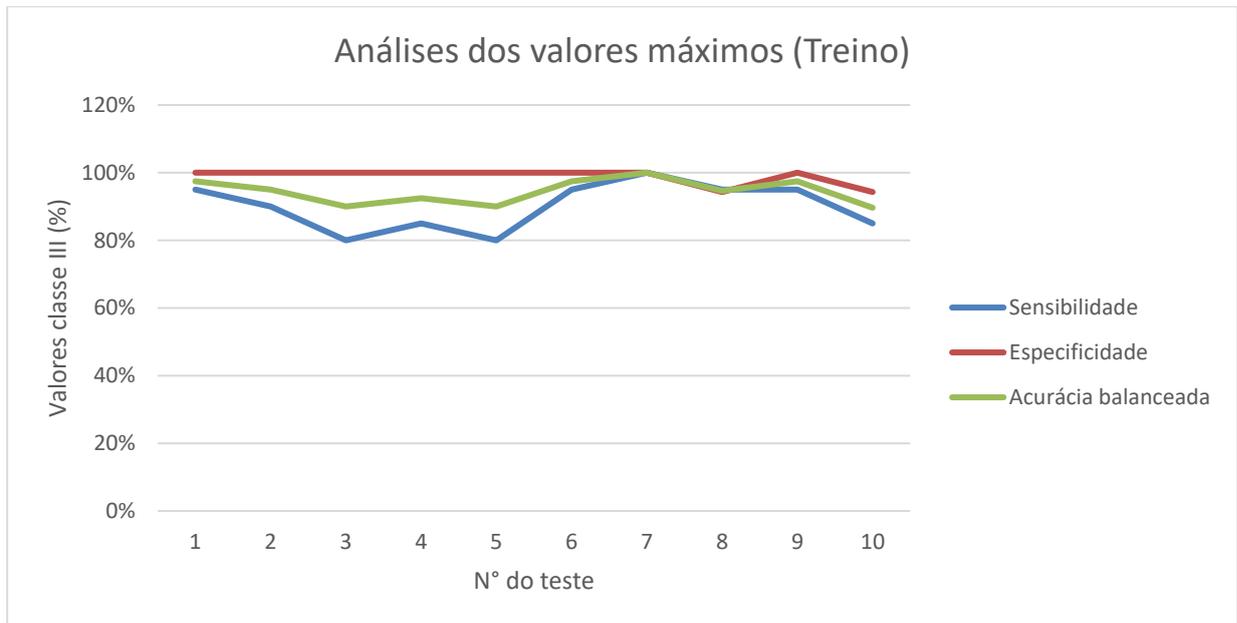


Figura 38: Resultados do treino para valores máximos de classe III.

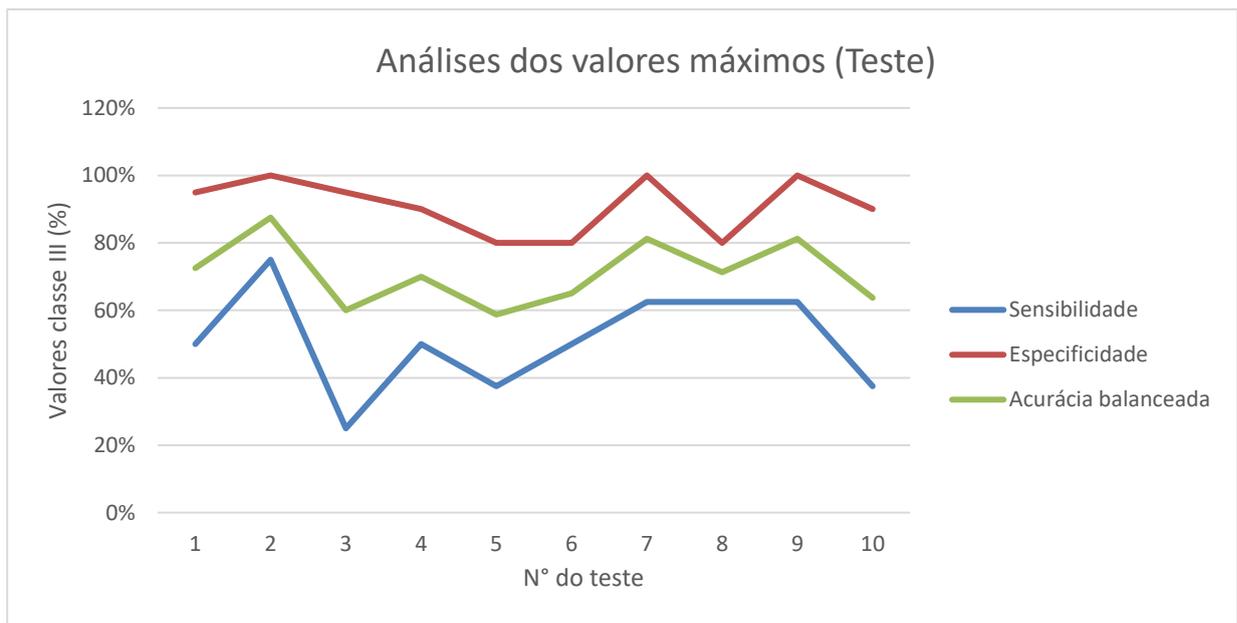


Figura 39: Resultados teste para valores máximos de classe III.

Para os resultados da classe IV temos que qualquer erro pode conduzir a uma maior variação nos valores de sensibilidade, especificidade e acurácia do gráfico e uma maior variação na média deduzindo que a quantidade de resultados pertencentes a essa classe é bem menor que a classe III. As Figuras 40 e 41 representam os efeitos em treino e teste. Os valores de média para esses parâmetros são 100%, 96% e 98% para o treino e 89%, 84% e 87% para o teste, respectivamente.

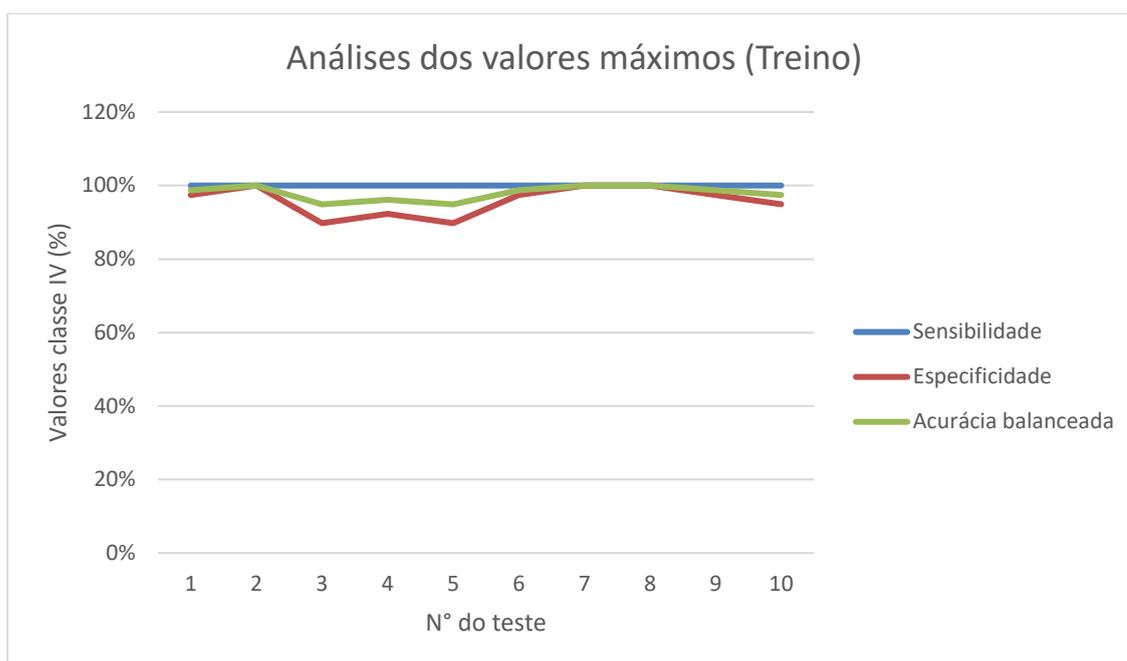


Figura 40: Resultados treino para valores máximos de classe IV.

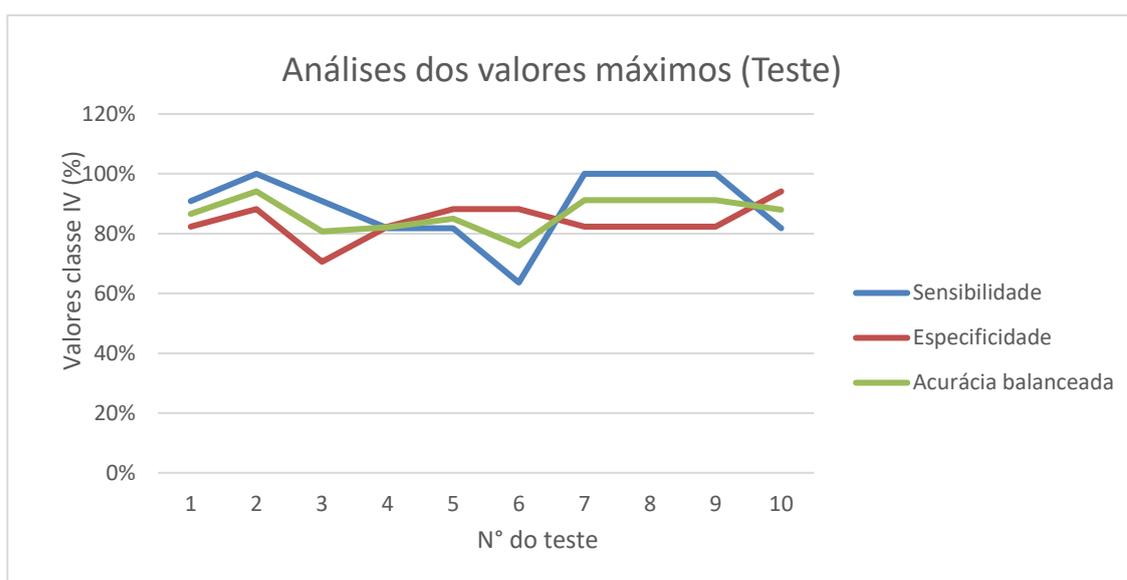


Figura 41: Resultados teste para valores máximos de classe IV.

Observa-se por ultimo que em ambas as classes a média da acurácia balanceada se estabilizou acima de 80%, dessa forma validando o modelo quanto a eficácia de classificação do modelo. Ao final no Anexo 2 está disponibilizado a tabela contendo todas as matrizes de confusão utilizadas para os cálculos dos parâmetros discutidos neste trabalho

5. CONCLUSÕES

Conclui-se que a necessidade da divisão entre valores máximos e valores mínimos é relevante pois os resultados apontaram uma divergência significativa entre os resultados de RMR para valores mínimos e máximos. Ressalta-se que o modelo não compreende valores de RMR de Classes I e V, pois, dentre todos os taludes classificados, encontrou-se apenas taludes Classes II, III e IV. Desse modo o modelo de Rede Neural Artificial proposto é limitado a Classes II, III e IV.

As medidas de sensibilidade do modelo comprovam que as Classes II e IV possuem maior sensibilidade para a Classe III, ou seja, quando o modelo classifica de forma errada as Classes II e IV, o resultado da eficácia é fortemente penalizado, diferente da Classe III, que quando classificada de forma errada, o erro tem menor relevância em comparação as outras classes. Esse fato ocorre de acordo com a distribuição desbalanceada das classes no banco de dados, a quantidade de taludes compreendidos em Classe III é consideravelmente maior que a quantidade compreendida entre as Classes II e IV.

O modelo de classificação referente a Classe II se mostra eficaz com médias de sensibilidade, especificidade e acurácia balanceada de 99%, 94% e 96% respectivamente em valores mínimos no intervalo (RMR 1) e 94%, 93% e 94% para valores máximos no intervalo (RMR 2).

Com base nas médias referentes aos parâmetros calculados pela matriz de confusão, observou-se que a Classe II no geral possui uma sensibilidade alta, abarcando valores acima de 90%, em contrapartida a acurácia balanceada que representa a eficácia do modelo em classificar corretamente a Classe II também possui média acima de 90%. O modelo é sensível a classificação na Classe II, contudo, apresenta alta eficácia na classificação.

Os valores médios de sensibilidade, especificidade e acurácia balanceada para o teste na Classe III, foi respectivamente, 54%, 91% e 72%, para valores mínimos no intervalo (RMR 1), para valores máximos no intervalo (RMR 2), os valores assumidos foram 51%, 91% e 71%, respectivamente.

Observou-se que previsivelmente a sensibilidade da classificação na Classe III é menor que para a Classe II, justamente pela diferença na distribuição no banco de dados, conforme apresentado anteriormente. Para Classe III a eficácia da classificação atingiu o menor valor de 71% e 72%, isso se dá em relação a quantidade maior de dados contido nessa classe, pois, em relação a essa quantidade o modelo tem uma maior

possibilidade de classificar de forma errada.

Para Classe IV, os valores dos parâmetros em comparação as Classes II e III, na média das duas. Para o teste os valores mínimos no intervalo (RMR 1), de sensibilidade, especificidade e acurácia balanceada, discorrem em torno de 84%, 85% e 84% respectivamente. Em relação aos mesmos parâmetros para valores máximos no intervalo (RMR 2), as médias assumem 89%, 84% e 87% respectivamente.

O modelo no geral obteve bons resultados na classificações, observa-se ainda que aplicar o modelo em um banco de dados que tenha uma distribuição mais equiparada pode melhorar os resultados obtidos podendo ultrapassar os 90% na eficácia.

6. REFERÊNCIAS

- BARRETO, Jorge M.. **Introdução às Redes Neurais Artificiais**. Florianópolis - SC: Laboratório de Conexionismo e Ciências Cognitivas da Ufsc -Departamento de Informática e de Estatística, 2002. 57 p.
- Barton, N., & Choubey, V. (1977). **The shear strength of rock joints in theory and practice**. *Rock mechanics*, 10(1), 1-54.
- Barton, Nick. (1978). **Suggested methods for the quantitative description of discontinuities in rock masses**: International Society for Rock Mechanics. *Int J Rock Mech Min Sci Geomech Abstr.* 15. 319-368.
- Bieniawski, Z. T. 1989. **Engineering Rock Mass Classification**. New York: John Wiley & Sons, 251 p.
- CUNHA, Harlem Enckel Souza. **CLASSIFICAÇÃO E CARACTERIZAÇÃO DE MACIÇOS ROCHOSOS NO ÂMBITO DA MINERAÇÃO**. 2016. 119 f. Monografia (Especialização) - Curso de Mestrado em Geologia de Minas Técnicas de Lavra A Céu Aberto, Instituto de Geociências, Universidade Federal do Pará, Belém, 2016.
- Deere, D. U. and Deere, D. W. **"The Rock Quality Designation (RQD) Index in Practice,"** In: L. Kirkaldie, Ed., *Rock Classification System for Engineering Purposes*, ASTM STP 984, American Society for Testing and Materials, Philadelphia, 1988, pp. 91-101.
- Deere, D.U., Hendron, A.J., Patton, F.D. and Cording, E.J. (1967) **Design of surface and near surface construction in rock**. In **Failure and breakage of rock**, proc. 8th U.S. symp. rock mech., (ed. C. Fairhurst), 237-302. New York: Soc. Min. Engrs, Am. Inst. Min. Metall. Petrolm Engrs.
- FIORI, Alberto Pio; CARMIGNANI, Luigi. **Fundamentos de mecânica dos solos e das rochas**: aplicações na estabilidade de taludes. São Paulo: Oficina de Textos, 2015. 548 p.
- FLECK, Leandro; TAVARES, Maria Herminia Ferreira; EYNG, Eduardo; HELMANN, Adrieli Cristina; ANDRADE, Maria Aparecida de Moraes. **REDES NEURAIAS ARTIFICIAIS: PRINCÍPIOS BÁSICOS**. *Revista Eletrônica Científica Inovação e Tecnologia*, Paraná, v. 1, n. 13, p. 47-57, jun. 2016. Semestral.
- Fritsch S, Guenther F, Wright M (2019). **_neuralnet: Training of Neural Networks_**. R package version 1.44.2, <<https://CRAN.R-project.org/package=neuralnet>>.
- Hadley Wickham (2011). **The Split-Apply-Combine Strategy for Data Analysis**. *Journal of Statistical Software*, 40(1), 1-29. URL <https://www.jstatsoft.org/v40/i01/>.
- Hoek, E. and Bray, J.W. (1981). **Rock Slope Engineering**. (Third ed.) London: Inst. Min.

Metall.

Hudson, J.A.; Harrison J.P. 1997. **Engineering rock mechanics: an introduction to the principles**. Elsevier Science Ltd Oxford, UK.

ISRM (1981): **Rock characterisation testing and monitoring**. In: Brown, E. T. (ed.) Pergamon Press, Oxford.

ISRM (1983) **Suggested methods for determining the strength of rock materials in triaxial compression**. Int J Rock Mech Min Sci 20(6):285–290.

Jaques, D. S. **Caracterização e classificação de maciços rochosos da mina de volta grande, nazareno, minas gerais**. 2014. Dissertação, Pós-Graduação em Engenharia Civil, Universidade Federal de Viçosa, 2014.

Kuhn M (2022). **_caret: Classification and Regression Training_**. R package version 6.0-93, <<https://CRAN.R-project.org/package=caret>>.

Naghadehi, M. Z., Jimenez, R., KhaloKakaie, R., & Jalali, S. M. E. (2013). **A new open-pit mine slope instability index defined using the improved rock engineering systems approach**. International Journal of Rock Mechanics and Mining Sciences, 61, 1-14.

NICOLI, Sidnei. **INTELIGÊNCIA ARTIFICIAL**. Rio de Janeiro: Copyright Seses, 2017. 129 p.

Palmström, A. 1982. **The volumetric joint count - a useful and simple measure of the degree of jointing**. Proc. IV Int. Congr. IAEG, New Delhi, pp.221-228.

PATTON, F. D.; DEERE, D. U. **Geologic factors controlling slope stability in open pit mines**. Proceedings of the Society of Mining Engineers of AIME—stability in open pit mining, v. 1, p. 23-47, 1971.

Paula Branco, Rita P. Ribeiro, Luis Torgo (2016)., **UBL: an R Package for Utility-Based Learning**, CoRR abs/1604.08079 [cs.MS], URL: <http://arxiv.org/abs/1604.08079>

R Core Team (2022). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

REIS, Fernando Mendes Palhares. **APLICAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA PARA ANÁLISE DA CONDIÇÃO DE ESTABILIDADE DE TALUDES DE MINA: REDES NEURAIS ARTIFICIAIS**. 2022. 62 f. Tese (Doutorado) - Curso de Engenharia de Minas, Universidade Federal de Ouro Preto, Ouro Preto, 2022.

Santos Baquero O (2019). **_ggsn: North Symbols and Scale Bars for Maps Created with 'ggplot2' or 'ggmap'_**. R package version 0.5.0, <<https://CRAN.R-project.org/package=ggsn>>.

SANTOS, Allan Erlichman Medeiros. **Classificação de maciços rochosos por meio**

de técnicas da estatística multivariada e inteligência artificial. 2021. 222 f. Tese (Doutorado) - Curso de Engenharia Mineral, Departamento de Engenharia de Minas, Universidade Federal de Ouro Preto, Ouro Preto, 2021.

SANTOS, Allan Erlichman Medeiros. **PREDIÇÃO DA CONDIÇÃO DE ESTABILIDADE DE TALUDES DE MINA POR MEIO DE ESTATÍSTICA MULTIVARIADA.** 2016. 117 f. Dissertação (Mestrado) - Curso de Pós-Graduação em Engenharia Mineral, Engenharia de Minas, Universidade Federal de Ouro Preto, Ouro Preto, 2016.

Warnes GR, Bolker B, Lumley T, SAIC-Frederick RCJcRCJaC, Program IFbtIR, NIH ot, Institute NC, NO1-CO-12400. CfCRuNC (2022). **_gmodels: Various R Programming Tools for Model Fitting_.** R package version 2.18.1.1, <<https://CRAN.R-project.org/package=gmodels>>.

Wei R, Wang J (2018). **_multiROC: Calculating and Visualizing ROC and PR Curves Across Multi-Class Classifications_.** R package version 1.1.1, <<https://CRAN.R-project.org/package=multiROC>>.

WOLPP, Luís Fernando de Lima. **CARACTERIZAÇÃO E CLASSIFICAÇÃO GEOMECÂNICA DE UM TALUDE DA SANTA HELENA MINERAÇÃO LTDA.** 2018. 61 f. TCC (Graduação) - Curso de Engenharia de Minas, Centro Federal de Educação Tecnológica de Minas Gerais, Araxá, 2018.

WYLLIE, Duncan C.; MAH, C. W. **Rock slope engineering—civil and mining,** 4th edn. Spon. 2005.

Xavier Robin, Natacha Turck, Alexandre Hainard, Natalia Tiberti, Frédérique Lisacek, Jean-Charles Sanchez and Markus Müller (2011) **pROC: an open-source package for R and S+ to analyze and compare ROC curves.** BMC Bioinformatics, 12, p. 77. DOI: 10.1186/1471-2105-12-77 <<http://www.biomedcentral.com/1471-2105/12/77/>>

Anexo 1

Local	PESOS RMR MÍNIMO										
	Resistência	RQD	Espaçamen to médio	Persistencia	Abertura	Rugosidade	Preenchime nto	Grau de alteração	Condições da percolação	RMR 1 Mínimo	Classe Mínimo
AGUAS CLARAS IRON ORE MINE-BRASIL-NORTHERN WALL	12	8,00	20,00	4,00	1,00	3,00	4,00	1,00	7,00	48,00	Classe III
AGUAS CLARAS IRON ORE MINE-BRASIL-NORTHERN WALL	4	3,00	15,00	2,00	1,00	5,00	4,00	1,00	7,00	38,00	Classe IV
AGUAS CLARAS IRON ORE MINE-BRASIL-NORTHERN WALL	4	13,00	15,00	2,00	1,00	0,00	4,00	3,00	10,00	48,00	Classe III
AGUAS CLARAS IRON ORE MINE-BRASIL-NORTHERN WALL	2	3,00	15,00	2,00	1,00	3,00	2,00	1,00	4,00	31,00	Classe IV
AGUAS CLARAS IRON ORE MINE-BRASIL-NORTHERN WALL	12	8,00	20,00	4,00	4,00	3,00	4,00	1,00	7,00	51,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	7	17,00	10,00	2,00	1,00	5,00	4,00	3,00	10,00	52,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	12	17,00	15,00	4,00	4,00	5,00	2,00	6,00	15,00	68,00	Classe II
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	7	13,00	15,00	4,00	1,00	5,00	2,00	5,00	10,00	55,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	12	17,00	10,00	4,00	4,00	5,00	2,00	5,00	15,00	62,00	Classe II
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	12	17,00	15,00	4,00	6,00	3,00	6,00	5,00	15,00	71,00	Classe II
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	12	17,00	15,00	4,00	4,00	0,00	4,00	5,00	10,00	59,00	Classe III
ANGOORAN LEAD&ZINC MINE, IRAN--EASTERN WALL	7	8,00	10,00	2,00	1,00	3,00	2,00	1,00	15,00	42,00	Classe III
ANGOORAN LEAD&ZINC MINE, IRAN--EASTERN WALL	7	13,00	10,00	0,00	1,00	3,00	2,00	3,00	15,00	47,00	Classe III
ANGOORAN LEAD&ZINC MINE, IRAN--EASTERN WALL	7	13,00	15,00	0,00	1,00	5,00	2,00	3,00	15,00	54,00	Classe III
ANGOORAN LEAD&ZINC MINE, IRAN--EASTERN WALL	7	13,00	15,00	2,00	1,00	3,00	2,00	5,00	15,00	56,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHEASTERN WALL	4	8,00	8,00	2,00	4,00	5,00	4,00	5,00	10,00	46,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHEASTERN WALL	7	13,00	15,00	4,00	6,00	3,00	4,00	5,00	15,00	65,00	Classe II
AITIK COPPER MINE-SWEDEN--NORTHEASTERN WALL	2	8,00	10,00	2,00	1,00	3,00	2,00	3,00	7,00	36,00	Classe IV
AITIK COPPER MINE-SWEDEN--NORTHEASTERN WALL	2	8,00	10,00	2,00	1,00	0,00	4,00	5,00	7,00	37,00	Classe IV
AITIK COPPER MINE-SWEDEN--NORTHEASTERN WALL	4	8,00	10,00	1,00	1,00	5,00	2,00	3,00	10,00	40,00	Classe IV
BETZE POST GOLD MINE-USA-- NORTHERN WALL	2	8,00	10,00	1,00	1,00	3,00	4,00	1,00	4,00	32,00	Classe IV
BETZE POST GOLD MINE-USA-- NORTHERN WALL	4	13,00	10,00	1,00	1,00	3,00	4,00	3,00	7,00	42,00	Classe III
BETZE POST GOLD MINE-USA-- NORTHERN WALL	2	8,00	10,00	1,00	0,00	3,00	2,00	1,00	4,00	29,00	Classe IV
BETZE POST GOLD MINE-USA-- NORTHERN WALL	4	8,00	10,00	1,00	0,00	5,00	0,00	1,00	7,00	32,00	Classe IV
BETZE POST GOLD MINE-USA-- NORTHERN WALL	7	13,00	15,00	2,00	4,00	5,00	4,00	5,00	10,00	58,00	Classe III

CADIA HILL GOLD&COPPER MINE-AUSTRALIA--EASTERN WALL	7	13,00	15,00	2,00	4,00	6,00	2,00	5,00	15,00	62,00	Classe II
CADIA HILL GOLD&COPPER MINE-AUSTRALIA--EASTERN WALL	7	13,00	10,00	4,00	1,00	5,00	2,00	5,00	10,00	50,00	Classe III
CADIA HILL GOLD&COPPER MINE-AUSTRALIA--EASTERN WALL	4	13,00	10,00	4,00	4,00	3,00	2,00	5,00	15,00	56,00	Classe III
CADIA HILL GOLD&COPPER MINE-AUSTRALIA--EASTERN WALL	4	13,00	10,00	2,00	1,00	5,00	2,00	3,00	7,00	43,00	Classe III
CADIA HILL GOLD&COPPER MINE-AUSTRALIA--EASTERN WALL	7	13,00	15,00	2,00	1,00	3,00	2,00	5,00	15,00	56,00	Classe III
CHADORMALOU IRON ORE MINE, IRAN--WESTERN WALL	7	3,00	8,00	0,00	1,00	3,00	2,00	5,00	15,00	37,00	Classe IV
CHADORMALOU IRON ORE MINE, IRAN--WESTERN WALL	12	8,00	15,00	2,00	4,00	3,00	4,00	6,00	15,00	57,00	Classe III
CHADORMALOU IRON ORE MINE, IRAN--WESTERN WALL	7	3,00	8,00	0,00	1,00	3,00	2,00	5,00	15,00	37,00	Classe IV
CHADORMALOU IRON ORE MINE, IRAN--WESTERN WALL	7	3,00	10,00	2,00	1,00	5,00	2,00	3,00	15,00	41,00	Classe III
CHOGHART COPPER MINE, IRAN--WESTERN WALL	7	13,00	10,00	1,00	1,00	5,00	4,00	5,00	15,00	54,00	Classe III
CHOGHART COPPER MINE, IRAN--WESTERN WALL	7	8,00	10,00	2,00	1,00	3,00	4,00	1,00	10,00	39,00	Classe IV
CHOGHART COPPER MINE, IRAN--WESTERN WALL	7	8,00	10,00	0,00	0,00	5,00	2,00	1,00	10,00	36,00	Classe IV
CHOGHART COPPER MINE, IRAN--WESTERN WALL	7	13,00	15,00	2,00	1,00	3,00	4,00	3,00	10,00	51,00	Classe III
<u>CHOGHART COPPER MINE, IRAN--WESTERN WALL</u>	7	8,00	10,00	2,00	1,00	3,00	4,00	3,00	15,00	46,00	Classe III
CHUQUICAMATA COPPER MINE-CHILE--EASTERN WALL	7	8,00	15,00	4,00	4,00	0,00	4,00	5,00	15,00	55,00	Classe III
CHUQUICAMATA COPPER MINE-CHILE--EASTERN WALL	7	8,00	15,00	4,00	4,00	3,00	4,00	3,00	15,00	56,00	Classe III
CHUQUICAMATA COPPER MINE-CHILE--EASTERN WALL	4	3,00	20,00	2,00	1,00	5,00	2,00	3,00	10,00	46,00	Classe III
CHUQUICAMATA COPPER MINE-CHILE--EASTERN WALL	7	13,00	15,00	4,00	4,00	5,00	4,00	3,00	15,00	63,00	Classe II
CHUQUICAMATA COPPER MINE-CHILE--EASTERN WALL	7	8,00	15,00	2,00	1,00	0,00	2,00	5,00	15,00	48,00	Classe III
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	4	8,00	10,00	2,00	1,00	5,00	4,00	3,00	7,00	40,00	Classe IV
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	7	13,00	15,00	2,00	4,00	5,00	4,00	3,00	10,00	56,00	Classe III
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	7	13,00	10,00	4,00	4,00	5,00	4,00	5,00	10,00	55,00	Classe III
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	4	13,00	15,00	4,00	4,00	3,00	4,00	3,00	10,00	56,00	Classe III
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	7	13,00	15,00	2,00	4,00	0,00	4,00	5,00	10,00	53,00	Classe III
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	7	8,00	10,00	2,00	4,00	3,00	2,00	3,00	7,00	39,00	Classe IV
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	4	8,00	15,00	2,00	1,00	5,00	2,00	3,00	7,00	43,00	Classe III
ESPERANZA PIT (PhelpsDodge)-COPPER-USA--NORTHERN WALL	12	8,00	10,00	2,00	0,00	3,00	2,00	3,00	10,00	38,00	Classe IV

GOLEGOHAR IRON ORE MINE, IRAN--EASTERN WALL	12	17,00	8,00	6,00	4,00	5,00	4,00	5,00	15,00	64,00	Classe II
GOLEGOHAR IRON ORE MINE, IRAN--EASTERN WALL	7	8,00	5,00	6,00	4,00	5,00	2,00	3,00	15,00	48,00	Classe III
GOLEGOHAR IRON ORE MINE, IRAN--EASTERN WALL	7	8,00	8,00	6,00	1,00	3,00	2,00	3,00	15,00	46,00	Classe III
GOLEGOHAR IRON ORE MINE, IRAN--EASTERN WALL	12	8,00	8,00	6,00	4,00	3,00	4,00	5,00	15,00	53,00	Classe III
LA YESA CLAYSTONE MINE-SPAIN--SOUTHEASTERN WALL	4	8,00	8,00	0,00	1,00	5,00	2,00	5,00	10,00	39,00	Classe IV
LA YESA CLAYSTONE MINE-SPAIN--SOUTHEASTERN WALL	7	13,00	10,00	2,00	1,00	3,00	2,00	5,00	15,00	51,00	Classe III
OKTEDI-COPPER&GOLD-GUINEA--NORTHWESTERN WALL	4	8,00	8,00	6,00	1,00	3,00	4,00	5,00	10,00	45,00	Classe III
OKTEDI-COPPER&GOLD-GUINEA--NORTHWESTERN WALL	4	3,00	8,00	6,00	1,00	3,00	4,00	3,00	7,00	35,00	Classe IV
OKTEDI-COPPER&GOLD-GUINEA--NORTHWESTERN WALL	4	3,00	8,00	6,00	1,00	5,00	4,00	3,00	7,00	37,00	Classe IV
PANDA PIT-Ekati-Diamond-CANADA--WESTERN WALL	12	13,00	15,00	6,00	4,00	3,00	6,00	5,00	10,00	62,00	Classe II
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	13,00	10,00	0,00	1,00	3,00	4,00	5,00	7,00	43,00	Classe III
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	13,00	10,00	0,00	1,00	0,00	2,00	3,00	4,00	33,00	Classe IV
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	13,00	10,00	1,00	1,00	3,00	2,00	3,00	7,00	40,00	Classe IV
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	13,00	10,00	0,00	1,00	5,00	2,00	5,00	7,00	43,00	Classe III
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	8,00	15,00	6,00	4,00	5,00	4,00	5,00	15,00	62,00	Classe II
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	13,00	10,00	0,00	1,00	5,00	4,00	3,00	10,00	46,00	Classe III
SARCHESHMEH COPPER MINE, IRAN--EASTERN WALL	4	8,00	15,00	2,00	1,00	3,00	4,00	5,00	15,00	53,00	Classe III
SARCHESHMEH COPPER MINE, IRAN--EASTERN WALL	4	3,00	15,00	1,00	1,00	3,00	2,00	5,00	10,00	40,00	Classe IV
SARCHESHMEH COPPER MINE, IRAN--EASTERN WALL	4	3,00	10,00	1,00	1,00	5,00	2,00	5,00	10,00	37,00	Classe IV
SARCHESHMEH COPPER MINE, IRAN--EASTERN WALL	4	3,00	10,00	2,00	1,00	3,00	4,00	5,00	15,00	43,00	Classe III
SUNGUN COPPER MINE, IRAN--SOUTHEASTERN WALL	4	3,00	10,00	1,00	1,00	5,00	2,00	3,00	15,00	40,00	Classe IV
SUNGUN COPPER MINE, IRAN--SOUTHEASTERN WALL	7	8,00	15,00	2,00	0,00	5,00	0,00	5,00	10,00	45,00	Classe III
SUNGUN COPPER MINE, IRAN--SOUTHEASTERN WALL	4	3,00	10,00	1,00	1,00	5,00	2,00	1,00	10,00	33,00	Classe IV
SUNGUN COPPER MINE, IRAN--SOUTHEASTERN WALL	7	8,00	10,00	2,00	1,00	5,00	4,00	3,00	10,00	43,00	Classe III
Ujina pit (Collahuasi)-Copper-CHILE--WESTERN WALL	7	13,00	10,00	2,00	1,00	3,00	2,00	3,00	15,00	49,00	Classe III
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	13,00	15,00	6,00	1,00	5,00	4,00	3,00	7,00	54,00	Classe III
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	8,00	10,00	6,00	1,00	5,00	4,00	3,00	10,00	47,00	Classe III
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	8,00	10,00	4,00	1,00	3,00	2,00	1,00	7,00	36,00	Classe IV

VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	8,00	10,00	6,00	1,00	3,00	4,00	1,00	4,00	37,00	Classe IV
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	8,00	15,00	6,00	4,00	5,00	4,00	3,00	7,00	52,00	Classe III
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	13,00	8,00	6,00	4,00	3,00	4,00	3,00	10,00	51,00	Classe III
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	13,00	10,00	4,00	1,00	3,00	4,00	5,00	10,00	50,00	Classe III

Local	PESOS RMR MÁXIMO										
	Resistência	RQD Máximo	Espaçamento	Persistência da descontinuidade	Abertura	Rugosidade	Preenchimento2	Grau de alteração	Condições da percolação	RMR 2 Máximo	Classe Máxima
AGUAS CLARAS IRON ORE MINE-BRASIL-NORTHERN WALL	12	8,00	20,00	2,00	0,00	3,00	2,00	1,00	7,00	43,00	Classe III
AGUAS CLARAS IRON ORE MINE-BRASIL-NORTHERN WALL	4	3,00	20,00	2,00	0,00	5,00	2,00	1,00	7,00	40,00	Classe IV
AGUAS CLARAS IRON ORE MINE-BRASIL-NORTHERN WALL	4	13,00	20,00	0,00	0,00	0,00	2,00	3,00	10,00	48,00	Classe III
AGUAS CLARAS IRON ORE MINE-BRASIL-NORTHERN WALL	2	3,00	20,00	2,00	0,00	3,00	0,00	1,00	4,00	33,00	Classe IV
AGUAS CLARAS IRON ORE MINE-BRASIL-NORTHERN WALL	12	8,00	20,00	2,00	1,00	3,00	4,00	1,00	7,00	46,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	7	17,00	20,00	1,00	0,00	5,00	2,00	3,00	10,00	58,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	12	17,00	20,00	2,00	1,00	5,00	2,00	6,00	15,00	68,00	Classe II
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	7	13,00	20,00	2,00	0,00	5,00	0,00	5,00	10,00	55,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	12	17,00	20,00	2,00	1,00	5,00	2,00	5,00	15,00	67,00	Classe II
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	12	17,00	20,00	2,00	0,00	3,00	6,00	5,00	15,00	68,00	Classe II
AITIK COPPER MINE-SWEDEN--NORTHWESTERN WALL	12	17,00	20,00	0,00	1,00	0,00	4,00	5,00	10,00	57,00	Classe III
ANGOORAN LEAD&ZINC MINE, IRAN--EASTERN WALL	7	8,00	15,00	0,00	0,00	3,00	0,00	1,00	15,00	42,00	Classe III
ANGOORAN LEAD&ZINC MINE, IRAN--EASTERN WALL	7	13,00	15,00	0,00	0,00	3,00	0,00	3,00	15,00	49,00	Classe III
ANGOORAN LEAD&ZINC MINE, IRAN--EASTERN WALL	7	13,00	15,00	0,00	1,00	5,00	2,00	3,00	15,00	54,00	Classe III
ANGOORAN LEAD&ZINC MINE, IRAN--EASTERN WALL	7	13,00	15,00	1,00	1,00	3,00	2,00	5,00	15,00	55,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHEASTERN WALL	4	8,00	15,00	1,00	1,00	5,00	4,00	5,00	10,00	49,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHEASTERN WALL	7	13,00	20,00	2,00	0,00	3,00	2,00	5,00	15,00	60,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHEASTERN WALL	2	8,00	20,00	1,00	0,00	3,00	0,00	3,00	7,00	42,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHEASTERN WALL	2	8,00	20,00	1,00	0,00	0,00	2,00	5,00	7,00	43,00	Classe III
AITIK COPPER MINE-SWEDEN--NORTHEASTERN WALL	4	8,00	15,00	0,00	0,00	5,00	0,00	3,00	10,00	41,00	Classe III
BETZE POST GOLD MINE-USA-- NORTHERN WALL	2	8,00	15,00	0,00	0,00	3,00	2,00	1,00	4,00	33,00	Classe IV
BETZE POST GOLD MINE-USA-- NORTHERN WALL	4	13,00	20,00	0,00	0,00	3,00	2,00	3,00	7,00	48,00	Classe III

BETZE POST GOLD MINE-USA-- NORTHERN WALL	2	8,00	15,00	0,00	0,00	3,00	2,00	1,00	4,00	33,00	Classe IV
BETZE POST GOLD MINE-USA-- NORTHERN WALL	4	8,00	15,00	0,00	0,00	5,00	0,00	1,00	7,00	36,00	Classe IV
BETZE POST GOLD MINE-USA-- NORTHERN WALL	7	13,00	20,00	2,00	1,00	5,00	4,00	5,00	10,00	60,00	Classe III
CADIA HILL GOLD&COPPER MINE-AUSTRALIA--EASTERN WALL	7	13,00	20,00	2,00	1,00	6,00	2,00	5,00	15,00	64,00	Classe II
CADIA HILL GOLD&COPPER MINE-AUSTRALIA--EASTERN WALL	7	13,00	20,00	2,00	0,00	5,00	0,00	5,00	10,00	55,00	Classe III
CADIA HILL GOLD&COPPER MINE-AUSTRALIA--EASTERN WALL	4	13,00	20,00	2,00	1,00	3,00	2,00	5,00	15,00	61,00	Classe II
CADIA HILL GOLD&COPPER MINE-AUSTRALIA--EASTERN WALL	4	13,00	20,00	2,00	0,00	5,00	0,00	3,00	7,00	50,00	Classe III
CADIA HILL GOLD&COPPER MINE-AUSTRALIA--EASTERN WALL	7	13,00	20,00	2,00	0,00	3,00	0,00	5,00	15,00	58,00	Classe III
CHADORMALOU IRON ORE MINE, IRAN--WESTERN WALL	7	3,00	15,00	0,00	0,00	3,00	0,00	5,00	15,00	41,00	Classe III
CHADORMALOU IRON ORE MINE, IRAN--WESTERN WALL	12	8,00	20,00	1,00	1,00	3,00	4,00	6,00	15,00	58,00	Classe III
CHADORMALOU IRON ORE MINE, IRAN--WESTERN WALL	7	3,00	15,00	0,00	0,00	3,00	0,00	5,00	15,00	41,00	Classe III
CHADORMALOU IRON ORE MINE, IRAN--WESTERN WALL	7	3,00	20,00	1,00	0,00	5,00	0,00	3,00	15,00	47,00	Classe III
CHOGHART COPPER MINE, IRAN--WESTERN WALL	7	13,00	15,00	0,00	1,00	5,00	4,00	5,00	15,00	58,00	Classe III
CHOGHART COPPER MINE, IRAN--WESTERN WALL	7	8,00	20,00	0,00	0,00	3,00	2,00	1,00	10,00	44,00	Classe III
CHOGHART COPPER MINE, IRAN--WESTERN WALL	7	8,00	20,00	0,00	0,00	5,00	2,00	1,00	10,00	46,00	Classe III
CHOGHART COPPER MINE, IRAN--WESTERN WALL	7	13,00	15,00	0,00	0,00	3,00	2,00	3,00	10,00	46,00	Classe III
<u>CHOGHART COPPER MINE, IRAN--WESTERN WALL</u>	7	8,00	15,00	1,00	0,00	3,00	2,00	3,00	15,00	47,00	Classe III
CHUQUICAMATA COPPER MINE-CHILE--EASTERN WALL	7	8,00	20,00	1,00	1,00	0,00	4,00	5,00	15,00	54,00	Classe III
CHUQUICAMATA COPPER MINE-CHILE--EASTERN WALL	7	8,00	20,00	2,00	1,00	3,00	4,00	3,00	15,00	56,00	Classe III
CHUQUICAMATA COPPER MINE-CHILE--EASTERN WALL	4	3,00	20,00	2,00	0,00	5,00	0,00	3,00	10,00	43,00	Classe III
CHUQUICAMATA COPPER MINE-CHILE--EASTERN WALL	7	13,00	20,00	2,00	1,00	5,00	4,00	3,00	15,00	63,00	Classe II
CHUQUICAMATA COPPER MINE-CHILE--EASTERN WALL	7	8,00	20,00	0,00	0,00	0,00	0,00	5,00	15,00	48,00	Classe III
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	4	8,00	15,00	1,00	0,00	5,00	2,00	3,00	7,00	41,00	Classe III
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	7	13,00	15,00	1,00	1,00	5,00	4,00	3,00	10,00	52,00	Classe III
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	7	13,00	20,00	2,00	1,00	5,00	4,00	5,00	10,00	60,00	Classe III
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	4	13,00	20,00	2,00	1,00	3,00	4,00	3,00	10,00	56,00	Classe III
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	7	13,00	20,00	2,00	1,00	0,00	4,00	5,00	10,00	55,00	Classe III
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	7	8,00	15,00	1,00	1,00	3,00	2,00	3,00	7,00	40,00	Classe IV
ESCONDIDA COPPER MINE-CHILE--SOUTHERN WALL	4	8,00	20,00	1,00	0,00	5,00	0,00	3,00	7,00	44,00	Classe III
ESPERANZA PIT (PhelpsDodge)-COPPER-USA--NORTHERN WALL	12	8,00	20,00	1,00	0,00	3,00	2,00	3,00	10,00	47,00	Classe III
GOLEGOHAR IRON ORE MINE, IRAN--EASTERN WALL	12	17,00	20,00	2,00	1,00	5,00	4,00	5,00	15,00	69,00	Classe II

GOLEGOHAR IRON ORE MINE, IRAN--EASTERN WALL	7	8,00	20,00	2,00	1,00	5,00	2,00	3,00	15,00	56,00	Classe III
GOLEGOHAR IRON ORE MINE, IRAN--EASTERN WALL	7	8,00	20,00	2,00	1,00	3,00	2,00	3,00	15,00	54,00	Classe III
GOLEGOHAR IRON ORE MINE, IRAN--EASTERN WALL	12	8,00	20,00	2,00	1,00	3,00	4,00	5,00	15,00	58,00	Classe III
LA YESA CLAYSTONE MINE-SPAIN--SOUTHEASTERN WALL	4	8,00	15,00	0,00	0,00	5,00	0,00	5,00	10,00	43,00	Classe III
LA YESA CLAYSTONE MINE-SPAIN--SOUTHEASTERN WALL	7	13,00	15,00	2,00	0,00	3,00	0,00	5,00	15,00	53,00	Classe III
OKTEDI-COPPER&GOLD-GUINEA--NORTHWESTERN WALL	4	8,00	15,00	1,00	0,00	3,00	2,00	5,00	10,00	44,00	Classe III
OKTEDI-COPPER&GOLD-GUINEA--NORTHWESTERN WALL	4	3,00	15,00	1,00	0,00	3,00	2,00	3,00	7,00	34,00	Classe IV
OKTEDI-COPPER&GOLD-GUINEA--NORTHWESTERN WALL	4	3,00	15,00	1,00	0,00	5,00	2,00	3,00	7,00	36,00	Classe IV
PANDA PIT-Ekati-Diamond-CANADA--WESTERN WALL	12	13,00	20,00	1,00	1,00	3,00	6,00	5,00	10,00	59,00	Classe III
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	13,00	20,00	0,00	0,00	3,00	2,00	5,00	7,00	50,00	Classe III
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	13,00	20,00	0,00	0,00	0,00	0,00	3,00	4,00	40,00	Classe IV
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	13,00	15,00	1,00	0,00	3,00	0,00	3,00	7,00	42,00	Classe III
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	13,00	20,00	0,00	0,00	5,00	0,00	5,00	7,00	50,00	Classe III
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	8,00	20,00	2,00	1,00	5,00	4,00	5,00	15,00	60,00	Classe III
SANDSLOOT PLATINUM MINE-SOUTH AFRICA--SOUTHERN WALL	12	13,00	15,00	0,00	0,00	5,00	2,00	3,00	10,00	48,00	Classe III
SARCHESHMEH COPPER MINE, IRAN--EASTERN WALL	4	13,00	20,00	1,00	0,00	3,00	2,00	5,00	15,00	59,00	Classe III
SARCHESHMEH COPPER MINE, IRAN--EASTERN WALL	4	13,00	20,00	0,00	0,00	3,00	0,00	5,00	10,00	51,00	Classe III
SARCHESHMEH COPPER MINE, IRAN--EASTERN WALL	4	13,00	20,00	0,00	0,00	5,00	0,00	5,00	10,00	53,00	Classe III
SARCHESHMEH COPPER MINE, IRAN--EASTERN WALL	4	13,00	20,00	0,00	0,00	3,00	2,00	5,00	15,00	58,00	Classe III
SUNGUN COPPER MINE, IRAN--SOUTHEASTERN WALL	4	8,00	15,00	0,00	0,00	5,00	0,00	3,00	15,00	46,00	Classe III
SUNGUN COPPER MINE, IRAN--SOUTHEASTERN WALL	7	8,00	15,00	1,00	0,00	5,00	0,00	5,00	10,00	44,00	Classe III
SUNGUN COPPER MINE, IRAN--SOUTHEASTERN WALL	4	3,00	15,00	0,00	0,00	5,00	0,00	1,00	10,00	34,00	Classe IV
SUNGUN COPPER MINE, IRAN--SOUTHEASTERN WALL	7	8,00	15,00	0,00	0,00	5,00	2,00	3,00	10,00	43,00	Classe III
Ujina pit (Collahuasi)-Copper-CHILE--WESTERN WALL	7	13,00	20,00	1,00	0,00	3,00	0,00	3,00	15,00	55,00	Classe III
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	13,00	20,00	0,00	0,00	5,00	2,00	3,00	7,00	50,00	Classe III
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	8,00	10,00	0,00	0,00	5,00	2,00	3,00	10,00	38,00	Classe IV
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	8,00	10,00	0,00	0,00	3,00	0,00	1,00	7,00	29,00	Classe IV
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	8,00	10,00	0,00	0,00	3,00	2,00	1,00	4,00	28,00	Classe IV

VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	8,00	15,00	0,00	1,00	5,00	4,00	3,00	7,00	43,00	Classe III
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	13,00	8,00	0,00	1,00	3,00	4,00	3,00	10,00	42,00	Classe III
VENETIA DIAMOND MINE-SOUTH AFRICA-NORTHERN WALL (PIT-K2)	12	13,00	10,00	0,00	0,00	3,00	2,00	5,00	10,00	43,00	Classe III

Anexo 2

Classificação para valores mínimos nos intervalos - RMR 1		Treino			Teste		
		Referência					
Teste 1	Previsto	Classe_II	Classe_III	Classe_IV	Classe_II	Classe_III	Classe_IV
	Classe_II	19	0	0	9	1	0
	Classe_III	0	19	0	0	5	0
	Classe_IV	0	1	16	0	2	11
Teste 2	Classe_II	19	0	0	9	1	1
	Classe_III	0	20	0	0	7	1
	Classe_IV	0	0	16	0	0	9
Teste 3	Classe_II	19	0	0	9	1	0
	Classe_III	0	17	1	0	6	3
	Classe_IV	0	3	15	0	1	8
Teste 4	Classe_II	19	0	0	9	1	0
	Classe_III	0	18	0	0	3	3
	Classe_IV	0	2	16	0	4	8
Teste 5	Classe_II	19	0	0	9	1	0
	Classe_III	0	12	0	0	2	1
	Classe_IV	0	8	16	0	5	10
Teste 6	Classe_II	19	0	0	9	0	0
	Classe_III	0	18	1	0	6	2
	Classe_IV	0	2	15	0	2	9
Teste 7	Classe_II	17	2	0	9	3	0
	Classe_III	2	16	0	0	2	1
	Classe_IV	0	2	16	0	3	10
Teste 8	Classe_II	19	0	0	9	0	0
	Classe_III	0	16	0	0	2	0
	Classe_IV	0	4	16	0	6	11
Teste 9	Classe_II	13	0	0	8	0	0
	Classe_III	6	19	0	1	5	1
	Classe_IV	0	1	16	0	3	10
Teste 10	Classe_II	19	0	0	9	3	0
	Classe_III	0	20	5	0	5	5
	Classe_IV	0	0	11	0	0	6

Classificação para valores máximos nos intervalos - RMR 2	Treino			Teste			
	Referência						
	Previsto	Classe_II	Classe_III	Classe_IV	Classe_II	Classe_III	Classe_IV
Teste 1	Classe_II	19	0	0	9	1	0
	Classe_III	0	19	0	0	4	1
	Classe_IV	0	1	16	0	3	10
Teste 2	Classe_II	19	2	0	9	0	0
	Classe_III	0	18	0	0	6	0
	Classe_IV	0	0	16	0	2	11
Teste 3	Classe_II	19	0	0	9	1	0
	Classe_III	0	16	0	0	2	1
	Classe_IV	0	4	16	0	5	10
Teste 4	Classe_II	19	0	0	9	1	0
	Classe_III	0	17	0	0	4	2
	Classe_IV	0	3	16	0	3	9
Teste 5	Classe_II	19	0	0	8	3	1
	Classe_III	0	16	0	1	3	1
	Classe_IV	0	4	16	0	2	9
Teste 6	Classe_II	19	0	0	9	2	0
	Classe_III	0	19	0	0	4	4
	Classe_IV	0	1	16	0	2	7
Teste 7	Classe_II	19	0	0	9	0	0
	Classe_III	0	20	0	0	5	0
	Classe_IV	0	0	16	0	3	11
Teste 8	Classe_II	17	1	0	5	0	0
	Classe_III	2	19	0	4	5	0
	Classe_IV	0	0	16	0	3	11
Teste 9	Classe_II	19	0	0	9	0	0
	Classe_III	0	19	0	0	5	0
	Classe_IV	0	1	16	0	3	11
Teste 10	Classe_II	17	1	0	9	4	0
	Classe_III	2	17	0	0	3	2
	Classe_IV	0	2	16	0	1	9

Anexo 3

Script dados mínimos

```
## Carregando os pacotes exigidos ##  
library(neuralnet)  
library(gmodels)  
library(ggsn)  
library(caret)  
library(plyr)  
library(multiROC)  
library(pROC)  
library(UBL)  
## Limpando a memoria do R ##  
rm(list = ls())  
## setando o diretorio ##  
setwd("C:/Users/adrie/OneDrive/Área de Trabalho/TCC/Scripts")  
## Entrada do banco de dados ##  
dados <- read.table("dados_min.txt",header=TRUE,dec = ".")  
## verificacao do banco de dados ##  
head(dados)  
dim (dados)  
  
## Pre-Processamento dos dados ##  
## correcao da variavel RMR e escalonamento dos dados##  
dados_min <- dados[,2:12]  
head (dados_min)  
dados_3 <- scale(dados_min[,1:10])  
head(dados_min)  
dados_3 <- cbind(dados_3,dados_min[11])  
head(dados_3)  
dados_3$rnr <- as.factor(dados_3$rnr)
```

```

## Balanceamento dos dados ##
dados_balanceados <- SmoteClassif(rmr ~.,
                                dados_3,
                                C.perc = "balance",
                                k = 5,
                                repl = FALSE,
                                dist = "Manhattan")

plot(dados_3$rmr)
plot(dados_balanceados$rmr)
#####
## separa das amostras de treino e teste ##
## Random Subsampling ##
set.seed(12345)
train_idx <- sample(nrow(dados_balanceados), 2/3 *
nrow(dados_balanceados))
dados_train <- dados_balanceados[train_idx, ]
dados_test <- dados_balanceados[-train_idx, ]

# SmoteClassif -----

#####
## Treinamento da rede neural artificial ##
set.seed(12345)
nn <- neuralnet(rmr ~. , dados_train,
               hidden = c(3),
               act.fct = "tanh",
               linear.output = FALSE)
## Plot da rede neural artificial ##
plot(nn)
#####

```

```
#####
```

```
## Validação da rede neural artificial - Amostra Treino ##
```

```
pred_train_nn <- predict(nn, dados_train)
```

```
d_train_nn <- apply(pred_train_nn, 1, which.max)
```

```
d_train_nn <- mapvalues(d_train_nn, from = c(1,2,3), to = c("Classe_II",
                                                         "Classe_III",
                                                         "Classe_IV"))
```

```
d_train_nn <- as.factor(d_train_nn)
```

```
resultado_train_nn <- confusionMatrix(d_train_nn, dados_train$rmr)
```

```
resultado_train_nn
```

```
#####
```

```
## Teste da rede neural artificial - Amostra Teste ##
```

```
pred_test_nn <- predict(nn, dados_test)
```

```
d_test_nn <- apply(pred_test_nn, 1, which.max)
```

```
d_test_nn <- mapvalues(d_test_nn, from = c(1,2,3), to = c("Classe_II",
                                                         "Classe_III",
                                                         "Classe_IV"))
```

```
d_test_nn <- as.factor(d_test_nn)
```

```
resultado_test_nn <- confusionMatrix(d_test_nn, dados_test$rmr)
```

```
resultado_test_nn
```

```
resultado_train_nn$overall
```

```
resultado_test_nn$overall
```