



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA HIDRÁULICA E AMBIENTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

ANA RAQUEL SENA LEITE

**APLICAÇÕES DE REDES NEURAS ARTIFICIAIS PARA PREVISÃO DO
COMPORTAMENTO CISALHANTE EM DESCONTINUIDADES DE MACIÇOS
ROCHOSOS**

FORTALEZA

2019

ANA RAQUEL SENA LEITE

APLICAÇÕES DE REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DO
COMPORTAMENTO CISALHANTE EM DESCONTINUIDADES DE MACIÇOS
ROCHOSOS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Civil. Área de concentração: Geotecnia

Orientador: Prof. Dr. Silvrano Adonias Dantas Neto

FORTALEZA

2019

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- L55a Leite, Ana Raquel Sena.
Aplicações de redes neurais artificiais para previsão do comportamento cisalhante em descontinuidades de maciços rochosos / Ana Raquel Sena Leite. – 2019.
156 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil: Geotecnia, Fortaleza, 2019.
Orientação: Prof. Dr. Silvrano Adonias Dantas Neto.
1. Descontinuidades. 2. Resistência ao cisalhamento. 3. Dilatância. 4. Redes neurais artificiais. I. Título.
CDD 624.15
-

ANA RAQUEL SENA LEITE

APLICAÇÕES DE REDES NEURAIIS ARTIFICIAIS PARA PREVISÃO DO
COMPORTAMENTO CISALHANTE EM DESCONTINUIDADES DE MACIÇOS
ROCHOSOS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Civil. Área de concentração: Geotecnia

Aprovada em 22/12/2019.

BANCA EXAMINADORA

Prof. Dr. Silvrano Adonias Dantas Neto (Orientador)

Universidade Federal do Ceará (UFC)

Prof. Dr. Francisco Chagas Da Silva Filho

Universidade Federal do Ceará (UFC)

Prof. Dr. César Ulisses Vieira Veríssimo

Universidade Federal do Ceará (UFC)

AGRADECIMENTOS

Aos meus pais João Edson Pereira Leite e Maria do Socorro Sena (In Memoriam).
Cujos exemplos de vida, força, perseverança, amor e dedicação me fazem sempre querer ser uma pessoa melhor. À eles sou eternamente grata.

Ao professor orientador, Silvrano Adonias Dantas Neto, cujo amor pela profissão, dedicação e doce brutalidade me serviram e servem de inspiração para ser a melhor profissional que eu possa ser.

Às minhas irmãs de alma, Ellainy Cristine e Ravenna Bessa, cujos exemplos como mulheres fantásticas me fortalecem e me inspiram. Obrigada por sempre estarem comigo nos momentos mais maravilhosos, e mais difíceis.

Aos meus amigos do mestrado, David, Giorgia, Daniel, Paulo, Hiago, Anderson, Constantinos, Edno, Caio, por terem feito desse mestrado comigo, não só mais um degrau, mas uma experiência única e memorável, por serem pessoas maravilhosas e terem estado do meu lado em grande parte dessa jornada. Levarei as lembranças das nossas risadas e momentos para o resto da vida.

Aos meus amigos do IFCE Morada Nova, Juceline, Daianne, Nádia, Stephanie, Sávio, Tidy, por ter dividido comigo tempos maravilhosos no trabalho, por todo apoio, compreensão, risadas, por tempos de tão grandiosa evolução e ensinamento. Guardo por vocês um sincero amor e melhores lembranças.

Aos meus amigos do IFCE de Itapipoca Márcia, Fausto, Hugo, Larissa, Adriana por ainda que tenham dividido um curto tempo dessa jornada comigo, me apoiaram e ajudaram quando necessário. Às minhas parêas potiguares favoritas Jayna e Elione por todas as risadas, apoio e verdadeiro sentimento de irmandade mesmo que com pouco tempo de convivência.

À Paula, Daniel, Malu, Lucas por fazerem parte da minha vida, e serem essas pessoas maravilhosas que tenho orgulho de ter na minha vida. Obrigada por toda compreensão, amor, carinho e principalmente pela paciência comigo. Amo vocês.

À toda minha família pelo apoio incondicional, compreensão e amor.

“Only as high as I reach can I grow
Only as far as I seek can I go
Only as deep as I look can I see
Only as much as I dream can I be”

Karen Ravn

RESUMO

A resistência dos maciços rochosos é significativamente influenciada pela presença das descontinuidades, tendo o comportamento cisalhante dessas como governante em diversos problemas de estabilidade. Apesar de existir modelos consagrados para a obtenção dos valores de resistência, esses não são válidos com o aumento da complexidade do problema; devido a presença de preenchimento, ou pela presença de sistemas confinantes. Os modelos existentes que mensuram essas e outras particularidade apresentam limitações, sobretudo devido à falta de ensaios laboratoriais suficiente para validá-los e a dificuldade em obter alguns de seus parâmetros. Nesse contexto, foi proposto o uso de redes neurais artificiais (RNA) do tipo perceptron multicamadas com retropropagação do erro, para prever o comportamento cisalhante de descontinuidades rochosas com e sem preenchimento, sob carga normal constante (CNL) e rigidez normal constante (CNS). Para tal feito, foram desenvolvidos dois modelos para previsão do comportamento cisalhante: um primeiro modelo para aquisição da tensão cisalhante e dilatância com o decorrer do deslocamento horizontal e um segundo modelo para resistência cisalhante pico. Os parâmetros de entrada usados em geral foram: rigidez normal do contorno (k_n); razão entre espessura do preenchimento pela amplitude da aspereza (t/a); tensão normal inicial (σ_{no}); índice de rugosidade da rocha (JRC); resistência à compressão uniaxial da rocha sã (σ_c); ângulo de atrito básico (ϕ_b), ângulo de atrito do preenchimento (ϕ_{fill}); e o deslocamento horizontal (δ_h), mas apenas para o primeiro modelo. Para previsão da tensão cisalhante e dilatância com deslocamento horizontal, após a análise de diversos modelos, foi selecionado o Gm de arquitetura 8-20-10-5-2 em 500 mil iterações e coeficiente de correlação na fase de treinamento de 99,3% e de teste de 99,0%. Como variável de entrada mais relevante, o modelo Gm teve a σ_{no} e k_n para tensão cisalhante e σ_c , t/a e JRC para dilatância. O modelo teve boa concordância com as comparações gráficas, dados experimentos, juntas hipotéticas e com modelos da literatura. Para a resistência cisalhante de pico, após a avaliação dos modelos propostos, foi obtido como melhor o G1m, com arquitetura 7-30-1 em 797.660 iterações. Seu coeficiente de correlação na fase de treinamento foi de 99,5% e na de teste 98,0%. O modelo apresentou boa correlação com os dados experimentais, boa interpretação das variáveis governantes em juntas hipotéticas e boa interpolação com modelos da literatura. Modelo G1m teve como variáveis de entrada com maior influência a σ_{no} , σ_c , k_n e JRC.

Palavras-chave: Descontinuidades. Resistência ao Cisalhamento. Dilatância. Redes Neurais Artificiais.

ABSTRACT

The existing discontinuities in rock masses play a fundamental role in their resistance, having shear behavior as a ruler in several stability problems. Although there are well-established models for the shear behavior prediction, these are not viable within the increasing complexity of the problem, due to the presence of infill, or the presence of restricted dilation. Existing models that measure these and other characteristics have limitations mainly due to being validated with limited experimental data and the difficulty in obtaining some of their parameters. In this context, it was adopted the use of a multilayer perceptron artificial neural network with backpropagation to predict the shear behavior of infilled and unfilled rock discontinuities, with constant normal load (CNL) and constant normal stiffness (CNS). For this purpose, two shear behavior prediction models are presented: a first model for prediction of shear stress and dilation with the horizontal displacement, and a second model for predicting the peak shear strength. The input parameters generally used were: boundary normal stiffness (k_n); the ratio of fill thickness to height of roughness (t/a); initial normal stress (σ_{no}); joint roughness coefficient (JRC); compressive strength of intact rock (σ_c); basic friction angle (ϕ_b), filling friction angle (ϕ_{fill}); horizontal displacement (δ_h), but only for the first model. For the shear stress and dilation with the horizontal displacement, after several models analysis, it was selected for the Gm model with architecture 8-20-10-5-2 with 500 thousand iterations and correlation coefficient in the training phase of 99.3% and for test 99.0%. The σ_{no} , k_n are the variables with more contribution to the shear stress for Gm model, and the σ_c , t/a e JRC are the ones with greater influence for the dilation. The model has good agreement with graphical comparisons, experimental data, hypothetical joints and literature models. For peak shear strength, after the evaluation of several models, the G1m model was selected for the behavior prediction, the model has the 7-30-1 architecture and was stopped at 797,660 iterations. Its correlation coefficient in the training phase is 99.5% and the test data correlates 98.0%. The model shows a good correlation of experimental data, good interpretation of the governing parameters in the hypothetical joints and good comparison with established and new models from the literature. For the input data contribution, the greater influence for the Gm1 model are the σ_{no} , σ_c , k_n , and JRC.

Keywords: Discontinuities. Shear strength. Dilation. Artificial Neural Networks.

LISTA DE FIGURAS

Figura 2.1	– Envoltória de resistência ao cisalhamento proposta por Patton	22
Figura 2.2	– Perfil típico de rugosidade para JRC	23
Figura 2.3	– Perfil típico de rugosidade para JRC e ϕ_b	24
Figura 2.4	– Representação gráfica do modelo de Barton (1973b) para descontinuidades	25
Figura 2.5	– Reconstrução da junta após escaneamento por elementos triangulares	30
Figura 2.6	– Escavação subterrânea feita em um maciço rochoso com descontinuidades	30
Figura 2.7	– Representação simplificada do ensaio sob CNS	31
Figura 2.8	– Tipos de descontinuidades triangulares ensaiadas por Indraratna et al. (1998)	33
Figura 2.9	– Arquitetura do modelo neuronal para previsão de δv e τ_h para descontinuidades limpas	36
Figura 2.10	– Efeito do aumento da espessura do preenchimento na resistência cisalhante da descontinuidade preenchida	38
Figura 2.11	– Ensaio de cisalhamento direto para diferentes tipos de descontinuidades com e sem preenchimento	38
Figura 2.12	– Ocorrências na engenharia de preenchimento nas descontinuidades que torna necessária o conhecimento da resistência ao cisalhamento	39
Figura 2.13	– Quatro categorias de espessura de preenchimento na descontinuidade	40
Figura 2.14	– Diagrama esquemático do equipamento de cisalhamento direto das descontinuidades preenchidas	41
Figura 2.15	– Perfis das descontinuidades ensaiadas por Papaliangas et al. (1990)	43
Figura 2.16	– Proposta empírica para relação entre resistência ao cisalhamento de descontinuidades preenchidas e razão t/a	44
Figura 2.17	– Comportamento cisalhante de descontinuidades Tipo II preenchidas sob diferentes tensões normais e valores de t/a	45
Figura 2.18	– Formulação para obtenção dos parâmetros para cálculo do NSD	46
Figura 2.19	– Modos de falha para juntas preenchidas	47
Figura 2.20	– Modelo da tensão cisalhante para juntas preenchidas	48
Figura 3.1	– Modelo não-linear de um neurônio k	53

Figura 3.2	– Exemplo de uma arquitetura de perceptron com duas camadas ocultas ..	54
Figura 3.3	– Aprendizado por correção de erro	55
Figura 3.4	– Esquematisação do treinamento de um modelo neuronal	56
Figura 3.5	– Parada antecipada baseada nos dados de validação	57
Figura 3.6	– Variação de frequência da rigidez normal	61
Figura 3.7	– Variação da frequência do t/a por classe	61
Figura 3.8	– Variação da frequência da σ_{no}	62
Figura 3.9	– Variação da frequência do JRC	62
Figura 3.10	– Variação da frequência da σ_c	62
Figura 3.11	– Variação da frequência da ϕ_b	63
Figura 3.12	– Variação da frequência da ϕ_{fill}	63
Figura 3.13	– Forma de seleção por ponto de um gráfico	65
Figura 3.14	– Variação da frequência da rigidez normal	68
Figura 3.15	– Variação da frequência do t/a por classe	68
Figura 3.16	– Variação da frequência da σ_{no}	69
Figura 3.17	– Variação da frequência do JRC	69
Figura 3.18	– Variação da frequência da σ_c	69
Figura 3.19	– Variação da frequência do ϕ_b	70
Figura 3.20	– Variação da frequência do ϕ_{fill}	70
Figura 4.1	– Variação do RMS para os dados do treinamento no decorrer de 500.000 iterações para arquitetura 8-20-10-5-2 do grupo A	75
Figura 4.2	– Variação do RMS para os dados da validação no decorrer de 500.000 iterações para arquitetura 8-20-10-5-2 do grupo A	75
Figura 4.3	– Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatância das três arquiteturas com maior correlação com dados de teste do Grupo A	76
Figura 4.4	– Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatância das três arquiteturas com maior correlação com dados de teste do Grupo A2	77
Figura 4.5	– Variação do RMS para os dados do treinamento no decorrer de 500.000 iterações para arquitetura 8-30-2 do grupo B	78
Figura 4.6	– Variação do RMS para os dados de teste no decorrer de 500.000 iterações para arquitetura 8-30-2 do grupo B	79

Figura 4.7	– Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatância das três arquiteturas com maior correlação com dados de teste do Grupo B	80
Figura 4.8	– Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatância das três arquiteturas com maior correlação com dados de teste do Grupo B2	81
Figura 4.9	– Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatância das três arquiteturas com maior correlação com dados de teste do Grupo C	82
Figura 4.10	– Variação entre dados requeridos e obtidos para dilatância pelo modelo neuronal referente a arquitetura 7-30-2 com 45,7% de correlação para teste	83
Figura 4.11	– Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatância das três arquiteturas com maior correlação com dados de teste do Grupo E	84
Figura 4.12	– Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatância das três arquiteturas com maior correlação com dados de teste do Grupo F	85
Figura 4.13	– Grupo A2, com arquitetura 8-30-10-2 sob CNL com variação dos valores de t/a para junta hipotética	87
Figura 4.14	– Grupo B, com arquitetura 8-30-15-2 sob CNL com variação dos valores de t/a para junta hipotética	87
Figura 4.15	– Grupo B2, com arquitetura 8-30-15-5-2 sob CNL com variação dos valores de t/a para junta hipotética	88
Figura 4.16	– Grupo C, com arquitetura 8-30-15-5-2 sob CNL com variação dos valores de t/a para junta hipotética	89
Figura 4.17	– Modelo neuronal de arquitetura 8-20-10-5-2	90
Figura 4.18	– Comparação entre os resultados do ensaio de cisalhamento direto de Haque (1999) com os previstos pelo modelo Gm	94
Figura 4.19	– Comparação entre os resultados do ensaio de cisalhamento direto de Benmokrane e Ballivy (1989) com os previstos pelo modelo Gm	95
Figura 4.20	– Comparação entre os resultados do ensaio de cisalhamento direto de Mehrishal et al. (2016) com os previstos pelo modelo Gm	96
Figura 4.21	– Comparação entre os resultados do ensaio de cisalhamento direto de Oliveira et al. (2009) com os previstos pelo modelo Gm	97

Figura 4.22	– Comparação entre os resultados do ensaio de cisalhamento direto sob CNS de descontinuidade sem preenchimento de Shrivastava e Rao (2017) com os previstos pelo modelo Gm	98
Figura 4.23	– Comparação entre os resultados do ensaio de cisalhamento direto em descontinuidade sob CNL com preenchimento de Shrivastava e Rao (2017) com os previstos pelo modelo Gm	99
Figura 4.24	– Resultados da rede Gm para previsão das tensões cisalhantes das descontinuidades hipotéticas comparadas aos resultados do modelo neuronal de Dantas Neto et al. (2017), para variação das condições de contorno	101
Figura 4.25	– Resultados da rede Gm para previsão das dilatâncias das descontinuidades hipotéticas comparadas aos resultados do modelo neuronal de Dantas Neto et al. (2017), para variação das condições de contorno	101
Figura 4.26	– Resultados da rede Gm para previsão das tensões cisalhantes das descontinuidades hipotéticas comparadas aos resultados do modelo neuronal de Dantas Neto et al. (2017). Para variação nas tensões normais iniciais aplicadas	102
Figura 4.27	– Resultados da rede Gm para previsão das dilatâncias para as descontinuidades hipotéticas comparadas aos resultados do modelo neuronal de Dantas Neto et al. (2017). Para variação nas tensões normais iniciais aplicadas	103
Figura 4.28	– Resultados da rede Gm para descontinuidade hipotética preenchida sob CNL com diferentes valores de t/a	104
Figura 4.29	– Resultados da rede Gm para descontinuidade hipotética preenchida sob CNS com diferentes valores de t/a	104
Figura 4.30	– Parâmetros de Fourier da junta serra idealizada Tipo II sob CNS	105
Figura 4.31	– Comparação entre dados observados e previstos para previsão do comportamento cisalhante de uma junta idealizada de serra Tipo II sob CNS	105
Figura 5.1	– Variação entre dados requeridos e obtidos para resistência cisalhante de pico pelo modelo neuronal referente de G1 de arquitetura 7-15-1 com 31,31% de correlação para teste após 1.000.000 de iterações	111

Figura 5.2	– Variação entre dados requeridos e obtidos para resistência cisalhante de pico pelo modelo neuronal referente de G1 de arquitetura 7-30-1 com 98,0% de correlação para teste após 797.660 iterações	111
Figura 5.3	– Variação entre dados requeridos e obtidos para resistência cisalhante de pico pelo modelo neuronal referente de G2 de arquitetura 7-30-15-5-1 com -17,1% de correlação para teste após 1.000.000 iterações	112
Figura 5.4	– Modelo neuronal de arquitetura 7-30-1	114
Figura 5.5	– Comparação entre resistência ao cisalhamento de pico experimentais de Haque (1999) com os previstos pelo modelo G1m com variação da tensão normal aplicada e condição de contorno	117
Figura 5.6	– Comparação entre resistência ao cisalhamento de pico experimentais de Haque (1999) com os previstos pelo modelo G1m com variação da do JRC e t/a	118
Figura 5.7	– Comparação entre resistência ao cisalhamento de pico experimentais de Papaliangas et al. (1993) com os previstos pelo modelo G1m com variação do t/a para diferentes tensões normais iniciais	119
Figura 5.8	– Comparação entre resistência cisalhante de pico experimentais de Oliveira et al. (1993) com os previstos pelo modelo G1m com variação do t/a	120
Figura 5.9	– Comparação entre resistência cisalhante de pico experimentais de Shrivastava e Rao (2017) sob CNL com os previstos pelo modelo G1m com variação da tensão normal inicial para diferentes valores de t/a	120
Figura 5.10	– Comparação entre resistência cisalhante de pico experimentais de Shrivastava e Rao (2017) sob CNS com os previstos pelo modelo G1m com variação da tensão normal inicial para diferentes valores de t/a	121
Figura 5.11	– Comparação entre resistência cisalhante de pico experimentais de Mehrishal et al. (2016) sob CNL com os previstos pelo modelo G1m com variação da tensão normal inicial	121
Figura 5.12	– Variação da resistência cisalhante de pico para diferentes k_n da junta hipotética pelos modelos G1m, Gm e Dantas Neto et al (2017)	122
Figura 5.13	– Variação da resistência cisalhante de pico para diferentes valores de tensão normal inicial aplicada para juntas hipotética pelos modelos G1m, Gm e Dantas Neto et al (2017)	123

Figura 5.14	– Variação da resistência cisalhante de pico para diferentes valores de t/a aplicada para juntas hipotética pelos modelos G1m e Gm	124
Figura 5.15	– Variação da resistência cisalhante de pico com t/a para diferentes tensões normais iniciais aplicada em uma junta hipotética sob CNL pelos modelo G1m	125
Figura 5.16	– Variação da resistência cisalhante de pico com t/a para diferentes valores de k_n em uma junta hipotética sob CNL pelo modelo G1m	125
Figura 5.17	– Comparação entre os dados experimentais, a previsão pelo modelo de Barton (1973) e do modelo G1m para os ensaios de Haque (1999)	126
Figura 5.18	– Comparação entre os dados experimentais, a previsão pelo modelo de Barton (1973) e do modelo G1m para os ensaios de Mehrishal et al. (2016)	127
Figura 5.19	– Comparação entre os dados experimentais de Shrivastava e Rao (2017) de descontinuidades sob CNL preenchidas com $t/a = 1$, com os modelos de Ladanyi e Archambault (1977), de Shrivastava e Rao (2017) e pelo modelo G1m	128
Figura 5.20	– Comparação entre os dados experimentais de Shrivastava e Rao (2017) de descontinuidades sob CNL preenchidas com $t/a = 1,4$, com os modelos de Ladanyi e Archambault (1977), de Shrivastava e Rao (2017) e pelo modelo G1m	128
Figura 5.21	– Comparação entre os dados experimentais de Shrivastava e Rao (2017) de descontinuidades sob CNL preenchidas com $t/a = 2$, com os modelos de Ladanyi e Archambault (1977), de Shrivastava e Rao (2017) e pelo modelo G1m	129
Figura 5.22	– Comparação entre a previsão do modelo G1m e do modelo de Ladany e Archambault (1977) para descontinuidades hipotéticas preenchidas do Item 5.2.2	130

LISTA DE TABELAS

Tabela 2.1	– Resumo sobre alguns modelos para obtenção da tensão cisalhante de pico para juntas não preenchidas	28
Tabela 2.2	– Apresentação do resultado de diferentes critérios de previsão da tensão cisalhante de pico para descontinuidades sem preenchimento sob condição CNL via análise de parâmetros estatísticos	29
Tabela 2.3	– Detalhes e limitações dos modelos e técnicas existentes para previsão do comportamento cisalhante de descontinuidades sob condição CNS	35
Tabela 2.4	– Coeficiente x e y para diferentes valores de t/a	49
Tabela 3.1	– Parâmetros utilizados para o treinamento das RNA para previsão do comportamento cisalhante	58
Tabela 3.2	– Valores máximos e mínimos utilizados para treinamento e validação das RNA	60
Tabela 3.3	– Dados dos grupos dos modelos de previsão da tensão cisalhante e dilatação com deslocamento horizontal	64
Tabela 3.4	– Dados usados para tensão de pico a partir dos obtidos por cada autor	66
Tabela 3.5	– Grupos para tensão de pico	67
Tabela 4.1	– Quantidade de modelos com correlações para dados de teste maior que 95% para cada grupo	72
Tabela 4.2	– Resultados principais do Grupo A	74
Tabela 4.3	– Resultados principais do Grupo A2	76
Tabela 4.4	– Resultados principais do Grupo B	78
Tabela 4.5	– Resultados principais do Grupo B2	80
Tabela 4.6	– Resultados principais do Grupo C	81
Tabela 4.7	– Resultados principais do Grupo E	83
Tabela 4.8	– Resultados principais do Grupo F	84
Tabela 4.9	– Melhores arquiteturas dos grupos A, A2, B, B2, C	86
Tabela 4.10	– Pesos sinápticos e Bias da Camada Intermediária 1	91
Tabela 4.11	– Pesos sinápticos e Bias da Camada Intermediária 2	92
Tabela 4.12	– Pesos sinápticos e Bias da Camada Intermediária 3	93
Tabela 4.13	– Pesos sinápticos e Bias da Camada de saída	93

Tabela 4.14	– Contribuição percentual de cada variável para previsão do cisalhamento e da dilatação para Gm	93
Tabela 5.1	– Relação de grupos sobre maiores correlação com os dados de teste	110
Tabela 5.2	– Pesos sinápticos e Bias da Camada Oculta 1 da rede G1m	115
Tabela 5.3	– Pesos sinápticos e Bias da Camada de saída do modelo G1m	116
Tabela 5.4	– Contribuição percentual de cada variável para previsão do cisalhamento e da dilatação para G1m	116

LISTA DE SÍMBOLOS

CNL	Carga normal constante
CNS	Rigidez normal constante
RNA	Redes neurais artificiais
τ_p	Resistência ao cisalhamento de pico
σ_n	Tensão normal aplicada
ϕ	Ângulo de atrito entre os planos
c	Intercepto coesivo
ϕ_b	Ângulo de atrito interno
ϕ_r	Ângulo de atrito residual
i_0	Ângulo de inclinação inicial do plano de falha relacionado à direção da força cisalhante
μ	Coefficiente de atrito
JRC	Coefficiente de rugosidade da junta
JCS	Resistência efetiva à compressão da junta
σ_c	Resistência à compressão uniaxial da rocha sã
σ'_n	Tensão normal efetiva aplicada
k_n	Rigidez normal do contorno
k_s	Rigidez cisalhante do contorno
δ_h	Deslocamento horizontal causado durante o cisalhamento
δ_v	Dilatância ocorrida durante o cisalhamento
σ_{no}	Tensão normal inicial aplicada
τ_h	Tensão cisalhante atuante com deslocamento horizontal
E	Módulo de Young da rocha intacta
ν	Módulo de Poisson da rocha intacta

E_m	Módulo de elasticidade dos blocos rochosos
i_h	Ângulo da dilatação no deslocamento horizontal
$\Delta\sigma_{n,h}$	Variação da tensão normal com o deslocamento horizontal.
t	Espessura do preenchimento
a	Amplitude da rugosidade da descontinuidade
c_u	Parâmetro da tensão cisalhante da argila não-drenada
ϕ_{fill}	Ângulo de atrito do preenchimento
μ_{max}	Coefficiente de fricção para descontinuidade sem preenchimento
μ_{min}	Coefficiente de fricção mínima de descontinuidade com preenchimento
t/a	Razão entre espessura do preenchimento e amplitude da rugosidade da descontinuidade
t/a_{cr}	Razão entre espessura do preenchimento e amplitude da rugosidade da descontinuidade na qual o
NSD	Decréscimo normalizado da tensão cisalhante
h_{tp}	Deslocamento horizontal no pico
i_{hp}	Dilatação no pico
MLP	Perceptron multicamadas
Gm	Modelo neuronal ótimo escolhido para previsão da tensão cisalhante e dilatação com deslocamento horizontal apresentado no Capítulo 4
G1m	Modelo neuronal ótimo escolhido para previsão da resistência cisalhante de pico apresentado no Capítulo 5

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Justificativa	16
1.2	Objetivos	18
1.2.1	<i>Objetivo geral</i>	18
1.2.2	<i>Objetivos específicos</i>	18
1.3	Metodologia	18
1.4	Escopo do trabalho	19
2	COMPORTAMENTO CISALHANTE DAS DESCONTINUIDADES ROCHOSAS	21
2.1	Descontinuidades sem preenchimento	21
2.2	Descontinuidades com preenchimento	37
2.3	Conclusões parciais	50
3	DESENVOLVIMENTO DOS MODELOS	52
3.1	RNA conceitos básicos	52
3.2	Modelagem da RNA	57
3.3	Modelos desenvolvidos	59
3.3.1	<i>Modelos para previsão da tensão cisalhante e dilatação pelo deslocamento horizontal</i>	59
3.3.2	<i>Modelos para previsão da resistência cisalhante de pico</i>	66
4	RESULTADOS - MODELOS PARA PREVISÃO DA TENSÃO CISALHANTE E DILATÂNCIA COM DESLOCAMENTO HORIZONTAL	71
5	RESULTADOS - MODELO PARA PREVISÃO DA RESISTÊNCIA CISALHANTE DE PICO	109
6	CONCLUSÕES E SUGESTÕES PARA PESQUISAS FUTURAS	132
	REFERÊNCIAS	136
	APÊNDICE A	142

1 INTRODUÇÃO

Neste capítulo encontra-se a justificativa motivacional da pesquisa, seus objetivos gerais e específicos, a metodologia desenvolvida e a forma de estruturação textual da presente dissertação.

1.1 Justificativa

Os maciços rochosos são estruturas de extrema importância para engenharia devido à sua extensão pelo globo sendo usados como fundação, estrutura de contenção, sistema estrutural, minas, túneis entre outros. Contudo, até maciços rochosos que apresentam em sua constituição rochas de alta resistência à compressão, possuem como fator preponderante de resistência global a natureza e propriedades das suas descontinuidades. Em termos de descontinuidade, a resistência ao cisalhamento é tida geralmente como a principal limitante no cálculo de equilíbrio limite, preocupação essa gerando a motivação de pesquisas como de Patton (1966), Barton (1973a, 1976, 2016), Barton e Choubey (1977), Barton e Bandis (1982), Benmokrane e Bavillivy (1989), Skinas *et al.* (1990), Papaliangas *et al.* (1993), Haque (1999), Indraratna (2000), Indraratna *et al.* (2005), Indraratna *et al.* (2012), Indraratna *et al.* (2014, 2015), Naghadehi (2015), Karakus *et al.* (2016), Mehrishal *et al.* (2016), Dantas Neto *et al.* (2017) Shrivastava e Rao (2017), Matos (2018), Matos *et al.* (2019a, 2019b), etc. Os resultados demonstraram a natureza não-linear, complexa do comportamento cisalhante das descontinuidades rochosas assim como a dependência de muitas variáveis, dentre as quais estão a tensão normal aplicada, a rugosidade da descontinuidade, as propriedades da rocha intacta, as condições de contorno quando sobre carga normal constante (CNL) ou rigidez normal constante (CNS), a presença e características dos preenchimentos encontrados.

É possível observar que no decorrer do avanço das pesquisas relacionadas à previsão da resistência ao cisalhamento, há o aumento gradativo na percepção da influência de um número cada vez maior das suas variáveis governantes. Historicamente têm-se Patton (1966) e Barton (1973b) como algum dos primeiros modelos analíticos criados no intuito de calcular a resistência cisalhante de pico das descontinuidades sem preenchimento, esses modelos levaram em consideração a interpretação do comportamento da amostra sob teste de cisalhamento direto em CNL com diferentes relações de rugosidade e tensões normais aplicadas. Trabalhos experimentais posteriores como de Kulhawy (1975), Barton (1976), Birkhauser (1978) atestaram que a forma de ruptura era dependente da relação entre intensidade

da tensão atuante com a resistência da rocha intacta. Com o avanço Dight e Chiu (1981), Leichnetz (1985), Benmokrane e Ballivy (1989), Skinas *et al.* (1990), Haque (1999), Indraratna *et al.* (2005) mostraram que a condição de contorno CNS influencia de forma significativa o comportamento cisalhante das descontinuidades, fator este não levado em consideração nos modelos analíticos clássicos desenvolvidos até então. Trabalho como de Ladanyi e Archambault (1977), Papaliangas *et al.* (1993), Indraratna *et al.* (2010) e Naghadehi (2015), por sua vez, trataram de explorar as influências causadas pela presença de preenchimento, observaram uma diminuição substancial nas tensões máximas cisalhantes, assim como uma variação na dilatância, tendo essas influência devido ao tipo de preenchimento e na razão entre amplitude do preenchimento com o da rugosidade. A junção desses fatores gera um comportamento complexo comprovadamente não-linear como relatado Prassettyo *et al.* (2017) e sensível a cada uma das variáveis como exposto experimentalmente em Shrivastava e Rao (2017).

Devido ao comportamento cisalhante ser de natureza não-linear, complexa, regido por uma quantidade grande de variáveis, as equações analíticas propostas quando não deixam de levar em consideração alguns parâmetros influenciadores relevantes, requerem coeficientes e parâmetros que só podem ser obtidos após complicadas correlações com resultados laboratoriais. Outras opções para obtenção do comportamento cisalhante, como ensaios de cisalhamento direto e triaxiais, possuem complicações como: dificuldade na representação da condição de contorno tal qual será encontrada em obra; dificuldade na obtenção de amostragens representativas da realidade; tempo necessário da obtenção ou replicação da amostra até o transporte para realização de ensaio; custos elevados.

Como alternativa aos modelos analíticos criados alguns trabalhos propuseram modelos a partir dos princípios das redes neurais artificiais (RNA) para previsão do comportamento cisalhante das descontinuidades. Dantas Neto *et al.* (2016, 2017) propuseram modelos neuronais para previsão da variação da tensão cisalhante e dilatância com decorrer do deslocamento horizontal. Para a previsão da resistência cisalhante de pico, Moshrefii *et al.* (2018) desenvolveram um modelo específico para xisto sob ensaio triaxial, seus resultados constataram uma melhor previsão da RNA que os demais métodos convencionais comparados.

As RNA vem sendo cada vez mais utilizadas em diferentes ramos relacionados a tomadas de decisão baseadas em previsão como reconhecimento de padrões. Seu princípio se baseia na capacidade humana de percepção/aproximação a partir da comparação com a forma de funcionamento dos neurônios do cérebro humano. Dentro dos seus benefícios estão sua flexibilidade, adaptabilidade, capacidade de generalizar e aprender um problema por meio dos

seus estímulos externos e internos, capacidade de produzir uma resposta linear e não-linear. Esses entre outros fatores fizeram dessa tecnologia ser amplamente utilizada nas áreas de medicina, internet das coisas, engenharias e demais áreas. Suas características tornam a tecnologia da RNA uma forte candidata para ser usada como modelo alternativo para compreensão e comparação dos resultados referente à previsão do comportamento cisalhante de descontinuidades preenchidas.

1.2 Objetivos

1.2.1 Objetivo geral

Criar modelos de RNA capazes de prever o comportamento cisalhante das descontinuidades rochosas com e sem preenchimento para diferentes condições de contorno, comparando-os com dados experimentais, modelos analíticos e neuronal.

1.2.2 Objetivos específicos

Como objetivos específicos, podem ser citados:

- Desenvolver modelos de previsão da tensão cisalhante e dilatância com deslocamento horizontal para descontinuidades rochosas sob CNL e CNS, com e sem preenchimento;
- Desenvolver modelos de previsão da resistência cisalhante de pico das descontinuidades rochosas sob CNL e CNS, com e sem preenchimento.
- Avaliar a influência das variáveis de entrada nos modelos desenvolvidos e de que forma a supressão delas influenciam no comportamento cisalhante das descontinuidades.
- Comparar os resultados obtidos dos modelos neuronais com dados experimentais e modelos analíticos;
- Verificar a capacidade dos modelos neuronais de representar a influência das variáveis no comportamento cisalhante das descontinuidades.

1.3 Metodologia

A princípio houve uma pesquisa bibliográfica sobre o comportamento cisalhante das descontinuidades dos maciços rochosos e os modelos criados até então para caracterizá-los.

Foi estudado a modelagem de fenômenos na engenharia com a aplicação das redes neurais artificiais sobretudo na previsão de propriedades da mecânica das rochas e os modelos criados para prever as propriedades das descontinuidades do maciço.

Após o estudo foram definidas as variáveis a serem usadas nos modelos neuronais obtidas a partir da extração de dados de cisalhamento direto da literatura de descontinuidades preenchidas e não preenchidas, de rochas brandas e duras, sob CNL e CNS. Em sequência foram desenvolvidos diversos modelos de RNA para previsão do comportamento cisalhante em dois diferentes aspectos: tensão cisalhante e dilatância com deslocamento horizontal, previsão da resistência cisalhante de pico para descontinuidades rochosas.

A partir da seleção dos melhores modelos foram feitos testes e validações para comparar os resultados provenientes dos modelos neuronais com dados experimentais. Análises de sensibilidade por meio de juntas hipotéticas, a fim de se averiguar, se os resultados das previsões dos modelos estavam coerentes com as mudanças nas variáveis da entrada governantes. Comparação entre os modelos, comparação com modelos analíticos e neuronais existentes.

1.4 Escopo do trabalho

Essa dissertação é composta por seis capítulos. Após este capítulo introdutório, o segundo capítulo remete aos aspectos importantes das descontinuidades, os modelos relevantes desenvolvidos para previsão do comportamento cisalhante, seguindo uma linha cronológica de consideração das variáveis. Sendo a princípio discutido de descontinuidades sem preenchimento e em seguida, com preenchimento. Também é debatido sobre o uso das RNA na mecânica das rochas, incluindo a aplicação relativa à resistência ao cisalhamento de descontinuidades sem preenchimento.

No Capítulo 3, é exposto de forma simplificada o funcionamento das redes neurais artificiais, o tipo de RNA usado para este trabalho e os parâmetros da RNA usados para desenvolvimento dos modelos. Também é retratado como foram desenvolvidos os modelos para previsão da tensão cisalhante e dilatância com deslocamento horizontal e resistência cisalhante de pico, os grupos criados para prever os comportamentos e detalhes sobre os dados de entrada utilizados para os modelos.

O Capítulo 4 expressa os resultados dos modelos para previsão da tensão cisalhante e dilatância com deslocamento horizontal, como se comportaram os diferentes grupos e melhores modelos. É apresentado o modelo escolhido para previsão do comportamento, modelo

Gm. É exposto seu comportamento diante os dados experimentais, em juntas hipotéticas e comparado com os modelos de Dantas Neto *et al.* (2017) e Indraratna e Haque (2000).

No quinto capítulo se encontram os resultados dos modelos para resistência cisalhante de pico, as eficiências dos modelos de acordo com a forma de seleção de dados utilizados. Ao fim é apresentado o modelo principal escolhido, modelo G1m. É discutido sobre a previsão do modelo diante dos dados experimentais utilizados, também seu comportamento para descontinuidades hipotéticas comparando ao modelo Gm e ao modelo de Dantas Neto *et al.* (2017). As previsões do modelo G1m também são usadas em dados experimentais e provindos de descontinuidades hipotéticas, para serem comparadas aos modelos de Barton (1973b), Ladanyi e Archambault (1977), Shrivastava e Rao (2018) e Patton (1966).

Capítulo 6 retrata as conclusões da pesquisa e sugestões para possíveis futuros trabalhos.

Por último são descritas as referências bibliográficas utilizadas para o desenvolvimento dessa pesquisa e em seguida, o Apêndice A referente aos resultados de alguns modelos de previsão tensão cisalhantes e dilatação com deslocamento horizontal comparados à dados experimentais.

2 COMPORTAMENTO CISALHANTE DAS DESCONTINUIDADES ROCHOSAS

Neste capítulo é retratado a revisão bibliográfica a respeito do comportamento cisalhante das descontinuidades com e sem preenchimento existentes nos maciços rochosos. As informações visam além da compreensão do fenômeno estudado, a identificação das principais variáveis que influenciam no comportamento cisalhante das descontinuidades rochosas, e conseqüentemente, a definição dos parâmetros de entrada dos modelos de previsão propostos.

2.1 Descontinuidades sem preenchimento

Existe uma relação clara sobre a resistência ao cisalhamento entre dois planos de uma descontinuidade e a tensão normal aplicada quando mecanismo responsável pela resistência ao cisalhamento é o atrito. Bucher (1921) em seu trabalho sobre a interpretação mecânica das descontinuidades cita a teoria de Mohr, a qual lida com a ruptura sob o deslizamento entre os planos. A teoria postula que a resistência cisalhante de pico (τ_p) é dependente de uma função normal aplicada (σ_n) e o ângulo de atrito entre os planos (ϕ), sendo c a interseção do envelope com o eixo da tensão cisalhante (Equação 2.1).

$$\tau_p = c + \sigma_n \tan \phi \quad (2.1)$$

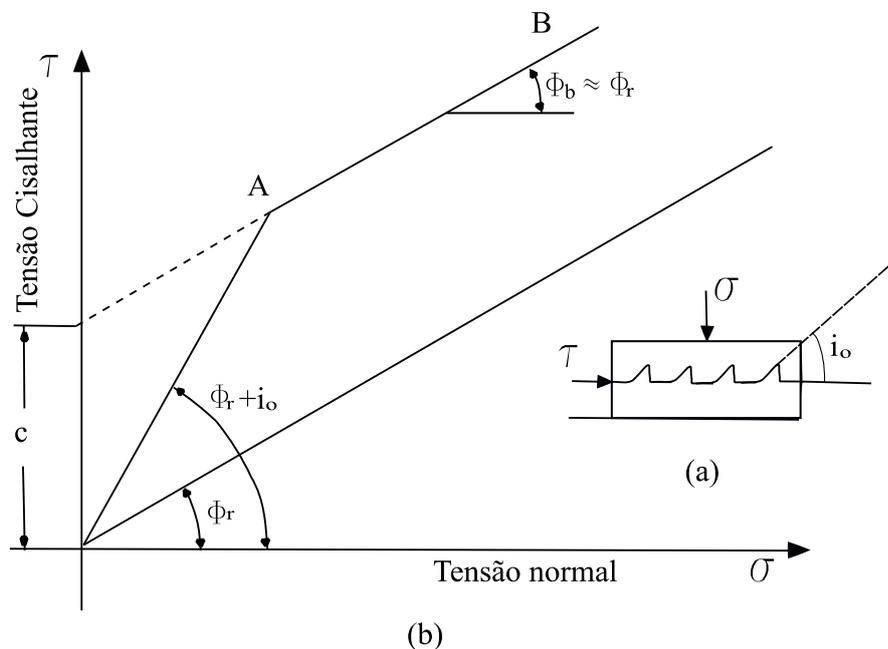
No estudo experimental de Patton (1966), suas percepções sobre uma série de ensaios de cisalhamento direto, sob condições CNL foram: a não linearidade da envoltória de ruptura; que a mudanças na inclinação da envoltória de ruptura alterava também o modo de falha do maciço; que as alterações dessas envoltórias estão relacionadas às propriedades físicas das irregularidades e que, apesar de ϕ_b (ângulo de atrito básico) não variar consideravelmente, a soma do ϕ_b com ângulo de inclinação inicial da aspereza (i_o), varia tendo muitas implicações práticas

Patton (1966) propôs um dos primeiros modelos analíticos na Mecânica das Rochas para a estimativa da resistência ao cisalhamento de pico das descontinuidades rochosas sem preenchimento com perfis de regulares (Figura 2.1a). Segundo o autor, a envoltória de resistência obtida apresenta o comportamento bilinear (caminho B) representado na Figura 2.1b, na qual: para baixos níveis de tensão normal, a τ_p é dada pelo deslizamento entre as asperezas, sendo função da σ_n e do ângulo de atrito da descontinuidade, cujo valor é uma

combinação do ϕ_b com o ângulo de inclinação inicial do plano de falha relacionado à direção da força cisalhante (i_o), conforme apresentado na Equação 2.2; enquanto que, para elevados níveis de carregamento normal, o processo de cisalhamento produz a degradação das asperezas, gerando um intercepto coesivo (c) na envoltória de ruptura, semelhante ao critério de Mohr-Coulomb (Equação 2.1).

$$\tau_p = \sigma_n \tan(\phi_b + i_o) \quad (2.2)$$

Figura 2.1 – Envoltória de resistência ao cisalhamento proposta por Patton



Fonte: Adaptado de Patton (1966).

Jaeger (1971) salientou que, embora o critério de Coulomb pudesse ser utilizada de forma satisfatória para representar a resistência ao cisalhamento dos solos, a realidade não era a mesma para as discontinuidades rochosas, sugerindo que para representá-las devidamente o modelo descritivo do comportamento deveria ter uma característica não linear. O autor sugeriu modelo descrito na Equação 2.3 e Equação 2.4 para previsão da resistência cisalhante de pico.

$$\tau_p = a\{1 - \exp(-b\sigma_n)\} + \mu\sigma_n \quad (2.3)$$

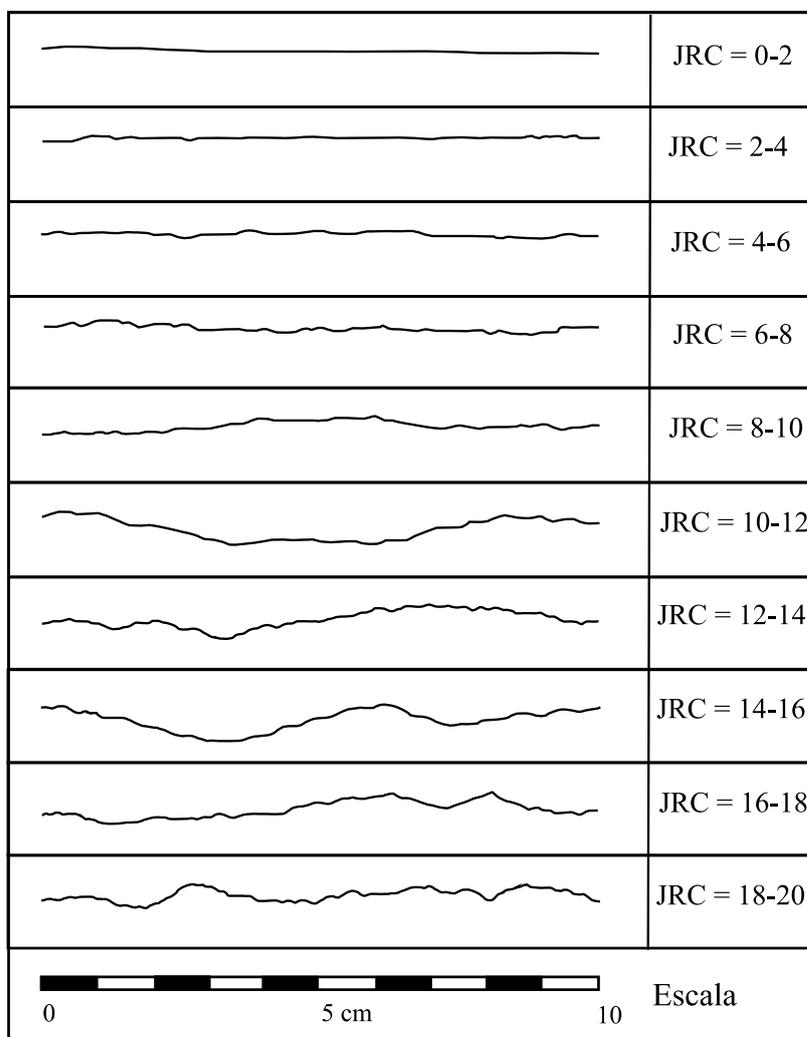
$$\mu = \tau/\sigma \quad (2.4)$$

Onde:

a e b são constantes para adequação da curva de acordo com material;

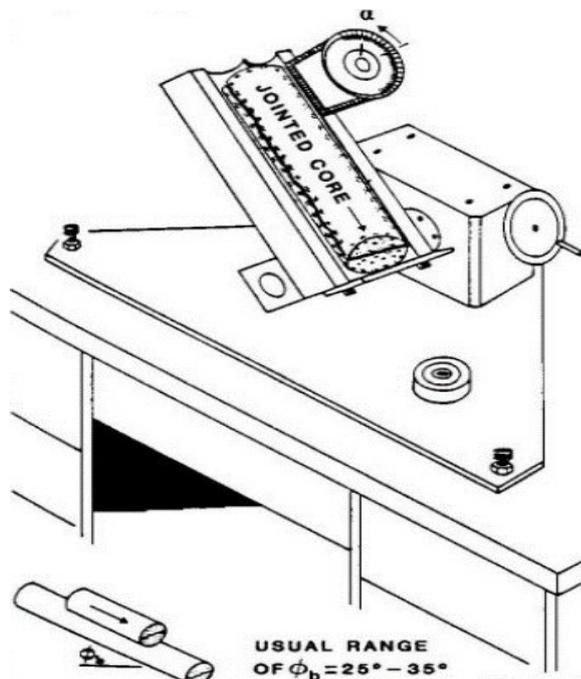
Para discretizar a rugosidade das discontinuidades, Barton (1973b) criou o coeficiente de rugosidade da junta (JRC) proposto inicialmente para aquisição por comparação à uma escala gráfica; sendo em Barton (1973b) as classes divididas em A, B e C que corresponderiam a coeficientes de 20, 10, e 5 respectivamente; em Barton e Choubey (1977) a escala foi dilatada para valores de 0 à 20 tal qual exposta na Figura 2.2. O valor de JRC também pode ser obtido em laboratório por regressão a partir do ensaio de cisalhamento direto ou do plano inclinado, *Tilt test* (Figura 2.3) (BARTON E CHOUBEY, 1977).

Figura 2.2 – Perfil típico de rugosidade para JRC



Fonte: Adaptado de Barton e Choubey (1977)

Figura 2.3 – Tilt test para obtenção do JRC e ϕ_b



Fonte: Barton e Bandis (1990)

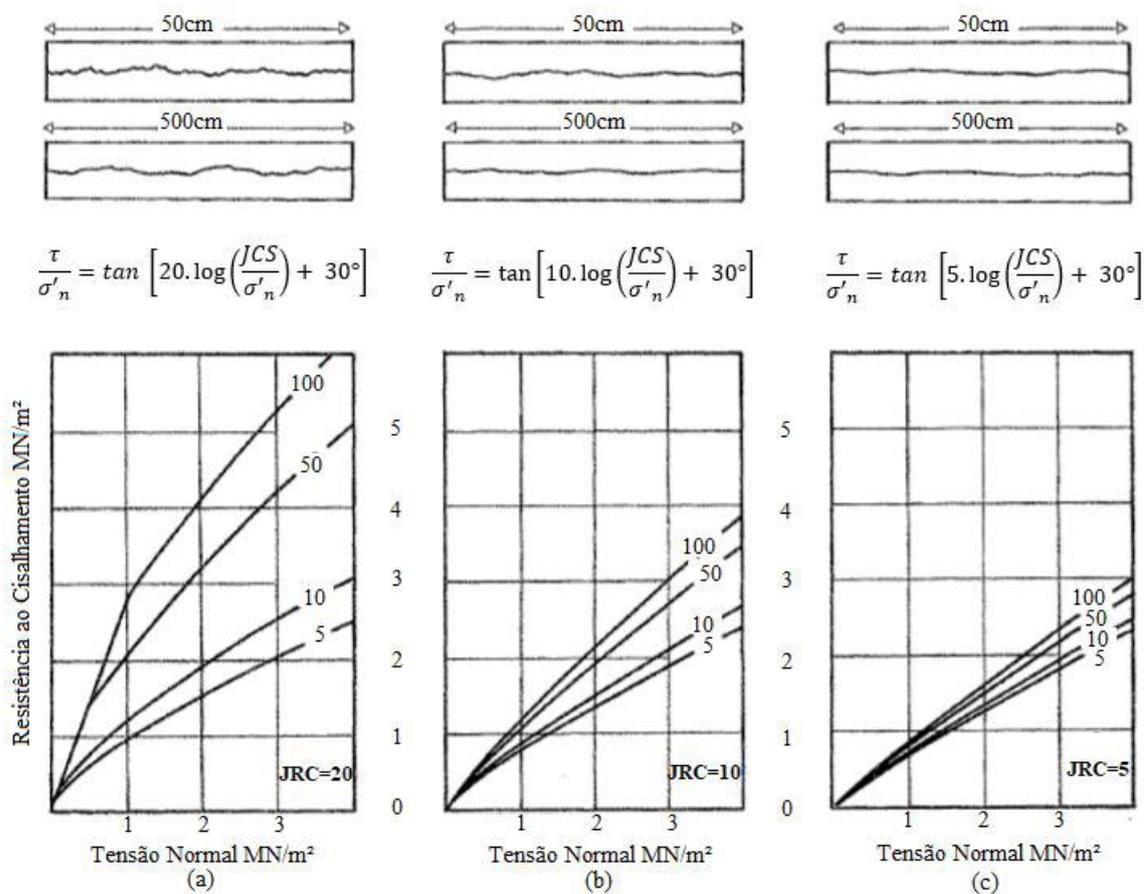
Barton (1973b) sugeriu um modelo empírico não-linear (Equação 2.5) para previsão da τ_p de descontinuidades sem preenchimento sob condição CNL, usando o coeficiente relativo à resistência à compressão simples da junta/descontinuidade (JCS). JCS podendo ser medido no ensaio de esclerometria diretamente na parede da descontinuidade. Segundo o autor o JCS é igual à resistência à compressão simples da rocha constituinte da junta (σ_c) exceto em caso que a descontinuidade estivesse úmida. A Figura 2.4 apresenta a representação gráfica da Equação 2.5 para diferentes descontinuidades com diferentes JRC, com ϕ_b hipotético de 30° . A Figura 2.4 deixa claro que o modelo de Barton (1973b) considera o aumento da resistência ao cisalhamento com o aumento do JRC e JCS de forma não linear, sendo compatível com as observações experimentais apresentadas pelo autor, e pelos demais citados até então.

$$\frac{\tau_p}{\sigma'_n} = \tan \left[\text{JRC} \cdot \log \left(\frac{\text{JCS}}{\sigma'_n} \right) + \phi_b \right] \quad (2.5)$$

Onde:

σ'_n é a tensão normal efetiva aplicada

Figura 2.4 – Representação gráfica do modelo de Barton (1973b) para descontinuidades:



Fonte: Adaptado de Barton e Choubey (1977)

Barton e Choubey (1977) propuseram um modelo semelhante ao de Barton (1973b), contudo substituindo ϕ_b pelo ângulo de atrito residual (ϕ_r), tal que $\phi_r \leq \phi_b$, sendo como apresentado na Equação 2.6. A substituição se deu porque, segundo os autores, geralmente ângulos de atrito tabelados na literatura eram na realidade baseados da resistência residual, fato salientado por Hencher e Richards (2015). Barton e Choubey (1977) enfatizaram que a umidade diminui o ângulo de atrito assim como o faz com JCS, fazendo com que em caso de descontinuidades úmidas, os valores de ϕ_r e JCS fossem obtidas em condições semelhantes às encontradas em campo.

$$\frac{\tau_p}{\sigma'_n} = \tan \left[\text{JRC} \cdot \log \left(\frac{\text{JCS}}{\sigma'_n} \right) + \phi_r \right] \quad (2.6)$$

O ângulo de atrito residual apresentado na Equação 2.6 é estimado empiricamente em função do ϕ_b e dos resultados obtidos nos ensaios de esclerometria com a utilização do martelo de Schimdt, conforme apresentado na Equação 2.7.

$$\phi_r = (\phi_b - 20^\circ) + 20 \cdot (r/R) \quad (2.7)$$

Onde:

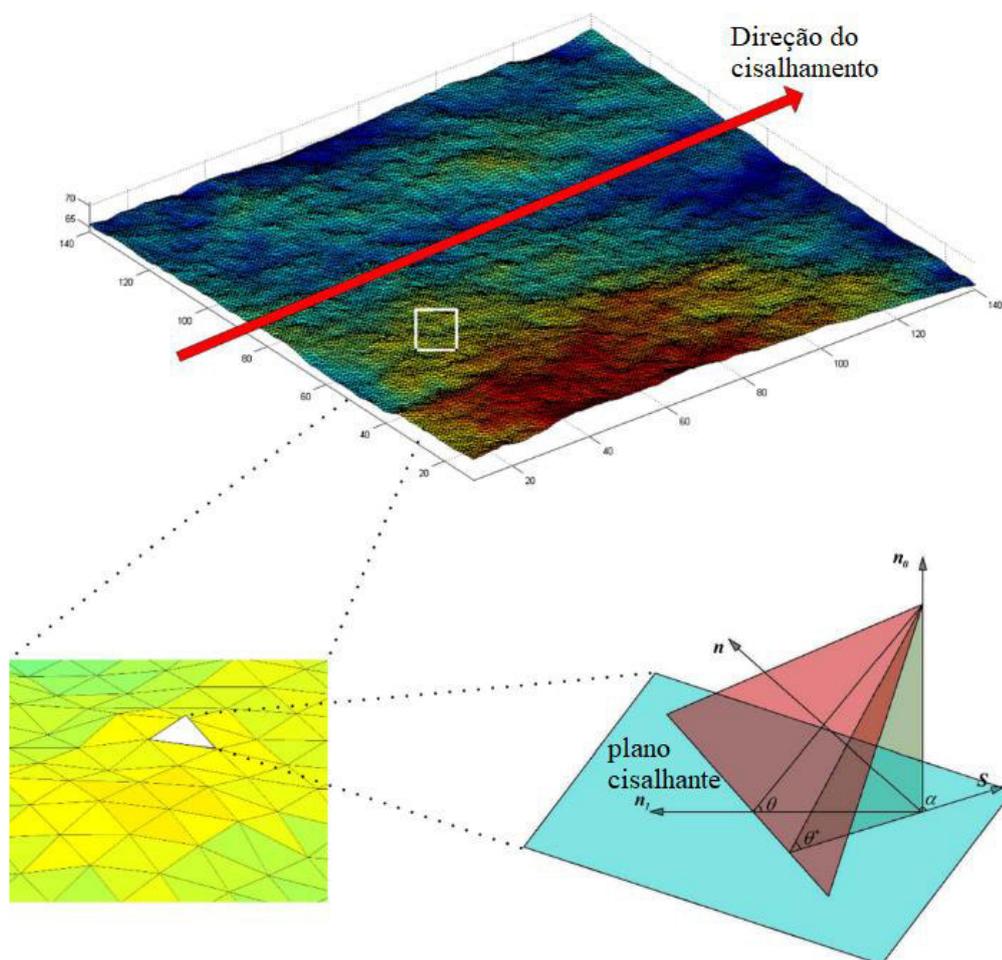
R é o resultado obtido no ensaio de esclerometria em descontinuidades secas;

r é o resultado obtido no ensaio de esclerometria em descontinuidades úmidas.

Os modelos de Barton (1973b) e Barton e Choubey (1977) são largamente utilizados no dia a dia da engenharia, principalmente pela facilidade da sua aplicação e bons resultados para descontinuidades sem preenchimento sob CNL. Contudo os modelos apresentam bons resultados para situações específicas de rochas brandas com baixa rugosidade (ASADOLLAHI E TONON, 2010; LEE *et al.* 2014).

Demais trabalhos trouxeram a importância e complexidade de lidar com a rugosidade de uma forma mais completa para o cálculo da resistência ao cisalhamento das descontinuidades. Foi verificado uma melhor correlação com a τ_p quando ao invés da rugosidade ser avaliada de uma forma usual, visual, unidirecional do JRC (que traz questões de subjetividade intrínseca), a mesma fosse quantificada a partir de um valor equivalente obtido após o escaneamento da superfície considerando sua morfologia tridimensional (GRASSELLI 2006; XIA *et al.*, 2014; ZHANG *et al.*, 2016; YANG *et al.*, 2016; TIAN *et al.*, 2018). Alguns dos parâmetros de cálculo para descrição da morfologia tridimensional, podem ser obtidos conforme apresentado na Figura 2.5, referente ao trabalho de Xia *et al.* (2014).

Figura 2.5 – Reconstrução da junta após escaneamento por elementos triangulares



Fonte: Adaptado de Tian *et al.* (2018)

Além dos modelos retratados, outros foram criados como exposto a seguir em função do estudo realizado por Singh e Basu (2018). As Tabela 2.1 e 2.2 apresentam respectivamente os modelos levantados para resistência cisalhante de pico pelos autores Singh e Basu (2018) e o erro médio e erro quadrático médio (RMSE) segundo às comparações com os resultados experimentais realizados com alguns desses modelos. Os modelos foram alguns dos analíticos criados até o momento da pesquisa do autor para a previsão da τ_p das descontinuidades não preenchidas, sendo a comparação realizada sob a condição CNL.

Tabela 2.1 – Resumo sobre alguns modelos para obtenção da tensão cisalhante de pico para juntas não preenchidas.

Referências	Critério para resistência cisalhante de pico
Patton (1966)	$\tau = \sigma_n \tan(\phi_b + i_o)$
Ladanyi and Archambault (1969)	$\tau = \frac{\sigma_n (1 - a_s)(\dot{v} + \tan \phi_u) + a_s(\sigma_n \cdot \tan \phi_i + s_0)}{1 - (1 - a_s) \cdot \dot{v} \cdot \tan \phi_f}$
Jaeger (1971)	$\tau = a\{1 - \exp(-b\sigma_n)\} + \mu\sigma_n$
Barton (1973)	$\tau = \sigma_n \tan \left[\phi_b + \text{JRC} \cdot \log \left(\frac{\text{JCS}}{\sigma_n} \right) \right]$
Schneider (1976)	$\tau = \sigma_n \tan \left[\phi_r + \arctan \left(\frac{h_0 e^{-h_1 \sigma_n}}{\Delta s} \right) \right]$
Barton and Choubey (1977)	$\tau = \sigma_n \tan \left[\phi_r + \text{JRC} \cdot \log \left(\frac{\text{JCS}}{\sigma_n} \right) \right]$
Jing et al., 1992	$\tau = \sigma_n \tan \left[\phi_b + i_0 \left(1 - \frac{\sigma_n}{\sigma_c} \right)^{k_2} \right]$
Maksimović (1992)	$\tau = \sigma_n \tan \left[\phi_b + \Delta\phi / \left(1 + \frac{\sigma_n}{F_N} \right) \right]$
Kulatilake et al. (1995)	$\tau = \sigma_n \tan \left[\phi_b + a(\text{SRP})^c \left[\log_{10} \left(\frac{\text{JCS}}{\sigma_n} \right) \right]^d + I \right]$
Zhao (1997)	$\tau = \sigma_n \tan \left[\phi_r + \text{JRC} \cdot \text{JMC} \log_{10} \left(\frac{\text{JCS}}{\sigma_n} \right) \right]$
Aydan et al. (1996)	$\tau = [c_j(1 - \exp(-B_1 \sigma_n)) + \sigma_n(\tan \phi_i + A_2 \exp(-B_2 \sigma_n))]$
Grasselli and Egger (2003)	$\tau = \sigma_n \tan \left[\phi_b + \left(\frac{\theta^*_{\max}}{C} \right)^{1.18 \cos \beta} \right] \times \left[1 + \exp \left[\frac{\theta^*_{\max} \cdot \sigma_n}{C \cdot 9A_0 \sigma_t} \right] \right]$
Tatone and Grasselli (2009)	$\tau = \sigma_n \tan \left[\phi_b + \left(\frac{\theta^*_{\max}}{C} \right)^{1.18 \cos \beta} \right] \times \left[1 + \exp \left[\frac{\theta^*_{\max} \cdot \sigma_n}{C + 1 \cdot 9A_0 \sigma_t} \right] \right]$
Cottrell et al. (2010)	$\tau = \sigma_n(1 - a_s) \tan(\phi_b + i) + a_s(\sigma_n \tan \phi_o + c)$
Ghazvinian et al. (2010)	$\tau = \sigma_n \tan \left[\phi_b + i_0 \frac{(\sigma_c / \sigma_n)^a}{b + (\sigma_c / \sigma_n)^a} \right]$
Ghazvinian et al. (2012)	$\tau = \sigma_n \tan \left[\phi_b + a \frac{(\sigma_t / \sigma_n)}{1 + (\sigma_t / \sigma_n)} \right]$
Lee et al. (2014)	$\tau = \sigma_n \left[\tan(\phi_b) + 0,017(\text{JRC})^{0,89} \left(\frac{\text{JCS}}{\sigma_n} \right)^{0,42} \right]$
Tang et al. (2014)	$\tau = \sigma_n \tan \left[\phi_b + 10 \frac{A_0 \theta^*_{\max}}{1 + C} \cdot \frac{(\sigma_t / \sigma_n)}{1 + (\sigma_t / \sigma_n)} \right]$
Xia et al. (2014)	$\tau = \sigma_n \tan \left[\phi_b + \frac{4A_0 \theta^*_{\max}}{C + 1} \left[1 + \exp \left(-\frac{1}{9A_0} \frac{\theta^*_{\max}}{C + 1} \cdot \frac{\sigma_n}{\sigma_t} \right) \right] \right]$
Jang and Jang (2015)	$\tau = \sigma_n^B \tan(\phi_b + \phi_j + S_n)$
Kumar and Verma (2016)	$\tau = \sigma_n \tan \left[\phi_b + \theta_A \exp \left\{ -(\theta_{\max})^{0,89} \left(\frac{\sigma_n}{\sigma_c} \right) \right\} + (\theta_{\max})^{1,07} \left(\frac{\sigma_n}{\sigma_c} \right)^{0,42 [\ln(\theta_{\max})^{1,07}] - 1,33} \right]$
Tang et al. (2016a, 2016b)	$\tau = \sigma_n \left[\tan(\phi_b) + 9,01 \frac{0,1A_0 \theta^*_{\max} / (1 + C)}{(1 + \sigma_n / \sigma_t)} \right]$
Tang and Wong (2016)	$\tau = \sigma_n \tan \left[\phi_b + \left[\frac{1}{1 + 8A_0 \theta^*_{\max} / (1 + C)} \cdot k \right] \frac{4A_0 \theta^*_{\max}}{C + 1} \left[1 + \exp \left(-\frac{1}{9A_0} \frac{\theta^*_{\max}}{C + 1} \cdot \frac{\sigma_n}{\sigma_t} \right) \right] \right]$
Yang et al. (2016) Zhang	$\tau = \sigma_n \tan \left[\phi_b + \frac{\theta^*_{\max}}{C^{0,45}} e^{-(\sigma_n / \text{JCS}) C^{0,75}} \right]$
Zhang et al. (2016)	$\tau = \sigma_n \tan \left[\phi_b + \frac{\tan^{-1}(z_{2r})}{(1 - C_m)^{0,64}} \left\{ 1 - \exp \left(-3,36 C_m \frac{\sigma_t}{\sigma_n} \right) \right\} \right]$

Tabela 2.2 – Apresentação do resultado de diferentes critérios de previsão da tensão cisalhante de pico para descontinuidades sem preenchimento sob condição CNL via análise de parâmetros estatísticos.

Critério para tensão de pico	Granito		Quartzito		Arenito	
	Erro médio (%)	RMSE	Erro médio (%)	RMSE	Erro médio (%)	RMSE
Barton (1973)	12.17	0.102	26.68	0.198	20.57	0.185
Aydan et al. (1996)	21.06	0.188	20.12	0.175	31.93	0.304
Tatone and Grasselli (2009)	67.22	0.567	39.23	0.352	55.57	0.410
Ghazvinian et al. (2012)	55.07	0.448	30.82	0.262	44.19	0.307
Lee et al. (2014)	16.80	0.118	15.70	0.132	13.82	0.129
Tang et al. (2014)	27.45	0.224	13.87	0.102	12.16	0.096
Xia et al. (2014)	17.80	0.152	15.05	0.109	10.09	0.087
Jang and Jang (2015)	102.43	0.744	81.72	0.649	192.68	1.444
Kumar and Verma (2016)	22.05	0.241	19.54	0.136	18.57	0.181
Yang et al. (2016)	10.48	0.092	18.37	0.132	11.63	0.110
Zhang et al. (2016)	11.07	0.085	21.85	0.155	14.14	0.120

Fonte: Adaptado de Singh e Basu (2018).

Embora os modelos de Barton (1973b) e Barton e Choubey (1977) sejam o mais utilizados no dia a dia da engenharia, os modelos de Xia *et al.* (2014), Zhang *et al.* (2016), Yang *et al.* (2016) e Lee et al. (2014) foram os superiores. Essa avaliação foi baseada no menor erro médio ($\approx 16\%$) para a média dos 196 ensaios de cisalhamento direto, performados na condição CNL, em diferentes tipos de rochas com uma tensão média de 0.22 à 2.01 MPa. (SINGH E BASU 2018).

Os modelos de Xia *et al.* (2014), Zhang *et al.* (2016), Yang *et al.* (2016), fazem parte dos modelos que inferem a resitência cisalhante de descontinuidade sem preenchimento sob a condição CNL, a partir de de parâmetros providos do escaneamento da superfície considerando então sua morfologia tridimensional. Embora tenham apresentados resultados relevantes segundo trabalho de Singh e Basu (2018), apresentam uma maior dificuldade na aquisição das variáveis de entradas, quando comparados aos modelos consagrados na Mecânica das Rochas. Lee et al. (2014), que também apresentou bons resultados, possui a vantagem de seus parâmetros serem de mais fácil aquisição: ϕ_b , JRC, JCS, σ_n , (SINGH E BASU 2018). O modelo de Lee et al. (2014) foi desenvolvido por meio de diversas análises de regressão, para o uso dele deve ser observado se a rocha tem as mesmas condições de contorno, assim como o JRC usando, que segue as recomendações de cálculo de Tse e Cruden (1979).

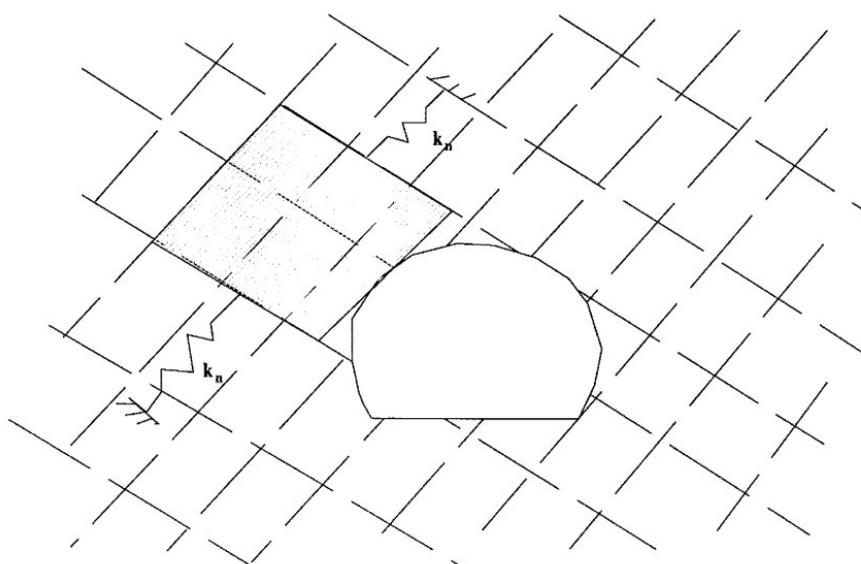
Os modelos tratados até então foram concebidas em descontinuidades sob CNL Essa condição de contorno corresponde às situações onde, não havendo limitações no

movimento, a massa de solo delimitada pelas discontinuidades, pelo talude e pela superfície do maciço, cisalha sem haver um aumento na tensão normal média ao longo da discontinuidade.

Vários autores mostraram que o confinamento das discontinuidades do maciço tem grande influência no seu comportamento cisalhante, sendo essa a condição de contorno referente à uma rigidez normal constante (CNS) (BENMOKRANE E BALLIVY, 1989; SKINAS *et al.*, 1990; SAEB E AMADEI, 1992). Goodman *et al.* (1968) destacou a importância dos parâmetros referentes a rigidez normal do contorno (k_n) e da rigidez cisalhante (k_s) das discontinuidades quando as mesmas se encontram confinadas, principalmente ao tratá-las por meio de métodos de elementos finitos. Jaeger (1971) pontuava que a presença de sistemas confinantes, provocariam efeitos substanciais no deslocamento e nas tensões normais, consequentemente, cisalhantes.

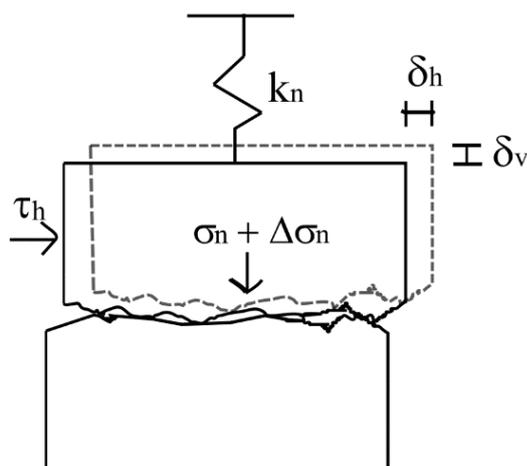
A condição de contorno de CNS se refere à quando restrições ao movimento dos blocos se configuram em uma variação da força perpendicular ao plano variando com o decorrer do deslocamento cisalhante. Alguns exemplo dessa condição são: de rochas sujeitas à ancoragens, blocos rochosos encaixados entre o si como em uma escavação de túnel (Figura 2.6). Nesses casos o mais adequado seria o ensaio sob CNS, cuja representação simplificada é apresentada na Figura 2.7.

Figura 2.6 – Escavação subterrânea feita em um maciço rochoso com discontinuidades



Fonte: Indraratna *et al* (1998).

Figura 2.7 – Representação simplificada do ensaio sob CNS



Fonte: Alterado de Skinas (1990).

O maciço sob CNS pode ser representado pelo k_n sendo essa a razão da tensão normal aplicada na descontinuidade pelo deslocamento normal produzido (dilatância). Como citado anteriormente tal rigidez pode ser provinda de tirantes, mas também como o próprio confinamento entre blocos de rochas. Skinas *et al.* (1990) verificaram que essa rigidez proveniente dos blocos intertravados era não-linear e variável, podendo variar de aproximadamente zero à valores correspondentes ao da rigidez da rocha intacta com o aumento da profundidade. Para condições de descontinuidades sem preenchimento, imersas no maciço rochoso, os autores propuseram que a rigidez normal de contorno poderia ser determinada a partir da Equação 2.8.

$$k_n = \frac{E \cdot L}{2c(1 - \nu^2)} \quad (2.8)$$

Onde:

E é o módulo de Young da rocha intacta;

L o comprimento retangular do bloco da descontinuidade;

c é uma constante;

ν é o módulo de Poisson da rocha intacta.

Outra possibilidade para o cálculo da rigidez normal do contorno foi proposta por Barton (1972), em seu trabalho sobre deformação das descontinuidades, tal qual exposto na Equação 2.9 a seguir.

$$\frac{E_m}{E} = \left[\frac{k_n \cdot L}{k_n \cdot L + E} \right] \quad (2.9)$$

Onde:

E é o módulo de elasticidade da rocha intacta;

E_m é o módulo de elasticidade dos blocos rochosos;

L é o espaçamento médio entre descontinuidades.

Para determinar a rigidez cisalhante de pico, Barton e Choubey (1977) propuseram a Equação 2.10, bastante utilizada até hoje para obtenção da variável.

$$k_s = \frac{100}{L} \sigma_n \cdot \tan[\text{JRC} \cdot \log_{10} \left(\frac{\text{JCS}}{\sigma_n} \right) + \phi_r] \quad (2.10)$$

Onde:

L é a comprimento da descontinuidade (limitada pelo espaçamento de outras juntas transversais, formadoras de blocos de rocha).

Benmokrane e Ballivy (1989) e Skinas *et al.* (1990) tiveram como resultado que a inclusão de uma rigidez normal proveniente da condição de contorno alterava significativamente as tensões cisalhantes e dilatância das amostras submetidas à ensaios de cisalhamento direto. Os resultados dos ensaios de cisalhamento direto apresentados por Skinas *et al.* (1990) em descontinuidades não preenchidas mostraram que sob condições CNS há um aumento nas tensões cisalhantes e um diminuição da dilatância durante o processo de cisalhamento das descontinuidades. Sendo importante salientar que CNS só traz resultados marcantes em casos que a rocha não fosse deformável o suficiente para absolver elasticamente o deslocamento vertical.

Levando em consideração a relevância da rigidez normal no comportamento cisalhante, Saeb e Amadei (1992) criaram um modelo matemático e um modelo gráfico capazes de descrever a tensão cisalhante e dilatância para as descontinuidades não preenchidas. Os modelos necessitam das curvas de tensão de dilatância obtidas a partir de ensaio de cisalhamento direto sob a condição CNL.

Indraratna *et al.* (1998) realizaram uma série de ensaios de cisalhamento direto de juntas triangulares como ilustradas na Figura 2.8, sendo estes em descontinuidades de rochas brandas sob condição CNL e CNS, com e sem preenchimento. Esse estudo demonstrou a diferença significativa do comportamento cisalhante na variação da condição de contorno; a

dilatância se apresentou sempre superior quando a junta estava sob CNL, contudo a tensão cisalhante de pico era subestimado quando comparado com a da junta sob condição CNL; foi observado também a mudança da trajetória da envoltória sendo observado uma trajetória bi linear quando sob CNL e não linear quando sob CNS. A Equação 2.11 apresenta a representação do modelo proposto pelos autores para cálculo da resistência cisalhante de pico sob condição CNS.

$$\left(\frac{\tau_p}{\sigma_n}\right)_{CNS} = \tan \left[\phi_b + i_0 \left(1 - \frac{\sigma_{no} + k_n \delta_v / A}{\sigma_c} \right)^\beta \right] \quad (2.11)$$

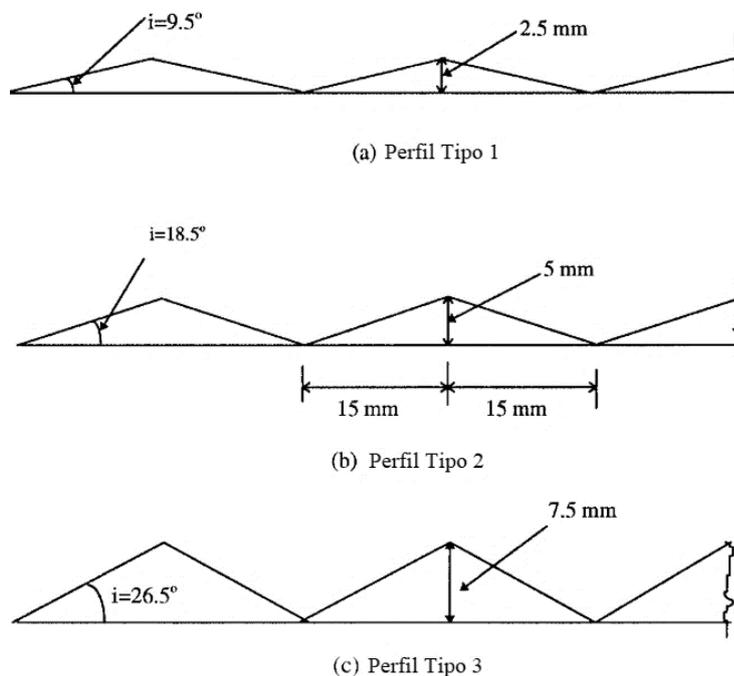
Onde:

A é a área da junta;

δ_v é a dilatância;

β é a característica da área correspondente a degradação da junta.

Figura 2.8 – Tipos de descontinuidades triangulares ensaiadas por Indraratna *et al.* (1998):



Fonte: Indraratna *et al.* (1998)

Haque (1999) a partir de diversos ensaios de cisalhamento direto, propôs um modelo para a previsão do comportamento cisalhante que considera a condição CNS da junta e a variação da tensão cisalhante com o deslocamento cisalhante. A variação se dá pela mudança

das tensões normais ao longo deslocamento cisalhante (δ_h), sendo isso obtido pela variação da dilatância. O autor utiliza uma série de Fourier (Equação 2.12), por ser possível interpolar com ela qualquer curva de variação da dilatância, e pelo fato de ser uma função contínua e diferenciável em todo o seu domínio.

$$\delta_v(\delta_h) = \frac{a_0}{2} + \sum_{n=1}^{\infty} \left[a_n \cos\left(\frac{2\pi n \delta_h}{T}\right) + b_n \text{sen}\left(\frac{2\pi n \delta_h}{T}\right) \right] \quad (2.12)$$

Onde:

a_0 , a_n e b_n são coeficientes da série de Fourier;

n é o número de harmônicos;

T o período da série;

As incógnitas da série podem ser determinadas a partir da interpolação com resultado da dilatância proveniente do ensaio de cisalhamento direto seguindo as recomendações de Haque (1999). A partir da obtenção da dilatância e da constante k_n , é possível determinar a σ_n conforme exposto na Equação 2.13.

$$\sigma_n(\delta_h) = \sigma_{no} + \frac{k_n \delta_v(\delta_h)}{A} \quad (2.13)$$

Tendo como base o modelo de Patton (1966), levando em consideração os princípios da energia e com auxílio das Equações 2.12 e 2.13, Haque (1999) propôs a Equação 2.11 para a previsão da tensão cisalhante para dado deslocamento horizontal.

$$\tau_h = \left\{ \sigma_{no} + \frac{k_n}{A} \left[\frac{a_0}{2} + \sum_{n=1}^{\infty} \left(a_n \cos\left(\frac{2\pi n \delta_h}{T}\right) + b_n \text{sen}\left(\frac{2\pi n \delta_h}{T}\right) \right) \right] \right\} \left[\frac{\tan(\phi_b) + \tan(i_h)}{1 - \tan(\phi_b) \tan(i_h)} \right] \quad (2.14)$$

Onde:

i_h é o ângulo da dilatância no deslocamento horizontal;

τ_h é tensão cisalhante atuante dado deslocamento horizontal;

$\Delta\sigma_{n,h}$ variação da tensão normal com o deslocamento horizontal.

Os modelos citados até então, para previsão do comportamento cisalhante de descontinuidades sob a condição de CNS, e outros foram debatidos em Thirukumaran e

Indraratna (2016). A Tabela 2.3 apresenta um quadro resumo dos detalhes e restrições de alguns modelos relatadas nesse estudo.

Tabela 2.3 – Detalhes e limitações dos modelos e técnicas existentes para previsão do comportamento cisalhante de descontinuidades sob condição CNS

Técnica de modelagem	Investigador(es)	Características	Limitações
Método gráfico	Saeb e Amadei (1990)	Método gráfico de Goodman (1980) foi estendido para fazer a previsão completa do comportamento cisalhante sob condição CNS.	Um largo número de experimentos é requerido para prever o comportamento cisalhante sob a condição CNS para uma dada tensão normal inicial; o comportamento cisalhante é assumido como independente do histórico de tensão pré-existente.
	Skinas et al. (1990)	Um novo modelo gráfico foi utilizado para calcular a junta mobilizada e dilatada sob CNS e prever o completo comportamento cisalhante. A rugosidade da junta e resistência a compressão (JRC e JCS) foram incluídas.	Histórico de cisalhamento sob CNL e resultados de ensaios são necessários para desenvolvimento do modelo; o comportamento cisalhante é assumido como independente do histórico de tensão pré-existente.
Abordagem conceitual	Heuze (1979)	Comportamento cisalhante da junta foi considerada dependente do estado de tensão. O conceito de bidilatação foi utilizado para calcular o ângulo de dilatação máxima sob CNS.	Aplicável a juntas com perfis de aspereza triangulares; apenas a tensão cisalhante de pico pode ser calculada.
	Leichnitz (1985)	Equações constitutivas foram propostas com uma matriz de rigidez bem definida.	O comportamento cisalhante é assumido como independente do histórico de tensão pré-existente.; as equações constitutivas consistiam em inúmeras constantes materiais; a rugosidade da superfície da junta não foi incorporada no modelo.
	Saeb e Amadei (1990)	Equações constitutivas semelhantes às de Leichnitz (1985) foram propostas com uma matriz de rigidez revisada, na qual um parâmetro simplificado de rugosidade da superfície da junta foi incluído.	O comportamento cisalhante é assumido como independente do histórico de tensão pré-existente; A rugosidade da superfície foi simplificada usando um ângulo de atrito inicial; O modelo foi validado com dados de teste limitados.
	Indraratna e Haque (2000)	O comportamento de cisalhamento foi considerado dependente do caminho do estresse sob CNS; a série de Fourier foi utilizada para obter a dilatação ótima.	O modelo foi validado com os resultados dos testes obtidos para perfis idealizados triangulares; necessário um grande número de coeficientes de Fourier para prever o comportamento completo de cisalhamento.
	Seidel e Haberfield (2002)	O comportamento de cisalhamento foi considerado dependente do caminho do estresse sob CNS; diferentes valores de rigidez da junta (ou seja, interfaces de concreto/ rocha ou rocha/rocha) foram incorporados.	A rugosidade da superfície foi simplificada usando um ângulo de atrito inicial; superfícies naturais não foram testadas; validado com dados experimentais limitados.
	Indraratna et al. (2010b)	O comportamento de cisalhamento foi considerado dependente do caminho do estresse sob CNS; O perfil natural da junta e o preenchimento foram considerados; A série de Fourier foi utilizada para obter a dilatação ideal da articulação. O comportamento de cisalhamento da articulação foi considerado dependente do caminho do estresse sob CNS.	Necessário um grande número de coeficientes de Fourier para prever o comportamento completo de cisalhamento; validado com dados experimentais limitados.
	Indraratna et al. (2015)	O comportamento cisalhante foi considerado dependente do caminho do estresse sob CNS; Um novo modelo simplificado (conceitual) de dilatação foi introduzido para prever o comportamento de cisalhamento completo da articulação; A rugosidade natural da superfície e sua resistência à compressão (JRC e JCS) foram consideradas no modelo; A degradação da aspereza sob CNS foi incorporada no modelo.	Validado com dados experimentais limitados.

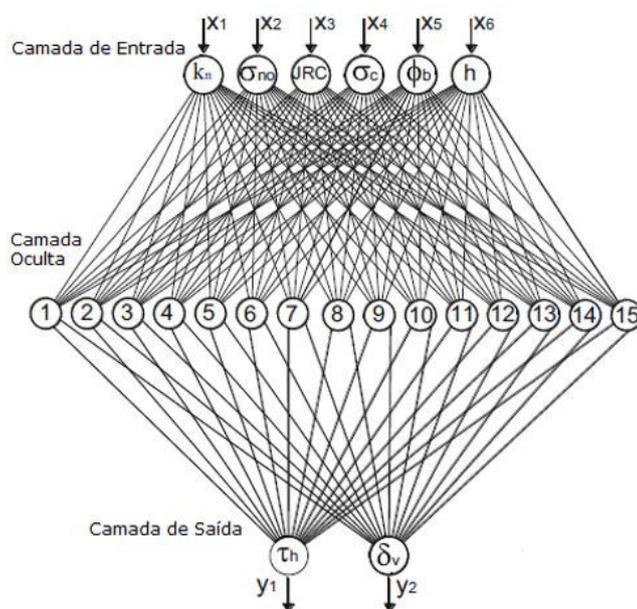
Fonte: Adaptado de Thirukumaran e Indraratna (2016)

Como alternativa aos modelos analíticos e gráficos retratados até então, que trazem limitações principalmente sobre a obtenção os parâmetros necessários, Dantas Neto *et al.* (2017) propuseram um modelo de previsão do comportamento cisalhante de descontinuidades não preenchidas sob condição CNL e CNS usando redes neurais artificiais (RNA). Os

parâmetros de entrada foram σ_{no} em MPa, ϕ_b em graus, JRC, k_n em kPa/mm, δ_h em mm; parâmetros de saída foram δ_v em mm e τ_h em kPa.

O modelo neuronal proposto por Dantas Neto *et al.* (2017) que apresentou melhor ajuste aos dados experimentais foi o de arquitetura A:6-15-2 onde cada valor representa o número de neurônios da camada. A Figura 2.9 apresenta a arquitetura do modelo de RNA selecionado pelo autor. O modelo que teve um coeficiente de correlação para testes e treinamento de aproximadamente 99% e um melhor ajuste dos dados experimentais do que aqueles obtidos com os métodos analíticos atualmente disponíveis.

Figura 2.9 – Arquitetura do modelo neuronal para previsão de δ_v e τ_h para descontinuidades limpas



Fonte: Dantas Neto *et al.* (2017)

Buscando estabelecer um modelo de previsão capaz de levar em consideração a influência da variabilidade própria das variáveis de entrada no comportamento cisalhante das descontinuidades sem preenchimento, modelos Fuzzy e Neuro-Fuzzy foram desenvolvidos (MATOS, 2018; MATOS *et al.*, 2019a, 2019b). Esses modelos foram criados a partir de dados de 44 testes de cisalhamento direto sob diferentes condições de contorno tendo como variáveis de entrada σ_{no} em MPa, ϕ_b em graus, JRC, k_n em kPa/mm, δ_h em mm tendo como saída a δ_v em mm e τ_h em kPa. Sobre os resultados gerais de Matos (2018), o modelo ANFIS (Modelo Neuro-Fuzzy adaptativo) desenvolvido foi avaliado como o melhor em termos de resultados. Esses modelos comparados com o de Dantas Neto *et al.* (2017), possuem como vantagem a

quantificação das incertezas relacionadas ao problema e como desvantagem, a necessidade da posse do software MATLAB para aplicação do modelo.

2.2 Descontinuidades com preenchimento

Sendo as descontinuidades rochosas planos onde eventualmente há uma ausência ou diminuição de contato rocha à rocha, é comum a presença quase constante de algum tipo de preenchimento (BARTON, 1972). Tais preenchimentos podem ser em virtude do carreamento de material, devido às águas das chuvas, vento ou gravidade; podem ser por efeito do intemperismo físico e químico da descontinuidade em si, justamente por ser uma região mais sensível às ações da natureza (ZEIGLER, 1972).

As características friccionalis dos minerais tem significativa influência na estabilidade das descontinuidades rochosas (HORN E DEERE, 1962). O aumento de umidade nas descontinuidades com alta quantidade de material argiloso poderia ter sido a causa de falha de maciços rochosos, sendo esse o fator responsável por falhas em túneis e minas abertas que ocorreram no tempo. Presença essa dos preenchimentos também apontada como possível causa da rupturas de taludes mesmo a pequenos níveis de stress (LADANYI E ARCHAMBAULT, 1969).

Goodman (1969) executou ensaios de cisalhamento direto em diversos tipos de descontinuidades limpas e preenchidas de argila com diferentes espessuras. O autor usou a expressão da Equação 2.15 para quantificar da relação entre amplitude das irregularidades com a espessura do preenchimento, pois foi observado que o aumento da porcentagem do preenchimento ocasionava a diminuição da resistência da descontinuidade tendendo à um valor constante próximo ao da resistência do preenchimento (Figura 2.10).

$$\text{porcentagem do preenchimento} = \frac{\text{espessura do preenchimento}}{\text{amplitude da irregularidade}} \times 100 \quad (2.15)$$

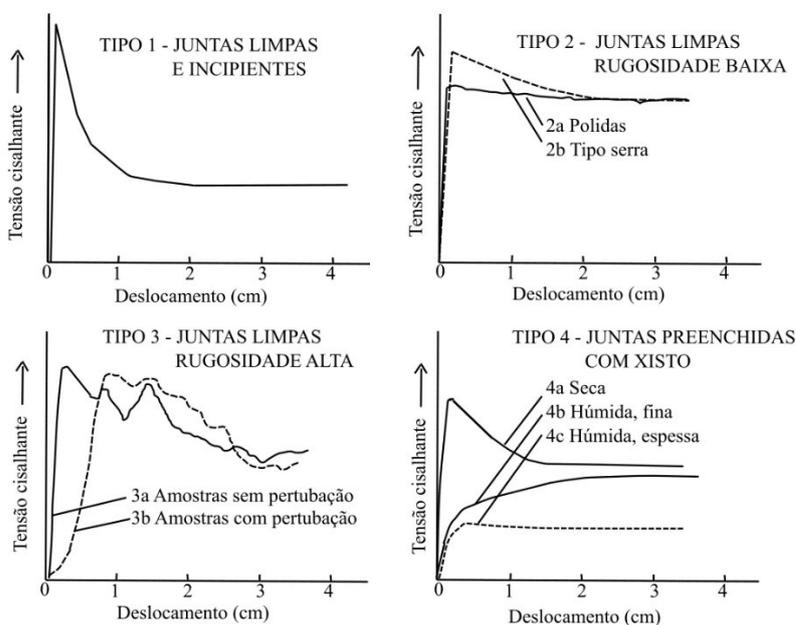
Figura 2.10 – Efeito do aumento da espessura do preenchimento na resistência cisalhante da descontinuidade preenchida.



Fonte: Adaptado de Goodman (1969).

A Figura 2.11 relativa ao estudo de Goodman (1969), apresenta diferentes tipos comportamento de tensão cisalhante com deslocamento, obtidos nos ensaios de cisalhamento direto em diferentes tipos de descontinuidades idealizadas e reais. Os tipos 1 e 2 apresentaram pouca, quase nenhuma não-linearidade, enquanto os tipos 3 e 4 apresentam progressivamente maior não-linearidade, sendo ainda mais perceptível com a presença do preenchimento e da umidade.

Figura 2.11 – Ensaios de cisalhamento direto para diferentes tipos de descontinuidades com e sem preenchimento

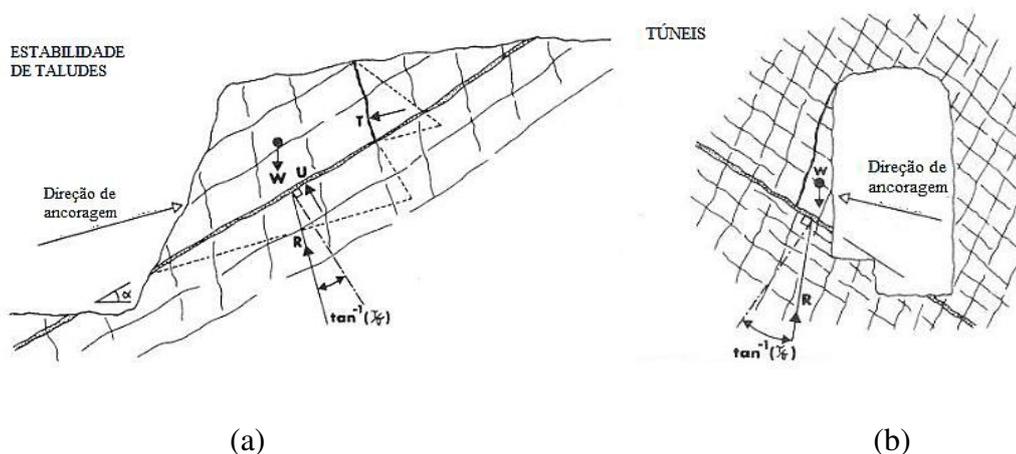


Fonte: Adaptado de Goodman (1969).

Na pesquisa de Zeigler (1972) foram comparados os resultados do ensaio de cisalhamento direto entre descontinuidade com e sem preenchimento, da rocha intacta e no contato entre concreto com rocha; sobre essa comparação a rocha intacta apresentou maior valor de resistência, enquanto a rocha preenchida a menor. Algumas de suas conclusões foi que o comportamento dessas descontinuidades preenchidas seria uma relação complexa entre resistência do preenchimento, espessura do preenchimento, condições de umidade, grau de consolidação, poro pressão em argilas, média da altura das asperezas, resistência da face da rocha e proporção da área curada da descontinuidade.

Em seu estudo sobre o efeito do preenchimento nas descontinuidades, Barton (1973a) descreveu a importância de se considerar o preenchimento ao se trabalhar com a resistência ao cisalhamento das descontinuidades. A Figura 2.12 apresenta dois exemplos onde a presença de preenchimento deve ser contabilizada no dia-a-dia da engenharia, como no caso de equilíbrio limite de um talude rochoso ou de blocos em túneis em casos de escorregamento, onde a desconsideração da diminuição da resistência ao cisalhamento pela presença do preenchimento é contra a segurança. O autor também chamou atenção para ocorrência de sobre adensamento de argilas do preenchimento e o efeito que isso teria na resistência ao cisalhamento.

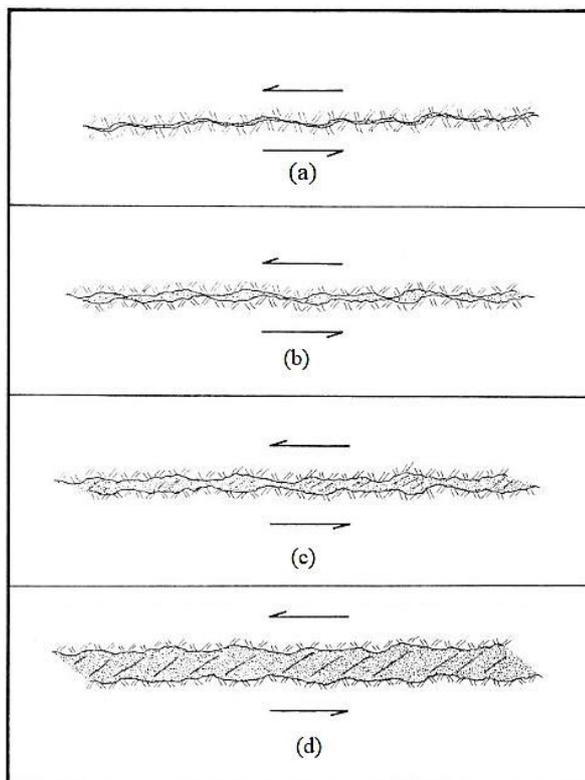
Figura 2.12 – Ocorrências na engenharia de preenchimento nas descontinuidades que torna necessária o conhecimento da resistência ao cisalhamento.



Fonte: Adaptado de Barton (1973a).

Barton (1973a) fez uma ilustração qualitativa (Figura 2.13) sobre as quatro possibilidades de preenchimento e suas relações com a resistência ao cisalhamento das descontinuidades com e sem preenchimento. O autor fez as seguintes considerações sobre cada caso:

Figura 2.13 – Quatro categorias de espessura de preenchimento na descontinuidade.



Fonte: Adaptado de Barton (1973a).

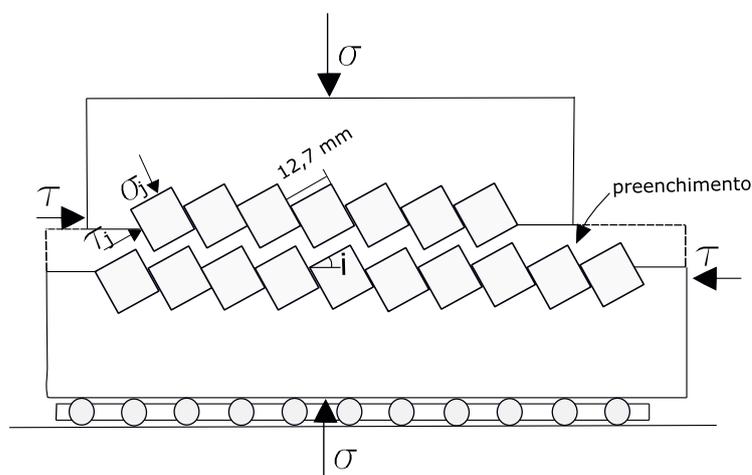
- Figura 2.13a: representa a situação na qual há um contato quase imediato entre as paredes das descontinuidades durante o processo de cisalhamento, com uma pequena porção de preenchimento entre elas. Neste caso, existe a tendência de haver uma pequena variação da tensão cisalhante mobilizada e da dilatância da descontinuidade quando comparado aos valores obtidos para a descontinuidade sem preenchimento. Sensível redução da dilatância na tensão de pico quando o preenchimento for argiloso devido à “adesividade” do mesmo. Tem-se ainda, que caso a velocidade de cisalhamento seja elevada, ocorram poropressões negativas.
- Figura 2.13b: poderá desenvolver o mesmo contato rocha/rocha que na Figura 2.13a, contudo somente após algum deslocamento. Dilatância, no momento que atingida a tensão cisalhante de pico, consideravelmente reduzida. Nesse a posição da tensão de pico será semelhante a tensão residual da descontinuidade limpa. Semelhante condição de “adesividade” que em Figura 2.13a. Menor tendência de poropressão negativa.

- Figura 2.13c: nessa situação não haverá um contato rocha/rocha mas haverá picos de tensão no preenchimento onde as asperezas das rochas se encontrarem próximas. Se a velocidade de cisalhamento for rápida gerará um aumento da poropressão e uma conseqüente diminuição da tensão cisalhante nesses pontos. Caso for lenta haverá adensamento e drenagem.
- Figura 2.13d: no caso que a amplitude do preenchimento é substancialmente maior que a da aspereza, a influência da face da rocha irá desaparecer e a resistência seguirá os princípios da mecânica dos solos.

Para o contato da interface entre rocha e solo, resultados de campo evidenciaram que a menor resistência se daria no contato rocha/solo (RICHARD, 1975; PAPALIANGAS *et al.*, 1990). Richard (1975) salientou que deveria haver a consideração sobre o histórico de carga na descontinuidade preenchida, para se avaliar o possível sobreadensamento do solo, pois tal fato influenciaria no resultado da resistência ao cisalhamento.

Ladanyi e Archambault (1977) realizaram ensaios de cisalhamento direto em descontinuidades triangulares (Figura 2.14), com preenchimento de argila caulinita e silte argiloso. Os autores observaram que a resistência das descontinuidades varia entre a resistência da mesma sem preenchimento e a do material do preenchimento. Verificou que a resistência ao cisalhamento diminuía com o aumento da quantidade do preenchimento, tendo a tensão de pico dos seus experimentos chegando à uma redução de 66% quando comparando a percentagem do preenchimento com 10% e 100%, assim como uma gradual diminuição da dilatância até tê-la como negativa com aumento do preenchimento.

Figura 2.14 – Diagrama esquemático do equipamento de cisalhamento direto das descontinuidades preenchidas.



Fonte: Adaptado de Ladanyi e Archambault (1977)

Ladanyi e Archambault (1977) propuseram um modelo baseado em dois domínios para prever o comportamento cisalhante de juntas preenchidas com argila, tendo os autores recomendado o uso da equação de Patton (1966) na ausência de preenchimento. No primeiro domínio, não haveria a quebra das rugosidades, é uma expansão da teoria de Patton (1966) para contabilizar o preenchimento. Nesta primeira condição a tensão de pico seria dada pela Equação 2.16.

$$\tau_p = \frac{c_u}{(1 - \tan i' \cdot \tan \phi_b)} + \sigma_n \cdot \tan(\phi_{\text{fill}} + i') \quad (2.16)$$

Onde:

c_u é parâmetro da tensão cisalhante da argila não-drenada;

i' é o ângulo da dilatância no pico com $\tan(i') = m \cdot \tan(i_o)$;

ϕ_{fill} é o ângulo de atrito do preenchimento;

m é um fator redutor que varia entre 0 e 1, conforme expresso na Equação 2.17.

$$m = \begin{cases} \left[1 - \frac{2}{3} \left(\frac{t}{a}\right)\right]^2 & \text{para } \frac{t}{a} \leq 1,5 \\ 0 & \text{para } \frac{t}{a} > 1,5 \end{cases} \quad (2.17)$$

Onde:

t/a é razão da amplitude do preenchimento pela amplitude da rugosidade.

Na segunda condição do modelo de Ladanyi e Archambault (1977), há a quebra da rugosidade, a relação proposta é válida para os limites $30^\circ \leq i_o \leq 45^\circ$ e $0,1 < \sigma_n / \sigma_c \leq 0,5$. A condição é a exposta pela Equação 2.18, tal R é a resistência da junta sem preenchimento $R = \sigma_n \cdot \tan(\phi_b + i')$ e C é a resistência ao cisalhamento do preenchimento dado por $C = c_u + \sigma_n \cdot \tan(\phi_{\text{fill}})$. O ângulo da dilatância no pico para a junta sem preenchimento é dada pela Equação 2.19

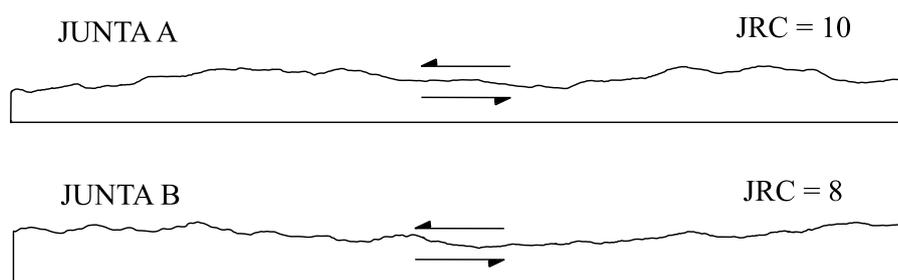
$$S = m \cdot (R - C) + C \quad (2.18)$$

$$\tan(i') = \left[1 - \left(\frac{\sigma_n}{\sigma_c}\right)\right]^{1/4} \cdot \tan(i_o) \quad (2.19)$$

Papaliangas *et al.* (1990, 1993) estudaram sobre a resistência de cisalhamento de descontinuidades preenchidas com materiais finos granulares, por meio de ensaios de

cisalhamento direto em juntas replicadas rochosas de arenito moldadas com diferentes valores de JRC (Figura 2.15). Seus resultados indicaram a diminuição da resistência ao cisalhamento com o aumento do t/a até um valor crítico (t/a_{cr}) entre 1,25 e 1,5, onde a resistência teria uma tendência à um valor menor constante, semelhante à do material do preenchimento.

Figura 2.15 – Perfis das descontinuidades ensaiadas por Papaliangas *et al.* (1990).

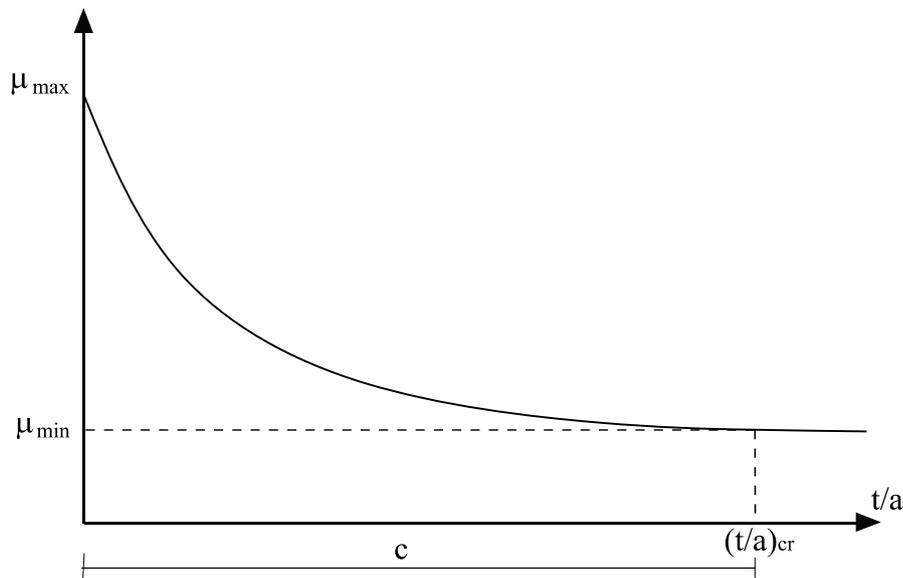


Fonte: Adaptado de Papaliangas *et al.* (1990).

Papaliangas *et al.* (1990) propôs um modelo empírico para tensão cisalhante de pico de descontinuidades preenchidas a partir do cálculo do coeficiente de atrito, conforme apresentada na Figura 2.16. Segundo esse modelo a tensão varia entre um valor máximo, referente a ausência do preenchimento, à um valor mínimo, onde t/a atingiria seu crítico. A Equação 2.20 descreve o modelo onde: μ_{\max} é o coeficiente de fricção para descontinuidade sem preenchimento, μ_{\min} é o mínimo, c e m são constantes experimentais. A τ_p será a dado pela Equação 2.4 com Equação 2.20.

$$\mu = \mu_{\min} + (\mu_{\max} - \mu_{\min}) \left[1 - \frac{1}{c} \left(\frac{t}{a} \right) \right]^m \quad (2.20)$$

Figura 2.16 – Proposta empírica para relação entre resistência ao cisalhamento de descontinuidades preenchidas e razão t/a .



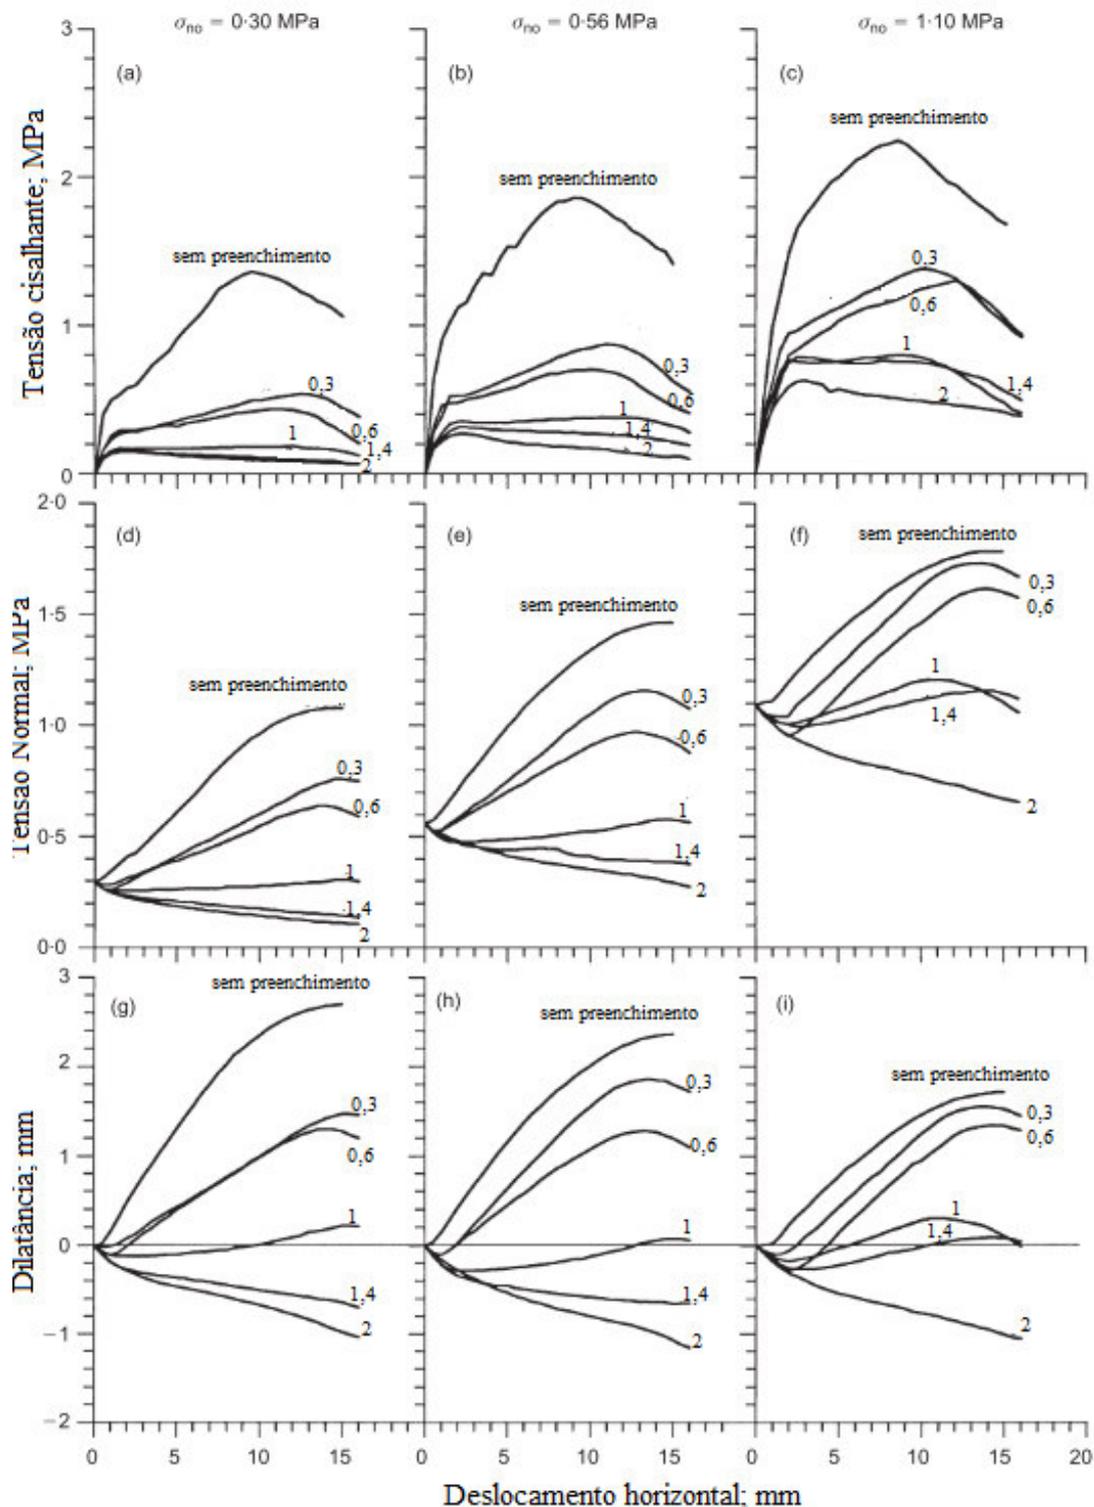
Fonte: Adaptado de Papaliangas et al. (1990).

Oliveira *et al.* (2009) apontam como maior desvantagem no modelo de Papaliangas *et al.* (1990) o requerimento da constante m para varias razões de t/a antecipadamente e por não levar em consideração parametros governantes como ϕ_b , ϕ_{fill} e i .

Os trabalhos citados até o momento foram desenvolvidos sob a condição de contorno CNL. Haque (1999) realizou um estudo experimental sobre o comportamento cisalhante de descontinuidades triangulares (*saw-tooth*) referente à rochas brandas idealizadas (Tipo I e Tipo II Figura 2.8), preenchidas com betonita comercial, sob a condição CNS.

Haque (1999) verificou os resultado de testes CNS são diferentes dos testes CNL principalmente na alteração da tensão normal e dilatância durante cisalhamento. Foi observado que o t/a crítico obtido nos testes de CNS de valores entre 1,4 e 1,8. A Figura 2.17 apresenta a descontinuidade tipo II preenchida sendo ensaiadas sob condição CNS com diferentes t/a e diferentes tensões normais aplicadas. Particularidades desse comportamento segundo os ensaios: aumento da tensão cisalhante com o aumento da tensão normal aplicada; comportamento não linear; diminuição da tensão cisalhante, normal e dilatância com o aumento do t/a , sendo expressivo até para valores de $t/a = 0,3$; dilatância negativa para t/a acima de 1 indicando a compressão do preenchimento;

Figura 2.17 – Comportamento cisalhante de discontinuidades Tipo II preenchidas sob diferentes tensões normais e valores de t/a .



Fonte: Adaptado de Haque (1999)

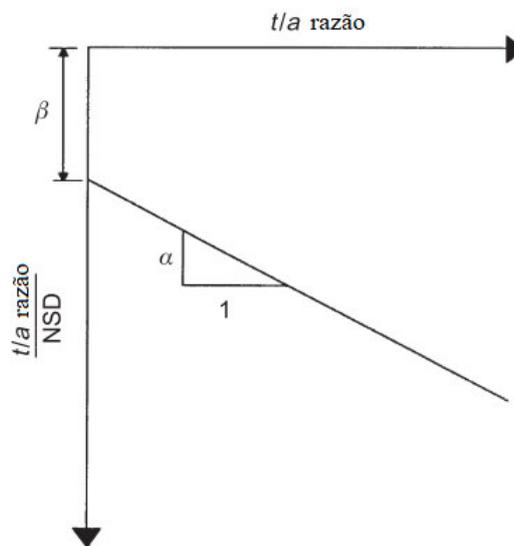
Haque (1999) propôs o parâmetro (NSD) para expressar a diminuição da tensão cisalhante com o aumento da t/a . Onde α e β são parâmetros obtidos por um ajuste dados experimentais com a Equação 2.21, graficamente ilustrada na Figura 2.18. A τ_p para descontinuidade preenchida sob condição CNS por ser dada, portanto pela Equação 2.22, uma

vez que a tensão normal inicialmente aplicada e a tensão de pico da descontinuidade limpa forem conhecidas.

$$NSD = \frac{t/a}{\alpha \left(\frac{t}{a}\right) + \beta} \quad (2.21)$$

$$\tau_p \text{ (com preenchimento)} = \tau_p \text{ (limpa)} - \sigma_{no} \times NSD \quad (2.22)$$

Figura 2.18 – Formulação para obtenção dos parâmetros para cálculo do NSD



Fonte: Adaptado de Haque (1999)

Haque (1999), sugeriu um modelo para a previsão da tensão de pico com preenchimento e sob condições CNL e CNS, quantificada pela Equação 2.23. A desvantagem desse modelo se dá por além dos testes obtidos serem de perfis triangulares, é necessário a obtenção dos coeficientes de Fourier para prever o comportamento completo.

$$\tau_p \text{ (preenchida)} = \left[\sigma_{no} + \frac{k_n}{A} \left(\frac{a_0}{2} + a_1 \cos \frac{2\pi h_{tp}}{T} \right) \right] \left[\frac{\tan(\phi_b) + \tan(i_o)}{1 - \tan(\phi_b)\tan(i_{hp})} \right] - \sigma_{no} \frac{t/a}{\alpha \left(\frac{t}{a}\right) + \beta} \quad (2.23)$$

Onde:

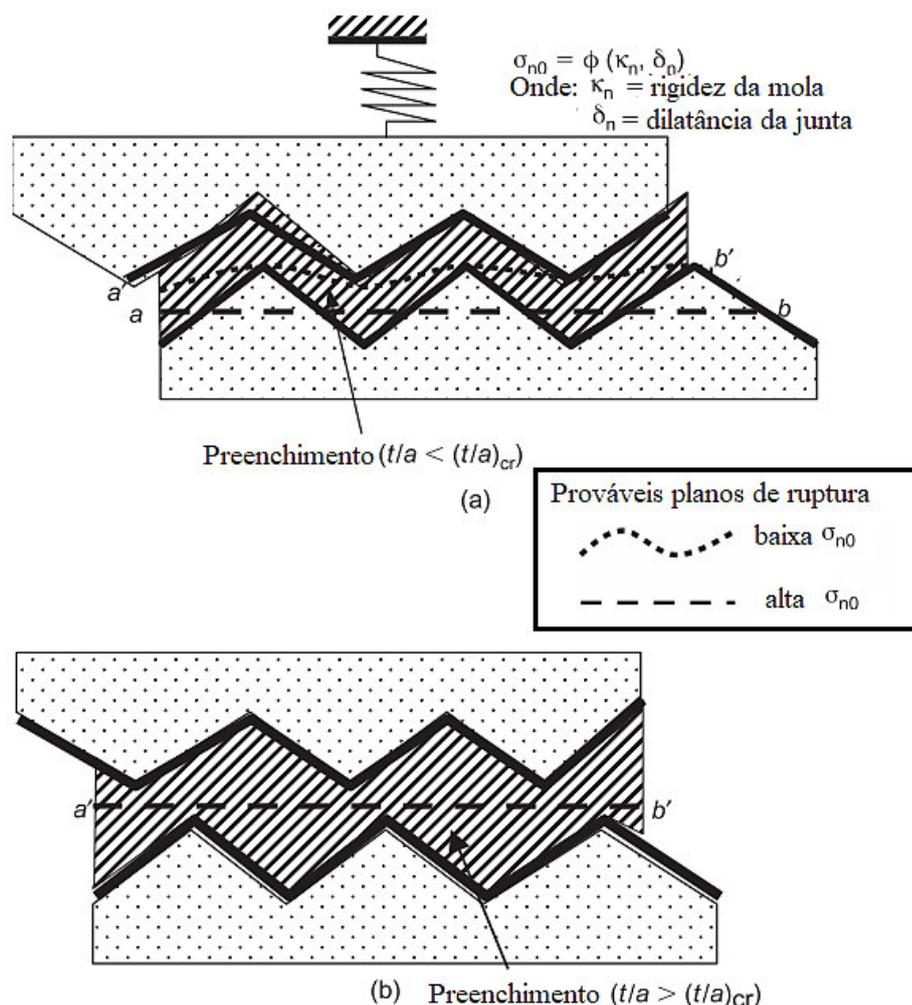
h_{tp} é o deslocamento horizontal no pico;

i_{hp} é a dilatação no pico;

a_0 e a_1 são coeficientes relacionados à série de Fourier.

Indraratna *et al.* (2005) propuseram um modelo para descrever a tensão cisalhante de pico para discontinuidades preenchidas sob condição CNS. Esse modelo apresenta a propagação da falha em duas diferentes possibilidades. No primeiro caso, Figura 2.19a, o t/a seria menor que um valor crítico; para baixas tensões normais, o plano seria seguiria o padrão (a'b'), não sendo suficiente para cisalhar as asperezas; para altas tensões normais a falha seria horizontal (ab), através das asperezas. O segundo caso (Figura 2.19b) é válido para t/a acima do valor crítico, condicionando assim o cisalhamento ocorresse somente pelo preenchimento.

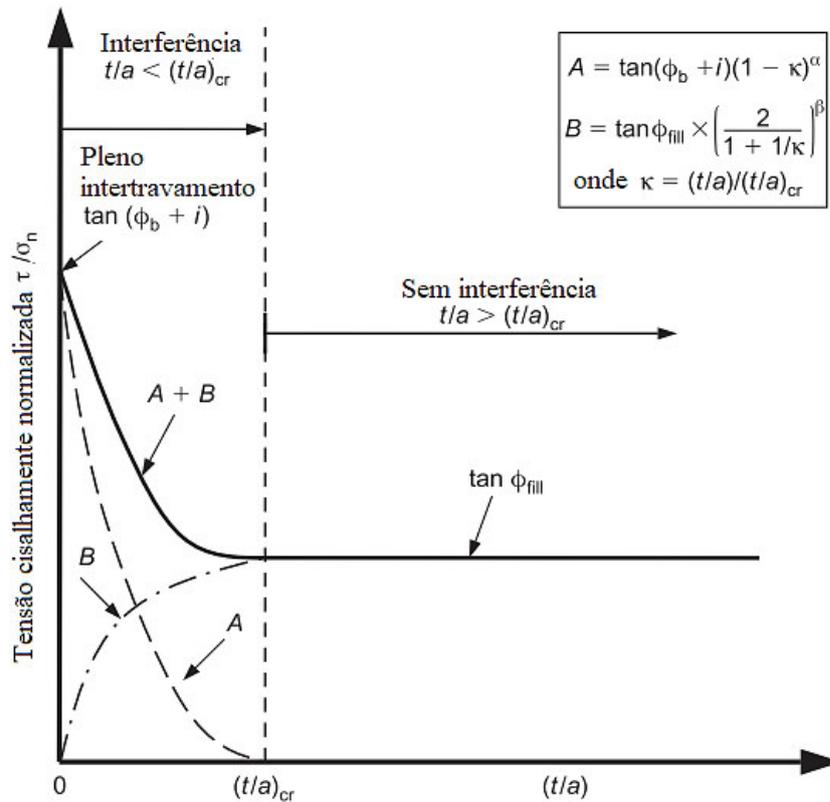
Figura 2.19 – Modos de falha para juntas preenchidas



Fonte: Adaptado de Indraratna *et al.* (2005).

O modelo então formulado para calcular a resistência cisalhante é composto por duas funções algébricas cuja soma, resulta na tensão cisalhante normalizada (τ_p/σ_n) para diferentes t/a até o valor t/a crítico. Para t/a acima do crítico, a resistência seria dependente da resistência do preenchimento apenas. A função está graficamente apresentada na Figura 2.20.

Figura 2.20 – Modelo da tensão cisalhante para juntas preenchidas.



Fonte: Adaptado de Indraratna *et al.* (2005).

Como relatado anteriormente, o modelo Indraratna *et al.* (2005) seria representado pelo primeiro caso (Equação 2.24) para t/a menor que o crítico, onde o cisalhamento estaria em função do preenchimento e da descontinuidade. Para o t/a acima do crítico, o modelo cisalhamento só levaria em conta a resistência do preenchimento (Equação 2.25).

$$\frac{\tau_p^{(fill)} - c'_{fill}}{\sigma_n} = A + B = \tan(\phi_b + i) \times \left(1 - \frac{t/a}{t/a_{cr}} \right)^\alpha + \tan \phi_{fill} \times \left(\frac{2}{1 + t/a_{cr}/t/a} \right)^\beta \quad (2.24)$$

$$\frac{\tau_p^{(fill)} - c'_{fill}}{\sigma_n} = \tan \phi_{fill} \quad (2.25)$$

Onde:

c'_{fill} é a coesão efetiva do preenchimento;

α e β são constantes empíricas definidas pela alocação na função A e B;

A é a parcela da resistência fornecida pelo preenchimento;

B é a parcela da resistência fornecida pelas asperezas.

Oliveira *et al.* (2009) sugeriu alterações para a Equação 2.24, referente à parcela A, resistência ao cisalhamento do preenchimento. Nesta alteração que houve maior correlação com seus dados experimentais, ao invés da parcela $\tan(\phi_b + i)$, inclui-se a parcela referente ao balanço energético tendo então a Equação 2.26.

$$\frac{\tau_p(\text{fill}) - c'_{\text{fill}}}{\sigma_n} = \left\{ \frac{[\tan(\phi_b) + \tan(i_0)]}{[1 - \tan(\phi_b) \times \tan(i_{\text{hp}}(\text{limpa}))]} \right\} \times \left(1 - \frac{t/a}{t/a_{\text{cr}}} \right)^\alpha + \tan\phi_{\text{fill}} \times \left(\frac{2}{1 + \frac{t/a_{\text{cr}}}{t/a}} \right)^\beta \quad (2.26)$$

Indraratna *et al.* (2008a, 2008b, 2014) propuseram modelos semelhantes ao de Oliveira *et al.* (2009), mas contando com o pré-adensamento do preenchimento. Indraratna *et al.* (2013), Premadasa e Indraratna (2015) também, mas levando em consideração o grau de saturação do preenchimento.

Shrivastava e Rao (2017) desenvolveram um modelo para obtenção da tensão cisalhante de pico de discontinuidades rochosas preenchidas após um estudo experimental de ensaios de cisalhamento direto em juntas triangulares sob condição CNL e CNS, para diferentes valores da razão t/a e diferentes condições de rugosidade. Assim como os modelos de Indraratna *et al.* (2005) e os semelhantes, baseados nele citados Indraratna *et al.* (2008a, 2008b, 2013, 2014), Oliveira *et al.* (2009), Premadasa e Indraratna (2015), o modelo de Shrivastava e Rao (2017) também foi baseado do modelo básico proposto por Patton (1966) apresentado na Equação 2.2. O modelo de Shrivastava e Rao (2017) é a seguir apresentado na Equação 2.27.

$$\tau_p = (a\sigma_n + b) \tan \left[\phi_b + x \ln \left(\frac{a\sigma_n + b}{\sigma_c} + y \right) \times i \right] \quad (2.27)$$

Onde a e b são constantes e a pode ser aproximado 1 e b entre 0 à 0,36 para k_n de 0 à 8 kN/mm e x e y são coeficientes dependentes de t/a tal qual indica a Tabela 2.4.

Tabela 2.4 – Coeficiente x e y para diferentes valores de t/a

i	t/a	X	Y	r^2
30°–30°	0	–0.30	–0.356	0.95
	1	–0.26	–0.494	0.96
	1.4	–0.33	–0.821	0.99
	2	–0.13	–0.906	0.75
15°–15°	1	–0.51	–1.14	0.88
0°–0°	$t = 5 \text{ mm}$	–0.07	0.73	0.99

2.3 Conclusões parciais

Pode-se perceber que a previsão do comportamento cisalhante das descontinuidades rochosas é de uma complexidade considerável devido à quantidade grande de variáveis envolvidas e às diferentes condições de contorno que podem ser consideradas.

Seguindo a cronologia dos estudos, nota-se o aumento das variáveis consideradas para terminação da tensão cisalhante das descontinuidades. Os primeiros modelos foram criados para determinação da τ_p para descontinuidades na condição CNL e sem preenchimento. Esses levaram em consideração alguns elementos avaliados pelos autores, devidos aos ensaios realizados, como relevantes para o τ_p tais como: tensão normal inicial aplicada (σ_{no}); os parâmetros relativos a resistência uniaxial sendo esses σ_c ou JCS; as características das rugosidades, sendo essas ϕ_b , ϕ_r , JRC, i . Muitos desses modelos antigos ainda são bastante usados hoje em dia, contudo corresponde a uma baixa frequência de aparecimento em campo.

Ainda sobre descontinuidades sem preenchimento e sob condição CNL, estudos foram realizados substituindo os parâmetros JRC e i , por quantificações da área por meio de escaneamento tridimensional. Essa vertente de estudo, apresentou resultados melhores que os modelos convencionais contudo, essa quantificação implica na necessidade de equipamento específicos para fazer escaneamento.

Modelos analíticos e gráficos foram criados buscando quantificar o comportamento cisalhante de descontinuidades sem preenchimento sob condição CNS. Nesses os parâmetros utilizados diferente dos modelos em CNL, foi na grande maioria a rigidez da normal (k_n), e em casos específicos a rigidez transversal (k_s). Dentro dos modelos estudados, as maiores deficiências encontradas foram: necessidades de ensaios CNL antecipadamente para obter parâmetros da equação; modelos testados com poucos dados experimentais.

Levando em consideração a presença dos preenchimentos, modelos foram desenvolvidos visando a obtenção da resistência cisalhante e dilatância no pico. Nesses foi observado o quanto mais fatores ainda poderiam ser levados em consideração, tornando o problema ainda mais complexo. Alguns parâmetros dos preenchimentos levados em consideração foram: razão entre a amplitude do preenchimento e da rugosidade (t/a); t/a crítico referente à quando o preenchimento é espesso o suficiente para ser o único governante do comportamento cisalhante (valores de 1,25 à 2,0 foram encontrados na literatura); ângulo de atrito do preenchimento (ϕ_{fill}); coesão do preenchimento (c); grau de sobreadensamento (OCR);

grau de saturação. Os modelos avaliados, além precisarem de ensaios anteriores para obtenção das constantes das fórmulas, só trazem a informação da tensão de pico, e não do comportamento cisalhante

Saindo ao fim, dessa proposta analítica convencional para previsão do comportamento cisalhante, e visando utilizar a inteligência artificial para previsão dos resultados, alguns modelos de redes neurais artificiais, fuzzy e neuro-fuzzy surgem como uma forma satisfatória com bons resultados de previsão da resistência cisalhante de descontinuidades limpas, requerendo como dados de entrada parâmetros que não precisam de ensaios laboratoriais para se obter. Tais modelos não se apresentam como substitutivo aos demais, mas como uma ferramenta que pode ser usada paralelamente para obtenção de dados de dilatância e tensão cisalhante de forma rápida e prática, podendo ser útil para aplicações rápidas usualmente necessárias no dia-a-dia da engenharia. Contudo, esses modelos não levam em consideração a presença do preenchimento, e tal particularidade passa a ser a motivação do trabalho em questão.

3 DESENVOLVIMENTO DOS MODELOS

Neste capítulo está a explanação acerca dos princípios e fundamentações sobre as redes neurais artificiais, descrição sobre a seleção dos dados, experimentos utilizados e demais procedimentos realizados para o desenvolvimento dos modelos neuronais para previsão da tensão cisalhante e dilatância com o deslocamento horizontal, e para previsão da resistência cisalhante de pico das descontinuidades rochosas.

Com intuito de sintetizar o procedimento de desenvolvimento dessa pesquisa, a mesma foi realizada nas seguintes etapas: análise e tratamento de dados, seleção dos dados, avaliação da eficiência dos modelos, definição dos melhores modelos para previsão dos resultados a que se propõe o trabalho.

3.1 RNA conceitos básicos

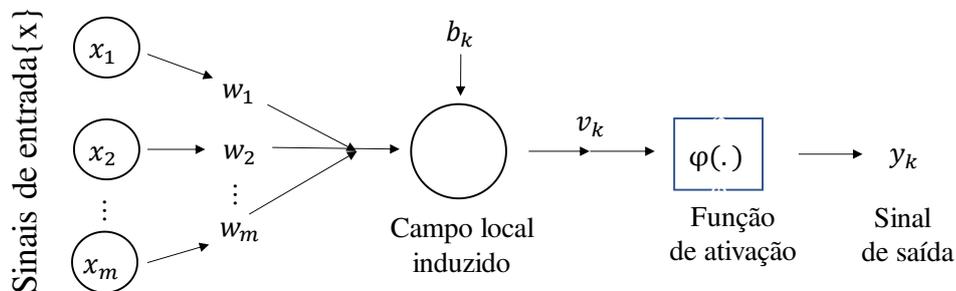
Diversos trabalhos na área de Mecânica das Rochas foram desenvolvidos utilizando as redes neurais como ferramenta importante e valiosa para o desenvolvimento de modelos de previsão. Na sua maioria contemplam a previsão de propriedades da rocha intacta como a resistência à compressão uniaxial como Meulenkamp e Grima (1999), Moshrefii *et al.* (2018); o módulo de elasticidade como Sonmez *et al.* (2006), Yilmaz e Yusek (2008), Dehghan *et al.* (2010); resistência à tração em Singh *et al.* (2001). No que se refere ao desenvolvimento de modelos de previsão para descontinuidades rochosas utilizando perceptron multicamadas (MLP) vale citar os trabalhos de Dantas Neto *et al.* (2016, 2017) e Leite *et al.* (2019).

RNA são modelos computacionais de inteligência artificial, aprendizado em máquina, baseados no cérebro humano e na sua capacidade de previsão de resultados a partir do reconhecimento de padrões proveniente da experiência por exemplos previamente estudados (RIPLEY, 1996). O seu desenvolvimento matemático é baseado na idealização da forma como os neurônios humanos funcionam e na sua capacidade de percepção e aprendizagem de fenômenos complexos, não lineares, e multivariados (BISHOP, 1995; HAYKIN, 2008; DANTAS NETO *et al.*, 2017; SCHMIDHUBER, 2015).

Para as RNA, a unidade básica para seu processamento de informação é o neurônio artificial, composto por uma função de ativação (BISHOP, 1995; HAYKIN, 2008). O sistema é descrito e formalmente apresentado por Haykin (2008). O resultado é obtido pela

aplicação sucessiva das Equações 3.1, 3.2 e 3.3, sendo esquematicamente representado na Figura 3.1. Fazendo uma associação com os neurônios biológicos, os pesos sinápticos (w_m) funcionam analogamente aos sinais sinápticos, que são mutáveis no decorrer do treinamento do modelo neuronal. Os bias (b_k), também mutáveis no decorrer do treinamento, tem a função de aumentar ou diminuir a entrada líquida da função de ativação. O campo local induzido (v_k) é uma combinação linear de todos os sinais de entrada no neurônio ponderados com seus respectivos pesos sinápticos. A função de ativação que pode ser triangular, parabólica, sigmóide, entre outras, representa o sinal de saída do neurônio, usualmente com amplitude normalizada entre $[0,1]$ ou $[-1,1]$ (HAYKIN, 2008).

Figura 3.1 – Modelo não-linear de um neurônio k



Fonte: Adaptado de Haykin (2008).

$$u_k = \sum w_m x_m = \{w\}^T \{x\} \quad (3.1)$$

$$v_k = u_k + b_k = \{w\}^T \{x\} + b_k \quad (3.2)$$

$$y_k = \varphi(v_k) = \varphi(\{w\}^T \{x\} + b_k) \quad (3.3)$$

Onde:

u_k = saída do combinador linear;

x_m = sinais de entrada;

$\varphi(.)$ = função de ativação do neurônio;

y_k = resultado saída do neurônio.

A normalização dos dados ocorre conforme a Equação 3.4, usada para comparar devidamente grandezas distintas com diferentes ordens de magnitude.

$$\frac{X' - X_{nor, min}}{X_{nor, max} - X_{nor, min}} = \frac{X - X_{min}}{X_{máx} - X_{min}} \quad (3.4)$$

Onde:

X' = variável resultante da normalização;

X = variável a ser normalizada;

$X_{\text{nor, mín}}$ = valor mínimo da normalização escolhida;

$X_{\text{nor, máx}}$ = valor máximo da normalização escolhida.

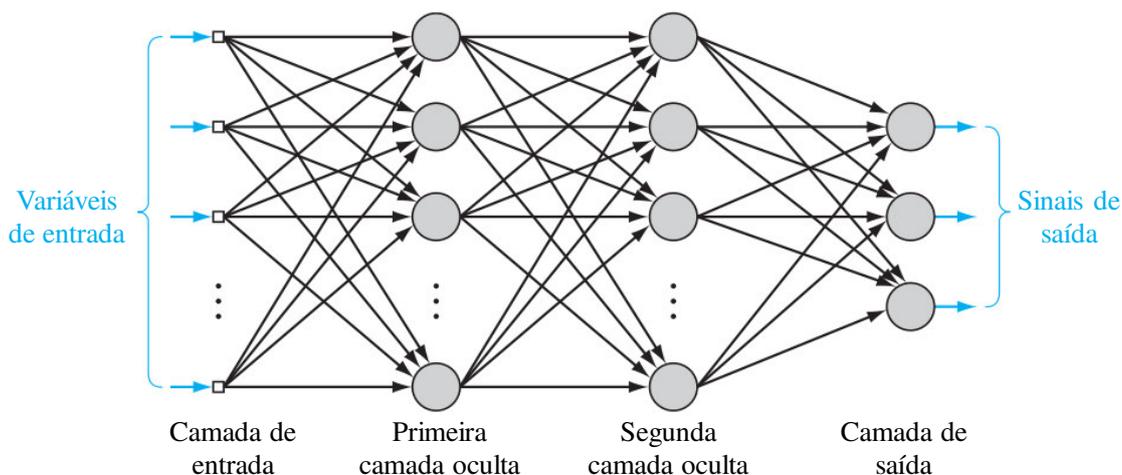
$X_{\text{mín}}$ = valor mínimo da variável a ser normalizada;

$X_{\text{máx}}$ = valor máximo da variável a ser normalizada.

Dentre os diferentes tipos de redes neurais artificiais existentes, com aplicações comprovadamente eficientes na engenharia, pode-se citar o perceptron multicamadas (MLP) (RIPLEY, 1996; BISHOP, 2006; HAYKIN, 2008; DANTAS NETO *et al.*, 2014, 2016, 2017; LEITE *et al.* 2019). Esse sistema consiste em uma rede neural com uma ou mais camadas ocultas paralelas, que tem como intuito aumentar a eficiência das ligações como ocorre no sistema nervoso humano.

A Figura 3.2 apresenta um exemplo de MLP com duas camadas ocultas. Nesse tipo de rede, a escolha da quantidade de neurônios nas camadas ocultas, assim como o número de camadas ocultas, são alguns dos elementos mais complexos e importantes a serem usados, essa variação do número de neurônios é chamada de arquitetura. Um número de neurônios reduzido não diminuiria satisfatoriamente o erro, enquanto um número grande poderia levar à uma falta de capacidade de generalização podendo gerar um processo de “overfitting” (RUNXUAN, 2005; SINGH E SINGH, 2006). Na maior parte dos algoritmos com aprendizado supervisionado, quando já se sabe o valor requerido dos neurônios de saída, esse número de neurônios escondidos só pode ser obtido por tentativa e erro (RUNXUAN, 2005).

Figura 3.2 – Exemplo de uma arquitetura de perceptron com duas camadas ocultas

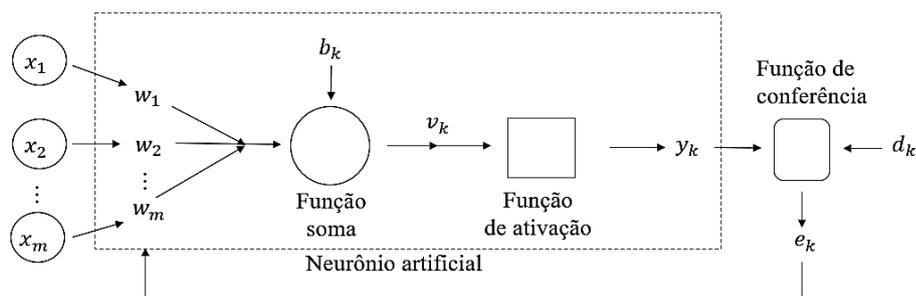


Fonte: Adaptado de Haykin (2008).

Uma das propriedades de uma rede neural é a sua habilidade de aprender a partir do ambiente na qual está inserida para que possa melhorar seu desempenho. Este recurso para rede neural é chamado de treinamento. O processo consiste na alteração de todos os pesos sinápticos (w_m) e bias (b_k), a partir da experiência obtida sobre o fenômeno estudado no decorrer de um número de iterações. Essa experiência, no chamado aprendizado supervisionado, é obtida por meio de um conjunto de dados do tipo entrada-saída conhecida disponível a partir do erro obtido entre eles (HAYKIN, 2008). O sinal de erro e_k é calculado a partir da diferença entre o valor de saída do neurônio no treinamento (y_k) com o valor desejado do neurônio de saída (d_k) para cada iteração durante o treinamento como apresentado na Equação 3.5 e exposto na Figura 3.3.

$$e_k = d_k - y_k. \quad (3.5)$$

Figura 3.3 – Aprendizado por correção de erro



Fonte: Autora.

Para aperfeiçoar os resultados das redes de alimentação progressiva, um método bastante utilizado é o algoritmo de retropropagação do erro. Esse algoritmo tem como objetivo otimizar a rede, levando ao menor erro por meio da minimização uma função de custo, sendo essa o erro médio quadrático (RMS) (Equação 3.6). A otimização se dar por meio do cálculo do erro e da retropropagação do sinal pelos neurônios ocultos de forma iterativa, otimizando os bias e pesos sinápticos até que o critério de parada seja atingido. (WERBOS, 1974; RUMELHART ET AL., 1985).

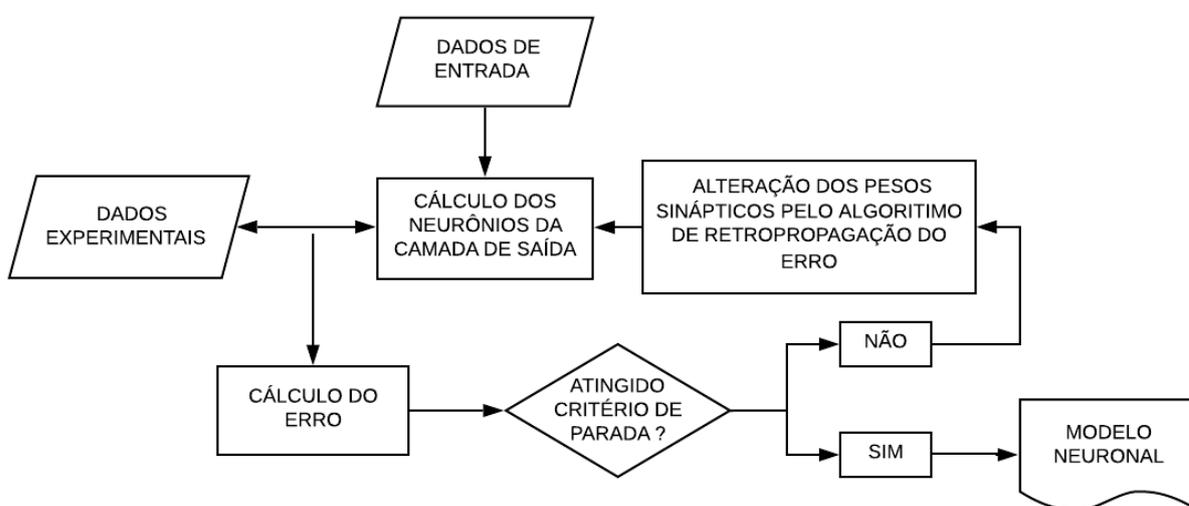
$$\xi(e_k) = \frac{1}{2} \sum e_k^2. \quad (3.6)$$

Sintetizando, o processo começa com a inserção das variáveis de entrada normalizadas usadas para o treinamento da rede, essa informação é passada de neurônio à neurônio calculada com os pesos sinápticos e bias gerados aleatoriamente. Ao fim a rede

proverá nos dados de saída, o resultado calculado, e esse será comparado com os dados experimentais do treinamento referente a cada conjunto de variável de entrada.

Desse processo inicial surgirá um erro referente a diferença entre o obtido e o almejado e, visando a minimização desse, haverá uma alteração dos pesos sinápticos e bias por meio de cálculos de gradientes iterativos correspondente ao algoritmo de retropropagação. Esse processo ocorrerá em iterações até que o critério de parada seja atingido. A Figura 3.4 apresenta o fluxograma do aprendizado dos modelos neuronais.

Figura 3.4 – Esquemática do treinamento de um modelo neuronal

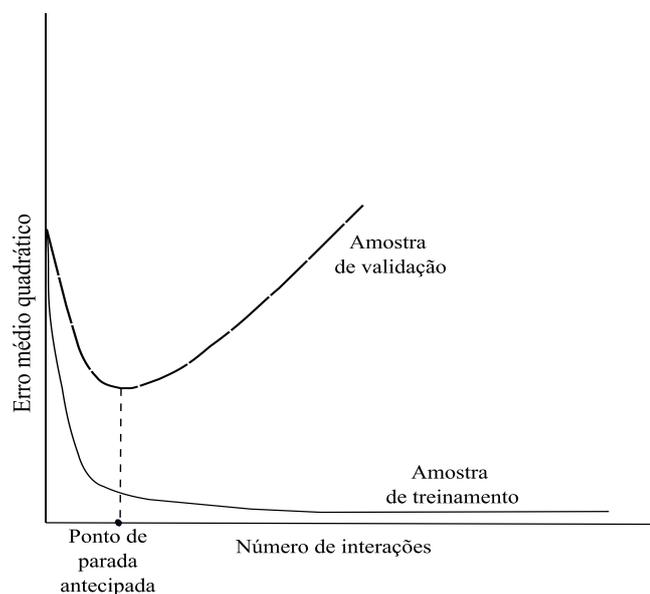


Fonte: Autora.

Em relação aos dados utilizados nos modelos, o usual é que parte desses dados sejam usados para o aprendizado/treinamento da rede e outra parte seja usado somente para validação/teste, sem ter este contato com o treinamento. Dessa forma é possível avaliar se o modelo neuronal está entendendo realmente o problema ou apenas memorizando como estão dispostos o dados de treinamento, sem aprender devidamente com o problema

Durante as iterações da rede, a mesma tende a ter uma diminuição do erro para os dados utilizados para treinamento e validação até um determinado ponto que a rede irá tender a um “overfitting” do modelo com os dados de treinamento, não tendo mais uma capacidade de generalização do problema. Devido a essa possibilidade é interessante que a parada seja antecipada sendo essa a mínima de erro quadrático médio das amostras usadas para validação, durante o treinamento da RNA, conforme exposto na Figura 3.5 (HAYKIN, 2008; SCHMIDHUBER, 2015).

Figura 3.5 – Parada antecipada baseada nos dados de validação



Fonte: Adaptado de Haykin (2008).

3.2 Modelagem da RNA

Para o desenvolvimento dos modelos neuronais foi utilizado o software QNET 2000. O programa já utilizado por Amancio *et al.* (2014), Araújo (2015), Dantas Neto *et al.* (2017), Leite *et al.* (2019), é um software feito para o desenvolvimento de modelos neuronais de MLP com o algoritmo de retropropagação de erro e permite a inserção de até 8 camadas ocultas. O software permite como função de ativação as funções: sigmóide, gaussiana, secante hiperbólica e tangente hiperbólica.

A função de ativação escolhida para todos os neurônios foi a sigmóide, descrita pela Equação 3.7 recomendada por ser a mais eficiente utilizada em MLP segundo Runxuan (2005), e também ter sido utilizada com resultados satisfatórios em Dantas Neto *et al.* (2014, 2016, 2017), Mohamad *et al.* (2014), Moshrefii *et al.* (2018), Koopialipoor *et al.* (2019), Leite *et al.* (2019).

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.7)$$

A Tabela 3.1 apresenta algumas das características sobre os parâmetros de treinamento dos modelos neuronais, os valores utilizados nesse trabalho e suas respectivas justificativas.

Tabela 3.1 – Parâmetros utilizados para o treinamento das RNA para previsão do comportamento cisalhante

Parâmetros utilizados para o treinamento			
Parâmetro	Função	Escolha	Justificativa
Número de Iterações	Número máximo de iterações em uma seção de treinamento, tendo a rede a possibilidade de terminar antes conforme o interesse do usuário. Foram escolhidos parâmetros diferentes de pausa de acordo com as características particulares dos modelos.	Modelos de previsão da tensão cisalhante e dilatância pelo deslocamento horizontal: parada ocorrida no alcance do número máximo de iterações, valores usados: 100.000, 200.000, 300.000, 500.000. Modelos de previsão de resistência cisalhante de pico: parada supervisionada quando houve o mínimo erro quadrático médio de correlação para amostras usadas para validação durante o treinamento da RNA, sendo o valor máximo de iterações de 1.000.000.	Valor máximo escolhido entre os usados em Amancio <i>et al.</i> (2014), Dantas Neto <i>et al.</i> (2014, 2017), Araújo (2015), Leite <i>et al.</i> (2019). Valor máximo escolhido entre os usados em Amancio <i>et al.</i> (2014), Dantas Neto <i>et al.</i> (2014, 2017), Araújo (2015), Leite <i>et al.</i> (2019). Recomendações de parada sugerida por Haykin (2008) e Schmidhuber (2015) conforme Figura 3.4.
Número de controle para começo das interações.	Quantidade de iterações iniciais anterior ao começo da variação da taxa de aprendizagem entre os valores mínimos e máximos. Durante o treinamento inicial é importante que o controle da variação devido à mesma oscilar rapidamente dentro das interações iniciais podendo o erro oscilar bruscamente.	1000.	Valor na faixa do valor sugerido pelo manual do programa, cerca de 1% do número mínimo de interações utilizado.
Taxa de aprendizado inicial, mínima e máxima:	Taxa correspondente a variabilidade da taxa de aprendizado do algoritmo, índice fundamental para o controle de estabilidade do programa. O software irá dentro desta faixa buscar a taxa ótima para encontrar o erro mínimo. Valor entre 0 e 1.	Taxa inicial de 0,001. Taxa mínima de 0,001. Taxa máxima de 0,1.	Semelhantes aos utilizadas por Araújo (2015), Leite <i>et al.</i> (2019).
Momentum (α)	Coefficiente de aprendizado utilizado pelo algoritmo de retropropagação. Valor responsável por amortecer as alterações de alta frequência nos pesos sinápticos e fornecer uma estabilidade ao algoritmo (RUMELHART <i>et al.</i> , 1986).	0,8.	Valor de 0,8 é o padrão do software e o mesmo de Araújo (2015), Leite <i>et al.</i> (2019).
Normalização dos dados	Redes neurais de retropropagação exigem que todos os alvos de treinamento sejam normalizados.	Dados normalizados entre 0,15 e 0,85.	Valor automático padrão do programa e o mesmo utilizado em Araújo (2015) e Dantas Netos <i>et al.</i> (2017).
Coefficiente de rápida propagação; padrões processados por ciclo de atualização de ciclo; valor de tolerância.	Parâmetros avançados para uso na RNA.	0	Valor padrão do programa e sugerido pelo mesmo.

Fonte: Autora.

3.3 Modelos desenvolvidos

Para criar modelos de RNA capazes de prever o comportamento cisalhante das descontinuidades rochosas, foram estabelecidas duas metas principais: criação de modelos para previsão da tensão cisalhante e dilatação com deslocamento horizontal e criação de modelos para previsão da resistência cisalhante de pico.

Esses estudos requerem diferentes abordagens devido ao primeiro permitir a previsão completa do comportamento cisalhante de uma descontinuidade, permitindo simular até mesmo o resultado de ensaios de cisalhamento direto. O segundo apenas a previsão da resistência cisalhante de pico necessária em algumas análises de equilíbrio limite dos maciços rochosos. Por esses motivos os modelos foram divididos em dois subgrupos e tratados de formas individuais conforme exposto nos subitens 3.3.1 e 3.3.2.

Os estudos realizados não visaram apenas a obtenção de um modelo ótimo para cada caso, mas também a avaliação de como influenciariam nos modelos a utilização de diferentes: quantidade de dados para teste e validação; formas de seleção dos dados para teste e validação e os efeitos da supressão de alguns dos dados de entrada utilizados.

3.3.1 Modelos para previsão da tensão cisalhante e dilatação pelo deslocamento horizontal

Inicialmente 116 ensaios de cisalhamento direto tiveram 2083 pontos dos gráficos obtidos de Benmokrane e Ballivy (1989), Skinas *et al.* (1990), Papaliangas *et al.* (1993), Haque (1999), Indraratna e Haque (2000), Oliveira *et al.* (2009), Indraratna *et al.* (2010), Mehrishal *et al.* (2016) e Shrivastava e Rao (2017). Procurou-se definir como dados de entrada aqueles apontados na literatura (ver Capítulo 2) como importantes para a descrição do comportamento cisalhante da descontinuidade com e sem preenchimento, assim como outros que fossem de possível de obtenção numa investigação geotécnica local ou por meio de valores fornecidas pela literatura. As variáveis de entrada escolhidas foram:

- x_1 = rigidez normal (k_n), em kPa/mm;
- x_2 = a razão a amplitude do preenchimento pelo da aspereza (t/a);
- x_3 = tensão normal inicial (σ_{n0}), em MPa;
- x_4 = JRC

- x_5 = resistência à compressão uniaxial da rocha (σ_c), em MPa;
- x_6 = o ângulo de atrito da rocha (ϕ_b), em graus;
- x_7 = ângulo de atrito do preenchimento (ϕ_{fill}), em graus;
- x_8 = deslocamento horizontal (δ_h), em mm;

A Tabela 3.2 apresenta os valores máximos e mínimos das variáveis utilizadas. Para o uso da RNA é importante que os dados de entrada estejam dentro da faixa utilizada para o treinamento, visto que, os pesos sinápticos e bias foram calculados a partir da normalização desses valores para os mínimos e máximos referentes à 0,15 e 0,85, respectivamente. Normalização sendo realizada conforme apresentada na Equação 3.4. Dados fora dessa faixa irão corresponder a valores sem sentido para o modelo neuronal desenvolvido.

Tabela 3.2 – Valores máximos e mínimos utilizados para treinamento e validação das RNA

kn kPa/mm	t/a	σ_{no} MPa	JRC	σ_c MPa	ϕ_b Graus	ϕ_{fill} Graus	δ_h mm
0	0	0,05	2	3,5	30	0	0,02
7515	2	46,5	20	150	37,5	35,5	26,00

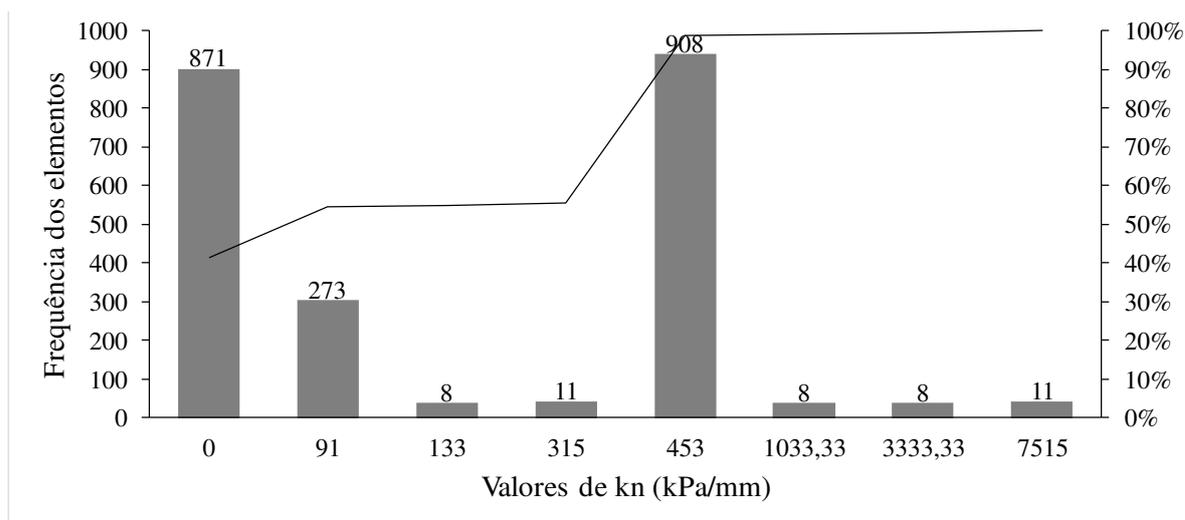
Fonte: Autora.

Sobre os dados obtidos a partir dos ensaios de cisalhamento direto em descontinuidades da literatura, há uma boa variabilidade neles. Os ensaios usados englobam: ensaios sob CNL e CNS, sendo 58% desses sob CNS com diferentes valores para rigidez normal do contorno; ensaios com e sem preenchimento sendo 45% desses com preenchimento; amplitude considerável de resistência à compressão uniaxial simples por serem usados ensaios em rochas brandas e duras; resistência à compressão uniaxial simples de rochas brandas bastante baixas até valores altos como da Onix, sendo para essa 150MPa; JRC entre valores mínimos e máximos da variável representando rochas lisas e extremamente ásperas; ângulo de atrito básico com baixa variabilidade, mas coerente com a realidade devido à variável em si não ter tanta alternância de valores na natureza; ângulo de atrito do preenchimento de 0 correspondente ao não preenchimento aos valores correspondentes à areias e argilas; t/a variando de 0 à 2, que é a faixa normalmente utilizada em descontinuidades nos ensaios de cisalhamento direto.

Na sequência as Figura 3.6, Figura 3.7, Figura 3.8, Figura 3.9, Figura 3.10, Figura 3.11 e Figura 3.12 apresentam as frequências dos dados experimentais usados para treinamento

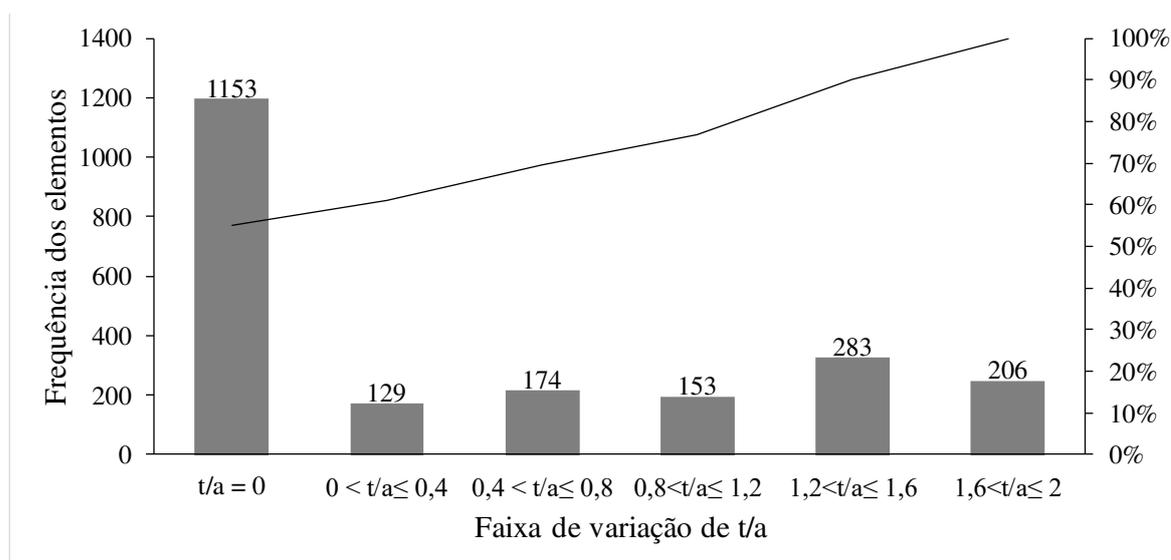
e teste dos modelos neuronais. Observa-se, contudo, que apesar da amplitude ser considerável como mencionado, a distribuição não é normal e variáveis como kn , σ_c e ϕ_b possuem boa parte de seus valores concentrados e faixas específicas, o que diminui a robustez dos modelos neuronais desenvolvidos.

Figura 3.6 – Variação de frequência da rigidez normal

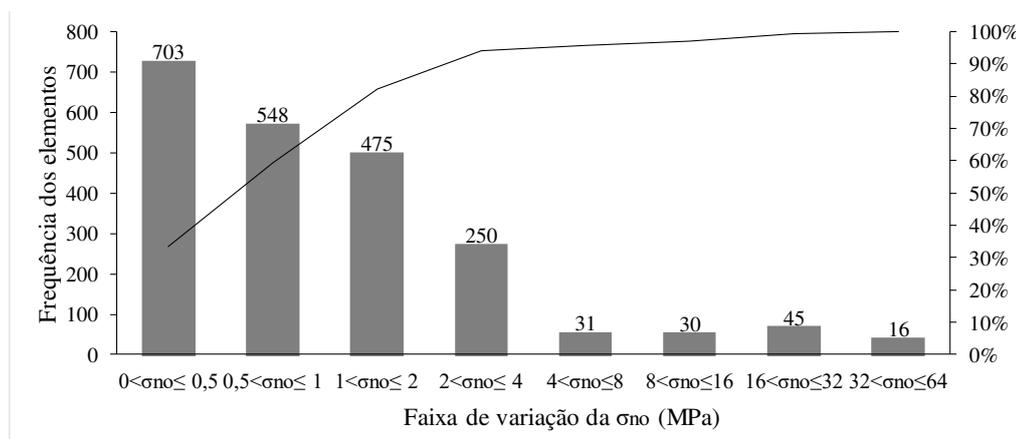


Fonte: Autora.

Figura 3.7 – Variação da frequência do t/a por classe

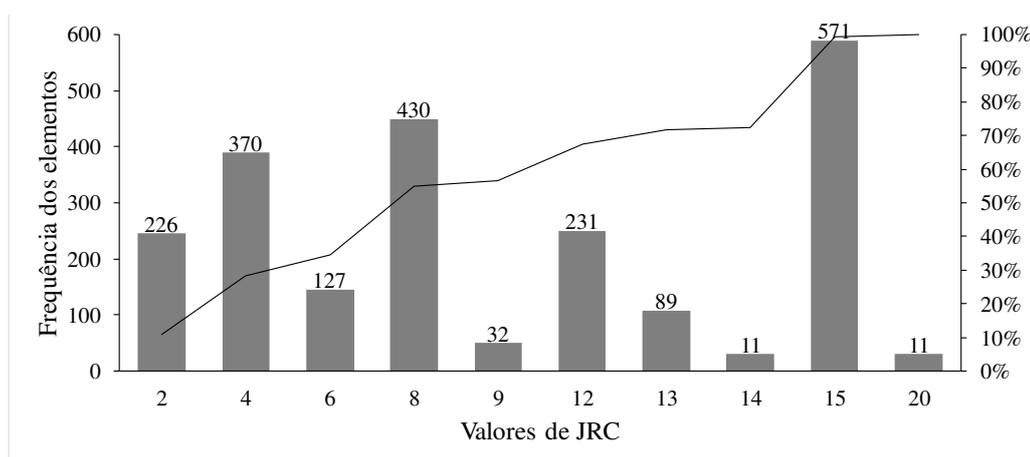


Fonte: Autora.

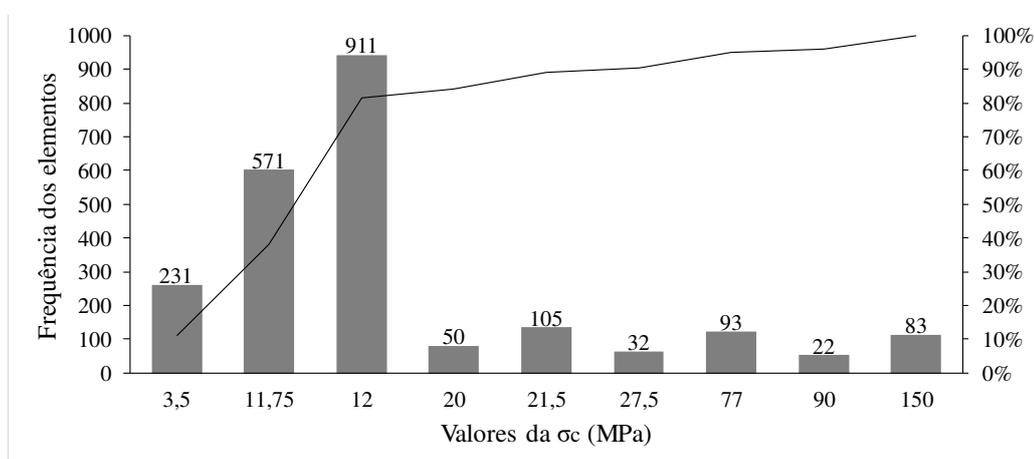
Figura 3.8 – Variação da frequência da σ_{no} 

Fonte: Autora.

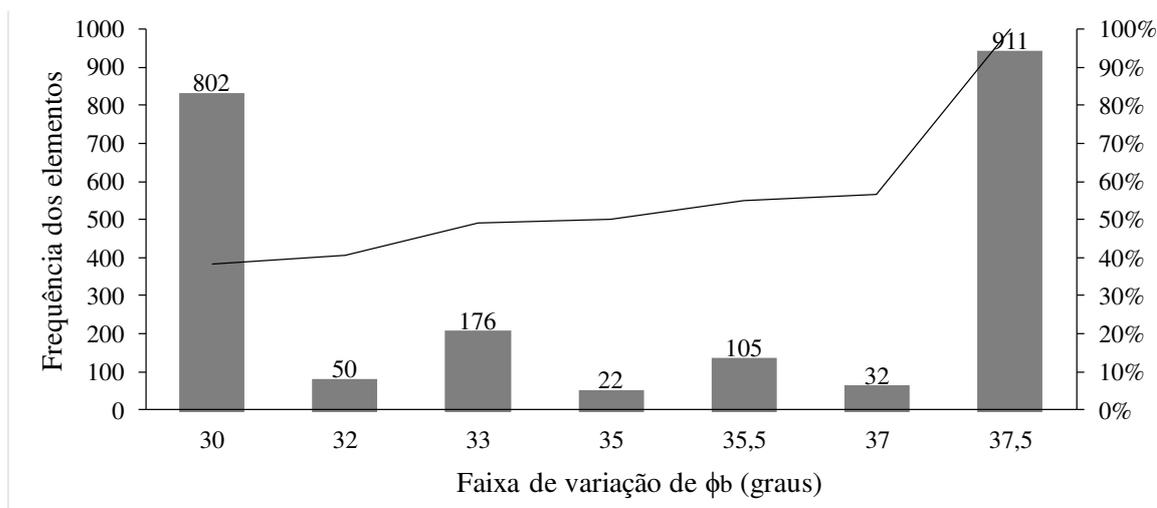
Figura 3.9 – Variação da frequência do JRC



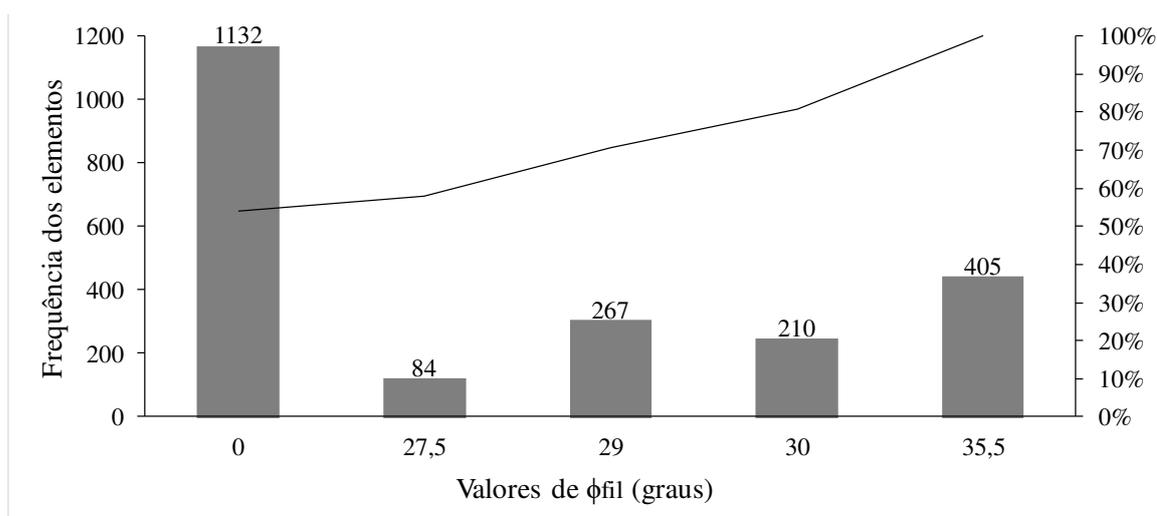
Fonte: Autora.

Figura 3.10 – Variação da frequência da σ_c 

Fonte: Autora.

Figura 3.11 – Variação da frequência da ϕ_b 

Fonte: Autora.

Figura 3.12 – Variação da frequência da ϕ_{fil} 

Fonte: Autora.

Para essa abordagem oito grupos foram desenvolvidos como apresentados na Tabela 3.3. Os grupos A, A2, B, B2 e C são os grupos principais para definição do modelo de previsão, os demais foram feitos de modo a avaliar de que forma a supressão de dados entrada no treinamento iriam afetar a eficiência do modelo neuronal.

Tabela 3.3 – Dados dos grupos dos modelos de previsão da tensão cisalhante e dilatação com deslocamento horizontal.

GRUPO	Número de dados	Número de ensaios	Seleção de dados para treinamento	Porcentagem de dados		Variáveis de entrada	Ensaio utilizados
				Treinamento	Teste		
A	2083	116	Por ponto	80%	20%	TODOS	$\sigma_c \geq 3,5$ MPa
A2	1849	105	Por ponto	80%	20%	TODOS	$\sigma_c \geq 11,75$ MPa
B	2083	116	Por ensaio	80%	20%	TODOS	$\sigma_c \geq 3,5$ MPa
B2	1871	105	Por ensaio	80%	20%	TODOS	$\sigma_c \geq 11,75$ MPa
C	2083	116	Por ensaio	60%	40%	TODOS	$\sigma_c \geq 3,5$ MPa
D	2083	116	Por ensaio	60%	40%	TODOS- ϕ_b	$\sigma_c \geq 3,5$ MPa
E	2083	116	Por ensaio	80%	20%	TODOS- ϕ_b	$\sigma_c \geq 3,5$ MPa
F	2083	116	Por ensaio	80%	20%	TODOS- σ_c	$\sigma_c \geq 3,5$ MPa

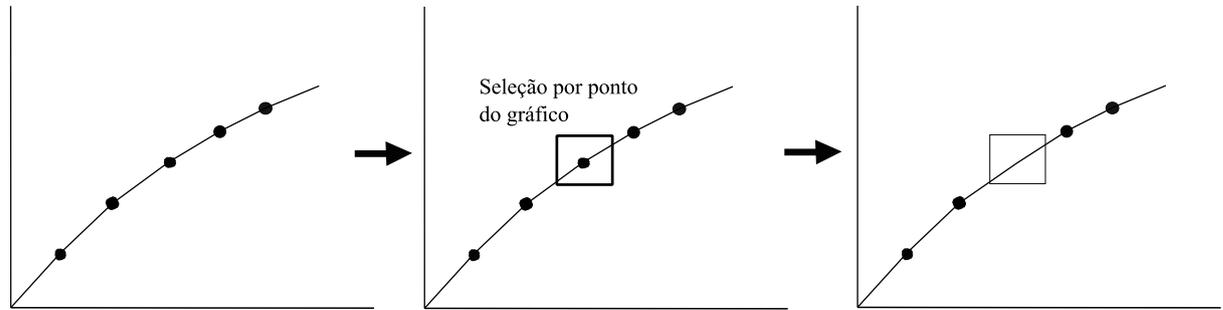
Fonte: Autora

Os grupos desenvolvidos foram definidos pelas seguintes justificativas:

- ✓ Grupo A: desenvolvido conforme o trabalho de Dantas Neto *et al.* (2017), usado todos os ensaios de cisalhamento direto e variáveis de entrada informadas no começo do capítulo.
- ✓ Grupo A2: mesmo que Grupo A, com supressão dos ensaios cuja rocha possui resistência a compressão uniaxial de 3,5 MPa por estar abaixo do encontrado na prática.
- ✓ Grupo B: semelhante ao grupo A, contudo com forma de seleção para os dados de validação diferente. Enquanto no grupo A os dados para teste foram selecionados por ponto do gráfico do cisalhamento direto (Figura 3.13), no grupo B a seleção dos dados de teste ocorreu por ensaio de cisalhamento direto.
- ✓ Grupo B2: semelhante ao grupo B, contudo com supressão dos ensaios cuja rocha possui resistência a compressão de 3,5 MPa.
- ✓ Grupo C: semelhante ao grupo B, contudo usando para treinamento 60% dos ensaios e para validação 40%. Buscou-se uma rede mais robusta a partir do uso de menos dados para treinamento e mais dados para validação.
- ✓ Grupo D: semelhante ao grupo C, mas suprimindo a variável de entrada ϕ_b , para avaliar de que forma a compreensão do fenômeno seria afetado com a ausência dessa variável.
- ✓ Grupo E: semelhante ao grupo B, mas suprimindo a variável de entrada ϕ_b , para avaliar de que forma a compreensão do fenômeno seria afetado com a ausência dessa variável.

- ✓ Grupo F: semelhante ao grupo B, mas suprimindo a variável de entrada σ_c para avaliar de que forma a compreensão do fenômeno seria afetado com a ausência dessa variável.

Figura 3.13 – Forma de seleção por ponto de um gráfico



Fonte: Autora

Todos os grupos foram treinados em nove arquiteturas diferentes, como as expostas a seguir, o primeiro número representa o número de variáveis de entrada, os intermediários as camadas ocultas e o final, a quantidade de variáveis de saída que são a tensão cisalhante e a dilatação. Para os grupos A, A2, B, B2 e C, foram treinadas as arquiteturas:

- ✓ Com uma camada oculta: 8-30-2, 8-20-2, 8-15-2, 8-10-2.
- ✓ Com duas camadas ocultas: 8-30-15-2, 8-30-10-2, 8-20-10-2.
- ✓ Com três camadas ocultas: 8-30-15-5-2, 8-20-10-5-2.

Para os grupos D, E e F, foram as arquiteturas:

- ✓ Com uma camada oculta: 7-30-2, 7-20-2, 7-15-2, 7-10-2.
- ✓ Com duas camadas ocultas: 7-30-15-2, 7-30-10-2, 7-20-10-2.
- ✓ Com três camadas ocultas: 7-30-15-5-2, 7-20-10-5-2.

Todas as arquiteturas foram treinadas em quatro números de iterações distintas, como já salientado e justificado na Tabela 3.1. A representação genérica da RNA é apresentada a seguir na Equação 3.8 para os grupos A, A2, B, B2 e C, Equação 3.9 para os grupos D e E, e Equação 3.10 para o grupo F.

$$\tau_v, \delta_v = g(k_n, t/a, \sigma_{no}, JRC, \sigma_c, \phi_b, \phi_{fill}, \delta_h) \quad (3.8)$$

$$\tau_v, \delta_v = g(k_n, t/a, \sigma_{no}, JRC, \sigma_c, \phi_{fill}, \delta_h) \quad (3.9)$$

$$\tau_v, \delta_v = g(k_n, t/a, \sigma_{no}, JRC, \phi_b, \phi_{fill}, \delta_h) \quad (3.10)$$

3.3.2 Modelos para previsão da resistência cisalhante de pico

Para os modelos referentes a previsão da resistência cisalhante de pico, foram usadas as mesmas fontes citadas no subitem 3.3.1 referente aos ensaios de cisalhamento direto em discontinuidades rochosas. Foram incluídos os dados de Shrivastava e Rao (2017) fornecidos a partir de curvas de ruptura. Foi obtido no final um total de 131 valores de resistência cisalhante de pico cujos limites obtidos por cada autor são expostos na Tabela 3.4.

Tabela 3.4 – Dados usados para tensão de pico a partir dos obtidos por cada autor

Autores	Ensaio	Limite	Rigidez normal (kPa/mm)	t/a	σ_{no} (MPa)	JRC	σ_c (Mpa)	ϕ_b Graus	ϕ_{fil} Graus	τ_p (Mpa)
Indraratna e Haque (2000) e Haque (1999)	62	Min	0	0	0,16	2	12	32	0	0,14
		Max	453	1,8	2,69	13	20	37,5	35,5	3,34
Skinas <i>et al.</i> (1990)	4	Min	0	0	1	9	27,5	37	0	1,28
		Max	3333,33	0	1	9	27,5	37	0	2,48
Benmokrane e Ballivy (1989)	2	Min	315	0	1	14	90	35	0	5,14
		Max	7515	0	1	20	90	35	0	6,68
Papaliangas <i>et al.</i> (1993)	11	Min	0	0	0,05	12	3,5	30	0	0,02
		Max	0	1,1	0,1	12	3,5	30	30	0,10
Oliveira (2009) e Indraratna <i>et al.</i> (2010)	5	Min	453	0	0,8	8	21,5	35,5	0	0,38
		Max	453	2	0,8	8	21,5	35,5	27,5	1,63
Mehrishal <i>et al.</i> (2016)	10	Min	0	0	1,5	2	77	33	0	0,28
		Max	0	0	46,5	2	150	33	0	2,79
Shrivastava e Rao (2017)	37	Min	0	0	0,05	7	11,75	30	0	0,08
		Max	91	2	2,04	15	11,75	30	28,8	2,60

Fonte: Autora

Para previsão da resistência ao cisalhamento de pico das discontinuidades, sete grupos foram desenvolvidos sendo separados de acordo com a resistência à compressão uniaxial simples da rocha como apresentado na Tabela 3.5. Procurou-se avaliar se um modelo geral poderia ser desenvolvido com os dados disponíveis ou se haveria a necessidade da retirada dos valores *outliers*, aqueles que se diferenciam consideravelmente de todos os outros.

Tabela 3.5 – Grupos para tensão de pico

Grupos	Dados usados	Total dados	Treinamento	Teste
G1	Todos	131	80%	20%
G2	Todos	131	60%	40%
G3	Todos com exceção Benmokrane e Ballivy (1989)	129	81%	19%
G4	Todos com exceção Mehrishal <i>et al.</i> (2016)	121	79%	21%
G5	Todos com exceção Benmokrane e Ballivy (1989) e Mehrishal <i>et al.</i> (2016)	119	79%	21%
G6	Todos com exceção Papaliangas <i>et al.</i> (1993)	120	79%	21%
G7	Rochas brandas ($\sigma_c \leq 21,5$ Mpa)	115	79%	21%

Fonte: Autora

Sobre os ensaios retirados para elaboração dos grupos, têm-se as seguintes particularidades sobre eles:

- ✓ Benmokrane e Ballivy (1989): possuem os maiores valores de tensão de pico sendo esses 5,14 MPa e 6,68 MPa, além disso são rochas duras com resistência à compressão uniaxial superior às demais (exceção de Mehrishal *et al.* (2016)).
- ✓ Mehrishal *et al.* (2016): são rochas duras com resistência à compressão uniaxial superior às demais.
- ✓ Papaliangas *et al.* (1993): são rochas que apresentam resistência à compressão uniaxial e tensões normais iniciais aplicadas significadamente menores que as demais.

Todos os grupos foram treinados em nove arquiteturas diferentes, como as expostas a seguir com a mesma organização da citada no item 3.3.1:

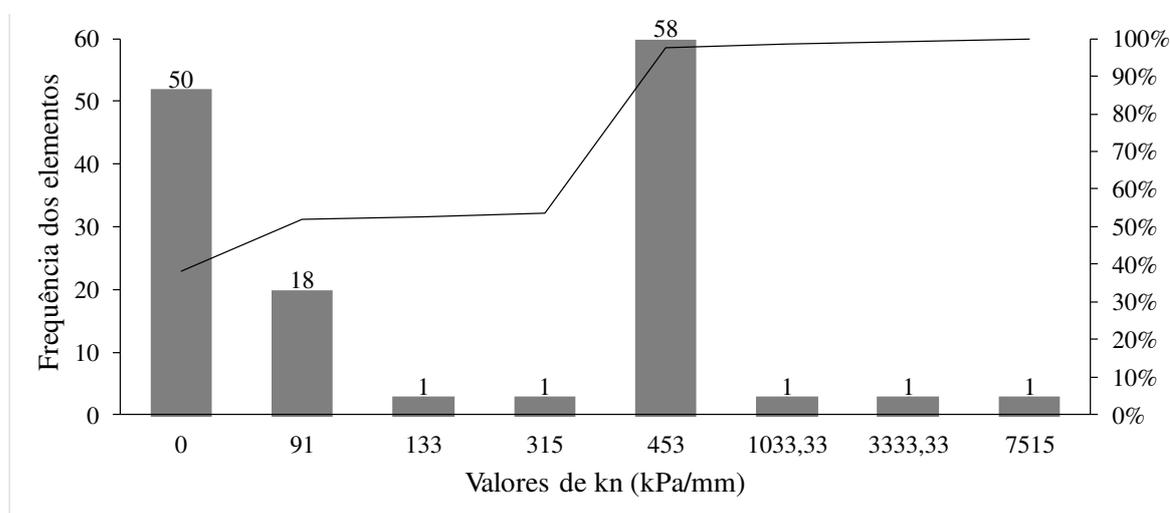
- ✓ Com uma camada oculta: 7-30-2, 7-20-2, 7-15-2, 7-10-2.
- ✓ Com duas camadas ocultas: 7-30-15-2, 7-30-10-2, 7-20-10-2.
- ✓ Com três camadas ocultas: 7-30-15-5-2, 7-20-10-5-2.

Cada arquitetura foi treinada até o valor máximo de interações de 1.000.000, sendo o critério de parada o número mínimo de erro para os dados de teste da rede, como já salientado e justificado na Tabela 3.1. A representação genérica da RNA é apresentada na Equação 3.11.

$$\tau_p = g(k_n, t/a, \sigma_{no}, JRC, \sigma_c, \phi_b, \phi_{fill}) \quad (3.11)$$

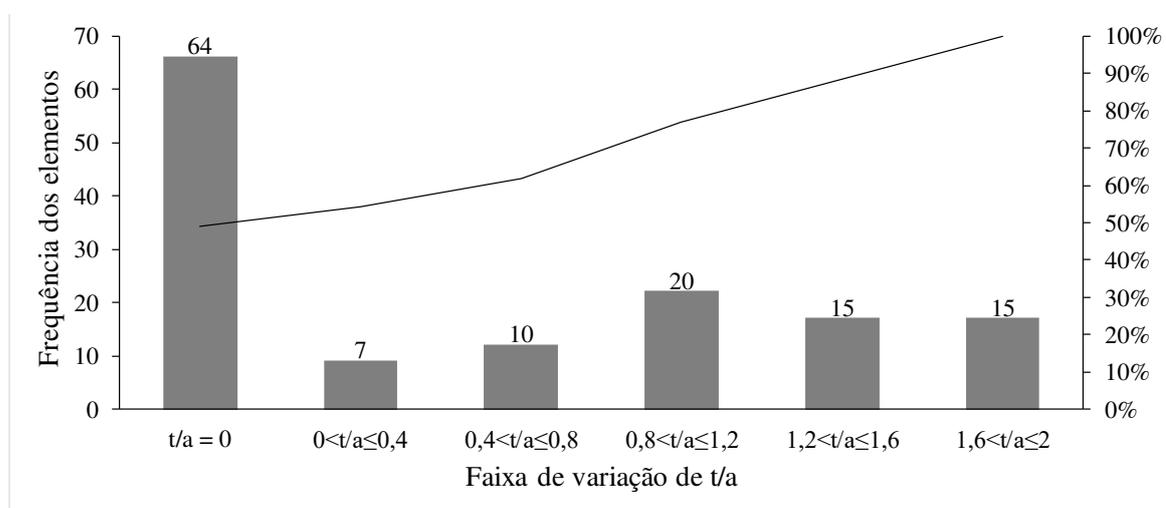
As Figura 3.14, Figura 3.15, Figura 3.16, Figura 3.17, Figura 3.18, Figura 3.19 e Figura 3.20 apresentam as frequências das variáveis de entrada para previsão da resistência cisalhante de pico. As observações sobre a variabilidade das variáveis são as mesmas mencionadas no item 3.1.1. Contudo com o acréscimo dos 6 ensaios de Mehrishal *et al.* (2016), a porcentagem das descontinuidades preenchidas passa para 51%, e dos ensaios sob CNS sobem para 61%.

Figura 3.14 – Variação da frequência da rigidez normal

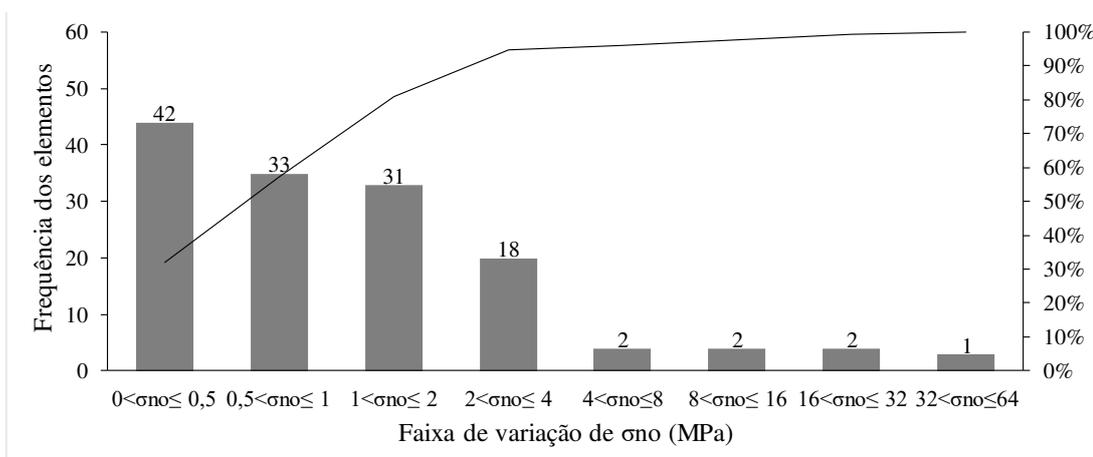


Fonte: Autora.

Figura 3.15 – Variação da frequência do t/a por classe

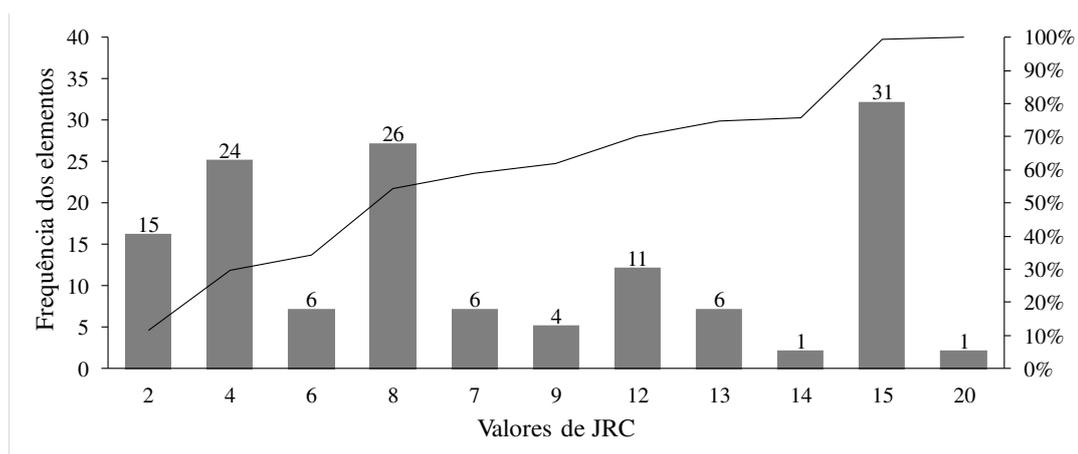


Fonte: Autora.

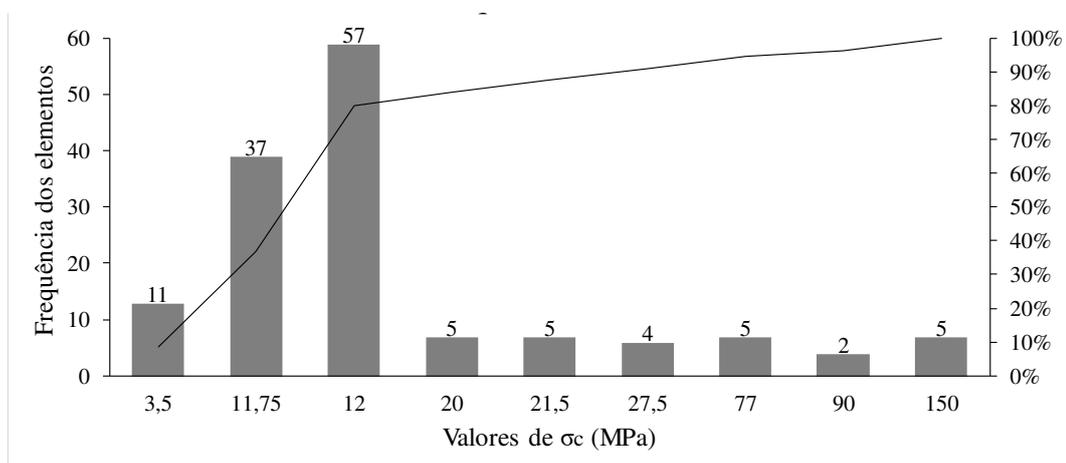
Figura 3.16 – Variação da frequência da σ_{no} 

Fonte: Autora.

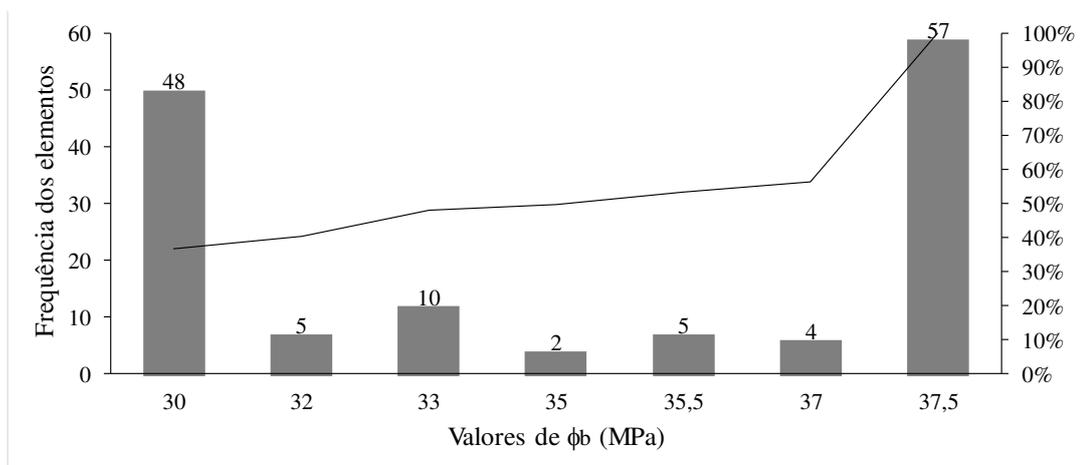
Figura 3.17 – Variação da frequência do JRC



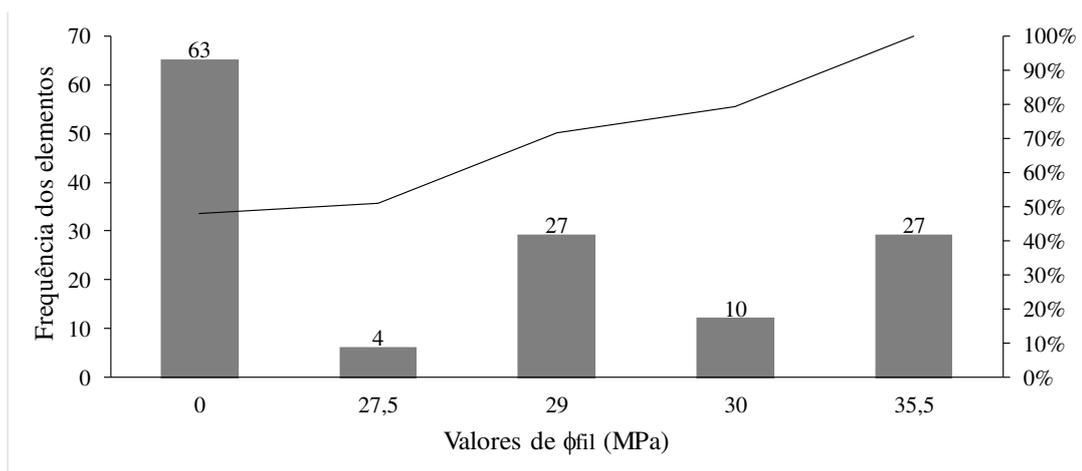
Fonte: Autora.

Figura 3.18 – Variação da frequência da σ_c 

Fonte: Autora.

Figura 3.19 – Variação da frequência do ϕ_b 

Fonte: Autora.

Figura 3.20 – Variação da frequência do ϕ_{fil} 

Fonte: Autora.

4 RESULTADOS - MODELOS PARA PREVISÃO DA TENSÃO CISALHANTE E DILATÂNCIA COM DESLOCAMENTO HORIZONTAL

O presente capítulo apresenta os resultados dos grupos criados para previsão do comportamento cisalhante referente a tensão cisalhante e dilatação com o deslocamento horizontal. É exposto a seguir: discussão sobre o comportamento das RNA para os grupos criados; os modelos com maiores e menor correlação entre os dados de saída experimentais e os resultantes dos modelos neuronais, para os dados de teste (validação); a contribuição das variáveis de entrada para as melhores arquiteturas de cada grupo; apresentação do modelo neuronal escolhido para previsão do comportamento e comparação com os resultados procedente dele com outros modelos e dados do ensaios de cisalhamento direto de Benmokrane e Ballivy (1989), Skinas *et al.* (1990), Papaliangas *et al.* (1993), Haque (1999), Oliveira *et al.* (2009), Mehrishal *et al.* (2016) e Shrivastava e Rao (2017); avaliação do modelo aplicado em juntas hipotéticas como realizado em Dantas Neto *et al.* (2017); comparação com modelo analítico de Indraratna e Haque (2000) e neuronal de Dantas Neto *et al.* (2017) para descontinuidades não preenchidas sob CNS.

4.1 Comparações entre modelos

Para cada grupo apresentado no Capítulo 3 foram testadas nove arquiteturas com quatro número de iterações, resultando um total de trinta e seis modelos para cada grupo. Foi estabelecido que cada modelo só seria um potencial para previsão da tensão cisalhante e dilatação com o deslocamento horizontal, caso obtivesse uma correlação, entre os dados experimentais usados para teste e os previstos pelos modelos neuronais para esses, maior que 95%. A Tabela 4.1 apresenta quantos modelos de cada grupo atingiram esse critério.

Tabela 4.1 – Quantidade de modelos com correlações para dados de teste maior que 95% para cada grupo

Grupo	Modelos com correlação de teste maior que 95%		Seleção de dados para treinamento
	Quantidade	Porcentagem	
A	36	100%	Por ponto
A2	36	100%	Por ponto
B	34	94%	Por ensaio
B2	9	25%	Por ensaio
C	7	19%	Por ensaio
D	0	0%	Por ensaio
E	18	50%	Por ensaio
F	29	81%	Por ensaio

Fonte: Autora.

Da Tabela 4.1, algumas considerações podem ser feitas relacionadas sobre, como a forma de desenvolvimento dos modelos neuronais, para o caso da previsão da tensão cisalhante e dilatância com o deslocamento horizontal, influenciaram na eficiência em termo de correlação para dados de teste.

A forma de separação de dados de treinamento e teste da RNA por pontos dos gráficos de cisalhamento direto se mostrou mais eficiente (grupo A e A2). Essa eficiência é esperada visto que, ao tirar pontos de uma curva composta por vários outros pontos, a interpretação da curva pelos pontos não selecionados tende a ser suficiente (Figura 3.13), o que não necessariamente implica que o modelo neuronal interpretou devidamente o comportamento da variação da tensão cisalhante e dilatância com o deslocamento horizontal para a descontinuidade rochosa

Quando comparados os Grupos A e B, notamos uma diminuição sensível na eficiência, sendo teoricamente o Grupo B um grupo de melhor interpretação do comportamento da variação da tensão cisalhante e dilatância com o deslocamento horizontal, visto que sua seleção para dados de teste e treinamento se dão por ensaios. No momento que a rede tem uma compreensão, não só de pontos dos gráficos, mas de um ensaio completo, existe uma tendência que aquela rede tenha compreendido o comportamento de uma forma generalizada.

Entre os Grupos B e B2, a diferença foi a resistência de compressão uniaxial rochas utilizadas. Essa supressão de ensaios que se teve do B para B2 fazendo a quantidade de modelos com correlações maiores que 95% para os dados de teste diminuísse de 94% para 25%, apontou

que esses dados de entrada de alguma forma ajudavam na eficiência da rede, seja por ter mais dados em si, ou pela importância dessa entrada de dados no modelo neuronal. Tal diminuição não ocorreu quando comparados os Grupos A com A2, reforçando a consideração feita anteriormente.

Comparando o Grupo B com C, sendo a diferença entre esses que as porcentagens usadas para treinamento/teste foram 80%/20% e 60%/40% respectivamente. A mudança fez com que a quantidade de modelos com correlações maiores que 95% para os dados de teste diminuísse de 94% para 19%. Contudo um modelo com correlação alta em C tende a ter mais capacidade de generalização que um modelo com correlação alta em B, devido ao fato de que mesmo usando menos dados para treinamento, se conseguiu uma boa correlação para uma quantidade ainda maior de dados usados para teste.

Entre os Grupos B e E, a supressão da variável de entrada ϕ_b reduziu a quantidade de modelos com correlações para teste maiores que 95% pela metade. Para o Grupo D, que se compara com o Grupo C, essa supressão fez com que nenhum modelo conseguisse uma correlação maior que 95%. Essas diminuições marcantes indicam a importância do ϕ_b , e justifica que o mesmo esteja constantemente nas equações empíricas e analíticas apresentadas no Capítulo 2.

No Grupo F, em que se suprimiu a variável de entrada σ_c , quando comparado ao Grupo B, a redução da quantidade de grupos com correlação maior que 95% para os dados teste, não foi tão alta quanto quando se retirou o ϕ_b (Grupo E), fazendo com a diferença do F para o B fosse apenas de 13%. Essa diminuição singela justifica a ausência da variável σ_c em algumas das equações empíricas e analíticas apresentadas no Capítulo 2.

Na sequência os resultados individuais dos grupos testados são apresentados. Os três modelos de cada grupo com maior correlação entre os dados experimentais usados para teste e previstos pelo modelo, tiveram os dados de Benmokrane e Ballivy (1989), Skinas *et al.* (1990), Papaliangas *et al.* (1993), Haque (1999), Oliveira *et al.* (2009), Mehrishal *et al.* (2016) e Shrivastava e Rao (2017), empregados para previsão do comportamento cisalhante. Os modelos que melhor interpolaram os resultados de previsão aos gráficos de cisalhamento direto dessas literaturas, em termos de tensão cisalhante e dilatação com deslocamento horizontal, foram escolhidos como modelos ótimos para previsão do comportamento por grupo.

4.1.1 Grupo A

O Grupo A teve como maiores e menor valor para correlação com os dados de teste, as arquiteturas com o número de iterações conforme apresentado a seguir na Tabela 4.2.

Tabela 4.2 – Resultados principais do Grupo A

Ordem	Arquitetura	Número de interações	Correlação	
			Treinamento	Teste
1o Maior	8-30-15-5-2	500.000	99,3%	99,1%
2o Maior	8-20-10-5-2	500.000	99,3%	99,0%
3o Maior	8-30-15-2	500.000	99,2%	99,0%
Menor	8-30-2	100.000	97,7%	97,4%

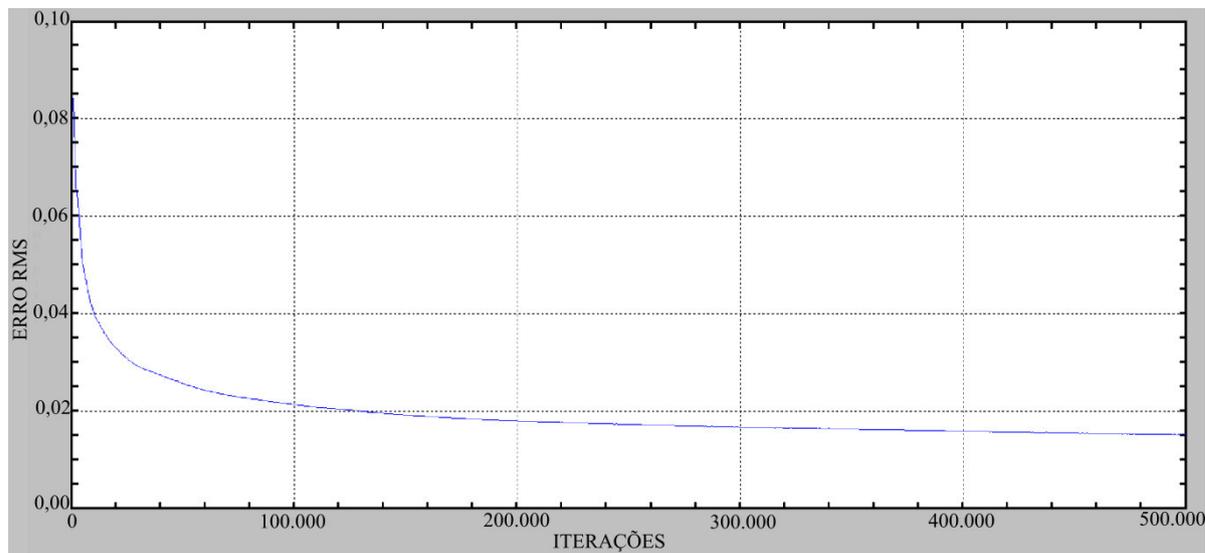
Fonte: Autora

As arquiteturas apresentaram quase nenhuma diferença entre seus valores de correlação para os dados de treinamento e teste, todas as com maior correlação tiveram esse resultado no maior número de iterações. A rede com menor correlação para dados de teste foi obtida no menor número de iterações usado, contudo esse modelo teve uma correlação relativamente alta quando comparada aos demais grupos.

Embora a arquitetura 8-30-15-5-2 tenha apresentado maior correlação, a arquitetura 8-20-10-5-2 foi aquela cujos resultados, melhor interpolaram com os dados experimentais comparados, apresentando uma boa compreensão das variáveis. O Apêndice A apresenta os gráficos obtidos pela previsão do modelo correspondente à arquitetura 8-20-10-5-2. Esse modelo, e todos os demais, não apresentaram boa interpolação com os dados de Papaliangas *et al.* (1993), que são os ensaios que correspondem à uma resistência a compressão uniaxial de 3,5 MPa e tensões normais aplicadas substancialmente baixas, de 0,05 MPa à 0,1 MPa.

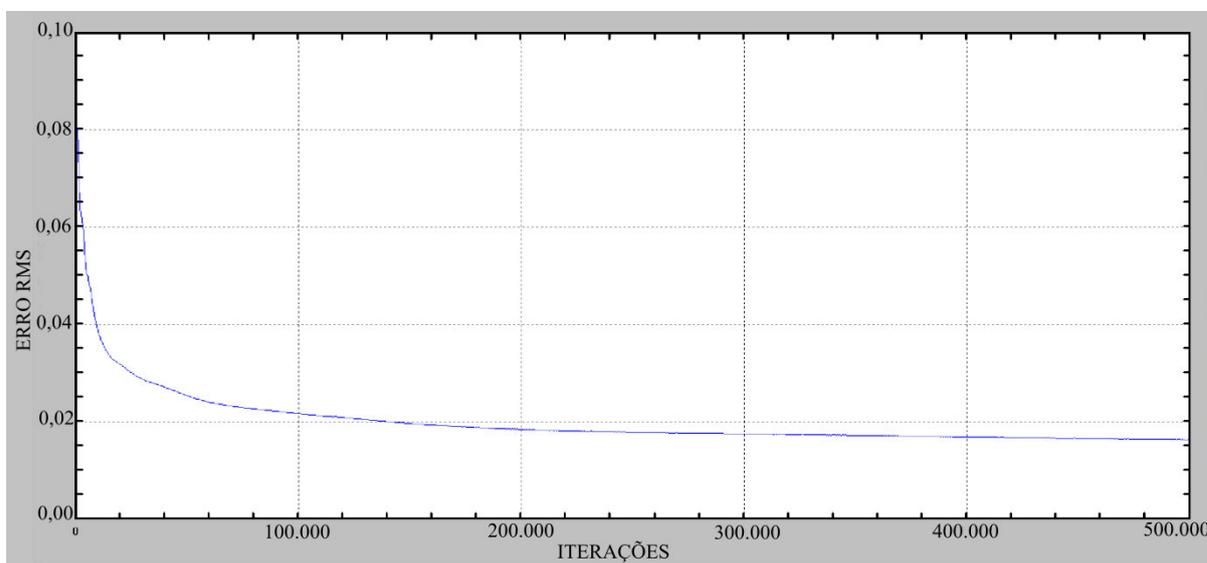
Nos modelos neuronais do grupo A e A2, diferente dos demais grupos, não apareceu claramente o fenômeno de overfitting como citado por Haykin (2008) e Schmidhuber (2015) demonstrado na Figura 3.5. Os gráfico da variação do RMS com o número de iterações referente aos dados de treinamento (Figura 4.1) e referentes aos dados de validação (Figura 4.2) foram constantemente descendente, diferente dos obtidos no Grupos B, B2, C, D, E e F. Esse comportamento pode ser justificado pela forma de seleção, como anteriormente mencionado.

Figura 4.1 – Variação do RMS para os dados do treinamento no decorrer de 500.000 iterações para arquitetura 8-20-10-5-2 do grupo A



Fonte: Autora.

Figura 4.2 – Variação do RMS para os dados da validação no decorrer de 500.000 iterações para arquitetura 8-20-10-5-2 do grupo A

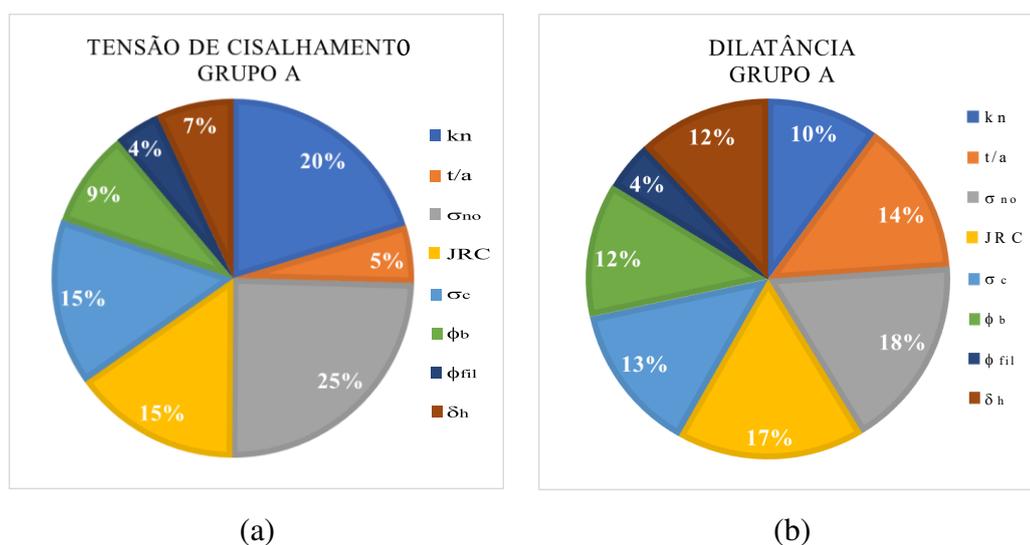


Fonte: Autora.

Fazendo um levantamento sobre a contribuição média das variáveis de entrada, para as arquiteturas com maior correlação com os dados de teste, obteve-se como variáveis de entrada com maior relevância para previsão da tensão de cisalhante o k_n , σ_{no} , JRC e σ_c . A soma da contribuição dessas variáveis de entrada foi de 75% para tensão cisalhante, como

apresentado na Figura 4.3a. Para a dilatação houve distribuição mais uniforme da contribuição das variáveis entrada, aparecendo σ_{no} , JRC e t/a como mais relevantes (Figura 4.3b).

Figura 4.3 – Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatação das três arquiteturas com maior correlação com dados de teste do Grupo A



Fonte: Autora.

4.1.2 Grupo A2

O Grupo A2 teve como maiores e menor valor para correlação com os dados de teste, as arquiteturas com o número de iterações conforme apresentado na Tabela 4.3.

Tabela 4.3 – Resultados principais do Grupo A2

Ordem	Arquitetura	Número de iterações	Correlação	
			Treinamento	Teste
1o Maior	8-20-10-5-2	500.000	99,1%	98,8%
2o Maior	8-20-10-2	500.000	98,9%	98,5%
3o Maior	8-30-10-2	500.000	98,8%	98,5%
Menor	8-30-2	100.000	96,6%	96,0%

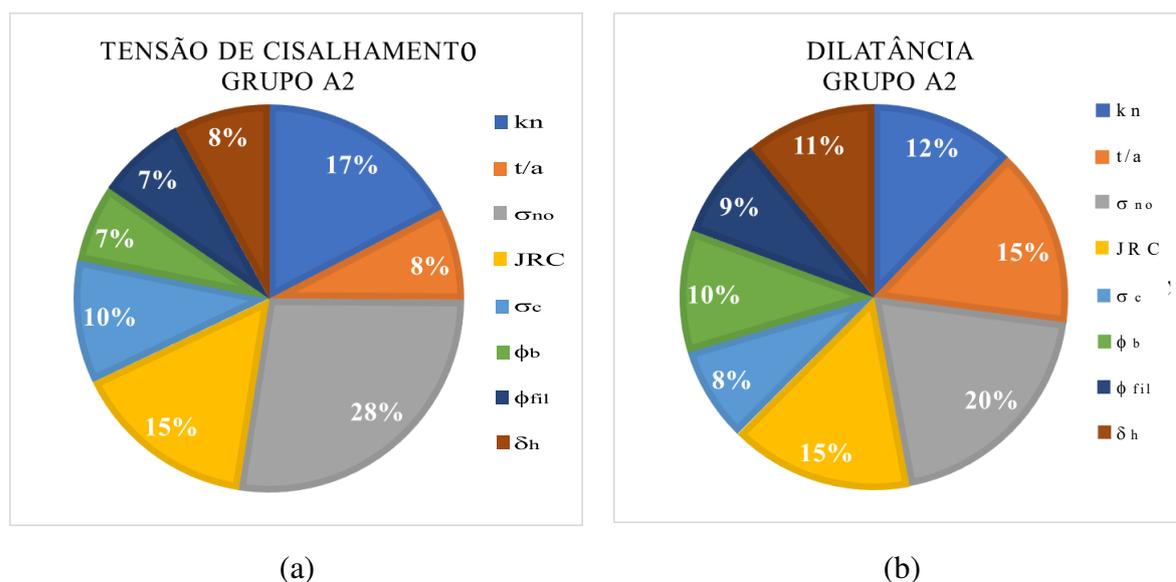
Fonte: Autora.

Esse grupo apresentou altos valores de correlação para treinamento e teste, sendo até mesmo o modelo com menor correlação para os dados de teste um total de 96%. Os valores de correlação para teste foram quase tão altos quanto os referentes aos do Grupo A. Assim como no Grupo A os maiores valores de correlação foram obtidos no número máximo de iterações, e o menor, no mínimo.

Dentre os três modelos com maior correlação, a arquitetura 8-30-10-2 com 500.000 iterações foi aquela cujos resultados melhor interpolaram com os dados experimentais comparados, apresentando uma boa compreensão das variáveis. O Apêndice A apresenta os gráficos obtidos pela previsão obtida do modelo correspondente à arquitetura 8-30-10-2.

Sobre a contribuição das variáveis de entrada, os resultados foram semelhantes aos obtidos para o Grupo A, como apresentado na Figura 4.4. Diferença mais perceptível foi o aumento para mais que o dobro da influência de ϕ_{fill} para dilatação e tensão cisalhante, ao mesmo tempo que gerou a redução da contribuição σ_c . Tal ocorrência está relacionada à ausência dos dados de $\sigma_c < 3,5$ MPa, e como a rede interpreta o comportamento sem eles.

Figura 4.4 – Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatação das três arquiteturas com maior correlação com dados de teste do Grupo A2



Fonte: Autora

4.1.3 Grupo B

O Grupo B teve como maiores e menor valor para correlação com os dados de teste, as arquiteturas com o número de iterações conforme apresentado na Tabela 4.4.

Tabela 4.4 – Resultados principais do grupo B

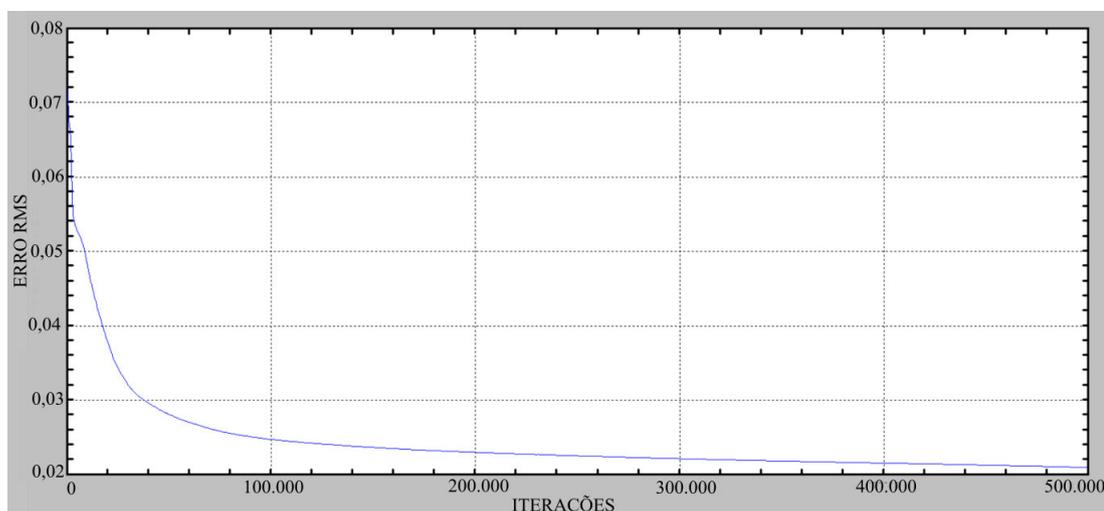
Ordem	Arquitetura	Número de interações	Correlação	
			Treino	Teste
1o Maior	8-30-15-5-2	200.000	98,9%	96,9%
2o Maior	8-30-15-2	200.000	98,8%	96,8%
3o Maior	8-20-10-2	300.000	98,9%	96,8%
Menor	8-20-10-5-2	100.000	98,3%	94,6%

Fonte: Autora.

Sobre a correlação com os dados de teste, o Grupo B apresenta uma diminuição quando comparado aos Grupos A e A2. A diferença na forma de seleção dos dados de teste fez com que as redes com maior correlação para dados de teste, fossem obtidas em um número de iterações intermediárias, de 200.000 e 300.000. Dentre os três modelos com maior correlação, a arquitetura 8-30-15-2 com 200.000 iterações, foi aquela cujos resultados, melhor interpolaram com os dados experimentais comparados, apresentando uma boa compreensão das variáveis, seus gráficos estão expostos no Apêndice A.

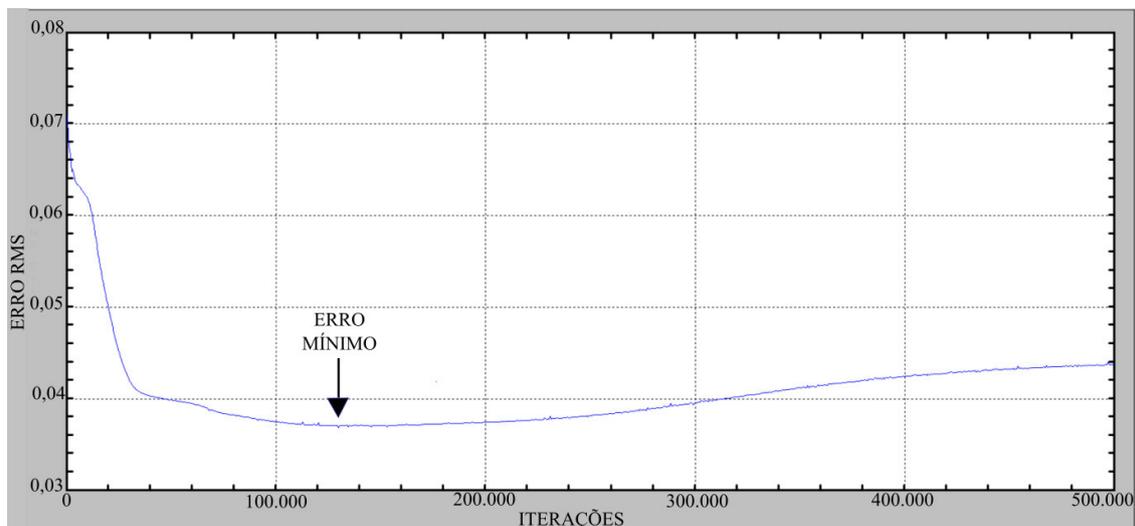
Nos modelos neuronais do Grupo B, assim como nos Grupos B2, C, D, E, F, pode-se observar o overfitting. A Figura 4.5, apresenta curva do RMS com o decorrer do número de iterações para os dados de treinamento da arquitetura 8-30-2 com uma diminuição constante, enquanto a Figura 4.6, que apresenta a curva do RMS com o decorrer do número de iterações para os dados de teste, exhibe que essa diminuição ocorre até um valor que seria o erro mínimo, passando depois a crescer. Esse comportamento ocorreu para essa e demais arquiteturas dos Grupos B2, C, D, E, F.

Figura 4.5 – Variação do RMS para os dados do treinamento no decorrer de 500.000 iterações para arquitetura 8-30-2 do grupo B



Fonte: Autora.

Figura 4.6 – Variação do RMS para os dados de teste no decorrer de 500.000 iterações para arquitetura 8-30-2 do grupo B

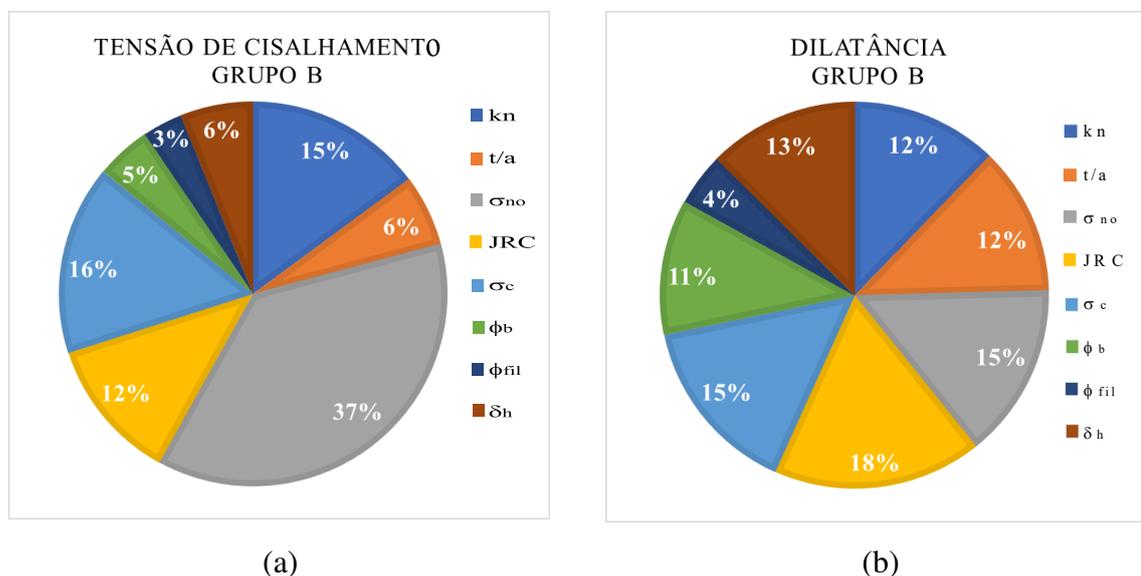


Fonte: Autora.

A melhor arquitetura para esse grupo foi a 8-30-15-2 com 200.000 iterações. Seus resultados, melhor interpolarem com os dados experimentais comparados, apresentando uma boa compreensão das variáveis. O Apêndice A apresenta os gráficos obtidos pela previsão.

Sobre a contribuição das variáveis de entrada, os resultados foram semelhantes aos obtidos nos Grupos A e A2. Como maior diferença, teve a contribuição da variável de entrada σ_{no} . Para o Grupo B (Figura 4.7) a variável passou a ter uma contribuição bem maior para tensão cisalhante passando de 25% (Grupo A) para 37%, enquanto para dilatação diminuiu de 20% (Grupo A) para 15%. A contribuição da variável ϕ_{fill} diminuiu para tensão cisalhante e dilatação passando a ser apenas de 3% e 4%. As demais variáveis permaneceram semelhantes aos valores referentes ao Grupo A.

Figura 4.7 – Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatância das três arquiteturas com maior correlação com dados de teste do Grupo B



Fonte: Autora.

4.1.4 Grupo B2

O grupo teve como maiores e menor valor para correlação com os dados de teste, as arquiteturas com o número de iterações conforme apresentado na Tabela 4.5.

Tabela 4.5 – Resultados principais do Grupo B2

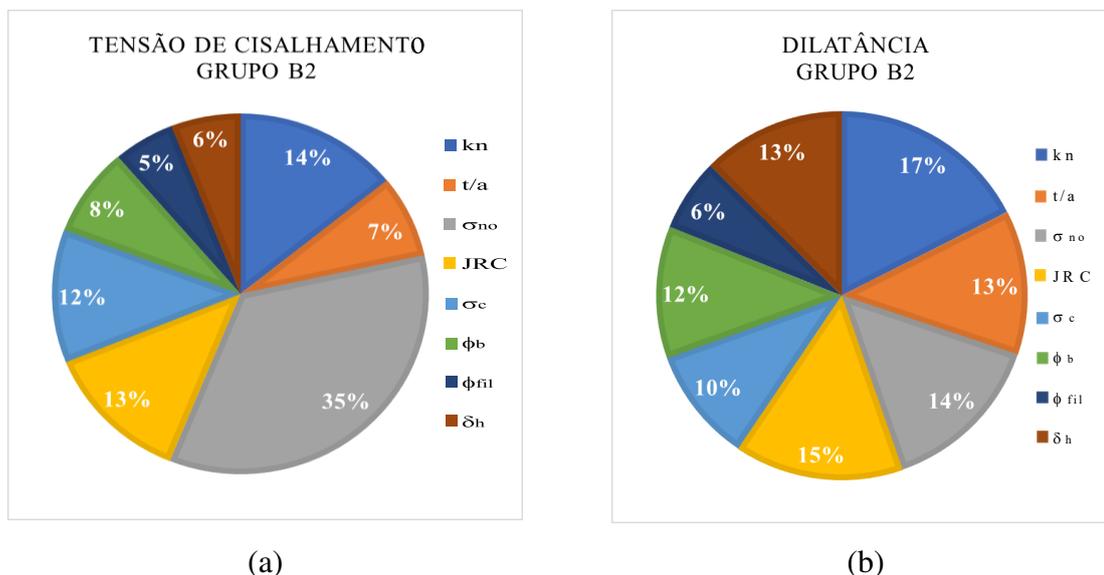
Ordem	Arquitetura	Número de interações	Correlação	
			Treino	Teste
1o Maior	8-30-15-5-2	500.000	98,9%	96,4%
2o Maior	8-30-15-5-2	200.000	97,7%	95,8%
3o Maior	8-20-10-2	500.000	98,6%	95,8%
Menor	8-30-2	500.000	98,0%	91,6%

Fonte: Autora

O Grupo B2, como apresentado na Tabela 4.1, obteve apenas 9 modelos com correlações acima de 95% para os dados de teste. A melhor arquitetura do grupo foi a 8-30-15-5-2 com 500.000 iterações, essa cujos resultados, melhor interpolaram com os dados experimentais comparados, apresentando uma boa compreensão das variáveis. O Apêndice A apresenta os gráficos obtidos pela previsão obtida do modelo correspondente à arquitetura 8-30-15-5-2. Sobre a contribuição das variáveis de entrada (Figura 4.8), as mesmas observações

sobre o Grupo B podem ser feitas. O Grupo B2, que assim como o Grupo A2, teve a supressão dos ensaios com $\sigma_c < 3,5$ MPa, também apresentou redução da contribuição da variável σ_c .

Figura 4.8 – Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatância das três arquiteturas com maior correlação com dados de teste do Grupo B2



Fonte: Autora.

4.1.5 Grupo C

O grupo C teve como maiores e menor resultado para correlação de teste, as arquiteturas com o número de iterações conforme apresentado a seguir na Tabela 4.6.

Tabela 4.6 – Resultados principais do Grupo C

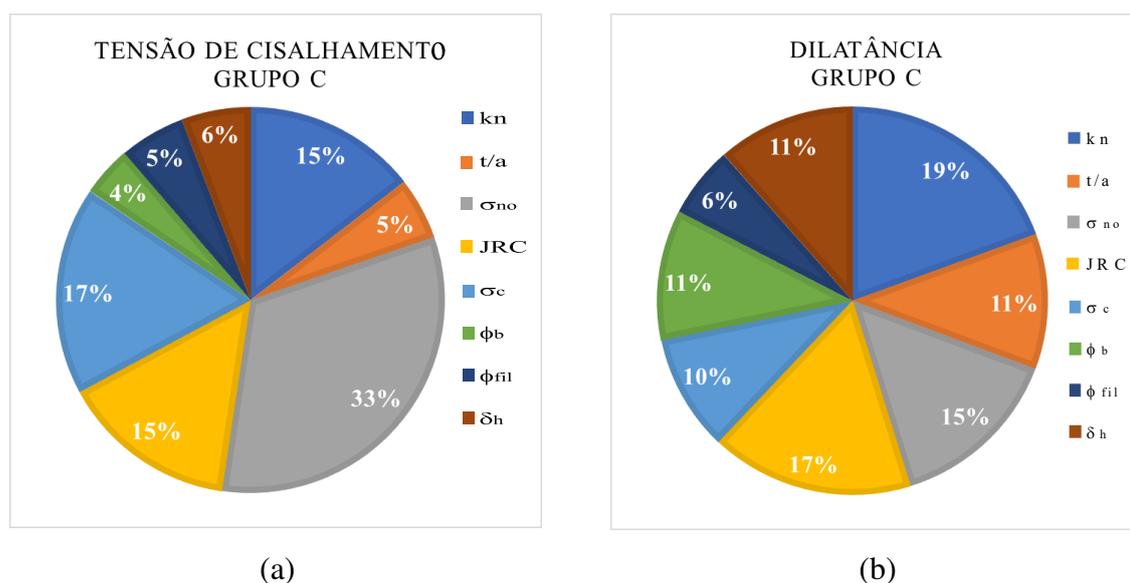
Ordem	Arquitetura	Número de iterações	Correlação	
			Treino	Teste
1o Maior	8-30-10-2	500.000	99,3%	96,3%
2o Maior	8-30-10-2	300.000	99,1%	96,1%
3o Maior	8-30-15-2	300.000	99,1%	95,9%
Menor	8-10-2	300.000	98,6%	92,5%

Fonte: Autora.

O Grupo C como apresentado na Tabela 4.1 obteve apenas sete modelos com correlação acima de 95% para os dados de teste. Os modelos do Grupo C não tiveram uma boa interpolação aos resultados experimentais da literatura comparada, o melhor modelo entre esses foi o 8-30-15-2 com 300.000 iterações e tem os gráficos comparativos expressos no Apêndice A.

Sobre a contribuição das variáveis de entrada no Grupo C (Figura 4.9), mesmo diminuindo o número de elementos usados para teste de 80% para 60%, os resultados permaneceram semelhantes ao encontrados no Grupo B.

Figura 4.9 – Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatação das três arquiteturas com maior correlação com dados de teste do Grupo C



Fonte: Autora.

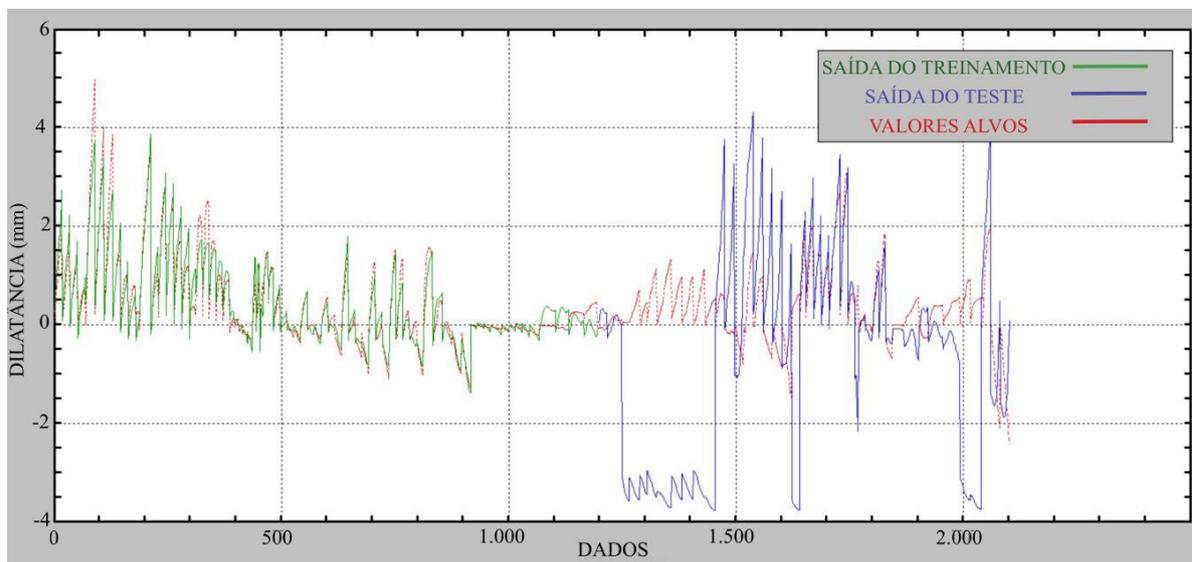
4.1.6 Grupo D

Com a retirada da variável de entrada ϕ_b , de uma rede já com um pequeno número de elemento usado para treinamento quando comparado às outras (60%), o grupo não conseguiu chegar ao valor de 95% de correlações para os dados de teste nas 36 redes testadas. Nesse grupo o melhor resultado se deu para arquitetura 7-30-15-5-2 com o total de 500.000 iterações, para a qual se obteve um coeficiente de correlação de 91,4% para o teste. O pior resultado, com 37,9% de correlação para os dados de teste, se deu para arquitetura 7-20-2 com 300.000 iterações.

O principal problema que se teve com as redes do grupo D, para implicar em correlações tão baixas foi a falta de capacidade de previsão da dilatação após a retirada do ϕ_b . A Figura 4.10 apresenta a comparação entre os valores de saída do modelo de arquitetura 7-30-2 com 500.000 iterações referente a dilatação, para dados de treinamento e teste, e os dados alvos de saída. É possível observar que os dados da dilatação, para os elementos de teste,

estavam gerando erros bruscos, em relação aos elementos alvos. O mesmo comportamento se repetiu para as demais redes desse grupo.

Figura 4.10 – Variação entre dados requeridos e obtidos para dilatância pelo modelo neuronal referente a arquitetura 7-30-2 com 45,7% de correlação para teste



Fonte: Autora.

4.1.7 Grupo E

O Grupo E teve como maiores e menor resultado para correlação de teste, as arquiteturas com o número de iterações conforme apresentado a seguir na Tabela 4.7.

Tabela 4.7 – Resultados principais do grupo E

Ordem	Arquitetura	Número de interações	Correlação	
			Treino	Teste
1o Maior	8-30-15-5-2	300.000	98,9%	97,4%
2o Maior	8-20-10-5-2	300.000	99,0%	97,1%
3o Maior	8-30-15-5-2	200.000	98,6%	97,1%
Menor	8-20-2	50.000	98,5%	91,9%

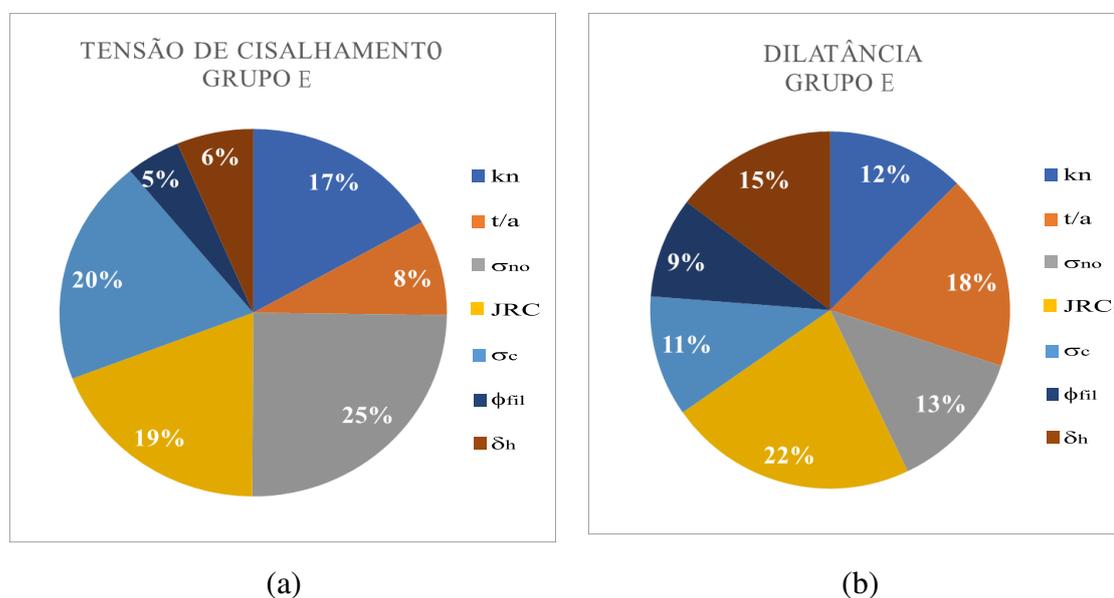
Fonte: Autora.

Ao comparar resultados das previsões das arquiteturas dos modelos D e E (que não possuem ϕ_b como variável de entrada) com aqueles obtidos nos Grupos A, A2, B, B2 e C, teve-se que a retirada não alterou consideravelmente a previsão da tensão cisalhante, mas influenciou bastante na previsão da dilatância. O motivo que o Grupo E chegou a ter modelos que conseguiram obter uma com correlação para dados de teste maior que 95%, e o grupo D não ter alcançado, foi devido ao aumento de dados usados no teste ter melhorado os resultados para

previsão da tensão cisalhante, mas a previsão da dilatação não teve melhoras substanciais fazendo com que erros como os apontados na Figura 4.10 ocorressem.

Para a contribuição das variáveis de entrada para previsão da tensão cisalhante (Figura 4.11a), a retirada de ϕ_b quando comparada ao grupo B, fez com que as contribuições da σ_c e JRC aumentassem em média de 5%, as outras em torno de 2%; a influência da σ_{no} diminuiu em 12%. Sobre a dilatação houve um aumento principalmente no t/a, JRC e ϕ_{fil} , as demais são apresentadas na Figura 4.11b.

Figura 4.11 – Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatação das três arquiteturas com maior correlação com dados de teste do Grupo E



Fonte: Autora

4.1.8 Grupo F

O Grupo F teve como maiores e menor resultado para correlação de teste, as arquiteturas com o número de iterações conforme apresentado a seguir na Tabela 4.8.

Tabela 4.8 – Resultados principais do grupo F

Ordem	Arquitetura	Número de interações	Correlação	
			Treino	Teste
1o Maior	8-20-10-5-2	200.000	98,8%	97,1%
2o Maior	8-30-15-5-2	300.000	99,0%	96,6%
3o Maior	8-30-15-2	200.000	98,6%	96,6%
Menor	8-30-15-5-2	500.000	99,3%	93,7%

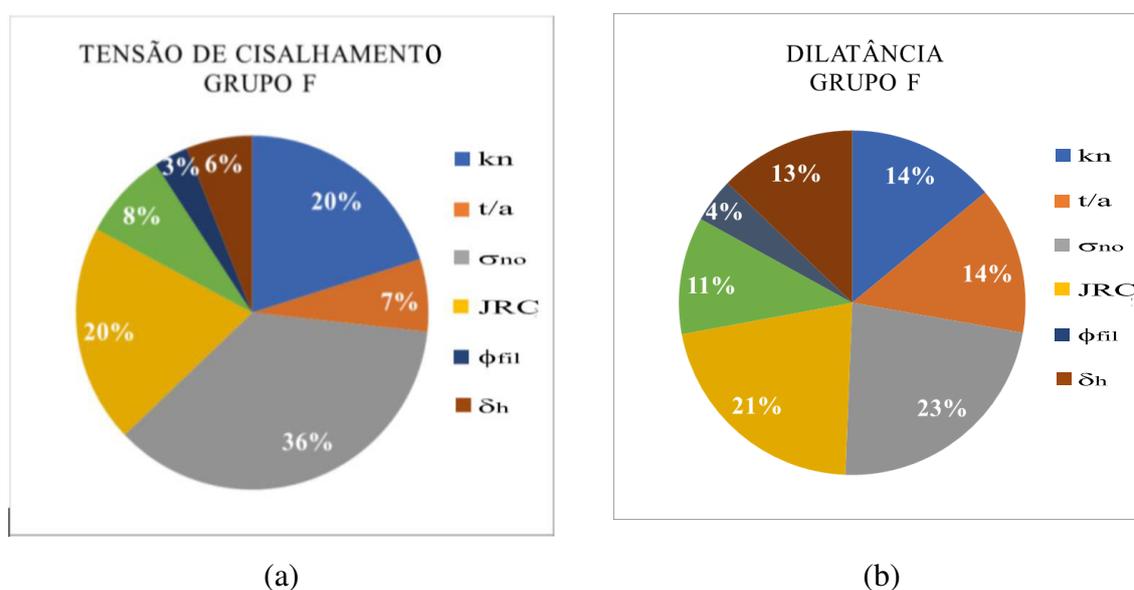
Fonte: Autora.

Como havia sido apresentado na Tabela 4.1, a supressão da σ_c , como variável de entrada dos modelos neuronais do Grupo F, não afetou tanto a eficiência da rede quanto a supressão do ϕ_b fez nos Grupos D e E. Eficiência essa relacionada a quantidade de grupos que alcançaram um correlação para dados de teste maior que 95%.

Levando em consideração as equações da Tabela 2.1 para previsão da tensão cisalhante, observa-se que apenas dois, dos 27 modelos não levam em consideração ϕ_b ou ϕ_r , enquanto a quantidade de modelos que não levam σ_c é maior, levando a crer que a percepção da variável ϕ_b como essencial é geral. Também pode ser levado em consideração que ensaios de cisalhamento direto normalmente levam uma relação de σ_{no} / σ_c implícita, que pode ter feito com que a ausência da variável não influenciasse tanto a rede.

Sobre a contribuição das variáveis de entrada para previsão da tensão cisalhante (Figura 4.12a), a retirada de σ_c , quando comparada ao grupo B, fez com que as contribuições da JRC e k_n aumentassem em média de 7%, ϕ_b aumentou 3% e as demais não alteraram; a influência da σ_{no} permaneceu a mesma, diferente do que aconteceu na retirada do ϕ_b no Grupo D. Sobre a dilatação houve um aumento principalmente no JRC e σ_{no} e ϕ_{fill} , as demais permaneceram praticamente constantes (Figura 4.12b).

Figura 4.12 – Contribuição média das variáveis de entrada para previsão da tensão cisalhante e dilatação das três arquiteturas com maior correlação com dados de teste do Grupo F



4.2 Comparação entre as melhores arquiteturas

Foram selecionadas 5 arquiteturas, as melhores do Grupo A, Grupos A2, Grupo B, Grupo B2 e Grupo C, por terem obtido melhor interpolação com os gráficos experimentais e os valores de correlação para dados de teste estarem entre os três maiores do grupo. Essas melhores arquiteturas são apresentadas na Tabela 4.9.

Tabela 4.9 – Melhores arquiteturas dos grupos A, A2, B, B2, C

Grupo	Arquitetura	Número de Iterações
A	8-20-10-5-2	500.000
A2	8-30-10-2	500.000
B	8-30-15-2	200.000
B2	8-30-15-5-2	500.000
C	8-30-15-2	300.00

Fonte: Autora.

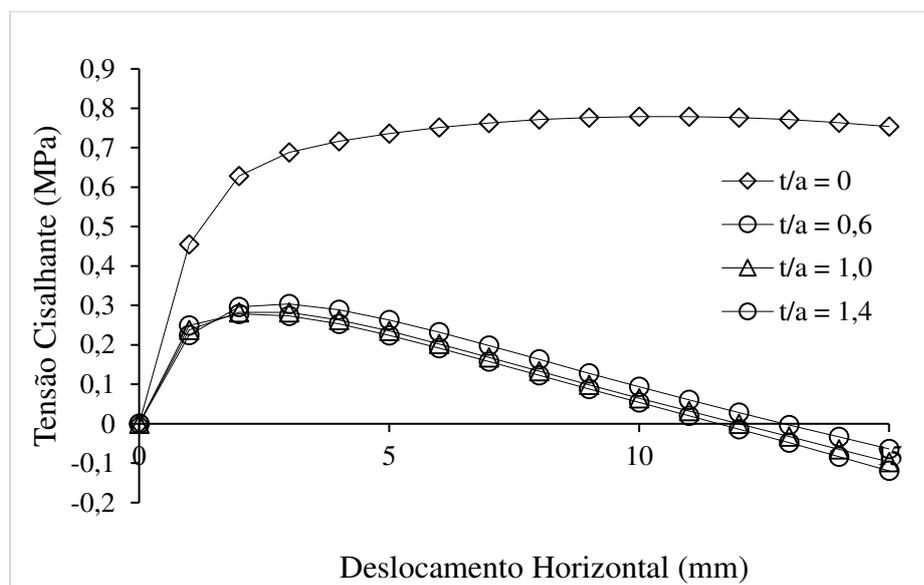
Para avaliar as arquiteturas e validar os modelos, uma junta fictícia, baseada na apresentada por Dantas Neto *et al.* (2017), foi testada. Essa junta teve como objetivo fim, verificar se os modelos neuronais eram capazes de expressar a influência das variáveis de entrada governantes no comportamento de cisalhamento de descontinuidades hipotéticas de rochas limpas e preenchidas.

Sobre a junta hipotética, as variáveis constantes foram: $\sigma_c = 12\text{MPa}$, $JRC = 5$, $\phi_b = 37,5^\circ$ e $\phi_{fill} = 35,5^\circ$. As variáveis de entrada foram as mesmas usadas em Dantas Neto *et al.* (2017), com exceção de ϕ_{fill} , que foi usado um valor médio dentre os usados no treinamento dos modelos neuronais.

Dentre as arquiteturas testadas, a única que demonstrou coerência em todas as variáveis de entrada foi a 8-20-10-5-2 do Grupo A com 500.000 iterações, sendo esta portanto, o grupo escolhido para previsão da variação da tensão cisalhante e dilatância com deslocamento horizontal de descontinuidades rochosas com e sem preenchimento, sob CNL e CNS. As demais apresentaram problemas na compreensão das variáveis.

A arquitetura 8-30-10-2 do Grupo A2, ao ser testada em uma descontinuidade hipotética sob CNL, com σ_{no} de 5MPa, não apresentou boa compreensão da variação do t/a . Era esperado que houvesse uma variação maior entre $t/a = 0,6$, $t/a = 1,0$ e $t/a = 1,4$, o que não aconteceu, conforme apresentado na Figura 4.13.

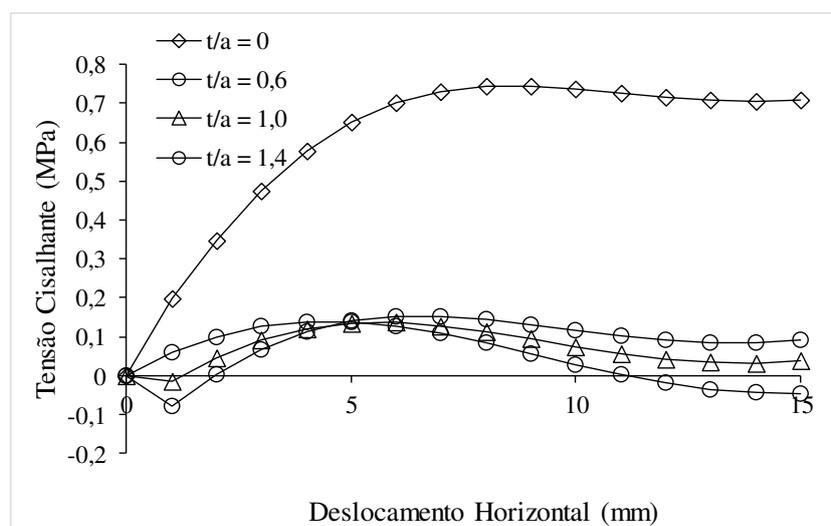
Figura 4.13 – Grupo A2, com arquitetura 8-30-10-2 sob CNL com variação dos valores de t/a para junta hipotética



Fonte: Autora.

A arquitetura 8-30-15-2 do Grupo B, ao ser testada em uma descontinuidade hipotética sob CNL, com σ_{no} de 5MPa, assim como o ocorrido na arquitetura 8-30-10-2 do Grupo A2, não apresentou boa compreensão na variação do t/a . Era esperado que houvesse uma variação maior entre $t/a = 0,6$, $t/a = 1,0$ e $t/a = 1,4$, o que aconteceu mas só após os mesmos terem tido uma conversão em um ponto incomum, que não apresenta significado físico para justificar (Figura 4.14).

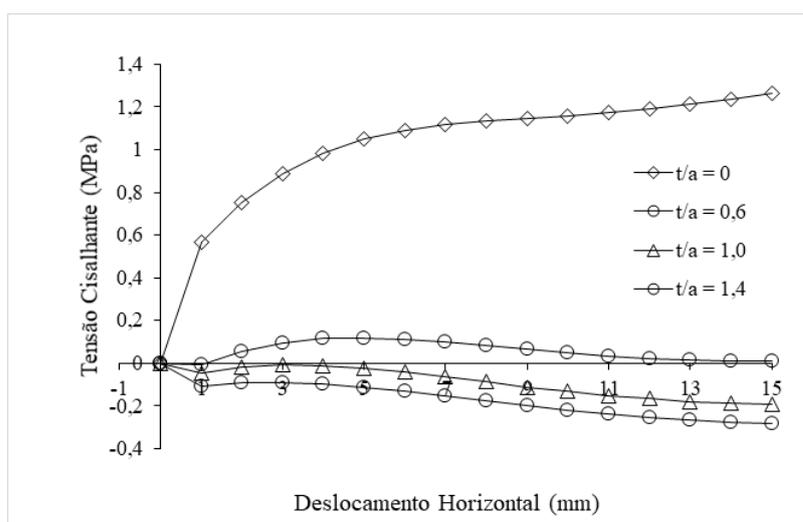
Figura 4.14 – Grupo B, com arquitetura 8-30-15-2 sob CNL com variação dos valores de t/a para junta hipotética



Fonte: Autora.

A arquitetura 8-30-15-5-2 do Grupo B2, ao ser testada em uma descontinuidade hipotética sob CNL, com σ_{no} de 5MPa, assim como o ocorrido na arquitetura 8-30-10-2 do Grupo A2 e 8-30-15-2 do Grupo B, não apresentou boa compreensão da variação do t/a . Nessa a falta de compreensão é grave pois, levou a tensões negativas para a previsão da variação da tensão cisalhante com deslocamento horizontal (Figura 4.15).

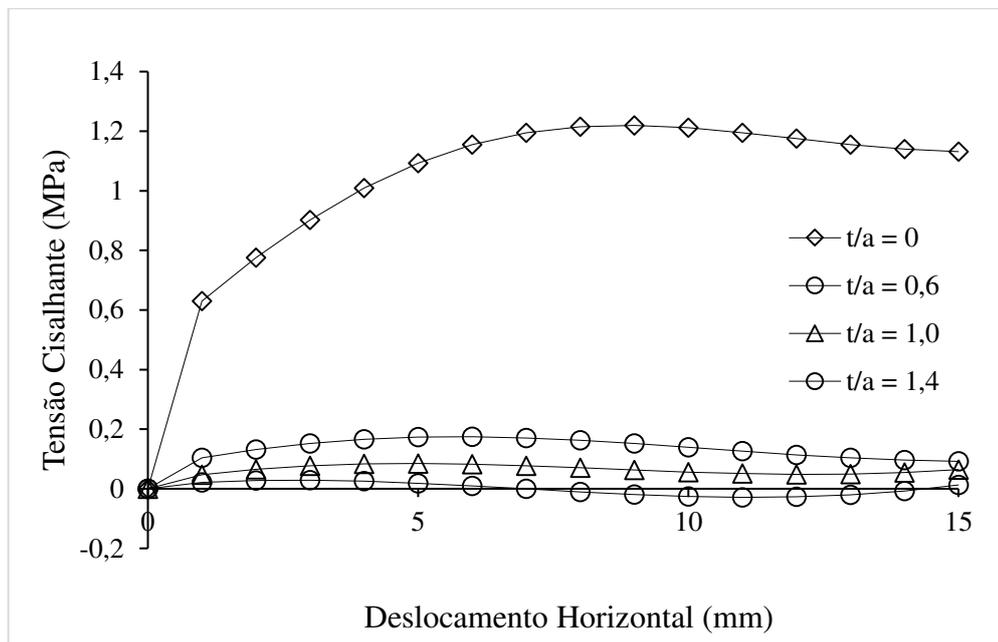
Figura 4.15 – Grupo B2, com arquitetura 8-30-15-5-2 sob CNL com variação dos valores de t/a para junta hipotética.



Fonte: Autora.

A arquitetura 8-30-15-2 do Grupo C, ao ser testada em uma descontinuidade hipotética sob CNL com σ_{no} de 5MPa, assim como o ocorrido na arquitetura 8-30-10-2 do Grupo A2, 8-30-15-2 do Grupo B e 8-30-15-5-2 do Grupo B2, não apresentou boa compreensão da variação do t/a . Assim como na arquitetura 8-30-15-5-2 do Grupo B2, essa falha na compreensão foi grave por resultar em tensões cisalhantes negativas (Figura 4.16).

Figura 4.16 – Grupo C, com arquitetura 8-30-15-5-2 sob CNL com variação dos valores de t/a para junta hipotética.



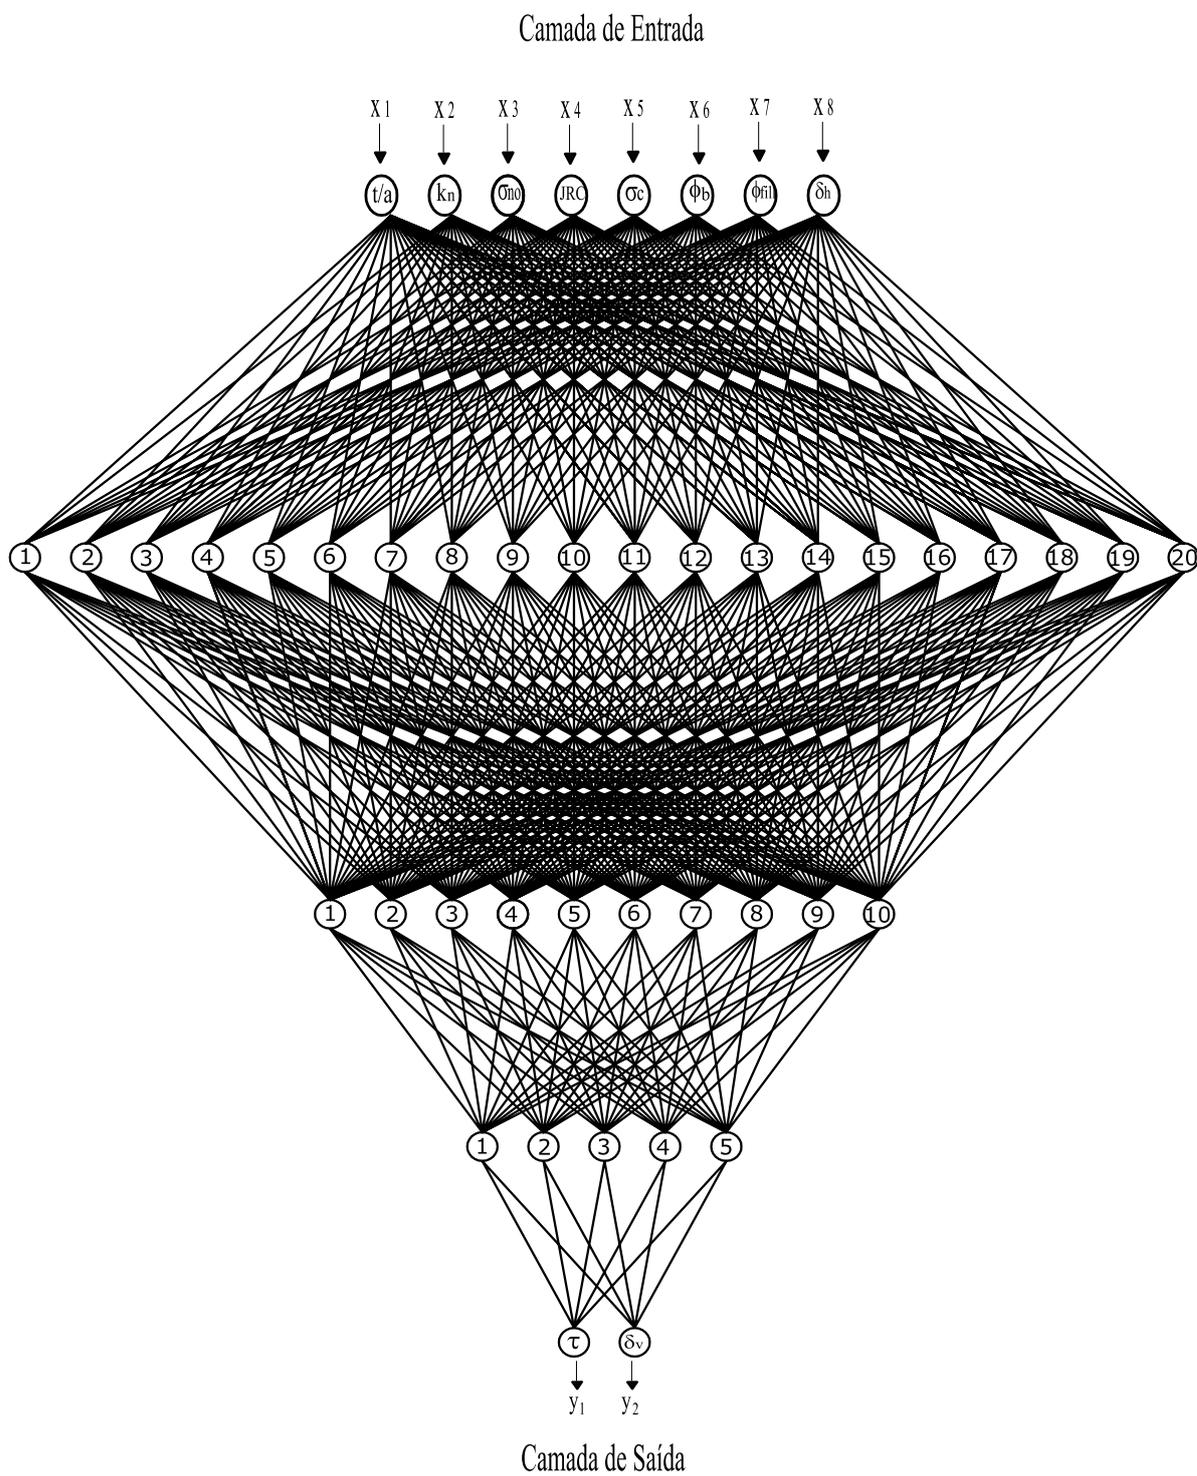
Fonte: Autora.

Como citado anteriormente, o modelo escolhido foi o de arquitetura 8-20-10-5-2 do Grupo A com 500.000 iterações, para previsão da variação da tensão cisalhante e dilatância com deslocamento horizontal de discontinuidades rochosas com e sem preenchimento, sob CNL e CNS. Este será apresentado a seguir em detalhes.

4.3 Modelo selecionado para previsão da variação da tensão cisalhante e dilatância com deslocamento horizontal

Com base nas análises anteriores, o modelo de RNA com melhor desempenho foi o do Grupo A com uma arquitetura 8-20-10-5-2, doravante chamado de Gm. Este teve seus pesos sinápticos obtidos e bias calculados após 500 mil iterações, e seu coeficiente de correlação na fase de treinamento foi de 99,3% e de teste de 99,0%, o que mostra uma boa concordância entre as previsões e os valores-alvo de tensão de cisalhamento e dilatância em todos os valores existentes no banco de dados de aprendizado. A Figura 4.17 mostra a arquitetura do modelo usada onde as respostas dos neurônios são calculadas usando a função sigmoideal apresentada na Eq. 3.7 e os pesos sinápticos apresentados nas, Tabela 4.11, Tabela 4.12, Tabela 4.13.

Figura 4.17 – Modelo neuronal de arquitetura 8-20-10-5-2



Fonte: Autora.

Tabela 4.10 – Pesos sinápticos e Bias da Camada Intermediária 1

	pesos sinápticos	Variáveis de Entrada								Bias
		X1	X2	X3	X4	X5	X6	X7	X8	
Camada Intermediária 1	1	-0,567	-0,448	1,409	-8,854	5,154	-0,706	0,649	0,443	-0,029
	2	0,875	0,323	3,331	0,703	2,397	-0,040	0,664	-0,847	-1,295
	3	-0,771	-0,456	-1,318	-4,166	-2,425	-0,393	-0,565	1,794	1,024
	4	-1,499	0,288	2,228	1,153	-0,186	1,031	-0,445	-0,161	-1,364
	5	0,288	-3,031	0,481	-0,537	-0,591	3,256	-1,292	-0,884	2,348
	6	-1,692	1,534	2,402	-5,548	-4,316	3,479	1,551	0,637	1,176
	7	2,265	-0,266	4,605	0,075	2,884	-0,593	0,374	0,033	-1,487
	8	-1,176	0,459	-1,751	3,742	0,507	-5,000	-0,864	0,411	-1,402
	9	-0,741	0,164	1,069	1,283	0,860	0,421	-0,258	-10,044	-0,178
	10	1,961	-0,682	2,798	-0,583	0,366	1,082	-1,274	-0,547	0,738
	11	-1,084	0,231	0,298	0,469	-1,226	1,718	-1,303	-0,211	-0,401
	12	-0,583	-0,258	-8,651	5,609	-2,532	0,743	-2,100	3,481	0,009
	13	-1,977	-1,352	-3,516	-0,527	0,702	-1,459	-0,216	2,270	0,633
	14	1,763	0,712	-1,999	-2,689	1,641	1,688	0,652	-1,152	-1,114
	15	-1,643	-1,011	-1,092	1,098	-1,902	1,558	-1,536	0,063	-0,956
	16	-0,017	0,203	-0,798	-2,063	0,084	-0,802	0,780	12,109	-0,130
	17	-3,248	-0,649	-4,410	-1,451	-3,267	0,879	0,756	-1,916	2,938
	18	0,384	-1,445	2,204	-4,186	-1,987	0,327	0,721	2,194	-0,155
	19	-2,756	-0,005	-1,260	0,152	-1,444	-1,604	1,384	-4,367	1,490
	20	1,772	-0,494	2,020	-0,993	-0,360	-0,178	-1,509	-1,009	0,404

Fonte: Autora.

Tabela 4.11 – Pesos sinápticos e Bias da Camada Intermediária 2

pesos sinápticos		Camada Intermediária 2									
		1	2	3	4	5	6	7	8	9	10
Camada Intermediária 1	1	-4,126	-1,661	-2,658	2,262	-2,165	0,620	3,590	4,380	2,236	-0,306
	2	-0,448	0,454	0,311	1,660	1,319	1,077	1,886	3,657	2,894	-0,728
	3	-1,251	-0,939	1,718	-1,277	-1,746	0,823	-0,921	-1,612	-1,477	-0,999
	4	1,941	1,663	-0,034	0,432	1,119	-0,572	-0,485	1,505	1,614	0,033
	5	0,664	1,004	1,004	-1,172	-1,622	-0,199	1,114	-1,494	-1,647	-0,116
	6	-2,364	1,849	-1,787	-1,849	-2,549	-3,082	-2,597	1,755	-0,690	0,215
	7	0,427	-0,283	-0,061	0,192	1,537	2,015	2,240	4,842	2,529	0,148
	8	0,213	-2,161	-1,982	4,149	-1,219	0,214	-0,509	0,848	1,562	-1,151
	9	0,419	0,186	3,631	1,590	0,542	-0,323	0,226	3,422	2,469	-5,684
	10	0,810	0,545	1,591	-1,493	-0,102	0,723	0,323	2,815	0,708	-0,564
	11	0,407	0,824	-0,507	0,329	0,186	-1,389	-1,628	0,279	0,476	-0,297
	12	-2,872	-1,470	0,509	0,953	-1,334	-3,214	0,517	-4,444	-3,241	1,955
	13	-0,632	-0,191	-0,317	-0,991	-0,889	0,054	1,102	-2,792	-0,844	2,846
	14	-3,305	-0,763	1,807	0,468	-0,638	-0,232	1,767	0,328	-0,072	0,036
	15	1,695	0,683	-0,684	-0,577	0,659	-0,973	-2,176	-0,822	-0,270	0,678
	16	7,118	-1,657	-2,108	-0,889	2,551	1,646	-0,238	0,864	0,047	4,229
	17	-1,572	0,076	2,447	-0,822	-1,162	-0,073	-1,547	-5,206	-2,287	-1,289
	18	0,552	-1,637	1,170	-2,793	-1,376	1,628	-0,691	0,474	-1,754	-0,868
	19	-4,097	0,131	1,401	0,863	-1,548	0,285	-0,641	-2,299	-0,560	-2,161
	20	-0,288	0,752	-0,119	-1,519	-1,817	-0,538	0,362	2,308	0,366	-1,521
Bias		-0,305	0,446	0,469	0,757	-0,004	0,596	0,361	1,086	1,418	-0,641

Fonte: Autora.

Tabela 4.12 – Pesos sinápticos e Bias da Camada Intermediária 3

		Camada Intermediária 3				
		1	2	3	4	5
Camada Intermediária 2	pesos sinápticos					
	1	1,71321	-3,6088	-1,57599	-3,04503	-3,48155
	2	-0,58428	-0,47798	-0,59742	0,93225	4,22766
	3	1,67309	0,57314	-3,69012	1,29331	-2,65313
	4	-2,22098	-0,84125	5,64426	0,92959	2,56717
	5	3,20625	-2,73038	-0,93794	0,95659	-0,78703
	6	4,04767	1,17354	-0,53868	1,60076	-0,1053
	7	1,00365	2,76552	1,88184	4,97104	2,01485
	8	4,27044	-1,15528	6,50979	-2,3014	-1,97953
	9	1,39333	2,08672	3,83486	-0,36313	-1,55574
10	-3,80926	0,32331	-0,60698	-0,0681	2,31898	
Bias		-3,41687	1,96519	-0,27116	1,65226	1,84653

Fonte: Autora.

Tabela 4.13 – Pesos sinápticos e Bias da Camada de saída

Saída	Camada Intermediária 3					Bias
	1	2	3	4	5	
Tensão cisalhante	6,272	-3,182	-1,53772	-2,03	-6,307	3,2631
Dilatância	3,605	-3,545	-8,79043	5,779	0,5465	2,0705

Fonte: Autora.

Da influência das variáveis de entrada, a Tabela 4.14 apresenta as contribuições para previsão da tensão cisalhante e da dilatância da rede escolhida. Para tensão cisalhante teve-se o k_n , σ_{no} , como variáveis de maior relevância sendo a soma delas igual à 47% da contribuição total. Sobre a contribuição da dilatância, a influência das variáveis de entrada ocorreu de forma mais equilibrada, para esta houve o aumento da influência de t/a e diminuição considerável da σ_{no} quando comparado seu efeito na tensão cisalhante.

Tabela 4.14 – Contribuição percentual de cada variável para previsão do cisalhamento e da dilatância para Gm.

Saída	k_n	t/a	σ_{no}	JRC	σ_c	φ_b	φ_{fill}	δ_h
Tensão Cisalhante	23	5	24	12	15	10	4	6
Dilatância	9	17	13	17	16	12	4	12

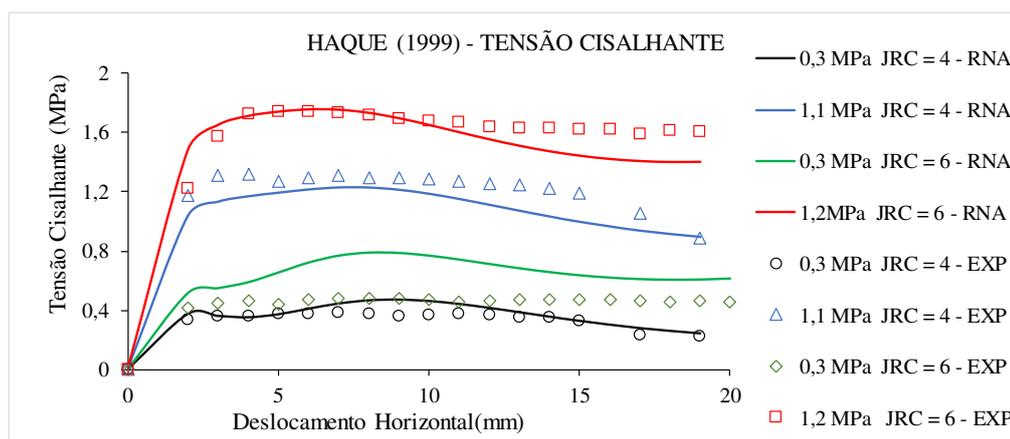
Fonte: Autora.

4.3.1 Comparação dos resultados obtidos pelo modelo escolhido com os dados experimentais usados na elaboração do modelo

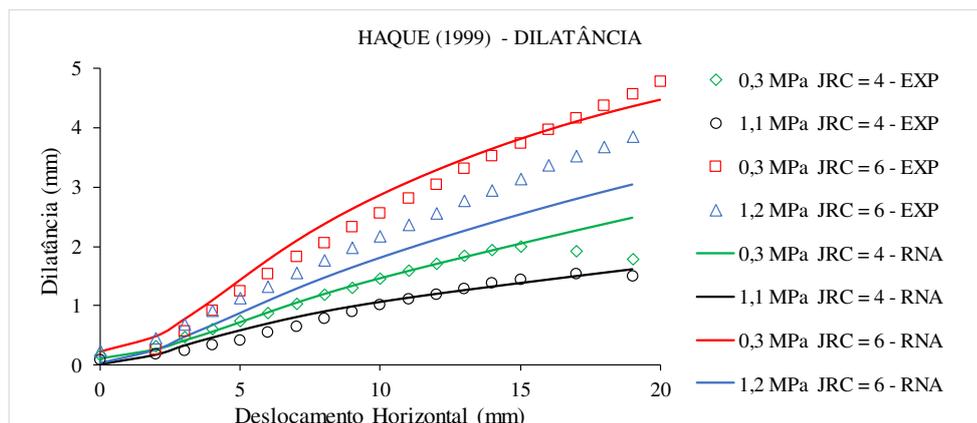
Com o intuito de avaliar se o modelo escolhido era capaz de compreender a influência da variação dos parâmetros entrada no comportamento da tensão cisalhante e dilatância no decorrer do deslocamento horizontal, ensaios de Benmokrane e Ballivy (1989), Haque (1999), Oliveira *et al.* (2009), Mehrishal *et al.* (2016) e Shrivastava e Rao (2017) foram usados. Esses ensaios foram alguns dos usados para desenvolvimento do modelo.

A Figura 4.18 apresenta resultados de ensaios de cisalhamento direto de Haque (1999) comparados com as previsões do modelo Gm. Nessa têm-se os gráficos de ensaios sob CNL de juntas não preenchidas mudando-se os valores da tensão normal inicial e o JRC. Para Figura 4.18a pode-se observar a boa compreensão do modelo neuronal para variação da tensão normal inicial e variação do JRC, em sua forma não-linear. O modelo compreende que quanto maior tensão normal, maior será tensão cisalhante desenvolvida, como esperado pela literatura (Capítulo 2) e mesma coisa para JRC. A mudança também teve resultados esperados para dilatância. Modelo apresentou uma aceitável interpolação com os gráficos experimentais.

Figura 4.18 – Comparação entre os resultados do ensaio de cisalhamento direto de Haque (1999) com os previstos pelo modelo Gm.



(a)



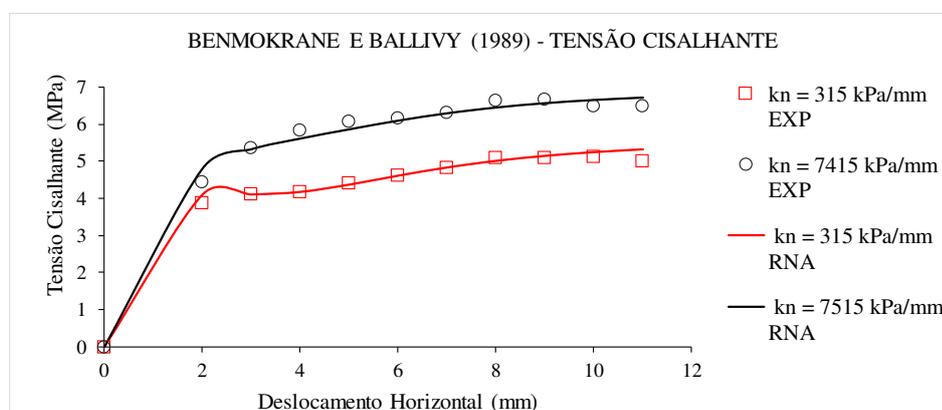
(b)

Fonte: Autora.

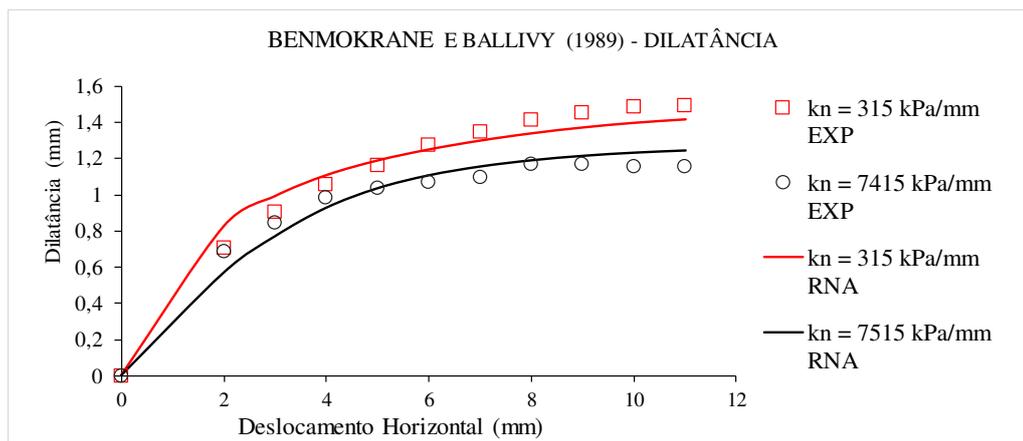
A Figura 4.19 apresenta resultados dos ensaios de cisalhamento direto de Benmokrane e Ballivy (1989), comparados com as previsões do modelo Gm. Esses são ensaios de cisalhamento direto sob CNS de juntas não preenchidas mudando-se os valores da rigidez normal. Vale ressaltar a diferença entre o ensaio de Benmokrane e Ballivy (1989) e Haque (1999), a capacidade da rede Gm interpretar ambos, mesmo se tratando de rochas brandas e duras e ensaios sob CNL e CNS, enaltece a robustez das RNA.

Na Figura 4.19 pode-se observar a boa compreensão do modelo neuronal para variação consideravelmente alta da variável de entrada kn em um exemplo de ensaio sob CNS. A rede Gm demonstrou prever adequadamente a influência do kn nesse exemplo, seguindo o esperado apontado pelo Capítulo 2, maiores valores de rigidez gerando maiores tensões cisalhantes e menores dilatâncias.

Figura 4.19 – Comparação entre os resultados do ensaio de cisalhamento direto de Benmokrane e Ballivy (1989) com os previstos pelo modelo Gm.



(a)

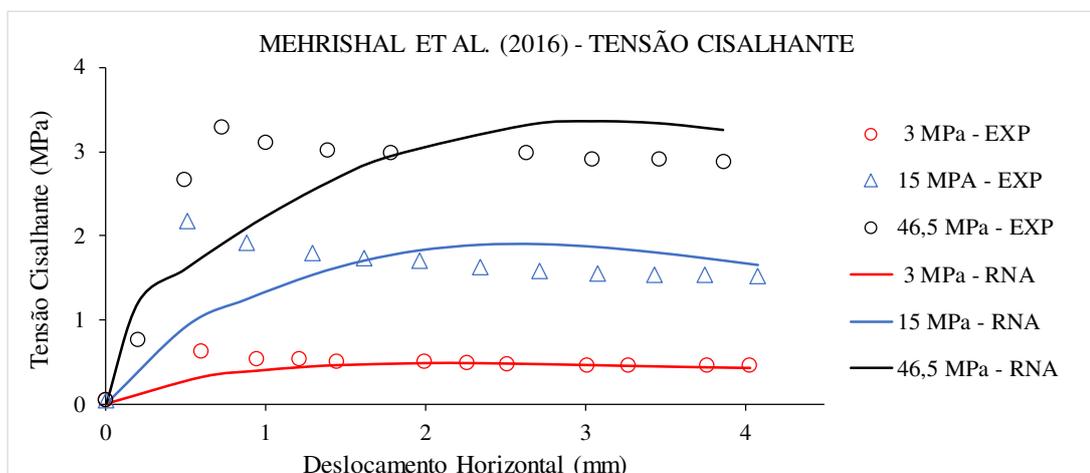


(b)

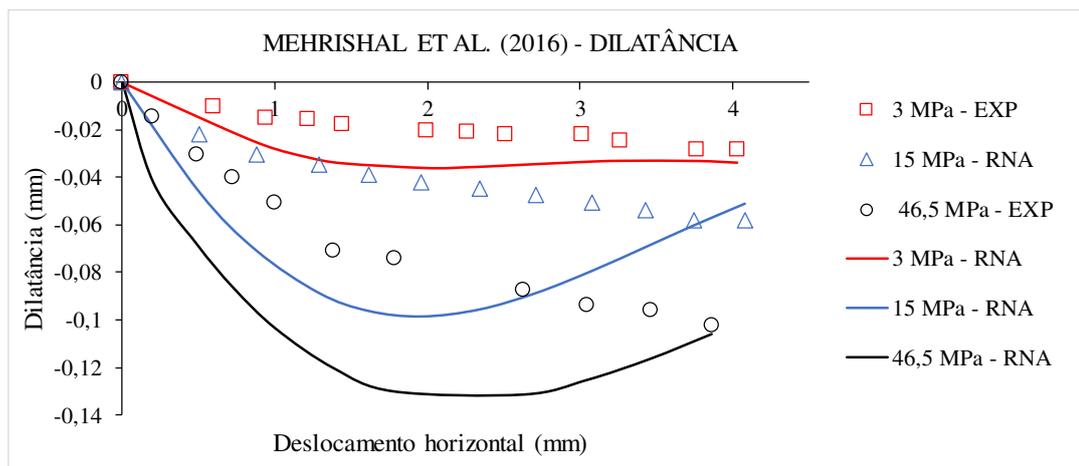
Fonte: Autora.

Na Figura 4.20 tem a comparação dos resultados dos ensaios de cisalhamento direto de Mehrishal *et al.* (2016) com a rede Gm. Esses ensaios correspondem a juntas sob CNL não preenchidas. A particularidade desse ensaio se dá pelas altas resistência a compressão uniaxial das rochas (150 MPa). Embora sendo valores altos e fora da faixa dos restantes usados, o modelo Gm apresentou boa compreensão para variação da tensão cisalhante (Figura 4.20a), apesar de não ter seguido exatamente o mesmo caminho de gráfico, os valores máximos atingidos foram semelhantes. Para a dilatação (Figura 4.20b) o modelo não apresentou boa interpolação.

Figura 4.20 – Comparação entre os resultados do ensaio de cisalhamento direto de Mehrishal *et al.* (2016) com os previstos pelo modelo Gm.



(a)

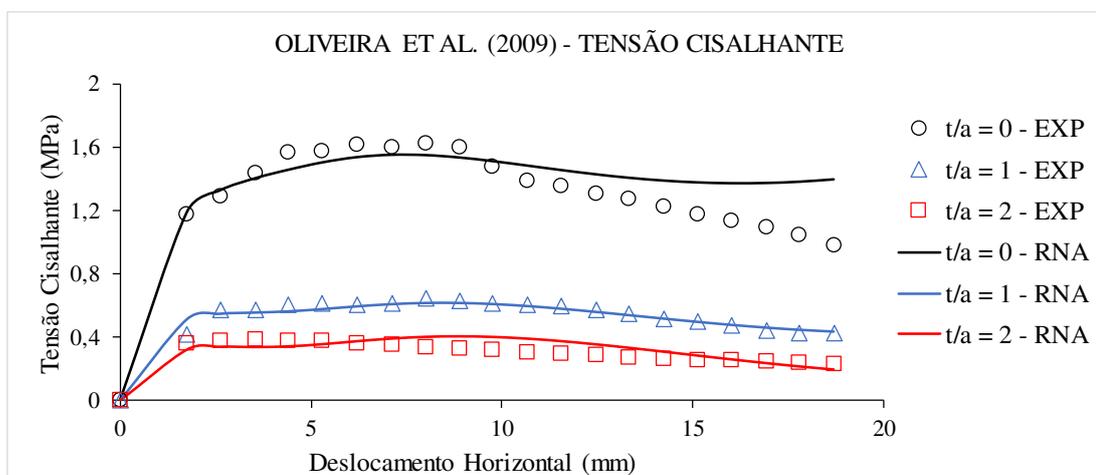


(b)

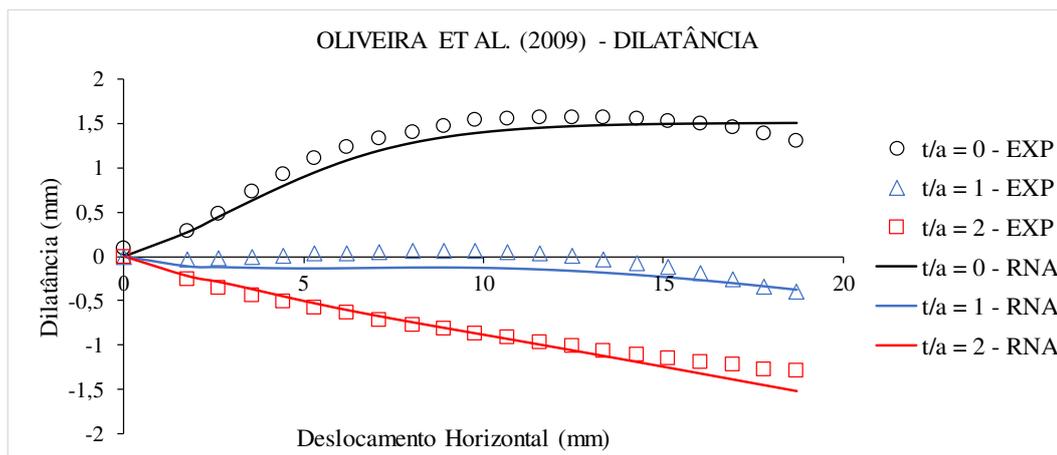
Fonte: Autora.

A Figura 4.21 apresenta a comparação entre os resultados do ensaio de cisalhamento direto de Oliveira *et al.* (2009) com os previstos pelo modelo Gm. Essa comparação se dá em descontinuidades com preenchimento, e pode-se observar a boa compreensão do modelo neuronal para variação para variação dos valores de t/a . Foi obtida uma diminuição da tensão cisalhante e dilatação com aumento do t/a conforme o esperado descrito no Capítulo 2. Além disso, a previsão do modelo neuronal obteve uma boa interpolação com os dados experimentais.

Figura 4.21 – Comparação entre os resultados do ensaio de cisalhamento direto de Oliveira *et al.* (2009) com os previstos pelo modelo Gm.



(a)

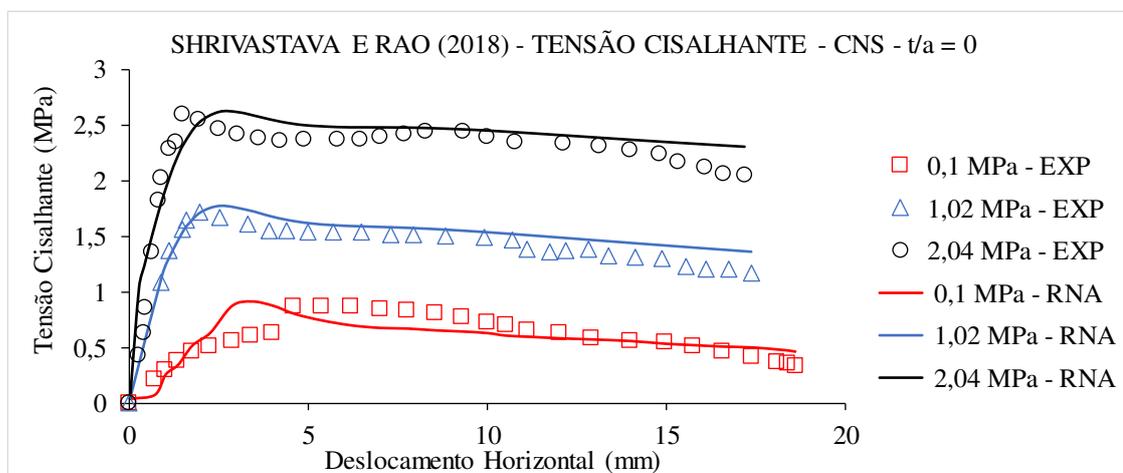


(b)

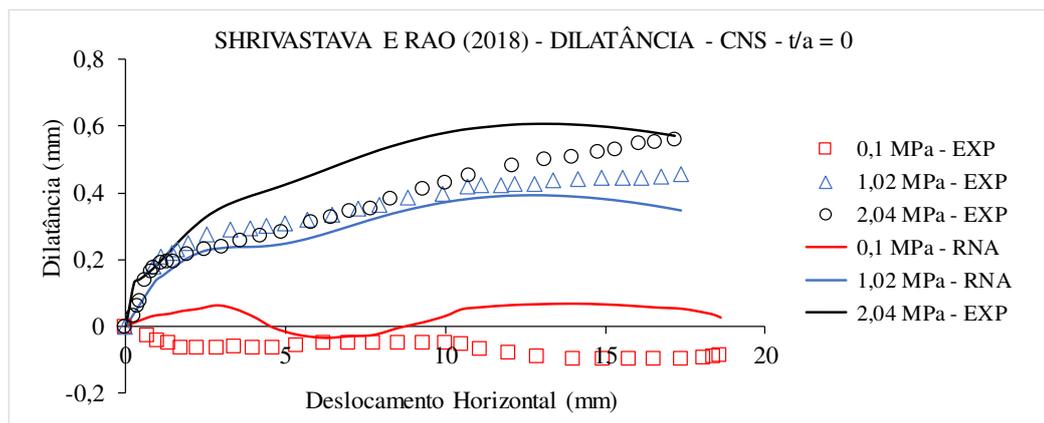
Fonte: Autora.

As Figura 4.22 e Figura 4.23 apresentam resultados dos ensaios de cisalhamento direto em juntas sob CNL e CNS com e sem preenchimento de Shrivastava e Rao (2017), comparados com as previsões resultantes do modelo Gm. Nessas comparações a rede Gm gerou uma boa interpolação para variação da tensão cisalhante com deslocamento horizontal, já a dilatação não teve uma interpolação tão boa, mas alcançado os valores máximo e mínimo dos dados experimentais.

Figura 4.22 – Comparação entre os resultados do ensaio de cisalhamento direto sob CNS de descontinuidade sem preenchimento de Shrivastava e Rao (2017) com os previstos pelo modelo Gm.



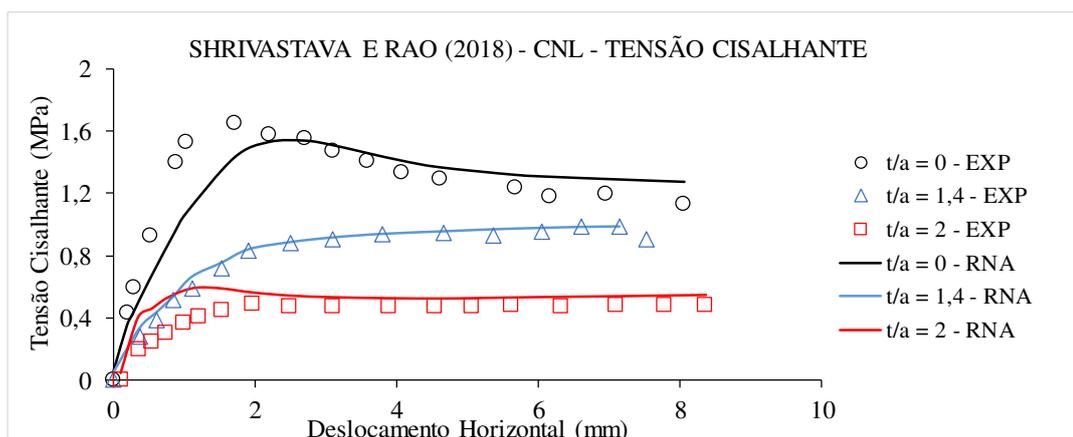
(a)



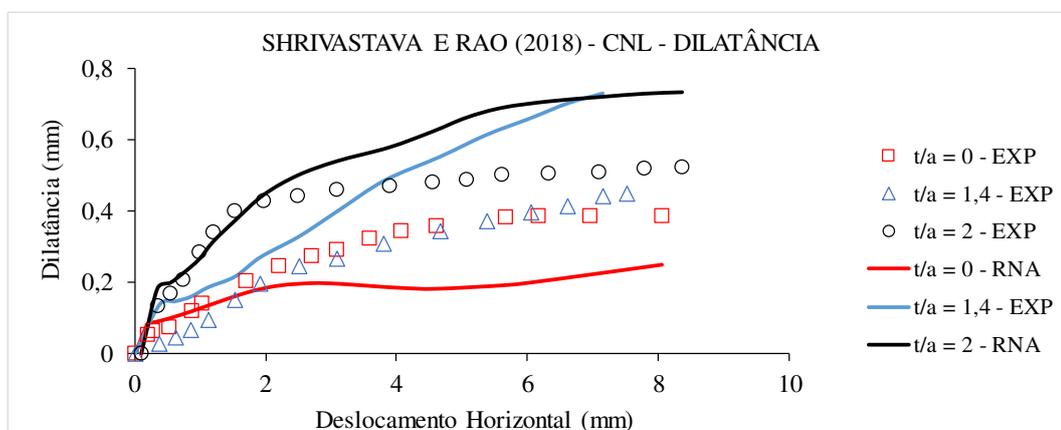
(b)

Fonte: Autora.

Figura 4.23 – Comparação entre os resultados do ensaio de cisalhamento direto em descontinuidade sob CNL com preenchimento de Shrivastava e Rao (2017) com os previstos pelo modelo Gm.



(a)



(b)

Fonte: Autora.

Os resultados das previsões da variação da tensão cisalhante e dilatância com deslocamento horizontal, em geral apresentaram uma boa interpolação aos dados experimentais, assim como uma boa compreensão das variáveis de entrada. A variação da tensão normal inicial aplicada, JRC, t/a , rigidez normal no comportamento CNS, e comportamento CNL, influenciaram na previsão conforme esperado a partir do Capítulo 2. Houve exceções quanto a interpretação da dilatância, houve casos que a interpolação não foi como o esperado, contudo a previsão do Gm em geral alcançou os máximos e mínimos dos ensaios.

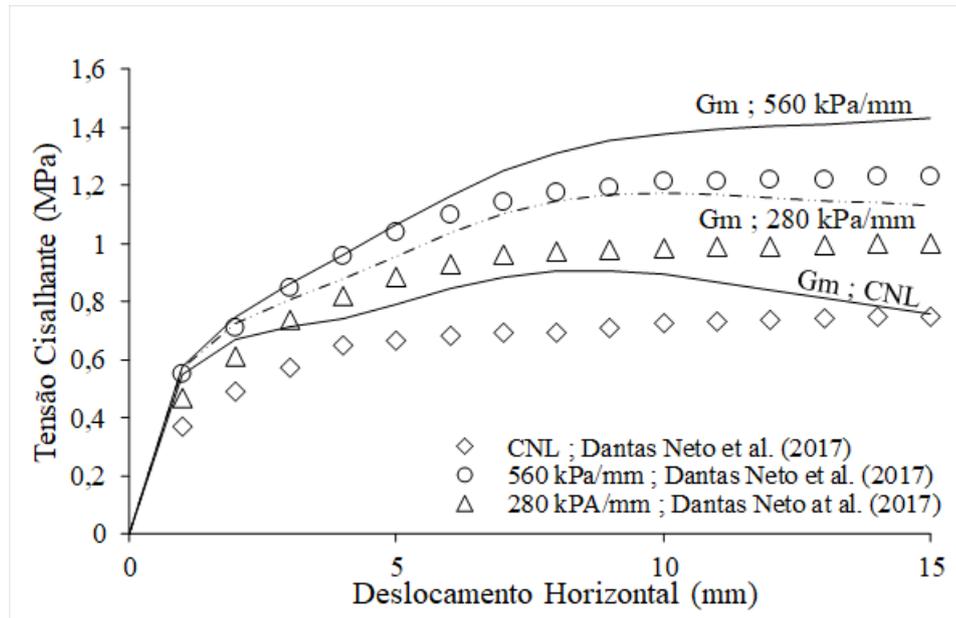
4.3.2 Avaliação dos resultados obtidos pelo modelo escolhido com uma junta hipotética

As comparações do Item 4.3.1 foram realizadas com alguns dos ensaios usados para o desenvolvimento do próprio modelo neuronal Gm. Para validação do modelo, foi usada uma junta hipotética, baseada na usada em Dantas Neto *et al.* (2017), para determinar se o modelo neuronal tinha a capacidade de expressar a influência das variáveis de entrada governantes no comportamento referente a variação da tensão cisalhante e dilatância com decorrer da variação do deslocamento horizontal.

A descontinuidade tinha como parâmetros principais os mesmos usados em Dantas Neto *et al.* (2017), ou seja: $JRC = 5$, $\sigma_c = 12$ MPa e $\phi_b = 37.5^\circ$. Para a descontinuidade com preenchimento, foi usado $\phi_{fill} = 35.5^\circ$ por ser um valor médio entre os usados no desenvolvimento do modelo.

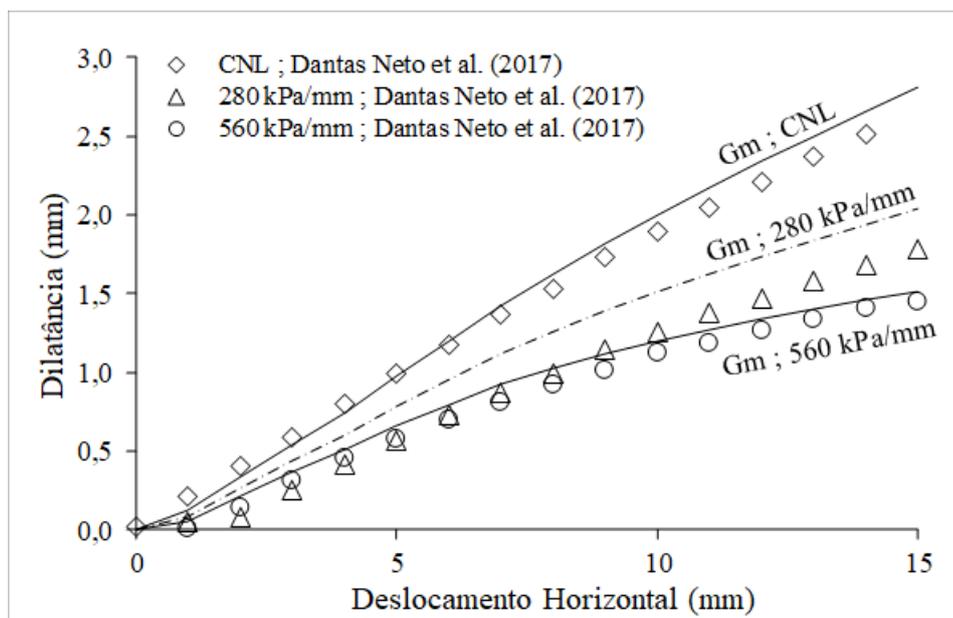
Visando verificar a resposta da previsão do modelo com a variação da tensão cisalhante (Figura 4.24) e dilatância (Figura 4.25). pelo deslocamento horizontal, com a mudança da condição do contorno da descontinuidade, a descontinuidade hipotética foi avaliada sob CNL, sob CNS com $kn = 280$ kPa/mm e com $kn = 560$ kPa/mm. Os resultados não só foram coerentes com os esperados segundo Capítulo 2, mas também apresentaram um resultado semelhante aos obtidos em Dantas Neto *et al.* (2017).

Figura 4.24 – Resultados da rede Gm para previsão das tensões cisalhantes das descontinuidades hipotéticas comparadas aos resultados do modelo neuronal de Dantas Neto *et al.* (2017), para variação das condições de contorno.



Fonte: Autora.

Figura 4.25 – Resultados da rede Gm para previsão das dilatâncias das descontinuidades hipotéticas comparadas aos resultados do modelo neuronal de Dantas Neto *et al.* (2017), para variação das condições de contorno.

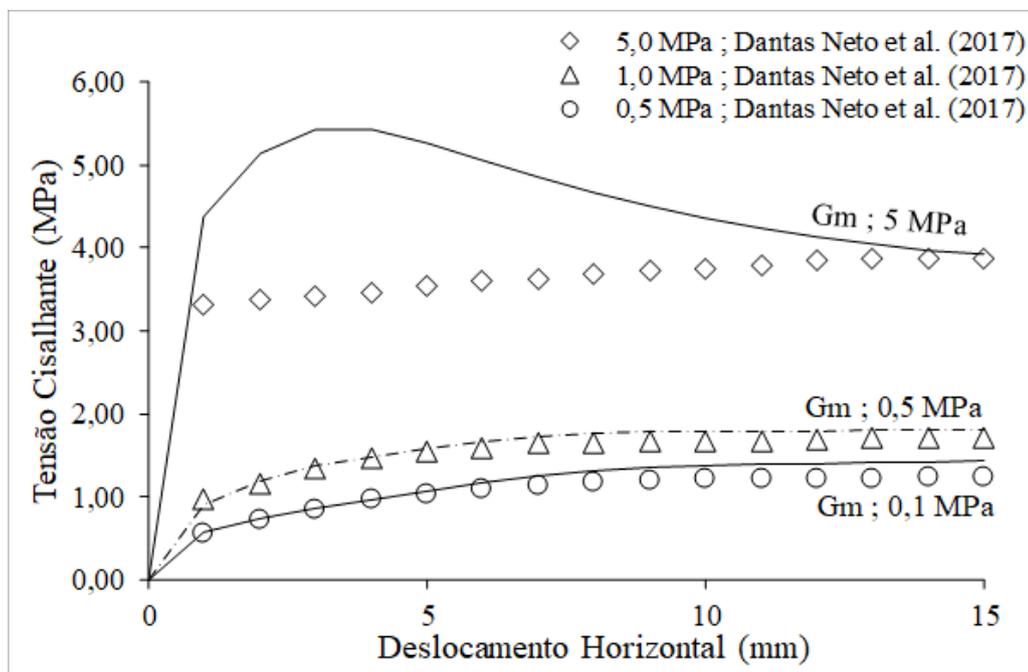


Fonte: Autora.

Visando verificar a resposta da previsão do modelo com a variação da tensão cisalhante e dilatância pelo deslocamento horizontal, com a mudança da tensão inicial normal aplicada, a descontinuidade hipotética foi avaliada sob CNL, sob para tensões normais de 0,5 MPa, 1,0 MPa, 5,0 MPa. Os resultados de previsão da rede Gm, foram coerentes aos esperados, maior tensão cisalhante (Figura 4.26) com aumento da tensão normal, e semelhante aos encontrados em Dantas Neto *et al.* (2017), maior tensão normal também resultando em menor dilatância (Figura 4.27).

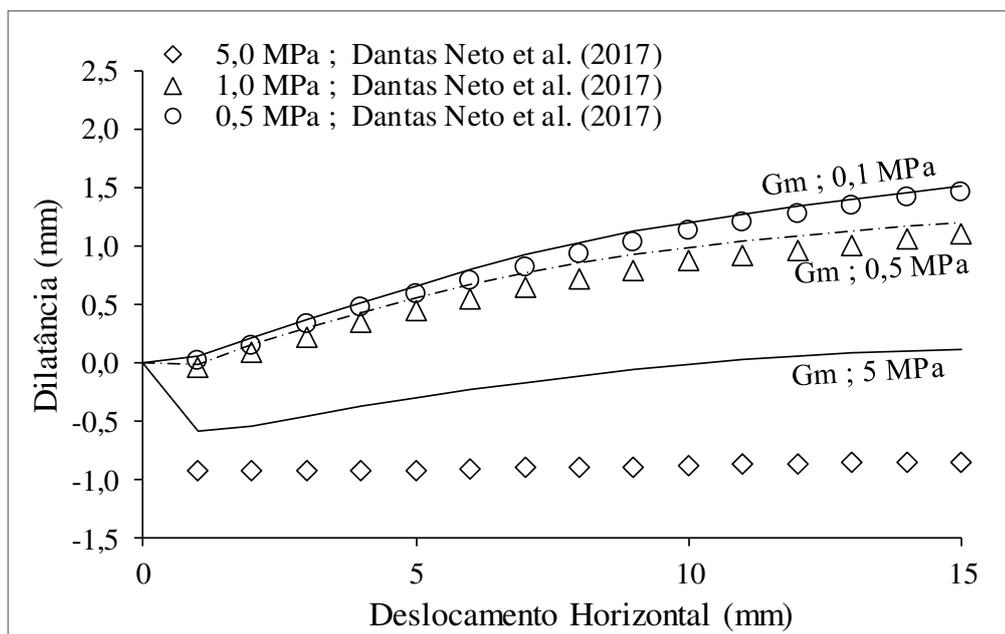
Na Figura 4.26, para o modelo de GM, ao ser aplicada de 5,0 MPa, a tensão cisalhante subiu até um certo pico, seguidamente tendendo à um valor residual semelhante ao de Dantas Neto *et al.* (2017); enquanto a dilatância apresentou um certo acréscimo, após a queda. Esse resultado pode ter ocorrido devido ao modelo ter interpretado a quebra da aspereza. Sendo a razão σ_{no}/σ_c igual à 0,42, valor esse dentro da faixa que Ladanyi e Archambault (1977) consideram a quebra da aspereza.

Figura 4.26 – Resultados da rede Gm para previsão das tensões cisalhantes das descontinuidades hipotéticas comparadas aos resultados do modelo neuronal de Dantas Neto *et al.* (2017). Para variação nas tensões normais iniciais aplicadas.



Fonte: Autora.

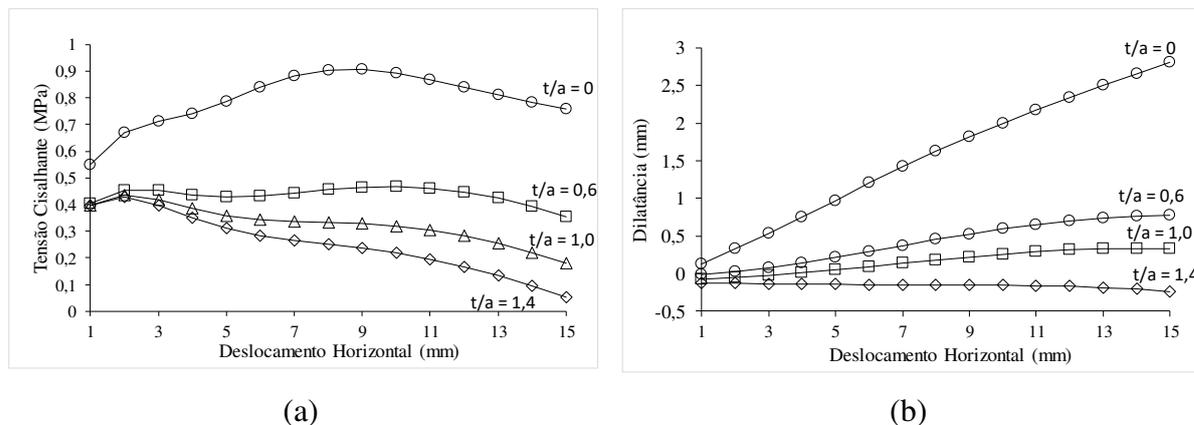
Figura 4.27 – Resultados da rede Gm para previsão das dilatações para as descontinuidades hipotéticas comparadas aos resultados do modelo neuronal de Dantas Neto *et al.* (2017). Para variação nas tensões normais iniciais aplicadas



Fonte: Autora.

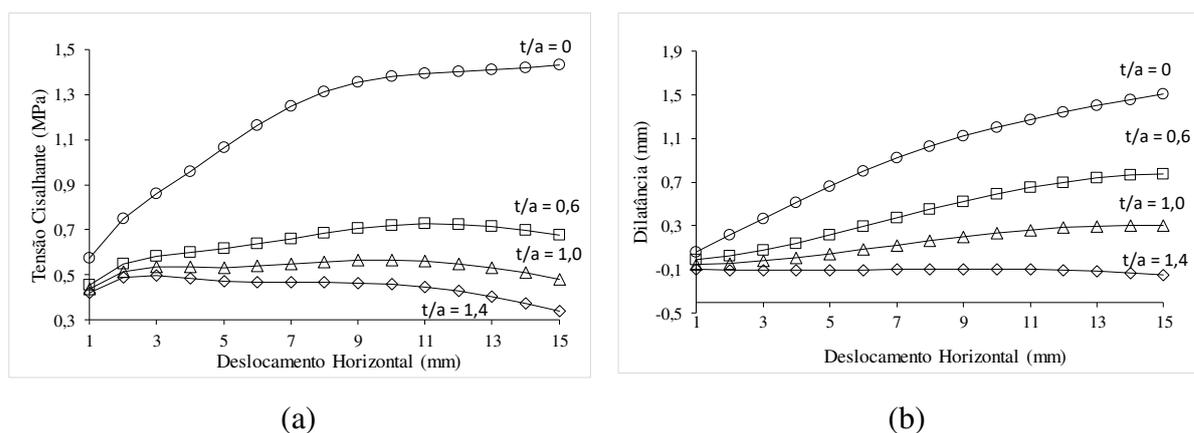
Para verificar a influência do preenchimento, a mesma descontinuidade foi idealizada sob CNL e CNS ($k_n = 560 \text{ kPa/mm}$), com $\sigma_{no} = 0,5 \text{ MPa}$, ambas condições de contorno, testadas com diferentes valores de t/a . Em ambas descontinuidades, a sob CNL (Figura 4.28) e a sob CNS (Figura 4.29), a rede teve uma compreensão coerente do comportamento cisalhante. As tensões cisalhantes diminuíram com o acréscimo da razão de t/a , e houve uma diminuição grande para tensão cisalhante para $t/a = 0$ em relação ao $t/a=0,6$, mas não tão acentuada quando comparada a tensão cisalhante do $t/a = 0,6$ com $t/a = 1$ e $t/a = 1,4$, como era esperado diante do relatado no Capítulo 2. Também foi coerente o fato de as tensões cisalhantes terem sido maiores na junta CNS do que nas juntas sob CNL. Por último as dilatações também seguiram o esperado, chegando a valores negativos em $t/a = 1,4$.

Figura 4.28 – Resultados da rede Gm para descontinuidade hipotética preenchida sob CNL com diferentes valores de t/a



Fonte: Autora.

Figura 4.29 – Resultados da rede Gm para descontinuidade hipotética preenchida sob CNS com diferentes valores de t/a



Fonte: Autora.

4.3.3 Comparação dos resultados obtidos com modelo analítico de Indraratna e Haque (2000) e com o modelo neuronal de Dantas Neto (2017)

Foi feita uma comparação para previsão tensão de cisalhante e dilatância de juntas de rochas brandas idealizadas triangulares sob CNS. Teve como objetivo a comparação entre a resposta gerada pelo modelo Gm, os dados experimentais de Indraratna e Haque (2000), o modelo analítico de Indraratna e Haque (2000) e os resultados provenientes do modelo neuronal para previsão do cisalhamento de descontinuidades limpas de Dantas Neto *et al.* (2017). A Tabela 10 apresenta os parâmetros de entrada necessários para o uso do modelo analítico obtido pela interpolação das curvas de dilatância por meio de uma série de Fourier.

Figura 4.30 – Parâmetros de Fourier da junta serra idealizada Tipo II sob CNS

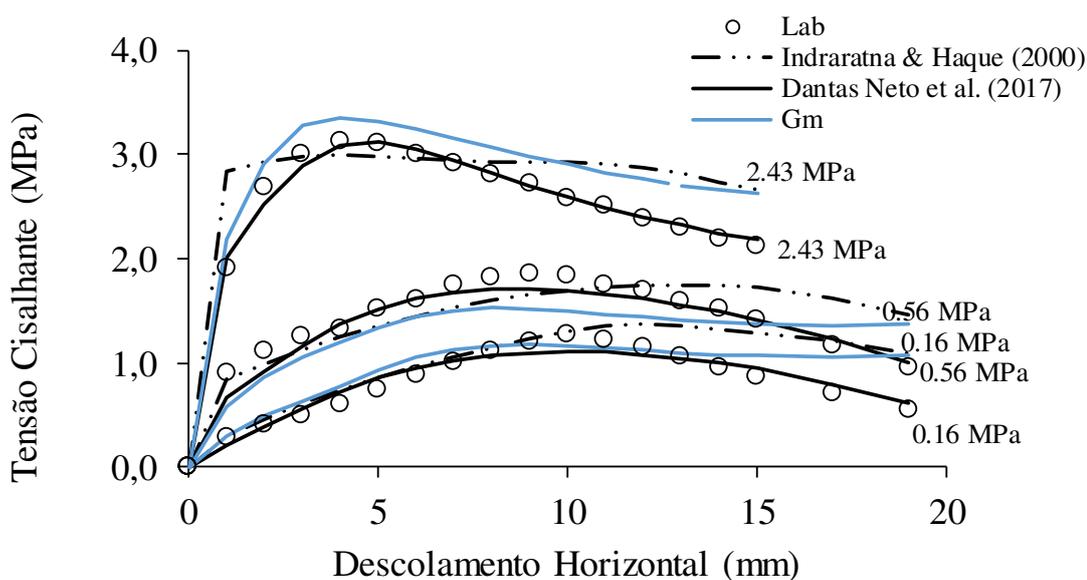
σ_{no}	T	a_0	a_1	a_2	a_3	b_1	b_2	b_3
0,16	29,410	3,556	-1,525	-0,234	-0,022	0,099	0,174	0,089
0,56	35,670	2,164	-1,136	0,039	0,000	-0,083	0,151	0,000
2,43	20,380	0,413	-0,194	-0,039	0,000	0,068	0,031	0,000

Fonte: Autora.

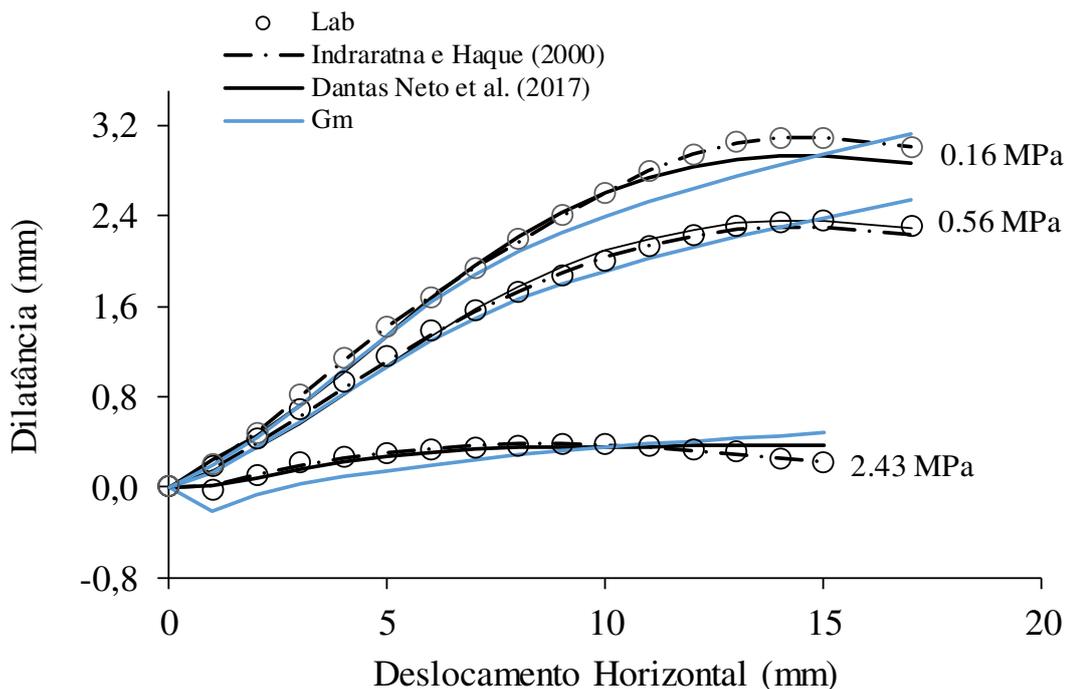
O modelo Gm teve um comportamento intermediário entre os resultantes do modelo analítico de Indraratna e Haque (2000) e Dantas Neto et al. (2017) tanto para tensão cisalhante (Figura 4.31a), quanto para dilatância (Figura 4.31b). Tendo uma previsão aceitável para variação da tensão cisalhante e dilatância em diferentes valores de tensão normal inicial aplicada.

Era esperado, contudo, que o modelo não apresentasse um comportamento tão bom quanto de Dantas Neto *et al.* (2017), visto que o modelo deste era especificado para descontinuidades sem preenchimento. O modelo Gm por sua vez, além de incluir descontinuidades preenchidas, apresenta um mais amplo conjunto de dados para treinamento, incluindo mais rochas duras, o que faz com que este seja mais generalista e possa ser aplicado em mais descontinuidades.

Figura 4.31 – Comparação entre dados observados e previstos para previsão do comportamento cisalhante de uma junta idealizada de serra Tipo II sob CNS



(a)



(b)

Fonte: Autora.

4.4 Conclusões parciais

Foi objetivo dessa etapa da pesquisa, obter um modelo para previsão da variação da tensão cisalhante e dilatação com o deslocamento horizontal para descontinuidade rochosas com e sem preenchimento, sob CNL e CNS, por meio do desenvolvimento de modelo neuronal. Salienta-se que esse modelo não tinha como objetivo substituir os ensaios de cisalhamento direto e as equações analíticas existentes; mas servir como ferramenta prática para apoio na tomada de decisão, que pudesse ser usada com praticidade a partir das variáveis de entrada descritas no Capítulo 2 como relevante e de fácil obtenção em campo.

Visando este objetivo, oito grupos foram criados para previsão do comportamento, sendo cinco desses grupos principais, usando todas as variáveis de entradas, k_n , t/a , σ_{no} , JRC, σ_c , ϕ_b , ϕ_{fill} , δ_h , e os outros três desenvolvidos para avaliar de que forma a retirada de σ_c e ϕ_b como variável de entrada, influenciariam no comportamento. Os grupos principais A, A2, B, B2 e C, diferenciavam-se em relação a forma de seleção de dados e da amplitude de valores de σ_c usados para o desenvolvimento da rede.

Foi avaliado que a retirada de ϕ_b como variável de entrada influenciava negativamente nos modelos neuronais, sobretudo na previsão da dilatância. Essa característica não era esperada, uma vez que ϕ_b corresponde apenas ao ângulo de atrito básico da rocha e o a influência maior da dilatância, em termos de rugosidade, se daria pelo JRC. Contudo, como a rede trabalha de uma forma interativa entre tensão cisalhante e dilatância, a falta da inserção dele para tensão cisalhante pode ter causado essa característica, uma vez que ϕ_b é um parâmetro que constantemente é usado nos modelos para tensão cisalhante (Capítulo 2). Já a retirada de σ_c não gerou uma influência tão significativa na eficiência das redes, acredita-se que isso seja devido a geralmente os ensaios de cisalhamento direto usarem uma relação entre σ_c e σ_{no} , e talvez o modelo neuronal possa ter compreendido essa relação.

Dentre as arquiteturas dos grupos A, A2, B, B2 e C, as três arquiteturas de cada grupo com maior correlação, entre os dados experimentais e os previstos pela rede para os dados usados para testes, foram pré-selecionados. Após a seleção desses, foi verificado quais, dentre os três de cada grupo, apresentavam melhor interpolação com os gráficos de cisalhamento direto de Benmokrane e Ballivy (1989), Haque (1999), Oliveira *et al.* (2009), Mehrishal *et al.* (2016) e Shrivastava e Rao (2017). Os com melhor interpolação, são apresentadas no Apêndice A.

Os modelos com melhores interpolações com os dados experimentais de cada grupo foram testados em juntas hipotéticas, semelhantes às usadas em Dantas Neto *et al.* (2017). Objetivo foi escolher dentre os cinco melhores modelos, o que melhor interpretava as possíveis variações das variáveis governantes, kn , σ_{no} , t/a , modelos em CNL e CNS. Os modelos, com exceção do modelo de arquitetura 8-20-10-5-2 do Grupo A, tiveram dificuldade na interpretação da variação do t/a . Dessa forma o modelo, que foi nomeado de Gm, de arquitetura 8-20-10-5-2 do Grupo A com 500 mil iterações e coeficiente de correlação na fase de treinamento foi de 99,3% e de teste de 99,0%, foi escolhido como modelo ótimo para previsão da variação da tensão cisalhante e dilatância com o deslocamento horizontal para descontinuidade rochosas com e sem preenchimento, sob CNL e CNS.

Sobre a contribuição das variáveis de entrada governante, em geral a tensão normal inicial, JRC e rigidez normal foram as com maior influência para tensão cisalhante. Para a dilatância, a contribuição das variáveis foi distribuída mais igualmente, tendo JRC, t/a e a tensão normal inicial aplicadas maiores valores. Para o modelo Gm, as variáveis de entrada da tensão normal inicial e a rigidez normal foram as mais relevantes, tendo uma influência na soma

de 47%. Para a dilatação as variáveis t/a , JRC e resistência a compressão inicial da rocha se sobressaíram, tendo um valor resultante de 50% na contribuição.

O Modelo Gm foi então descrito e teve o comportamento apresentado em diversas comparações gráficas, em dados experimentais, juntas hipotéticas e comparado, ao fim, com o modelo neuronal de Dantas Neto *et al.* (2017) e ao modelo analítico de Indraratna e Haque (2000).

Em geral o Modelo Gm apresentou bons resultados, mas algumas dificuldades em prever a dilatação, houve casos que a interpolação não foi tão boa quanto o esperado, contudo a previsão do Gm em geral alcançou os máximos e mínimos dos ensaios.

O modelo se apresenta ao fim como uma boa ferramenta para auxílio da tomada de decisão, precisando, contudo, atenção do usuário e experiência para verificar a coerências dos resultados. O modelo seria mais robusto caso houvesse mais ensaios a serem usados no seu treinamento e teste, sobretudo de rochas duras.

5 RESULTADOS - MODELO PARA PREVISÃO DA RESISTÊNCIA CISALHANTE DE PICO

Este capítulo apresenta os resultados dos grupos criados para previsão da resistência cisalhante de pico para descontinuidades rochosas, com e sem preenchimento, sob CNL e CNS. É exposto a seguir: comparação entre os grupos criados; apresentação do modelo escolhido, avaliação da compreensão do modelo para com as variáveis governantes, comparação com modelos analíticos e neuronal existente.

5.1 Comparação entre os modelos

Como apresentado no Capítulo 3 (Tabela 3.5), os sete grupos testados diferem em sua maioria em relação aos dados dos autores utilizados, com exceção do grupo G2. Essa forma de divisão foi estabelecida para avaliar se, com os dados utilizados para o desenvolvimento dos modelos neuronais, alguma rede seria capaz de entender satisfatoriamente o comportamento, ou se haveria a necessidade da retirada dos valores *outliers*.

Os modelos para previsão da resistência cisalhante de pico, diferente dos modelos de previsão da tensão cisalhante e dilatância com o deslocamento horizontal, tem como alvo um valor unitário, independente da variação do deslocamento. Por essa característica, uma correlação alta para os elementos de teste tem um significado suficientemente interessante. Diferente do modelo do Capítulo 4, onde era necessário verificar se a previsão do modelo obtinha uma interpolação com os gráficos de cisalhamento direto.

A Tabela 5.1 apresenta para cada um dos sete grupos, a quantidade de modelos cuja correlação entre, a previsão para os dados de teste e os experimentais, eram maior que 95% e 97%. Além disso dispõe qual foi o melhor modelo, em termos de maior correlação, para cada grupo, o número de iterações com as correspondentes correlações para treinamento e teste. É interessante notar que dentre os modelos com melhor correlação para teste, todos só possuíam uma camada oculta, diferente do ocorrido para os modelos do Capítulo 4. Tal característica possivelmente ocorre devido à resistência cisalhante de pico como parâmetro único de saída ser um problema de compreensão mais simples para as RNA.

Tabela 5.1 – Relação de grupos sobre maiores correlação com os dados de teste

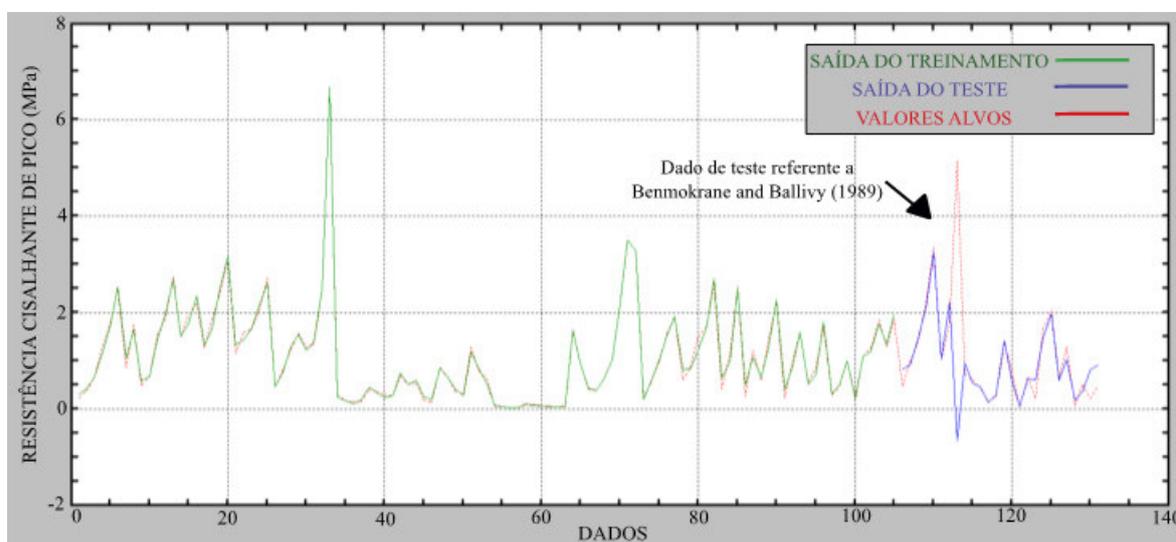
Grupo	Modelos com correlação p/ teste > 95%	Modelos com correlação p/ teste > 97%	Melhor arquitetura	Número de interações	Correlação treinamento	Correlação teste
G1	1	1	7-30-1	797.660	99,5%	98,0%
G2	0	0	-	-	-	-
G3	9	7	7-30-1	48.880	98,7%	98,4%
G4	1	0	7-15-1	-	-	-
G5	9	9	7-30-1	339.530	99,8%	99,2%
G6	5	2	7-20-1	465.955	99,3%	98,6%
G7	9	9	7-20-1	337.730	99,8%	99,0%

Fonte: Autora.

No Grupo G1, correspondente a todos os dados disponíveis com separação de treinamento e teste nos valores de 80% e 20% respectivamente, a única rede que passou de 95% para correlação de teste foi a G1-7-30-1, com 797660 iterações, tendo uma correlação para treinamento de 99,5% e para teste de 98%. As demais tiveram uma boa concordância com os dados de saída, contudo tiveram dificuldade de prever o valor de resistência cisalhante de pico de 5,14 Mpa, referente a Benmokrane and Ballivy (1989). Esse valor é o segundo maior, tendo como superior somente o do mesmo autor com valor de 6,68 Mpa. Os maiores valores experimentais seguidos deles correspondem a metade do valor, sendo então os dados de Benmokrane and Ballivy (1989) considerados como *outliers*.

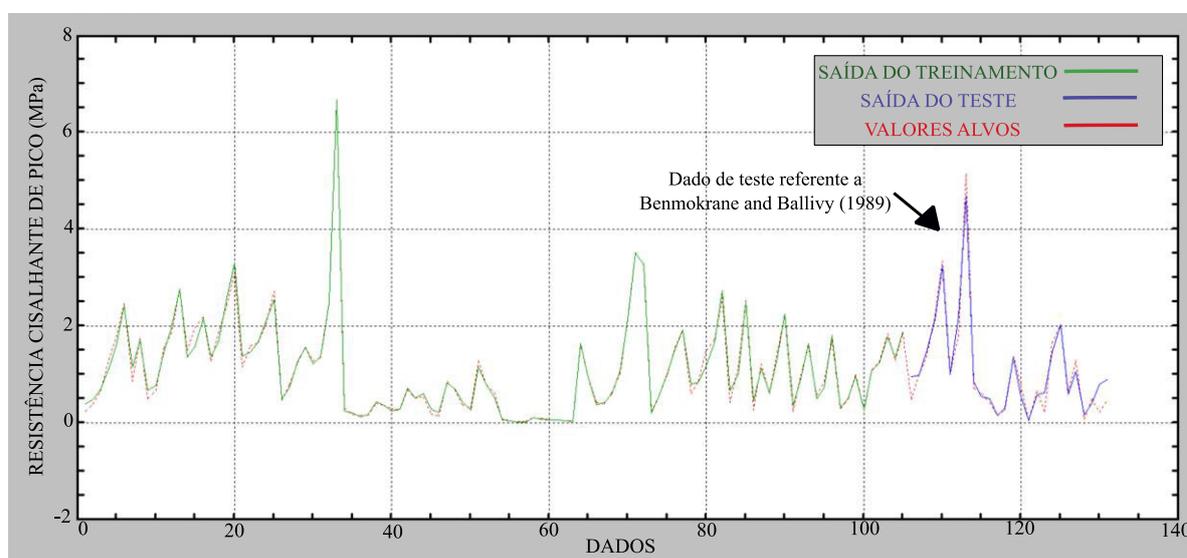
A Figura 5.1 apresenta a comparação entre os valores previstos da resistência cisalhante de pico do modelo de G1, com arquitetura 7-15-1 após 1.000.000 de iterações, para dados de treinamento e teste, e os dados alvos de saída. Essa arquitetura, que pode ser usada como exemplo para as demais do grupo, aponta a maior discrepância para o dado usado para o teste de Benmokrane and Ballivy (1989), sua correlação para o teste foi de 31,31%. Contudo o modelo de arquitetura 7-30-1 do G1, conseguiu representar bem todos, inclusive o dado de Benmokrane and Ballivy (1989) (Figura 5.2).

Figura 5.1 – Variação entre dados requeridos e obtidos para resistência cisalhante de pico pelo modelo neuronal referente de G1 de arquitetura 7-15-1 com 31,31% de correlação para teste após 1.000.000 de iterações.



Fonte: Autora.

Figura 5.2 – Variação entre dados requeridos e obtidos para resistência cisalhante de pico pelo modelo neuronal referente de G1 de arquitetura 7-30-1 com 98,0% de correlação para teste após 797.660 iterações

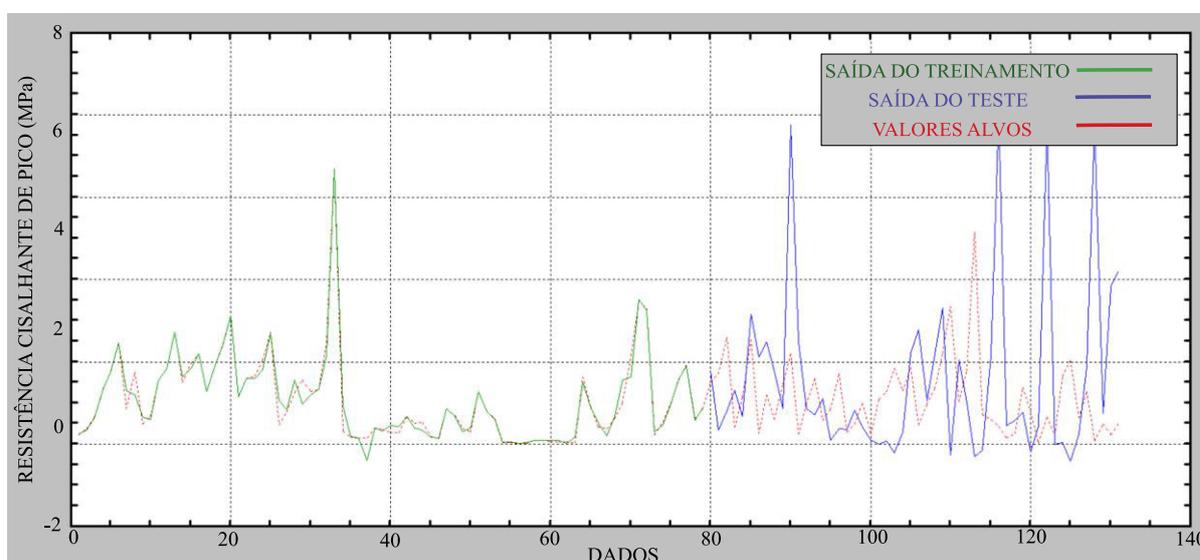


Fonte: Autora.

Para os modelos do Grupo G2, o qual foram usados 60% dos dados para treinamento e 40% dos dados para teste, não houve nenhuma correlação maior que 82%. A quantidade limitada de dados usados como treinamento de 60% se mostrou insuficiente para uma quantidade pequena de dados (131). Algumas redes desse modelo chegaram a produzir correlações negativas para os dados de teste.

Como exemplo do G2 tem a rede 7-30-15-5-1 que após 1.000.000 de iterações, produziu uma correlação negativa de -17,01%. A Figura 5.3 apresenta a comparação entre os valores previstos da resistência cisalhante de pico dos dados de treinamento e teste, e os dados alvos de saída desses. É possível observar que, para que a rede conseguisse maximizar a correlação para o teste com uma pequena quantidade de dados, a mesma gerou um overfitting de tal forma, que os dados de teste previstos foram completamente distorcidos dos almejados.

Figura 5.3 – Variação entre dados requeridos e obtidos para resistência cisalhante de pico pelo modelo neuronal referente de G2 de arquitetura 7-30-15-5-1 com -17,1% de correlação para teste após 1.000.000 iterações



Fonte: Autora.

Ao tirar os dados de Benmokrane and Ballivy (1989), as redes do grupo G2 tiveram uma melhora expressiva, principalmente por este ter sido o ensaio que trouxe maior dificuldade de previsão pelas redes do Grupo G1. Todas as redes do Grupo G2 conseguiram uma correlação para os dados de teste, maior que 95% em algum momento do treinamento, sete delas conseguiram correlação maior que 97%.

O Grupo G4, que foram suprimidos os dados de Mehrishal *et al.* (2016), teve a mesma dificuldade do G1 para interpretar os dados de Benmokrane and Ballivy (1989). Nesse grupo apenas uma rede chegou à uma correlação para dados de teste maior que 95%, contudo não chegando à 97%. A grande maioria das redes desse grupo, chegavam até quase 95% de correlação para os dados de teste e em seguida diminuía até um valor aproximado de 50%. Essa rede também teve caso de correlações negativas com 1.000.000 de iterações.

Nos Grupos G5 e G7, todas as arquiteturas conseguiram correlação maior que 97%. Contudo essas redes só são aconselháveis a ser utilizadas em rochas brandas, uma vez que para G1 só possui dois ensaios com resistência à compressão uniaxial de 27,5 MPa, e os do grupo G7, só há rochas brandas.

No Grupo G6, em que não foram usados de Papaliangas *et al* (1993), houve um acréscimo no número de redes que conseguiram uma aceitável correlação, quando comparado ao Grupo G1. Neste o número de redes que obtiveram correlação para os dados de teste maior que 95% subiu para 5 e o número de redes que obtiveram correlação maior que 97% subiu para 2. Ao tirar esses ensaios, tirou-se a rocha com resistência a compressão de 3,5 MPa, que é inusual dentro da mecânica das rochas. Contudo, também a remoção da quantidade de descontinuidades preenchidas.

Para verificar quais dentre os modelos poderiam ser usados para a previsão da resistência cisalhante de pico, os modelos com maior correlação para o teste dos Grupos G1, G3, G5, G6 e G7 foram testados para a junta hipotética de Dantas Neto *et al.* (2017). Assim como o realizado no Item 4.2, foi avaliado se os modelos neuronais eram capazes de compreender a influência das variáveis de entrada, na junta hipotética de : $\sigma_c = 12\text{MPa}$, $JRC = 5$, $\phi_b = 37,5^\circ$ e $\phi_{fill} = 35,5^\circ$. Objetivo foi avaliar quais dos cinco modelos interpretava as variações das variáveis governantes: kn , σ_{no} , t/a , modelos em CNL e CNS.

A partir dessa análise se verificou que o único modelo capaz de interpretar corretamente as variáveis governantes foi o do Grupo G1 de arquitetura 7-30-1 com 797.660 iterações, uma vez que os demais não conseguiram interpretar a variação do t/a adequadamente. Este modelo, além de interpretar adequadamente as variações das variáveis, teve um erro médio de 13% quando o comparando com tensão máximo obtida para essas juntas com o modelo Gm, descrito no Capítulo 4. Essa rede teve um erro médio de 7% entre as tensões de pico experimentais de Benmokrane e Ballivy (1989), Skinas *et al.* (1990), Papaliangas *et al.* (1993), Haque (1999), Oliveira *et al.* (2009), Mehrishal *et al.* (2016) e Shrivastava e Rao (2017), e as prevista pelo modelo neuronal.

5.2 Modelo selecionado para previsão da resistência cisalhante de pico

Com base nas comparações, o modelo de RNA o único modelo que teve um comportamento aceitável foi o do Grupo G1 com arquitetura 7-30-1, doravante chamado de G1m. Este teve seus pesos sinápticos obtidos e bias calculados após com 797.660 iterações, e seu coeficiente de correlação na fase de treinamento foi de 99,5% e na fase de teste de 98,0%, o que mostra uma boa concordância entre as previsões e os valores-alvo para resistência cisalhante de pico em todos os valores existentes no banco de dados de aprendizado.

A Figura 5.4 mostra a arquitetura do modelo G1m onde as respostas dos neurônios são calculadas usando a função sigmoideal apresentada na Eq. 3.7 e os pesos sinápticos apresentados nas Tabela 5.2 e Tabela 5.3.

Figura 5.4 – Modelo neuronal de arquitetura 7-30-1

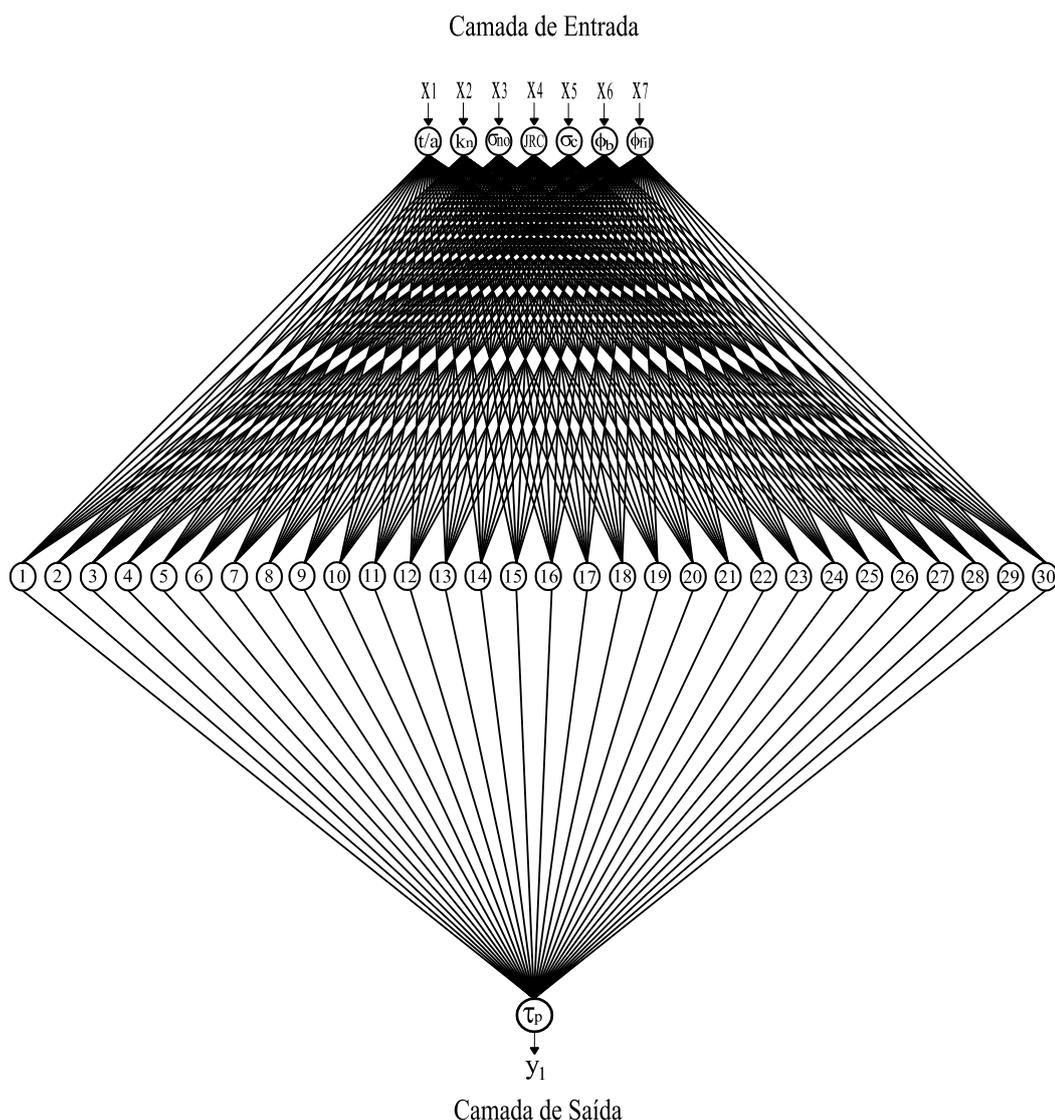


Tabela 5.2 – Pesos sinápticos e Bias da Camada Oculta 1 da rede G1m

pesos sinápticos	Variáveis de Entrada							Bias
	X1	X2	X3	X4	X5	X6	X7	
1	-2,20784	-2,74623	-6,48218	-10,62911	5,56891	5,04522	0,22286	-2,61743
2	0,03042	-0,44372	-1,98007	-0,47332	0,05074	-1,30101	0,17753	0,10506
3	-0,3473	0,1242	-0,44196	-0,75948	0,09081	-0,2891	0,24519	0,24224
4	-0,18326	1,01259	-1,67434	-1,56949	0,57208	-0,79375	0,31289	-0,09481
5	-0,08556	-0,43049	-1,01387	-0,45522	0,91707	-0,92081	0,35357	-0,52168
6	-0,77798	0,04684	0,33582	-0,06132	-0,10353	-0,11009	-0,08783	-0,12375
7	-0,09177	0,20376	0,41852	-0,00171	-0,3623	0,61119	-0,02049	0,00041
8	-6,45112	-3,9324	-4,64714	3,28915	-1,48756	-0,26422	0,97081	0,27444
9	-0,18799	0,15327	0,02753	-0,21472	-0,41826	0,29768	0,23659	-0,29759
10	0,06211	-1,96394	-0,75116	0,49307	0,81868	-1,30519	0,57731	1,6203
11	0,53185	-1,93254	0,34986	1,39397	-0,64226	-0,13282	-1,32959	-0,10419
12	1,92316	0,59022	-6,11128	-2,87545	11,5427	-2,80711	1,80342	0,10289
13	2,62279	3,30677	-9,81656	1,92434	-5,31424	1,29736	-1,67592	0,51462
14	4,65057	0,42489	2,61278	-1,96135	0,71874	-0,87489	-1,76853	1,82533
15	0,26943	-0,78325	1,13852	0,87436	-0,35034	0,95032	-0,26844	0,46079
16	-2,09683	2,84799	-2,29745	-7,46618	-2,52353	1,41049	-0,28711	4,83575
17	0,43996	0,07285	-0,74846	-0,44327	1,1025	-0,00743	0,46602	-0,03904
18	0,06263	-0,14742	-0,47799	-0,19008	0,734	-0,41065	-0,01992	-0,28805
19	-0,38238	0,24655	-0,70488	-0,3573	0,23533	-0,21854	0,10899	-0,17729
20	2,95688	-1,01418	-1,61065	-0,18561	0,2144	3,65284	1,32697	-1,18299
21	0,38174	1,57729	-0,90082	-0,34968	0,93001	1,42215	1,48927	-0,46075
22	-0,85913	-0,31678	0,05075	0,01258	-0,71768	-0,21357	-0,30809	-0,10097
23	0,00624	0,05606	-0,74605	-0,77304	0,15164	-0,54901	0,02546	0,21647
24	-0,25414	0,08561	0,46534	-0,12556	-0,33577	0,2136	0,07053	-0,27119
25	0,81502	3,77544	-3,57982	-0,14112	0,43923	-1,40337	-1,50074	-0,7371
26	-0,16918	-0,03561	-0,88491	-0,6011	2,3155	-1,07064	0,59269	-1,37624
27	1,57695	0,95586	-0,25803	-0,0651	0,81778	1,50839	0,57274	0,16476
28	-0,12993	-0,06177	-1,07431	-0,70872	0,51482	-0,81802	0,03063	-0,03909
29	-0,06173	-0,18105	-0,64051	-0,26932	0,64116	-0,39064	-0,1134	0,03059
30	-0,08075	0,08002	0,58202	0,05003	-0,24154	0,2027	-0,55097	-0,00326

Fonte: Autora.

Tabela 5.3 – Pesos sinápticos e Bias da Camada de saída do modelo G1m

Saída	Camada de Saída									
	1	2	3	4	5	6	7	8	9	10
Y1 - Resistência cisalhante de pico	-6,4483	1,898	0,759	2,619	1,835	-0,21	-0,787	-6,48	-0,175	1,6197

Saída	Camada de Saída									
	11	12	13	14	15	16	17	18	19	20
Y1 - Resistência cisalhante de pico	-2,5515	-8,4	-6,83	4,127	-1,88	-6,55	1,504	1	0,786	4,0056

Saída	Camada de Saída										Bias
	11	12	13	14	15	16	17	18	19	20	
Y1 - Resistência cisalhante de pico	2,6514	-0,81	1,005	-0,36	4,754	3,209	1,875	1,565	0,985	-0,62	0,198

Fonte: Autora.

Da influência das variáveis, a Tabela 5.4 apresenta as contribuições das variáveis de entrada para previsão da resistência cisalhante de pico do modelo G1m. Teve-se o k_n , σ_{no} , σ_c e JRC como variáveis de maior relevância sendo a soma delas igual à 82% da contribuição total.

Tabela 5.4 – Contribuição percentual de cada variável para previsão do cisalhamento e da dilatância para G1m.

k_n	t/a	σ_{n0}	JRC	σ_c	φ_b	φ_{fill}
15%	7%	31%	14%	22%	6%	6%

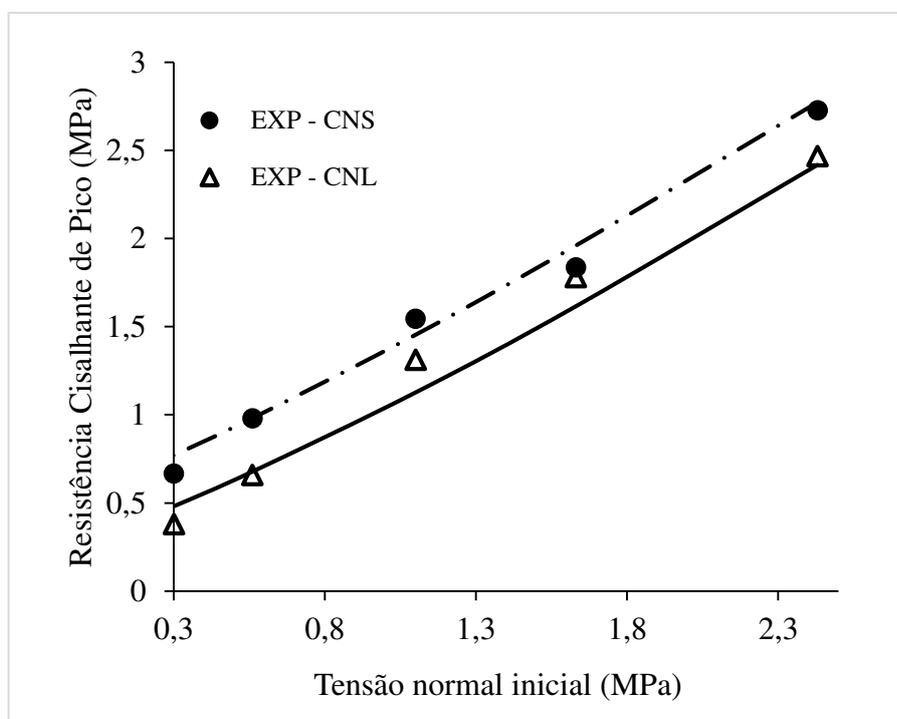
Fonte: Autora.

5.2.1 Comparação dos resultados obtidos pelo modelo escolhido com os dados experimentais usados na elaboração do modelo

Com o intuito de avaliar se o modelo escolhido era capaz de compreender a influência da variação dos parâmetros entrada para previsão da resistência cisalhante de pico, os ensaios de Benmokrane e Ballivy (1989), Haque (1999), Oliveira *et al.* (2009), Papaliangas *et al.* (1993) e Shrivastava e Rao (2017) foram usados. Esses ensaios foram alguns dos usados para desenvolvimento do modelo.

A Figura 5.5 apresenta resultados para resistência cisalhante de pico obtidas a partir de ensaios de cisalhamento direto de Haque (1999), comparados com as previsões do modelo G1m. Nessa há os resultados de ensaios sob CNL e CNS de juntas não preenchidas mudando-se os valores da tensão normal inicial aplicada. O modelo neuronal foi capaz de identificar que quanto maior a tensão normal inicial aplicada, maior a resistência ao cisalhamento de pico desenvolvida; também que um ensaio sob CNS desenvolveria maiores valores de tensão que o ensaio sob CNL, como esperado pela literatura (Capítulo 2). O modelo G1m demonstrou uma boa correlação com os dados experimentais.

Figura 5.5 – Comparação entre resistência ao cisalhamento de pico experimentais de Haque (1999) com os previstos pelo modelo G1m com variação da tensão normal aplicada e condição de contorno.

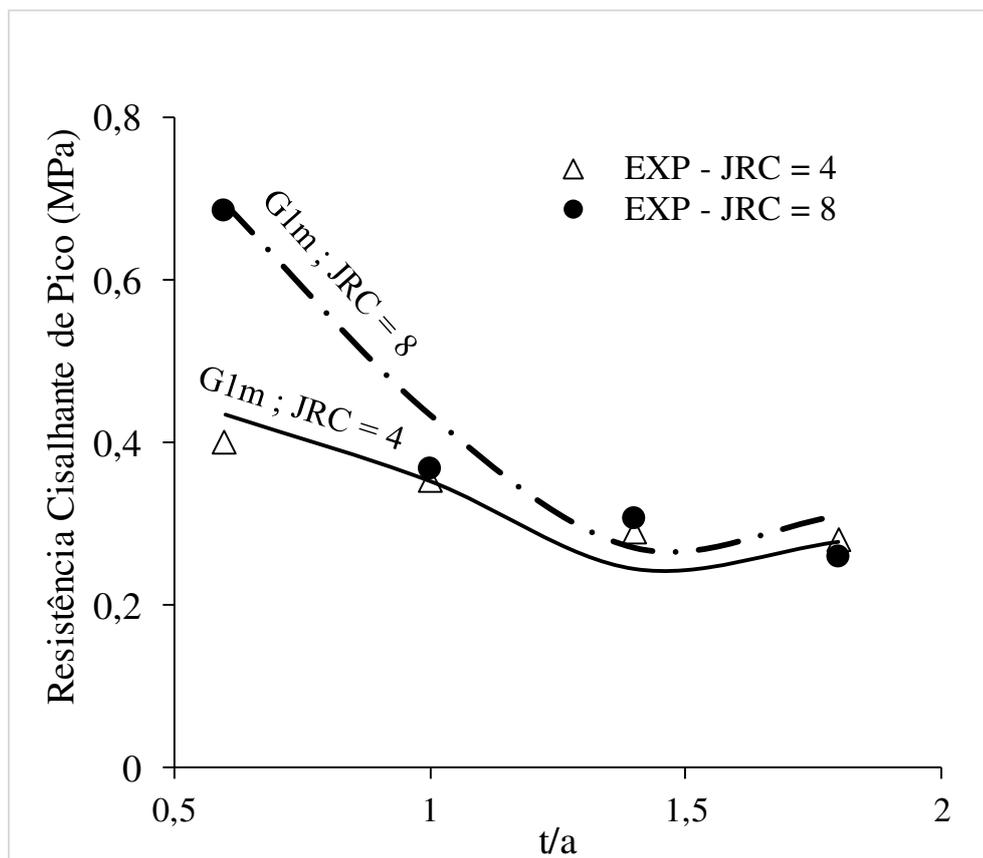


Fonte: Autora.

A Figura 5.6 apresenta resultados para resistência cisalhante de pico obtidas a partir de ensaios de cisalhamento direto de Haque (1999), comparados com as previsões do modelo G1m. Nessa há o resultado de ensaios sob CNS de juntas preenchidas com diferentes valores de JRC, mudando-se os valores da t/a . O modelo neuronal foi capaz de identificar que quanto maior a razão de t/a , menor a resistência ao cisalhamento de pico desenvolvida; também que o ensaio com maior valor de JRC mobiliza maiores valores para resistência cisalhante de pico. O modelo G1m foi capaz de prever que com o valor de t/a alto, o JRC não mais teria grande influência, pois o preenchimento governaria o comportamento, como esperado pela literatura

(Capítulo 2). O modelo G1m demonstrou uma boa correlação com os dados experimentais para esses dados também.

Figura 5.6 – Comparação entre resistência ao cisalhamento de pico experimentais de Haque (1999) com os previstos pelo modelo G1m com variação da do JRC e t/a .

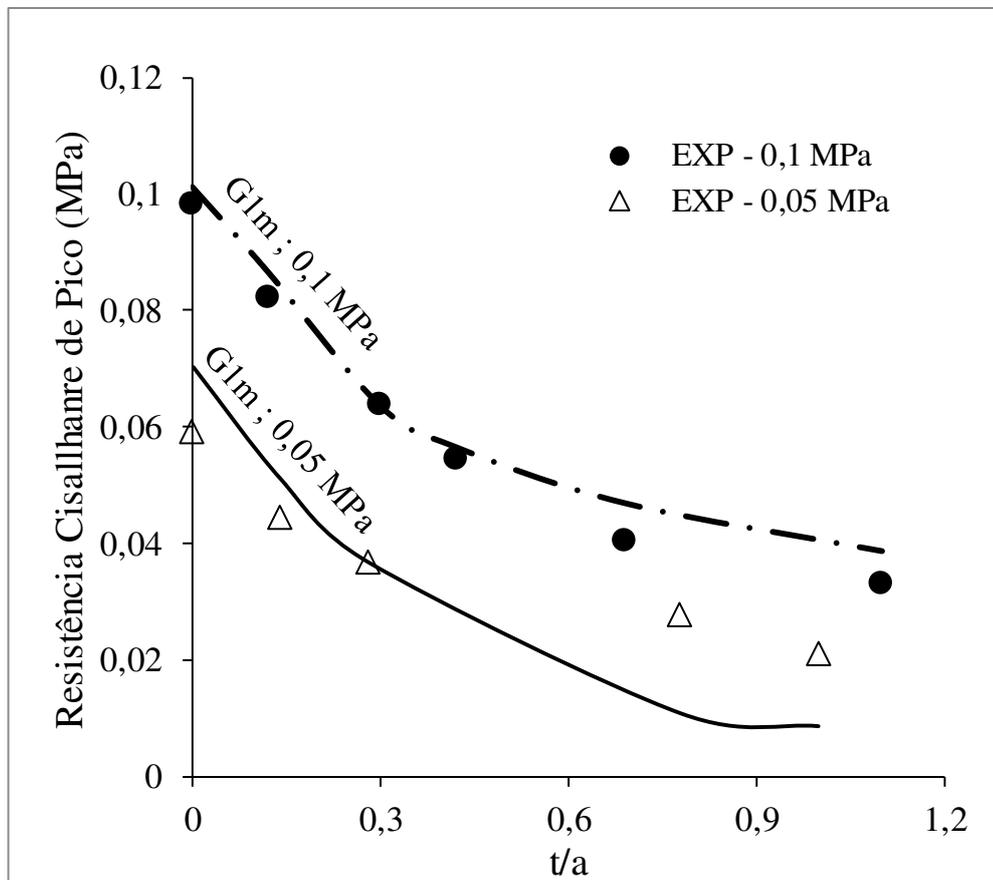


Fonte: Autora.

^

A Figura 5.6 apresenta resultados para resistência cisalhante de pico obtidas a partir de ensaios de cisalhamento direto de Papaliangas *et al.* (1993), comparados com as previsões do modelo G1m. Nessa há o resultado de ensaios sob CNL de juntas preenchidas com diferentes valores de tensão normal inicial aplicada, mudando-se os valores da t/a . O modelo neuronal foi capaz de identificar que quanto maior a razão de t/a , menor a resistência cisalhante de pico desenvolvida, assim como havia ocorrido para com os ensaios de Haque (1999); também que o ensaio com a maior valor de σ_{no} mobiliza maiores valores para resistência cisalhante de pico, como esperado pela literatura (Capítulo 2). O modelo G1m demonstrou uma boa correlação com os dados experimentais para esses, não tão bom quanto os demais, mas isso se dando principalmente pela σ_{no} extremamente baixa do ensaio de 0,05 MPa.

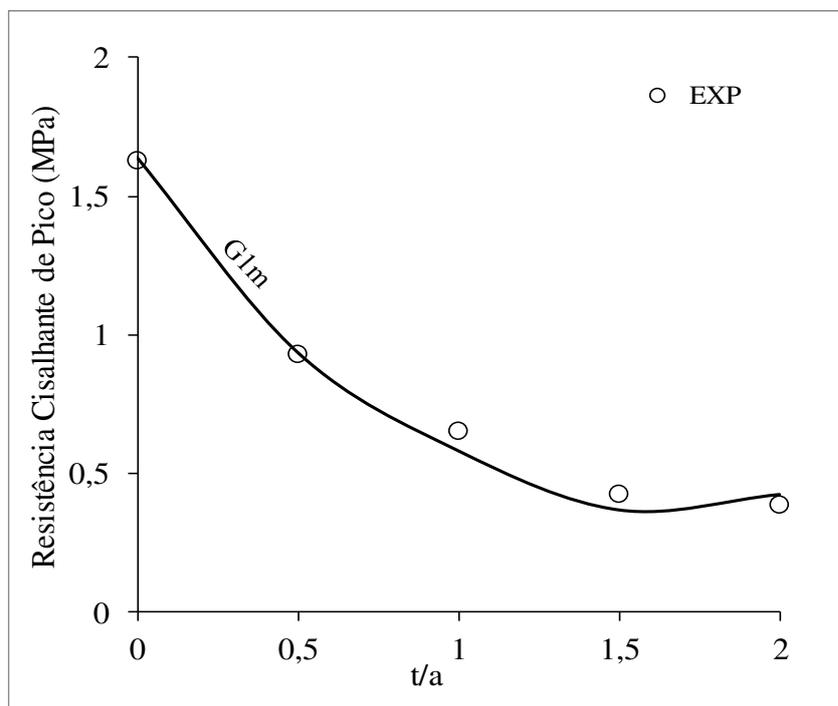
Figura 5.7 – Comparação entre resistência ao cisalhamento de pico experimentais de Papaliangas *et al.* (1993) com os previstos pelo modelo G1m com variação do t/a para diferentes tensões normais iniciais.



Fonte: Autora.

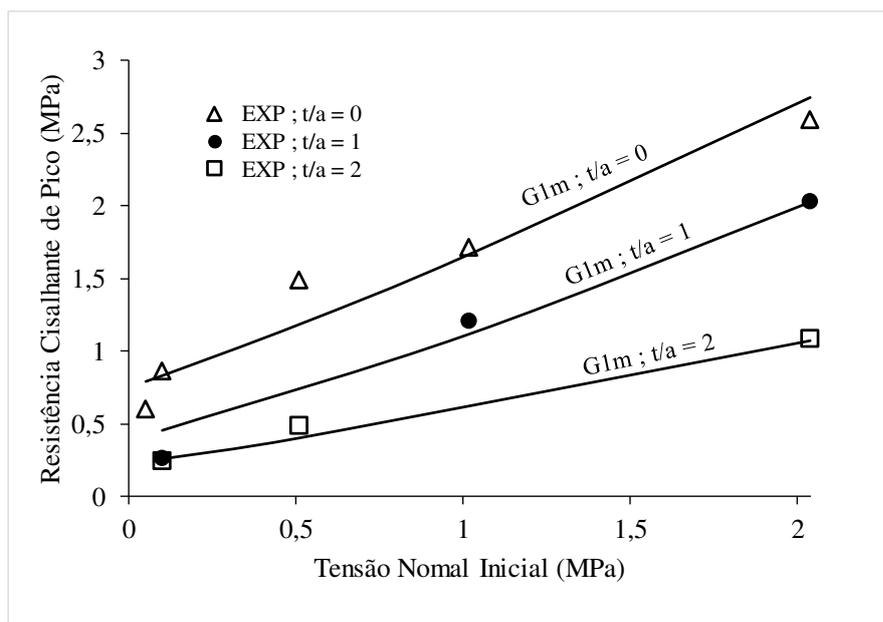
A compreensão da variação da resistência ao cisalhamento de pico de discontinuidades com preenchimento mobilizada pelas alternância da t/a , σ_{no} e condição de contorno citada acima, também ocorreu para os dados do ensaio de Oliveira *et al.* (2009) (Figura 5.8) e Shrivastava e Rao (2017) (Figura 5.9, Figura 5.10) pelo modelo G1m. Sendo os ensaios de Oliveira *et al.* (2009) sob CNS e os de Shrivastava e Rao (2017), CNL e CNS.

Figura 5.8 – Comparação entre resistência cisalhante de pico experimentais de Oliveira *et al.* (1993) com os previstos pelo modelo G1m com variação do t/a .



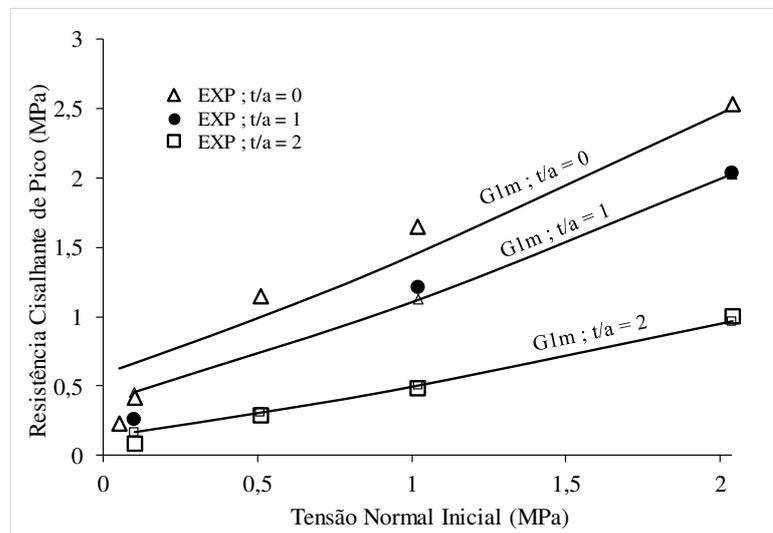
Fonte: Autora.

Figura 5.9 – Comparação entre resistência cisalhante de pico experimentais de Shrivastava e Rao (2017) sob CNL com os previstos pelo modelo G1m com variação da tensão normal inicial para diferentes valores de t/a .



Fonte: Autora.

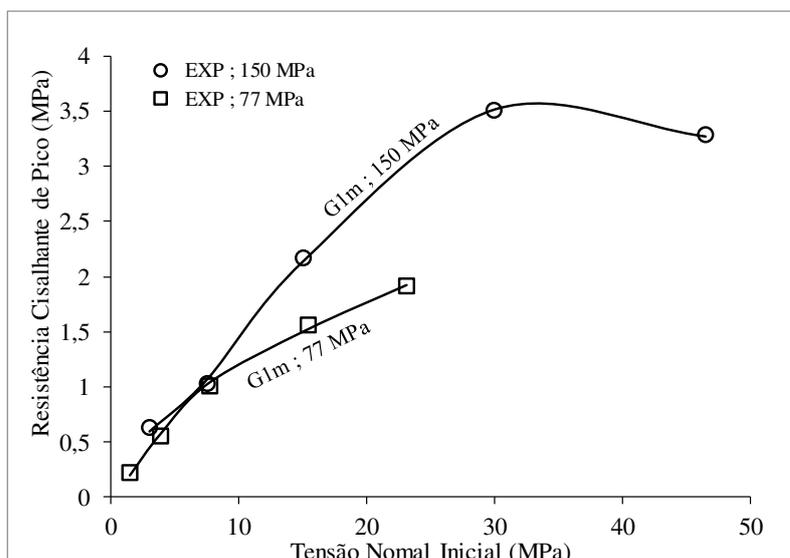
Figura 5.10 – Comparação entre resistência cisalhante de pico experimentais de Shrivastava e Rao (2017) sob CNS com os previstos pelo modelo G1m com variação da tensão normal inicial para diferentes valores de t/a .



Fonte: Autora.

A Figura 5.11 apresenta resultados para resistência cisalhante de pico obtidas a partir de ensaios de cisalhamento direto de Mehrishal *et al.* (2016), comparados com as previsões do modelo G1m. Esse modelo foi o que nas demais redes, gerou correlações tão baixas. Pode-se ver que o modelo G1m interpretou adequadamente o resultado. Sendo a rede então eficiente mesmo pra rochas com resistência à compressão uniaxial de 77 MPa e 150 MPa.

Figura 5.11 – Comparação entre resistência cisalhante de pico experimentais de Mehrishal *et al.* (2016) sob CNL com os previstos pelo modelo G1m com variação da tensão normal inicial.



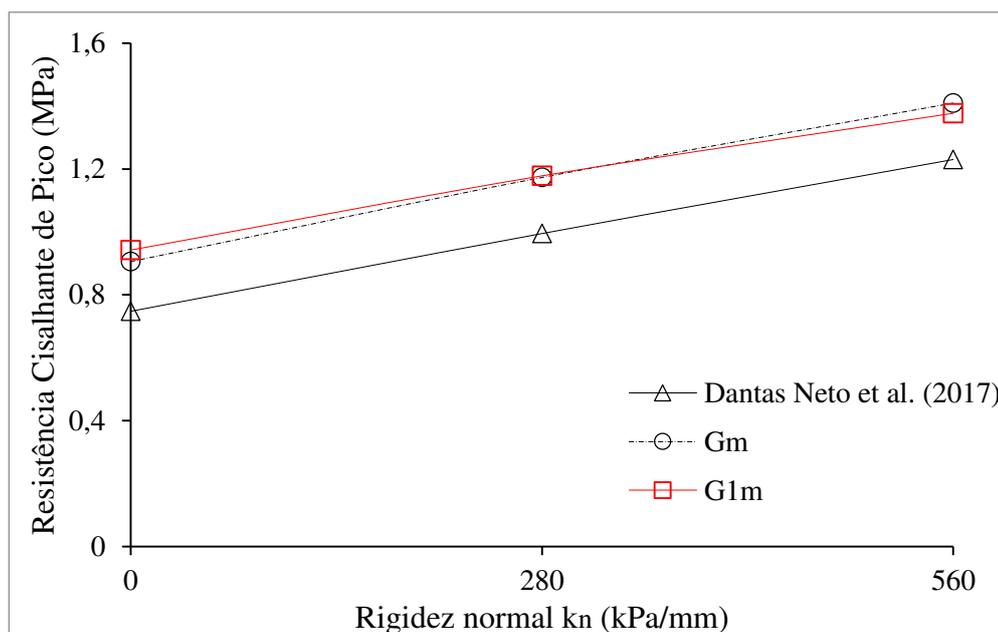
Fonte: Autora.

5.2.2 Avaliação do modelo escolhido com uma junta hipotética

As comparações do Item 5.2.1 foram realizadas com alguns dos ensaios usados para o desenvolvimento do próprio modelo neuronal G1m. Para validação do modelo, foi usada uma junta hipotética, baseada na usada em Dantas Neto *et al.* (2017), a fim de determinar se o modelo neuronal tinha a capacidade de expressar a influência das variáveis de entrada governantes no comportamento referente a resistência cisalhante de pico. As descontinuidades tiveram como parâmetros principais, os mesmos descritos no Item 4.3.2. Por fim, os valores de pico das juntas hipotéticas foram comparadas com os modelos de Dantas Neto *et al.* (2017) e o modelo Gm apresentado no Capítulo 4.

A Figura 5.12 apresenta a variação da resistência cisalhante de pico de uma junta hipotética para previsão pelos modelos G1m, Gm e Dantas Neto *et al.* (2017) para uma descontinuidade não preenchida com tensão normal inicial de 0,5 MPa sob diferentes condições de contorno. O modelo G1m apresentou uma variação de resistência cisalhante de pico ascendente, como era esperado, com o aumento do valor de kn. Os modelos Gm e G1m apresentaram resultados idênticos, sendo cerca de 20% maior que os previstos por Dantas Neto *et al.* (2017).

Figura 5.12 – Variação da resistência cisalhante de pico para diferentes kn da junta hipotética pelos modelos G1m, Gm e Dantas Neto *et al.* (2017).

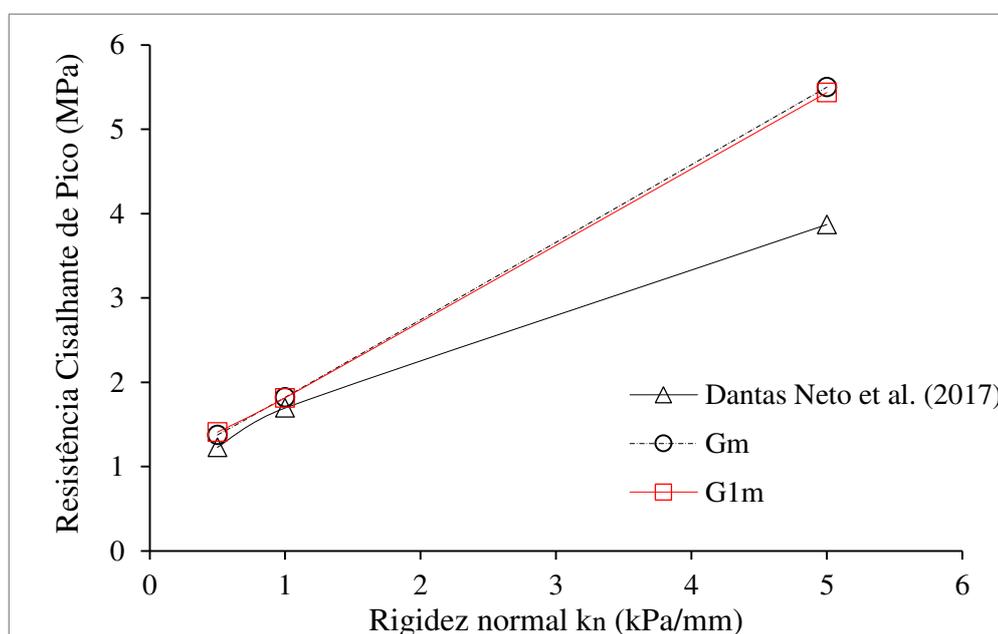


Fonte: Autora.

A Figura 5.13 apresenta a variação da resistência cisalhante de pico de uma junta hipotética com previsão pelos modelos G1m, Gm e Dantas Neto *et al.* (2017) para uma descontinuidade não preenchida sob CNS de $kn = 560$ kPa/mm, com diferentes valores de tensão normal aplicada. Os resultados em termo de tendência de variação foram adequados visto que houve o aumento da resistência cisalhante de pico mobilizada com o aumento da tensão normal inicial aplicada (Capítulo 2).

A resistência de pico mobilizada no modelo G1m e Gm foram idênticas, mas consideravelmente diferente do modelo de Dantas Neto *et al.* (2017) para tensão normal de 5 MPa, mas como descrito no Item 4.3.2, essa diferença provavelmente se deu devido à uma possível consideração de quebra da aspereza dos modelos Gm, principalmente quando levado em consideração a variação da dilatância (Figura 4.27). Como os modelos Gm e G1m foram desenvolvidos com quase toda a mesma base de dados, é possível que o modelo G1m também tenha considerado isso.

Figura 5.13 – Variação da resistência cisalhante de pico para diferentes valores de tensão normal inicial aplicada para juntas hipotética pelos modelos G1m, Gm e Dantas Neto *et al.* (2017).

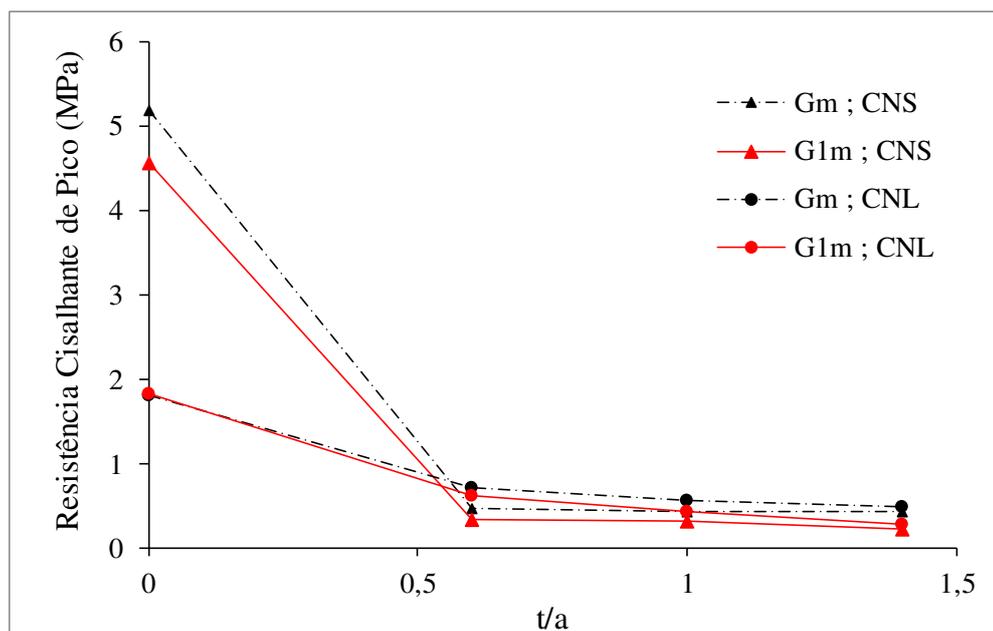


Fonte: Autora.

A Figura 5.14 apresenta a variação da resistência cisalhante de pico de uma junta hipotética para previsão pelos modelos G1m, Gm e Dantas Neto *et al.* (2017) em uma descontinuidade preenchida sob CNS de $kn = 560$ kPa/mm e CNL, com diferentes valores de t/a . Os resultados em termo de tendência de variação deram adequado, visto que houve a

diminuição da resistência cisalhante de pico com o aumento do t/a até um valor constante. Contudo era esperado que as descontinuidades sob CNS dessem sempre resistências de pico superiores, o que não ocorreu para t/a acima de 0,6, contudo a diferença não foi consideravelmente grande.

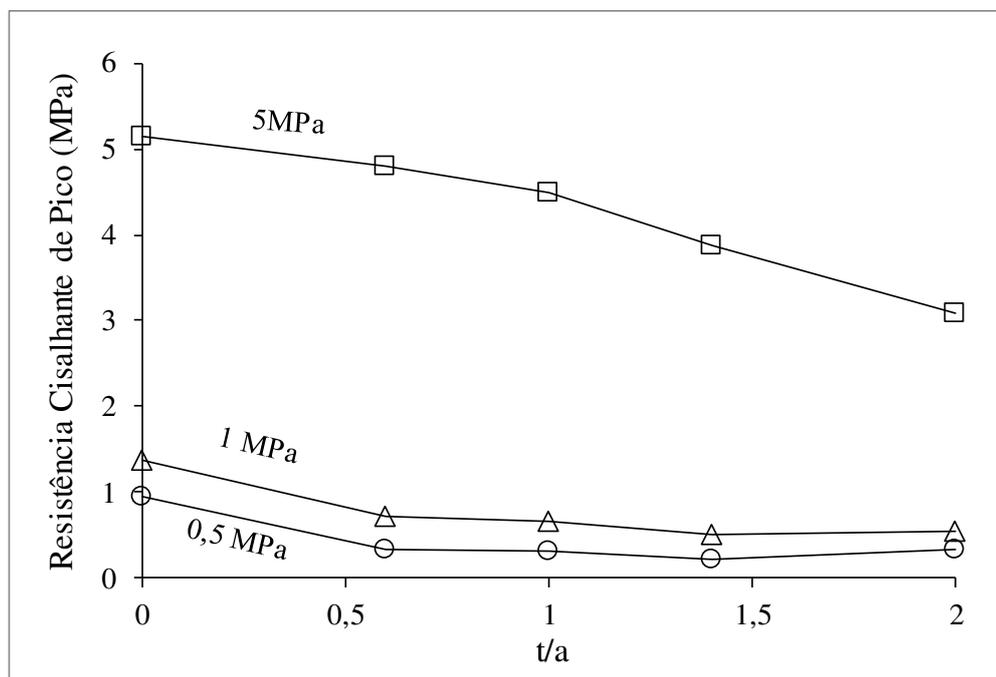
Figura 5.14 – Variação da resistência cisalhante de pico para diferentes valores de t/a aplicada para juntas hipotética pelos modelos G1m e Gm.



Fonte: Autora.

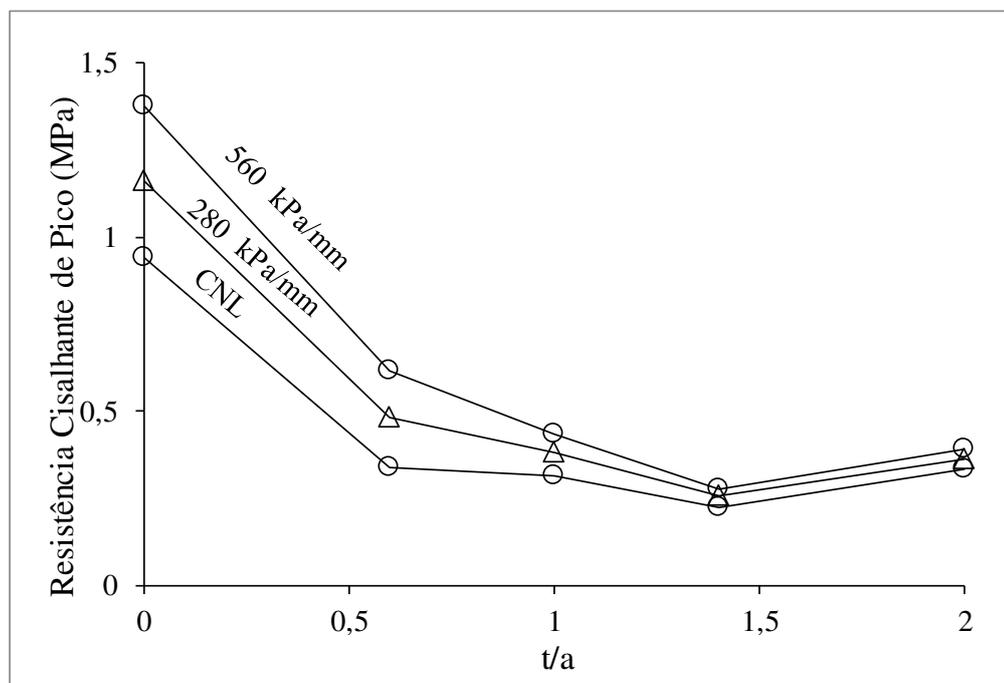
Para verificar mais profundamente se a descontinuidade compreendia o a variação da tensão normal inicial e o k_n para diferentes t/a , foram previstos essas variações para t/a de 0 à 2. A Figura 5.15 apresenta o resultando da previsão de G1m, mostrando que o comportamento esperado de diminuição da resistência de pico com aumento do t/a ocorreu, para as três tensões normais iniciais aplicadas, de 0,5 MPa, 1 MPa e 5 MPa. O comportamento coerente também ocorreu para os diferentes k_n , sendo a descontinuidade sob CNL, sob $k_n = 280$ kPa/mm e $k_n=560$ kPa/mm, como apresentado na Figura 5.16.

Figura 5.15 – Variação da resistência cisalhante de pico com t/a para diferentes tensões normais iniciais aplicada em uma junta hipotética sob CNL pelos modelo G1m.



Fonte: Autora.

Figura 5.16 – Variação da resistência cisalhante de pico com t/a para diferentes valores de k_n em uma junta hipotética sob CNL pelos modelo G1m.

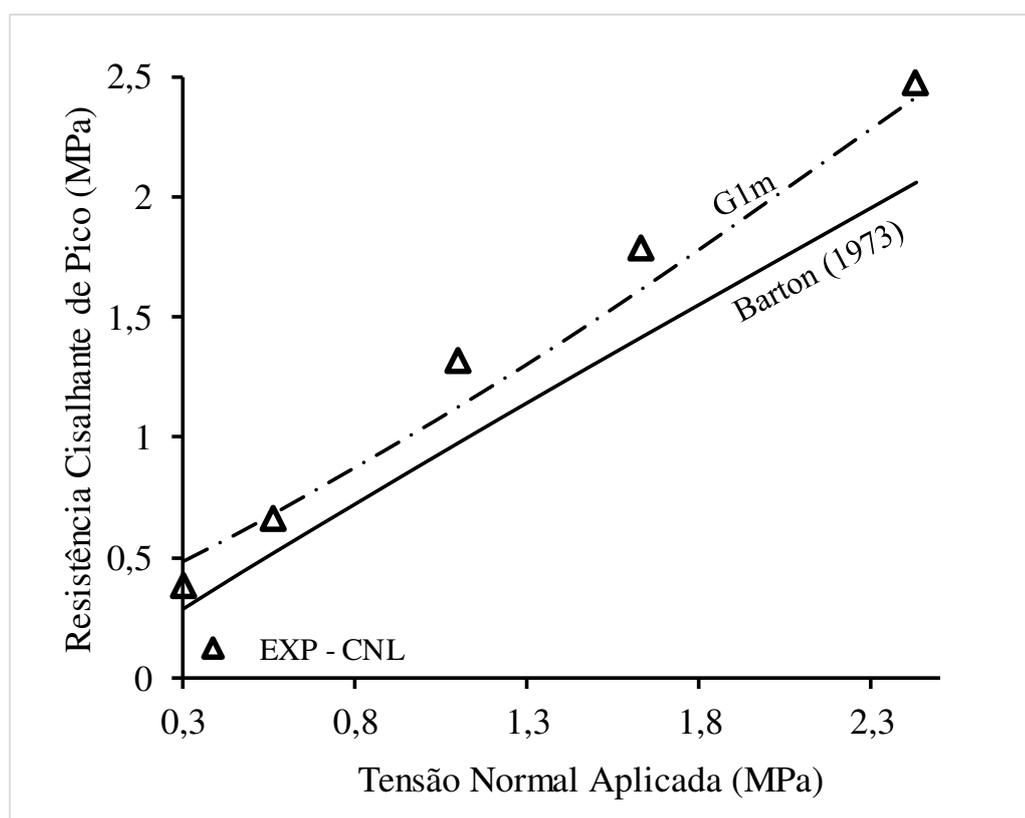


Fonte: Autora.

5.2.3 Comparação entre o modelo desenvolvido e equações analíticas.

Para comparação com descontinuidade sem preenchimento sob CNL, foi usado o modelo de Barton (1973b) por ser o mais usado no dia a dia da engenharia devido a sua simplicidade de parâmetros e bons resultados comprovados. A Figura 5.17 apresenta a comparação do modelo de Barton (1973b) com o G1m, para o ensaio de cisalhamento de Haque (1999) correspondente a uma rocha branda de σ_c de 12MPa e $JRC=4$. Nessa há a boa compreensão de ambos os modelos com os dados experimentais, sendo o G1m sutilmente melhor.

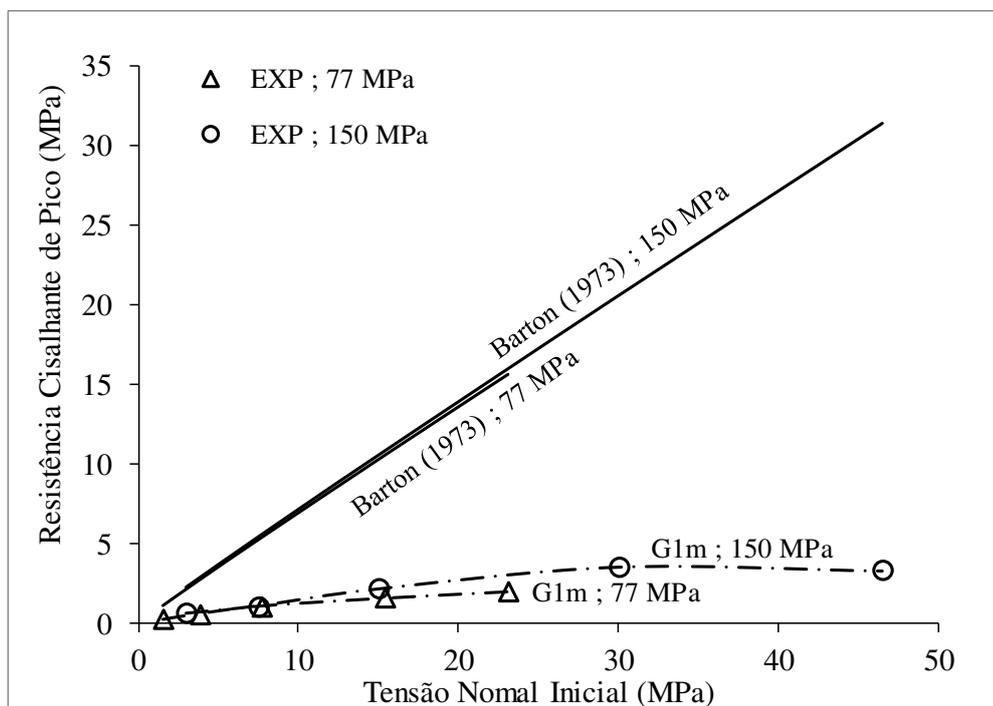
Figura 5.17 – Comparação entre os dados experimentais, a previsão pelo modelo de Barton (1973b) e do modelo G1m para os ensaios de Haque (1999)



Fonte: Autora.

Ao comparar o modelo G1m e de Barton (1973b) com os ensaios de Mehrishal *et al.* (2016) disposto na Figura 5.18, que são rochas duras com σ_c de 150 MPa e 77 MPa de $JRC = 20$, já não há uma interpretação adequada pelo modelo de Barton (1973b), pois como citado no Capítulo 2, seu modelo é aplicável bem apenas em rochas brandas e pouco rugosas. Contudo G1m compreende a variação adequadamente.

Figura 5.18 – Comparação entre os dados experimentais, a previsão pelo modelo de Barton (1973b) e do modelo G1m para os ensaios de Mehrishal *et al.* (2016)

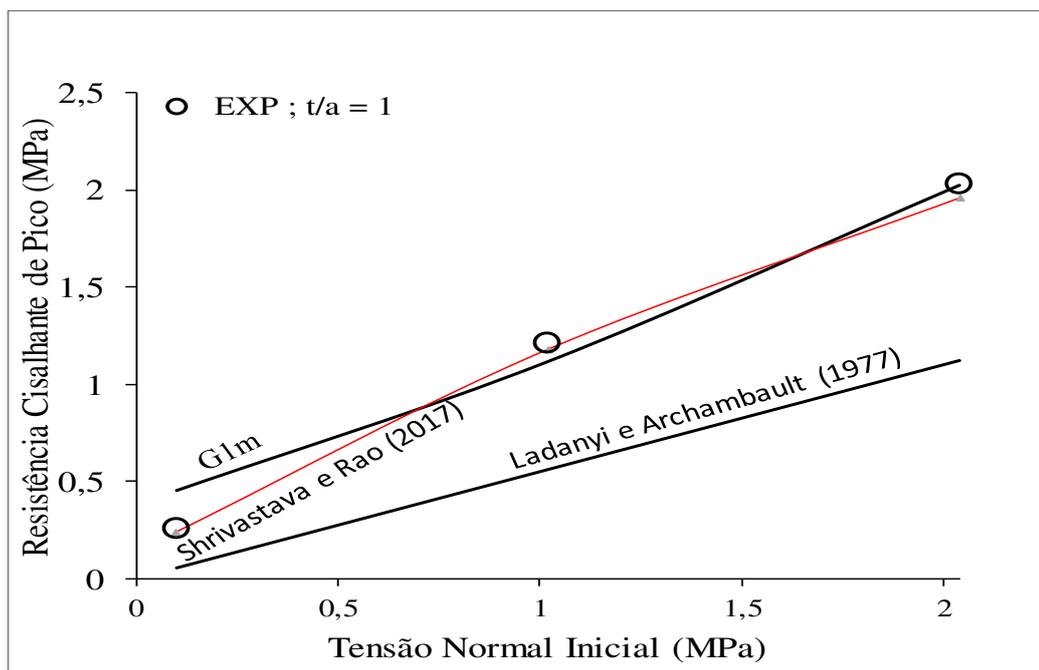


Fonte: Autora.

Para a comparação com descontinuidades com preenchimento, foram usados os dados de dados de descontinuidades preenchidas de Shrivastava e Rao (2017). Foram então comparados os modelos de Ladanyi e Archambault (1977), Shrivastava e Rao (2017) (desenvolvido a partir desses dados) e o modelo neuronal G1m.

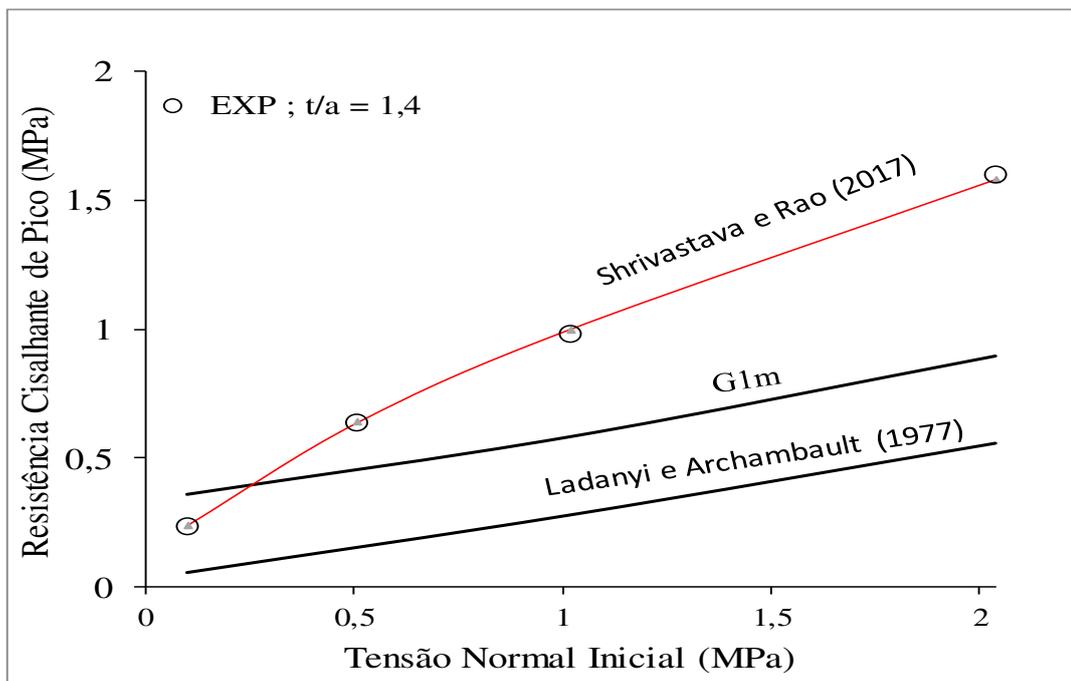
As Figura 5.19, Figura 5.20, Figura 5.21 apresentam a comparação entre os três modelos para t/a de 1, 1,4 e 2 respectivamente. É a tendência que o modelo de Shrivastava e Rao (2017) seja o com melhor desempenho, visto que o modelo foi feito por regressão a partir desses dados, contudo o modelo de Ladanyi e Archambault (1977) e o neuronal G1m apresentaram boa compreensão dos dados, sendo até mesmo melhor interpolação para a descontinuidade de $t/a = 2$.

Figura 5.19 – Comparação entre os dados experimentais de Shrivastava e Rao (2017) de descontinuidades sob CNL preenchidas com $t/a = 1$, com os modelos de Ladanyi e Archambault (1977), de Shrivastava e Rao (2017) e pelo modelo G1m.



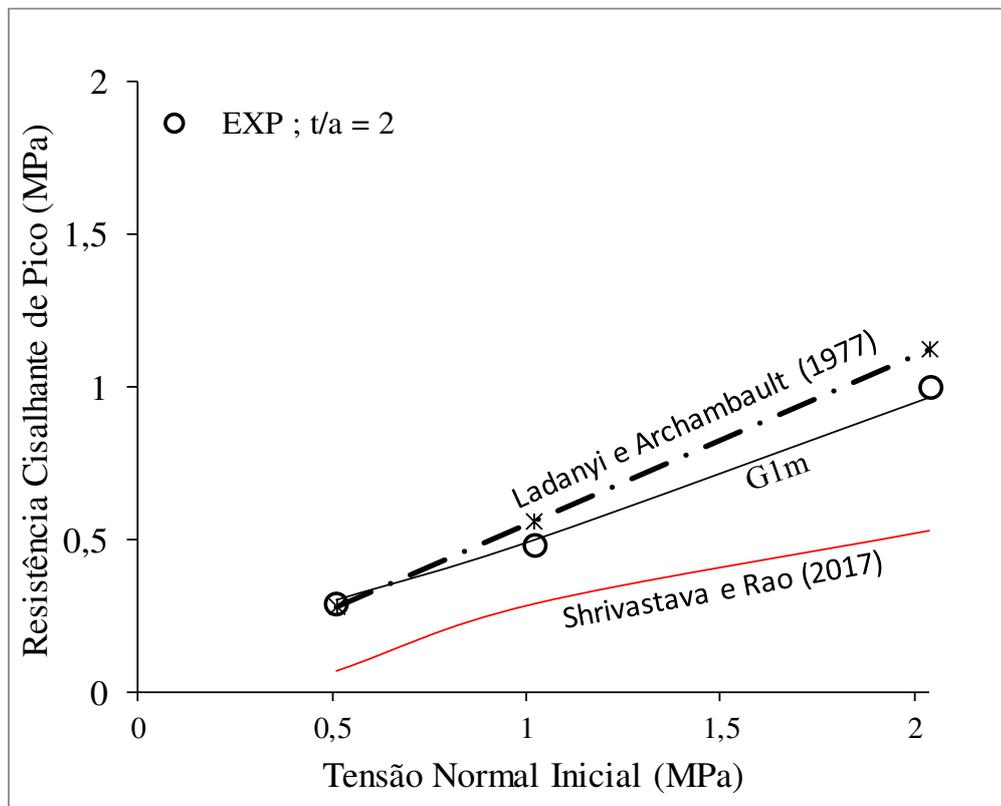
Fonte: Autora.

Figura 5.20 – Comparação entre os dados experimentais de Shrivastava e Rao (2017) de descontinuidades sob CNL preenchidas com $t/a = 1,4$, com os modelos de Ladanyi e Archambault (1977), de Shrivastava e Rao (2017) e pelo modelo G1m.



Fonte: Autora.

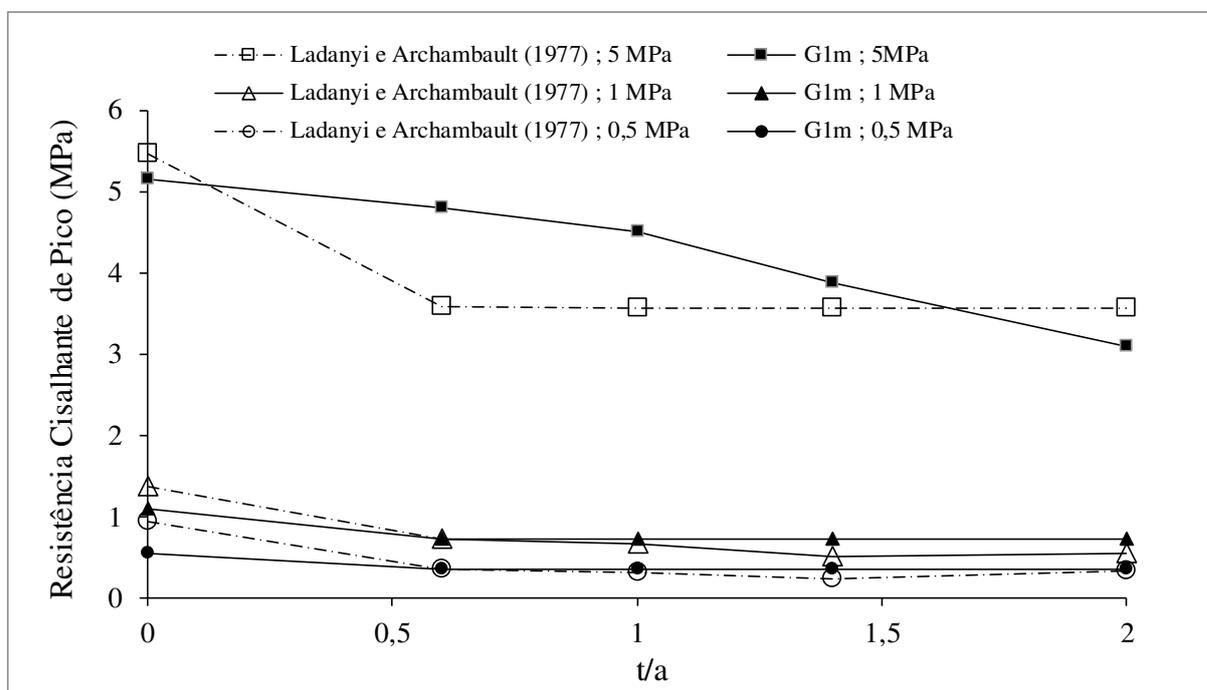
Figura 5.21 – Comparação entre os dados experimentais de Shrivastava e Rao (2017) de descontinuidades sob CNL preenchidas com $t/a = 2$, com os modelos de Ladanyi e Archambault (1977), de Shrivastava e Rao (2017) e pelo modelo G1m.



Fonte: Autora.

Por último, para avaliar se o modelo G1m apresentou uma resposta coerente quando aplicado na descontinuidade hipotética do Item 5.2.2, foi usado para a descontinuidade hipotética o modelo consagrado de Ladanyi e Archambault (1977). Foi obtido uma boa interporlação entre ambos para a junta hipotética como apresentado na Figura 5.22. Vale a observação que para $t/a = 0$ o modelo de Ladanyi e Archambault (1977) se torna igual ao de Patton (1966), tendo esse então tido boa correlação com os resultados do modelo neuronal G1m também.

Figura 5.22 – Comparação entre a previsão do modelo G1m e do modelo de Ladanyi e Archambault (1977) para descontinuidades hipotéticas preenchidas do Item 5.2.2.



Fonte: Autora.

5.3 Conclusões Parciais

Foi objetivo dessa etapa da pesquisa, desenvolver um modelo para previsão da resistência cisalhante de pico para descontinuidades rochosas com e sem preenchimento, sob CNL e CNS, por meio do desenvolvimento de modelo neuronal. Salienta-se que esse modelo não tinha como objetivo substituir os ensaios de cisalhamento direto e as equações analíticas existentes; mas servir como ferramenta prática para apoio na tomada de decisão, que pudesse ser usada com praticidade a partir das variáveis de entrada descritas no Capítulo 3 como relevantes e de fácil obtenção em campo.

Visando este objetivo, sete grupos foram criados para previsão do comportamento, os grupos testados diferem em sua maioria em relação aos dados dos autores utilizados. E após a avaliação desses grupos, foram selecionados um modelo de cada grupo que obteve maior correlação para com os dados de teste (validação) maior que 97%.

Cinco modelos foram então selecionados e testados com descontinuidades hipotéticas, semelhantes às usadas em Dantas Neto *et al.* (2017). Objetivando selecionar quais dentre esses era capaz de prever adequadamente a variação das variáveis governantes, como

esperado pela literatura do Capítulo 2. Desses apenas um grupo foi capaz de se comportar adequadamente com a variação de k_n , σ_{no} , t/a , modelos em CNL e CNS.

O modelo, que foi nomeado de G1m, do grupo G1 com arquitetura 7-30-1 com 797.660 iterações foi escolhido e apresentado. Seu coeficiente de correlação na fase de treinamento foi de 99,5% e de teste de 98,0%, esse modelo apresentou um erro médio de 7% para o banco de dados usado para o desenvolvimento da rede. A variáveis de entrada com maior influência para este modelo foi k_n , σ_{no} , σ_c e JRC, cuja soma delas igual à 82% da contribuição total

O modelo apresentou boa concordância com os dados, adequado comportamento segundo a mudança das variáveis, e boa concordância com os modelos analíticos existentes testados. Podendo, portanto, ser usado como auxílio na tomada de decisão.

6 CONCLUSÕES E SUGESTÕES PARA PESQUISAS FUTURAS

Neste capítulo são apresentadas as conclusões obtidas desse trabalho, a partir dos objetivos almejados. Ao fim, são tecidas as sugestões para pesquisas futuras que podem ser feitas, baseadas no estudo desenvolvido.

6.1 Conclusões

Este trabalho apresentou dois modelos neuronais para previsão do comportamento cisalhante de descontinuidades rochosas com e sem preenchimento sob CNL e CNS. O primeiro modelo é um modelo completo, onde é possível a previsão da tensão cisalhante e dilatância com o deslocamento horizontal, semelhante ao obtido em um ensaio de cisalhamento direto. O segundo é um modelo simplificado para previsão da resistência cisalhante de pico das descontinuidades.

Sobre o tema do presente trabalho, foi avaliado que, embora uma grande quantidade de modelos tenha sido desenvolvida, com o aumento da complexidade do problema, os modelos se tornam cada vez mais impraticáveis pela necessidade de parâmetros, ensaios e equipamentos. Sendo assim, os modelos neuronais propostos uma ferramenta prática para rápida aplicação no dia a dia da engenharia onde há a necessidade imediata de parâmetros de resistência dos maciços rochosos.

Para os modelos neuronais de previsão da tensão cisalhante e dilatância com o deslocamento horizontal, foi verificado em geral a influência mais relevante das variáveis de entrada da tensão normal inicial, JRC e rigidez normal do contorno como governantes para previsão da tensão cisalhante. Para a dilatância, teve-se o JRC, a razão t/a e a tensão normal inicial como mais importantes. Foi verificado que a retirada do parâmetro ϕ_b dos dados de entrada, influenciava negativamente a previsão sobretudo da dilatância. A retirada da variável σ_c , apesar de ter diminuído a capacidade de compreensão dos modelos, não apresentou resultados tão negativos como os com a retirada do ϕ_b .

Para os 116 ensaios de cisalhamento direto utilizados, com um total de 2083 exemplos tirados desses gráficos, com as variáveis de entrada k_n , t/a , σ_{no} , JRC, σ_c , ϕ_b , ϕ_{fill} , δ_h ; 80% dos ensaios usados para treinamento e 20% para teste validação, o modelo Gm foi escolhido para previsão da tensão cisalhante e dilatância com o deslocamento horizontal. O modelo Gm corresponde à um modelo do Grupo A uma arquitetura 8-20-10-5-2, que teve seus pesos sinápticos e bias obtidos após 500 mil iterações, seu coeficiente de correlação na fase de treinamento foi de 99,3% e na fase de teste de 99,0%.

O modelo Gm apresentou, em geral, uma boa interpolação com os ensaios usados para seu treinamento e validação. Para esses dados o modelo demonstrou boa compreensão para o aumento da tensão cisalhante e diminuição da dilatância com o aumento da tensão normal e k_n , assim como esperado pela literatura. O modelo demonstrou adequada compreensão tanto para rochas brandas quanto para duras, assim como apresentou o comportamento adequado e esperado para o aumento de t/a em termo de tensão cisalhante e dilatância.

O modelo Gm foi testado para descontinuidades hipotéticas como proposto por Dantas Neto *et al.* (2017) e comparado com resultados do modelo do autor. O modelo apresentou aumento da tensão cisalhante e diminuição da dilatância com aumento da tensão normal e rigidez normal, como era esperado. Também apresentou resultados semelhantes aos obtidos por Dantas Neto *et al.* (2017). Para a avaliação do modelo para descontinuidades hipotéticas preenchidas, o modelo apresentou diminuição da tensão cisalhante e dilatância com o aumento da razão t/a , como era esperado.

Por fim Gm foi comparado à equação analítica de Indraratna e Haque (2000), e com o modelo neuronal de Dantas Neto *et al.* (2017) para uma descontinuidade sem preenchimento sob CNS. O modelo Gm não conseguiu prever os dados experimentais tão bem quanto o modelo de Dantas Neto *et al.* (2017), que era esperado devido ao modelo de Dantas Neto *et al.* (2017) ser exclusivo para descontinuidades sem preenchimento. O Modelo Gm apresentou uma ordem de grandeza e interpolação boa, comparado aos modelos de Dantas Neto *et al.* (2017), Indraratna e Haque (2000) e aos dados experimentais.

Para a previsão da resistência cisalhante de pico, foram usados 131 dados para o desenvolvimento do modelo e as variáveis k_n , t/a , σ_{no} , JRC, σ_c , ϕ_b e ϕ_{fill} como dados de entrada. Para este modelo as variáveis de entrada k_n , σ_{no} , σ_c e JRC foram as mais relevantes para o modelo escolhido, cuja soma resulta em 82% da contribuição total.

O modelo G1m foi definido como o ótimo, correspondente ao modelo do grupo G1 com arquitetura 7-30-1 após 797.660 iterações. Seu coeficiente de correlação na fase de treinamento foi de 99,5% e na fase de teste de 98,0%. Este modelo foi escolhido à frente dos demais devido a ter sido o único a ter compreendido adequadamente as variáveis governantes quando aplicado nas juntas hipotéticas.

O modelo G1m apresentou excelente compreensão quando comparado os valores de sua previsão com os mesmos ensaios utilizados para seu treinamento e teste. O modelo previu o aumento da resistência cisalhante de pico com o aumento da tensão normal aplicada e da rigidez normal, conforme o esperado, para juntas de rochas brandas e duras. Para os ensaios

com preenchimento, apresentou diminuição da resistência cisalhante mobilizada de pico com o aumento do t/a . O modelo G1m foi comparado ao modelo Gm para as juntas hipotéticas e teve comportamento coerente e semelhante à Gm, para variação da tensão normal inicial aplicada, rigidez normal e t/a .

Também foi comparado G1m às previsões de cisalhamento de pico do modelo consagrado de Barton (1973b). Foi demonstrado, assim como esperado apresentado no Capítulo 2, que o modelo de Barton (1973b) seria coerente e consistente nos resultados para rochas brandas, cujo modelo G1m foi também foi, mas teve erros bruscos para rochas duras, nos quais os modelo G1m previu adequadamente.

Modelo G1m também foi comparado aos modelos analíticos, para resistência cisalhante de pico de descontinuidades preenchidas sob CNL. Foram comparados o modelo G1m, o modelo consagrado de Ladanyi e Archambault (1977) e o modelo de Shrivastava e Rao (2017), com os dados experimentais. Os três modelos apresentaram boa interpolação com os dados experimentais.

Ao fim, foi testada a descontinuidade hipotética para o modelo G1m e o modelo consagrado de Ladanyi e Archambault (1977) e conseqüentemente também o de Patton (1966). Os resultados gerados foram semelhantes para os modelos.

Em resumo, ambos os modelos geraram resultados satisfatórios em relação ao comportamento cisalhante. As comparações em relação aos dados usados para treinamento e teste, para a descontinuidade hipotética e para os modelos analíticos, seguiram conforme o almejado. Os modelos são então disponibilizados para previsão do comportamento cisalhante de forma prática, com o auxílio do uso de uma simples planilha usando os pesos sinápticos informados e equações apresentadas.

6.2 Sugestões para pesquisas futuras

Para a melhoria e validação dos resultados obtidos, segue as seguintes recomendações para pesquisas futuras:

- Aplicação do modelo em descontinuidades reais que sofreram falhas devido ao escorregamento para verificação dos resultados e possíveis melhorias dos modelos;

- Uso de mais exemplos para descontinuidades com e sem preenchimento, sobretudo de rochas duras para maior poder de aprendizado e representatividade de modelos neuronais;
- Avaliar o aumento das considerações das variáveis, levando em consideração a coesão do preenchimento, presença de humidade e sobreadensamento;
- Desenvolvimento de ábacos para uso do modelo sem a necessidade de uso de uso computacional;
- Aplicar os modelos em aplicações práticas para mecânica das rochas;
- Realizar análises de estabilidade de taludes rochosos rompidos reais com descontinuidades e condições de contorno diversas a fim de verificar a acurácia dos modelos.

REFERÊNCIAS

- AMANCIO, L. B.; DANTAS NETO, S. A.; ANJOS, G. J. M. Modelo de Previsão de Recalques Em Estacas Hélice Contínua Utilizando Redes Neurais Artificiais. In: XVII CONGRESSO BRASILEIRO DE MECÂNICA DOS SOLOS E ENGENHARIA GEOTÉCNICA, 2014, Goiânia, **Anais...** Goiânia: COBRAMSEG, 2014. CD-ROM.
- ARAÚJO, C. B. C. **Estimativa de Recalque Em Estacas Utilizando Redes Neurais Artificiais**. 2015. Dissertação (Mestrado) - Departamento de Engenharia Hidráulica e Ambiental, Universidade Federal do Ceará, Fortaleza, 2015.
- ASADOLLAHI, P.; TONON, F. Constitutive Model for Rock Fractures: Revisiting Barton's Empirical Model. **Engineering Geology**, v. 113, p. 11-32, 2010.
- BARTON, N. R. The shear strength of rock and rock joints. **Int. J. Rock Mech. Min. Sci.**, v. 13, n. 9, p. 255-279, 1976.
- BARTON, N. R. A Model Study of Rock-Joint Deformation. **International Journal of Rock Mechanics and Mining Sciences**, v. 9, p. 579-582, 1972.
- BARTON, N. R. A review of the shear strength of filled discontinuities in rock. **Norwegian Geotechnical Institute Publication**, n. 105, p. 1-38, 1973a.
- BARTON, N. R. A Review of a New Shear-Strength Criterion for Rock Joints. **Engineering Geology**, v. 7, n. 4, p. 287-332, 1973b.
- BARTON, N. R.; BANDIS, S. C. Review of predictive capabilities of JRC-JCS model in engineering practice. IN: INTERNATIONAL SYMPOSIUM ON ROCK JOINTS, 1990, Rotterdam. **Proceedings...** Loen, Balkema, Rotterdam: Barton N. & Stephansson O. (eds), 1990, p. 603-610.
- BARTON, N. R. Non-linear shear strength for rock, rock joints, rockfill and interfaces. **Innov. Infrastruct. Solut.**, v. 1, n. 1, p. 1-30, 2016.
- BARTON, N. R.; BANDIS, S. Effect of block size on the shear behavior of jointed rock. **J. Rock Mechanics**, v. 23, p. 739-760, 1982.
- BARTON, N. R.; CHOUBEY, V. The shear strength of rock joints in theory and practice. **Rock Mechanics and Rock Engineering**, v. 10, n. 1-2, p. 1-54, 1977.
- BENMOKRANE, B.; BALLIVY, G. Laboratory study of shear behaviour of rock joints under constant normal stiffness conditions. **Rock Mechanics as a Guide for Efficient Utilization of Natural Resources**, Khair, Balkema, Rotterdam, p. 899-906, 1989.
- BIRKHAUSER, V. Friction of Rocks. **Pageoph.**, v. 116, p. 615-626, 1978.
- BISHOP, C. M. Neural Networks for Pattern Recognition. **Technical Report: NCRG/96/001**, 1995.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. 1. ed. New York, USA: Springer, 2006.
- BUCHER, W. H. The mechanical interpretation of joints. **Journal of Geology**, v. 29, p. 1-28, 1921.
- DANTAS NETO, A. S.; INDRARATNA, B.; OLIVEIRA, D. A. F. Prediction of the Shear Behaviour of Clean Joints in Soft Rocks Using Perceptron. In: VII SIMPÓSIO BRASILEIRO

- DE MECÂNICA DAS ROCHAS, 2016, Belo Horizonte. **Anais...** Belo Horizonte, Minas Gerais: SBMR, 2016. p. 1817-1831.
- DANTAS NETO, S. A.; AMÂNCIO, L. B.; JACQUES, G. Pile Settlement Modeling with Multilayer Perceptrons. **EJGE**, v.19, p. 4517-4528, 2014.
- DANTAS NETO, S. A.; INDRARATNA, B.; OLIVEIRA, D. A. F.; ASSIS, P. Modelling the Shear Behaviour of Clean Rock Discontinuities Using Artificial Neural Networks. **Rock Mech. Rock Eng.**, v. 50, p. 1817-1831, 2017.
- DEGHAN, S.; SATTARI, G.; CHELGANI, C. S.; ALIABADI, M. A. Prediction of uniaxial compressive strength and modulus of elasticity for Travertine samples using regression and artificial neural networks. **Min. Sci. Technol.**, v. 20, p. 41-46, 2010.
- DIGHT, P. M.; CHIU, H. K. Prediction of Shear Behaviour of Joints Using Profiles. **International Journal of Rock Mechanics and Mining Sciences and Geomatics**, v. 18, p. 369-86, 1981.
- GOODMAN, R. E.; TAYLOR, R. L.; BREKKE, T. L. A model for the mechanics of jointed rock. *J. Soil Mech. Found. Div.*, **ASCE**, **94(SM3)**, p. 637-659, 1968.
- GOODMAN, R. E. The Deformability of Joints. In: Determination of the In-Situ Modulus of Deformation of Rock. **ASTM, STP 477**, p. 174-196, 1969.
- GRASSELLI, G. Shear strength of Rock Joints Based on Quantified Surface Description. **Rock Mech. Rock Eng.**, v. 39, n. 4, p. 295-314, 2006.
- HAQUE, A. **Shear Behaviour of Soft Rock Joints under Constant Normal Stiffness**. 1999. Tese (Doutorado) - University of Wollong. Department of Civil, Mining and Environmental Engineering. Wollongong, Austrália, 1999.
- HAYKIN, S. **Neural Networks And Learning Machines**. 3rd ed. Ontario, Canada: Pearsonn, 2008.
- HENCHER, S. R.; RICHARDS, L. R. Assessing the Shear Strength of Rock Discontinuities at Laboratory and Field Scales. **Rock Mechanics and Rock Engineering**, v. 48, n. 3, p. 883-905, 2015.
- HORN, H. M.; DEERE, D. U. Frictional Characteristics of Minerals. **Géotechnique**, v. 12, n. 4, p. 319-335, 1962.
- INDRARATNA, B.; FASCE, A. M.; OLIVEIRA, D. A. F.; PREMADASA, W. Shear Behaviour of Rock Joints Under Cyclic Loading. In: 11th AUSTRALIA - NEW ZEALAND CONFERENCE ON GEOMECHANICS: GROUND ENGINEERING IN A CHANGING WORLD, 2012, Melbourne. **Proceedings...** Melbourne, New Zealand: ANZ, 2012. p. 1256-1261.
- INDRARATNA, B.; JAYANATHAN, M.; BROWN, E. T. Shear strength model for overconsolidated clay-infilled idealised rock joints. **Géotechnique**, v. 58, n. 1, p. 55-65, 2008a.
- INDRARATNA, B.; OLIVEIRA, D. A. F.; BROWN, E. T. A Shear-Displacement Criterion for Soil-Infilled Rock Discontinuities. **Géotechnique**. v. 60, n. 8, p. 623-33, 2010.
- INDRARATNA, B.; WELIDENIYA, H. S.; BROWN, E. T. A Shear Strength Model for Idealised Infilled Joints under Constant Normal Stiffness. **Géotechnique**. v. 55, n. 3, p. 215-26, 2005.

INDRARATNA, B.; HAQUE, A.; AZIZ, N. Laboratory modelling of shear behaviour of soft joints under constant normal stiffness conditions. **Geotechnical and Geological Engineering**, v. 16, p. 17-44, 1998.

INDRARATNA, B.; HAQUE, A. Experimental and numerical modeling of shear behaviour of rock joints, **GeoEng 2000**, 2000. CD-ROM.

INDRARATNA, B.; PREMADASA, W.; BROWN, E. T.; GENS, A.; HEITOR, A. Shear strength of rock joints influenced by compacted infill. **Int. J. Rock Mech. Min. Sci.**, v. 70, p. 296-307, 2014.

INDRARATNA, B.; KUMARA, C.; ZHU, S.-P.; SLOAN, S. Mathematical Modeling and Experimental Verification of Fluid Flow through Deformable Rough Rock Joints, **Int. J. Geomech.**, v. 15, n. 4, p. 04014065-1-04014065-11, 2015.

INDRARATNA, B.; OLIVEIRA, D. A. F.; JAYANATHAN, M. Revised Shear Strength Model for Infilled Rock Joints Considering Overconsolidation Effect. In: 1ST SOUTHERN HEMISPHERE INTERNATIONAL ROCK MECHANICS SYMPOSIUM SHIRMS, 1, 2008, Perth, **Proceedings...** Perth, Australia: SHIRMS, 2008b. p. 16-19.

INDRARATNA, B.; PREMADASA, W.; BROWN, E. T. Shear Behaviour of Rock Joints with Unsaturated Infill. **Géotechnique**, v. 3, n. 15, p. 1356-1360. 2013.

JAEGER, J. C. Friction Of Rocks And Stability Of Rock Slopes. **Géotechnique**, v. 2, p. 97-134, 1971.

KARAKUS, M.; LIU, Y.; ZHANG, G.; TANG, H. A new shear strength model incorporating influence of infill materials for rock joints. **Geomech. Geophys. Geo-Energy Geo-Resources**, v. 2, n. 3, p. 183-193, 2016.

KOOPIALIPOOR, M.; FAHIMIFAR, A.; FAHIMIFAR, A.; GHALEINI, E. N.; MOMENZADEH, M.; ARMAGHANI, D. J. Development of a New Hybrid ANN for Solving a Geotechnical Problem Related to Tunnel Boring Machine Performance. **Engineering with Computers**, v. 34, p. 1-13, 2019.

KULHAWY, F. H. Stress Deformation Properties of Rock and Rock Discontinuities. **Engineering Geology**, v. 9, n. 4 p. 327-350, 1975.

LADANYI, B.; ARCHAMBAULT, G. Simulation of Shear Behavior of a Jointed Rock Mass. In: ELEVENTH U.S. SYMPOSIUM ON ROCK MECHANICS: THEORY AND PRACTICE. 1969, Berkeley, **Proceedings...** Alexandria, VA: American Rock Mechanics Association Press, 1969. p. 105-125,

LADANYI, B.; ARCHAMBAULT, G. Shear Strength and Deformability of Filled Indented Joints. In: INT. SYMP. ON GEOTECHNICS OF STRUCTURALLY COMPLEX FORMATIONS. 1977, Berkeley, **Proceedings...** Alexandria, VA: American Rock Mechanics Association Press, 1977. p. 317-326.

LEE, Y. K.; PARK, J. W.; SONG, J. J. Model for the Shear Behavior of Rock Joints under CNL and CNS Conditions. **International Journal of Rock Mechanics and Mining Sciences**, v. 70, p. 252-263, 2014.

LEICHNITZ, W. Mechanical Properties of Rock Joints. **International Journal of Rock Mechanics and Mining Sciences & Geomechanics**, v. 22, n. 5, p. 313-321, 1985.

LEITE, A. R. S.; DANTAS NETO, S. A.; POLEMIS JÚNIOR, K.; OLIVEIRA, C. M. O. Study

on the shear behaviour of rock joints using different models of artificial neural networks. In: INTERNATIONAL CONGRESS ON ROCK MECHANICS AND ROCK ENGINEERING, 2018, Foz do Iguaçu, **Proceedings...** Foz do Iguaçu, Paraná: ISRM, 2018. p. 2707-2714.

MATOS, Y. M. P. **Desenvolvimento de modelos de previsão do comportamento cisalhante em descontinuidades sem preenchimento de maciços rochosos utilizando técnicas fuzzy e neuro-fuzzy.** 2018. Dissertação (Mestrado) - Departamento de Engenharia Hidráulica e Ambiental, Universidade Federal do Ceará, Fortaleza, 2018.

MATOS, Y. M. P.; DANTAS NETO, S. A.; BARRETO, G. A. A Takagi-Sugeno fuzzy model for predicting the clean rock joints shear strength, **REM - Int. Eng. J.**, v. 72, o. 2, p. 193-198, 2019a.

MATOS, Y. M. P.; DANTAS NETO, S. A.; BARRETO, G. A. Predicting the Shear Strength of Unfilled Rock Joints with the First-Order Takagi-Sugeno Fuzzy Approach. **Soils and Rocks**, v. 42, n. 1, p. 21-29, 2019b.

MEHRISHAL, S.; SHARIFZADEH, M.; SHAHRIAR, K.; SONG, J. J. An Experimental Study on Normal Stress and Shear Rate Dependency of Basic Friction Coefficient in Dry and Wet Limestone Joints. **Rock Mech. Rock Eng.**, v. 49, n. 12, p. 4607-4629, 2016.

MEULENKAMP, F.; GRIMA, M. A. Application of neural networks for the prediction of the unconfined compressive strength (UCS) from Equotip hardness. **Int. J. Rock Mech. Min. Sci.**, v. 36, p. 29-39, 1999.

MOHAMAD, E. T.; ARMAGHANI, D. J.; MOMENI, E.; ABAD, S. V. A. N. K. Prediction of the Unconfined Compressive Strength of Soft Rocks : A PSO-Based ANN Approach. **Bull Eng Geol Environ.**, v. 74, n. 3, p. 745-757, 2014.

MOSHREFII, S.; SHAHRIAR, K.; RAMEZANZADEH, A.; GOSHTASBI, K. Prediction of ultimate strength of shale using artificial neural network. **Journal of Mining & Environment**, v. 9, n. 1, p. 91-105, 2018.

NAGHADEHI, M. Z. Laboratory Study of the Shear Behaviour of Natural Rough Rock Joints Infilled by Different Soils. **Periodica Polytechnica Civil Engineering**, v. 59, n. 3, p. 413-421, 2015.

OLIVEIRA, D. A. F.; INDRARATNA, B.; NEMCIK, J. Critical Review on Shear Strength Models for Soil-Infilled Joints. **Geomechanics and Geoengineering**, v. 4, n. 3, p. 237-244, 2009.

PAPALIANGAS, T.; HENCHER, S. R.; LUMSDEN, A. C.; MANOLOPOULOU, S. The Effect of Frictional Fill Thickness on the Shear Strength of Rock Discontinuities. **International Journal of Rock Mechanics and Mining Sciences and Geomatics**, v. 30, n. 2, p. 81-91. 1993.

PAPALIANGAS, T.; LUMSDEN A. C.; HENCHER, S. R.; MANOLOPOULOU, S. Shear Strength of Modelled Filled Rock Joints. In: INT. SYMP. ON ROCK JOINTS, 1990, Balkema, **Proceedings...** Balkema, Rotterdam: Barton & Stephansson (eds), 1990. p. 275-282.

PATTON, F. D. Multiple modes of shear failure in rocks. In: 1ST CONG, INT. SOC. ROCK MECH., 1, 1966. Lisboa. **Proceedings...** Lisboa, Portugal: ISRM, 1966. p. 509-513.

PRASSETYO, S. H.; GUTIERREZ, M.; BARTON, N. R. Nonlinear Shear Behavior of Rock Joints Using a Linearized Implementation of the Barton–Bandis Model. **Journal of Rock**

Mechanics and Geotechnical Engineering, v. 9, n. 4, p. 671-682 , 2017.

PREMADASA, W.; INDRARATNA, B. Shear Behaviour of Infilled Rock Joints Related to Partially Saturated Infill Conditions. In: INTERNATIONAL CONFERENCE ON GEOTECHNICAL ENGINEERING, 2015, Colombo, **Proceedings...** Colombo, United Kingdom: ICGE, 2015. CD-ROM.

RICHARD, L. R. **The Shear Strength of Joints in Weathered Rock**. 1975. Tese (Doutorado) - Faculty of Engineering, Universidade de Londres, 1975.

RIPLEY B. D. **Pattern Recognition and Neural Networks**. Cambridge University Press, 1996.

RUNXUAN, Z. **Efficient Sequential and Batch Learning Artificial Neural Network Methods for Classification Problems**. 2005. Tese (Doutorado) - School of Electrical & Electronic Engineering, Nanyang Technological, Singapura. 2005.

SAEB, S.; AMADEI, B. Modelling rock joints under shear and normal loading. **Int. J. Rock Mech. Min. Sci.**, v. 29, n. 3, p. 267-278, 1992.

SCHMIDHUBER, J. Deep Learning in Neural Networks : An Overview. **Neural Networks**, v. 61, p. 85-117, 2015.

SHRIVASTAVA, A. K.; RAO. K. S. Shear Behaviour of Rock Joints under CNS Boundary Conditions. In: 18TH INTERNATIONAL CONFERENCE ON SOIL MECHANICS AND GEOTECHNICAL ENGINEERING. 2013, Paris. **Proceedings...** Paris, France: CFMS. 2013. p. 961-964.

SHRIVASTAVA, A. K.; RAO, K. S. Physical Modeling of Shear Behavior of Infilled Rock Joints Under CNL and CNS Boundary Conditions. **Rock Mech. Rock Eng.**, v. 51, n. 1, p. 101-118, 2017.

SINGH, H. K.; BASU, A. A Comparison Between the Shear Behavior of ‘Real’ Natural Rock Discontinuities and Their Replicas. **Rock Mechanics and Rock Engineering**, v. 51, n. 1, p. 329-340, 2018.

SINGH, V.; SINGH, T. N. A Neuro-Fuzzy Approach for Prediction of Poisson’s Ratio and Young’s Modulus of Shale and Sandstone. In: 41ST U.S. SYMPOSIUM ON ROCK MECHANICS, 2006, Golden. **Proceedings...** Golden, Colorado: ARMA, 2006. p. 1-7.

SINGH V. K.; SINGH, D.; SINGHA, T. N. Prediction of strength properties of some schistose rocks from petrographic properties using artificial neural networks. **Int. J. Rock Mech. Min. Sci.**, v. 38, p. 269-284, 2001.

SKINAS, C. A.; BANDIS, S. C.; DEMIRIS, C. A. Experimental Investigations and Modelling of Rock Joint Behaviour Under Constant Stiffness. In: Barton, Stephanson (eds). **Rock joints**, Balkema Publisher, Rotterdam. p. 301-307, 1990.

SONMEZ, H.; ERCANOGLU, M.; KALENDER, A.; DAGDELENLER, G.; TUNUSLUOGLY, R.; Predicting uniaxial compressive strength and deformation modulus of volcanic bimrocks considering engineering dimension. **Int. J. Rock Mech. Min. Sci.**, v. 86, p. 91-103, 2016.

THIRUKUMARAN, S.; INDRARATNA, B. A Review of Shear Strength Models for Rock Joints Subjected to Constant Normal Stiffness. **Journal of Rock Mechanics and Geotechnical Engineering**, v. 8, n. 3, p. 405-414, 2016

TIAN, Y.; LIU, Q.; LIU, D.; KANG, Y.; DENG, P.; H. E. F. Updates to Grasselli's Peak Shear Strength Model Updates to Grasselli's Peak Shear Strength Model. **Rock Mechanics and Rock Engineering**, v. 51, n. 7, p. 2115-2133, 2018.

TSE, R.; CRUDEN, D. M. Estimating Joint Roughness Coefficients. **International Journal of Rock Mechanics and Mining Sciences**, v. 16, n. 5, p. 303-307, 1979.

YANG, J.; RONG, G.; CHENG, L.; HOU, D.; WANG, X. Experimental Study of Peak Shear Strength of Rock Joints. **Chinese J. Rock Mech Eng.**, v. 34, n. 5, p. 884-894, 2016.

YILMAZ, I.; YUKSEK, A. G. An example of artificial neural network (ANN) application for indirect estimation of rock parameters. **Rock Mechanics and Rock Engineering**, v. 41, n. 5, p. 781-795, 2008

XIA, C. C.; TANG, Z. C.; XIAO, W. M.; SONG, Y. L. New peak shear strength criterion of rock joints based on quantified surface description. **Rock Mechanics and Rock Engineering**, v. 47, p. 387-400, 2014.

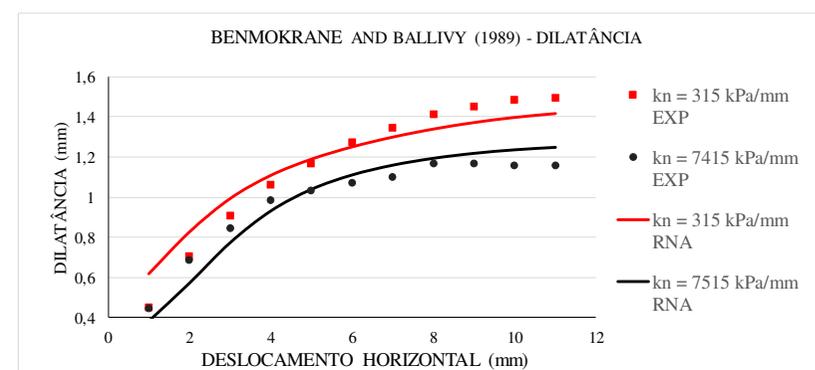
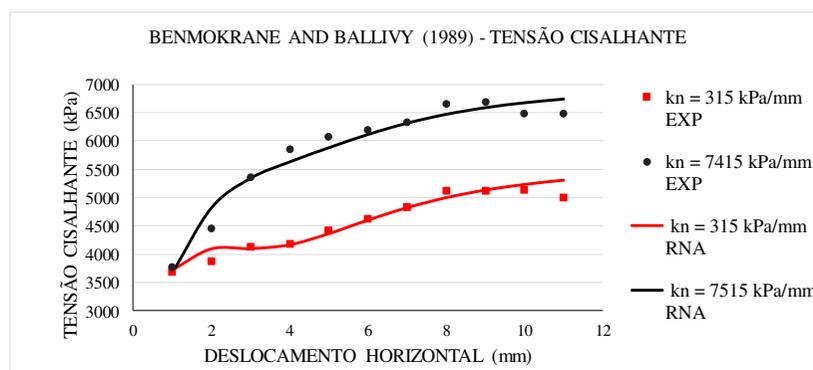
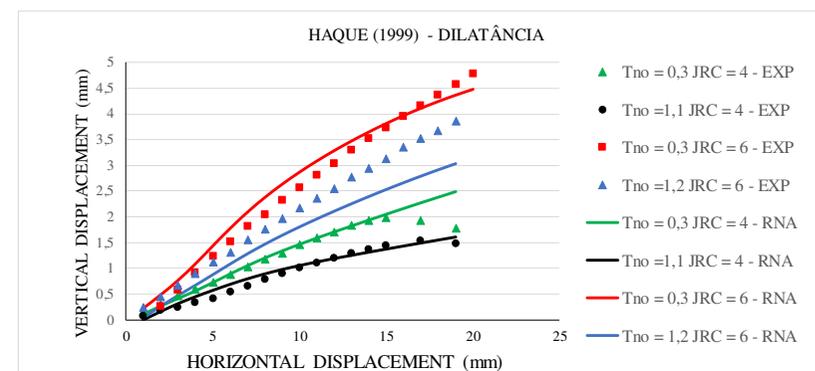
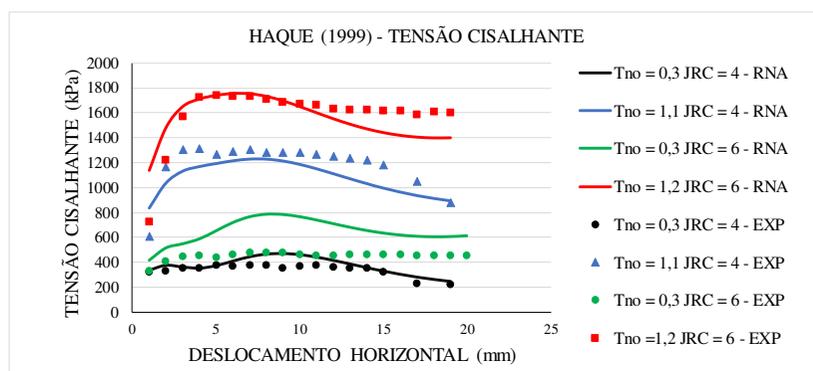
ZEIGLER, T. W. In Situ Tests For The Determination. **Technical Report S-72-12**, 1972.

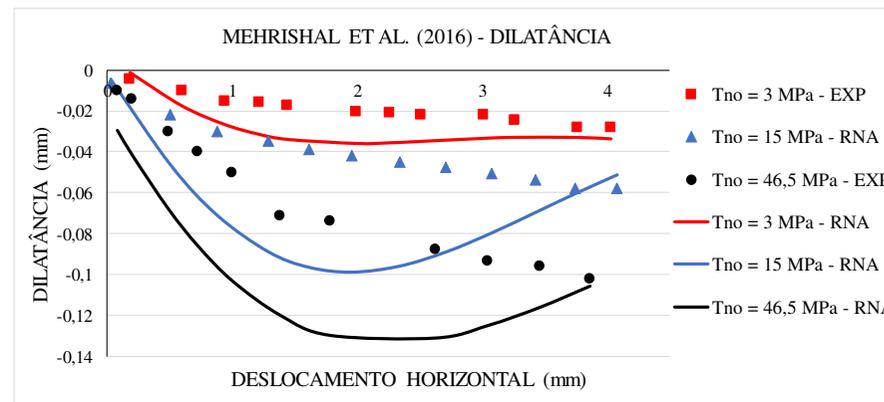
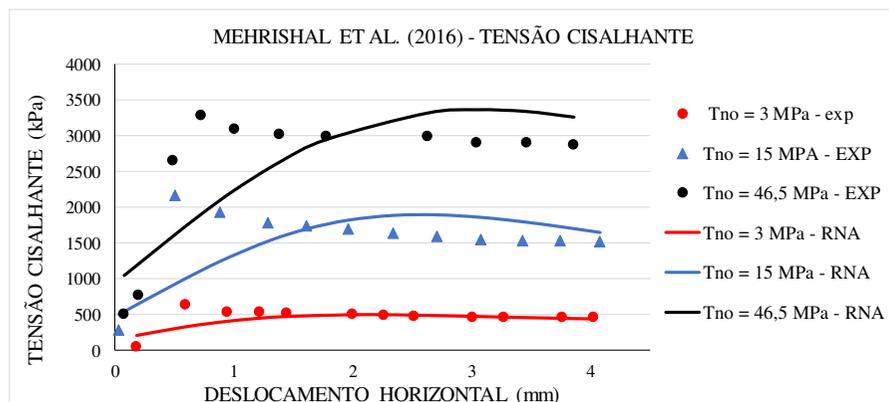
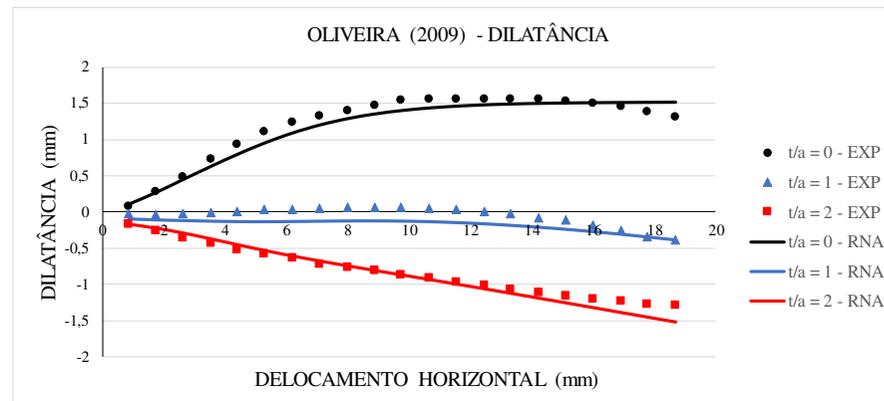
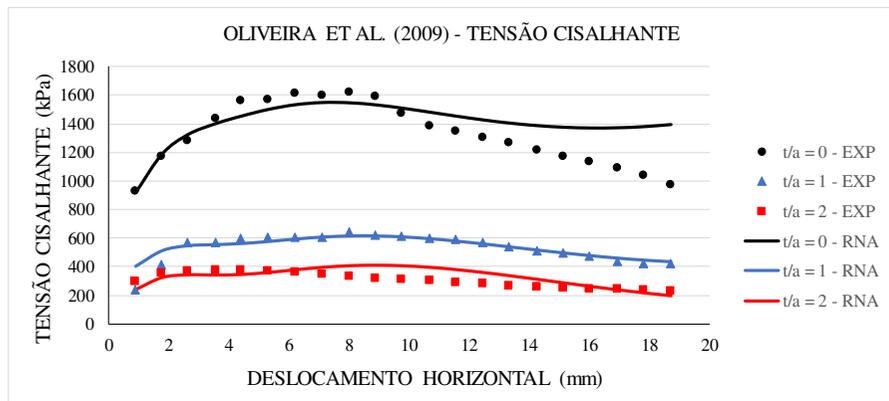
ZHANG, X.; JIANG, Q.; CHEN, N.; WEI, W.; FENG, X. Laboratory Investigation on Shear Behavior of Rock Joints and a New Peak Shear Strength Criterion. **Rock Mechanics and Rock Engineering**, v. 49, n. 9, p. 3495-3512, 2016.

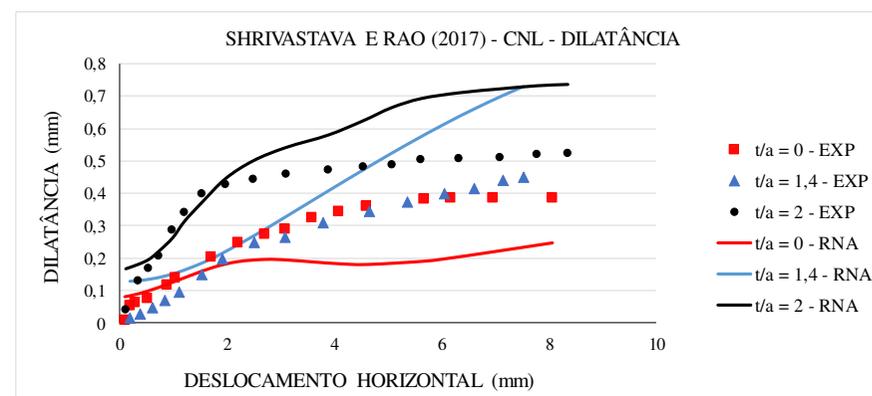
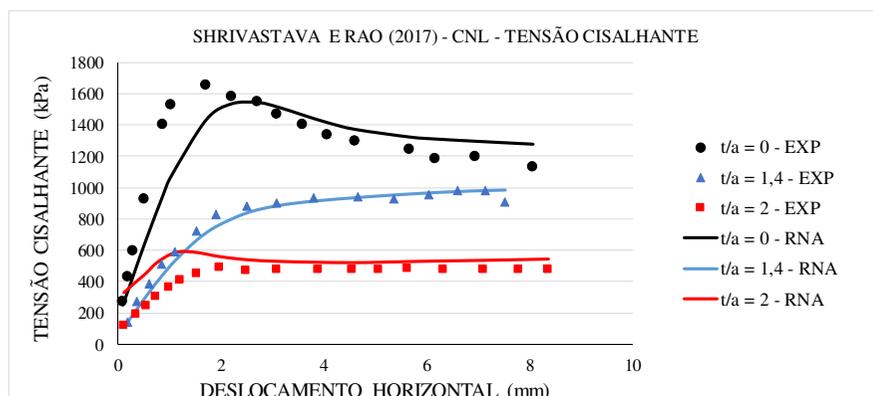
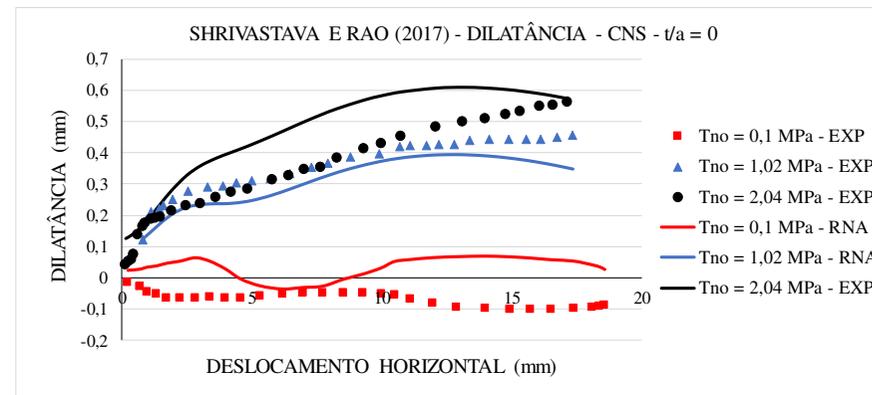
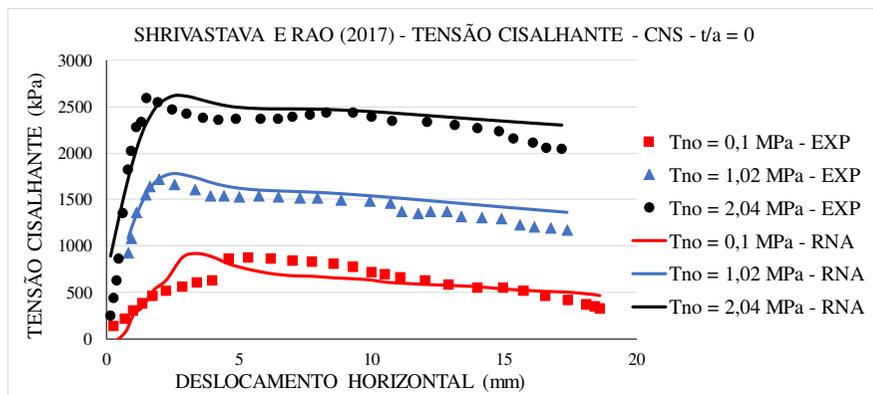
APÊNDICE A – INTERPOLAÇÃO DOS GRÁFICOS DAS MELHORES ARQUITETURAS

Gráficos de cisalhamento direto das discontinuidades rochosas de Benmokrane e Ballivy (1989), Haque (1999), Oliveira *et al.* (2009), Mehrishal *et al.* (2016) e Shrivastava e Rao (2018) foram usados a fim de verificar quais dos modelos com maior correlação para os dados de teste, melhor interpolavam os gráficos de tensão cisalhante e dilatância com deslocamento horizontal. Na sequência os gráficos dos melhores modelos dos grupos A, A2, B, B2, C.

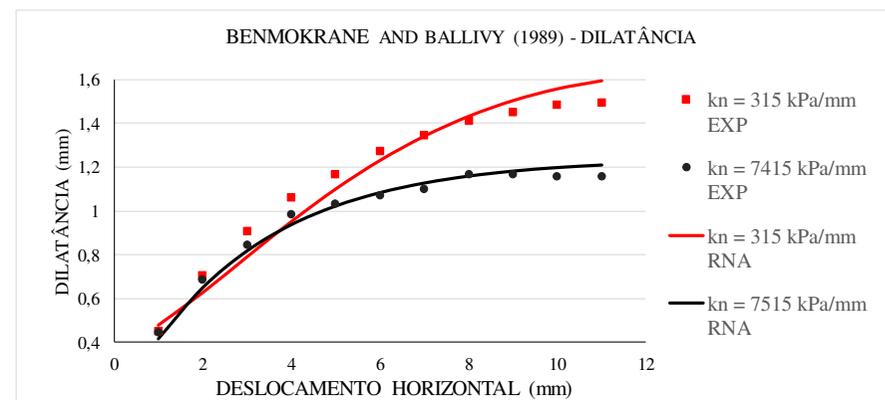
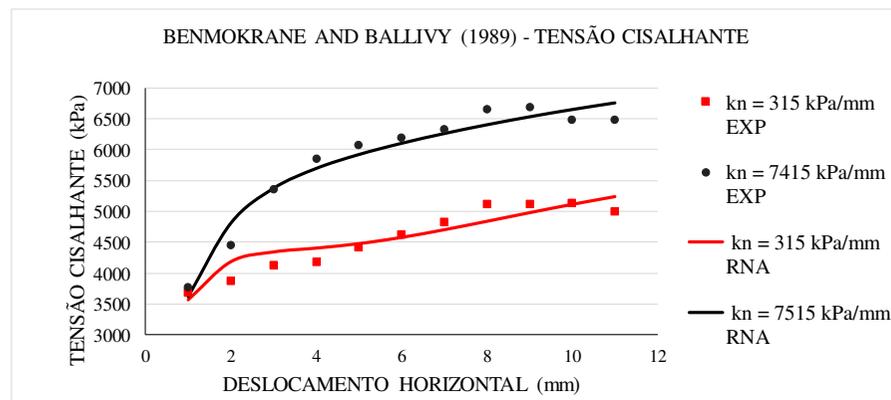
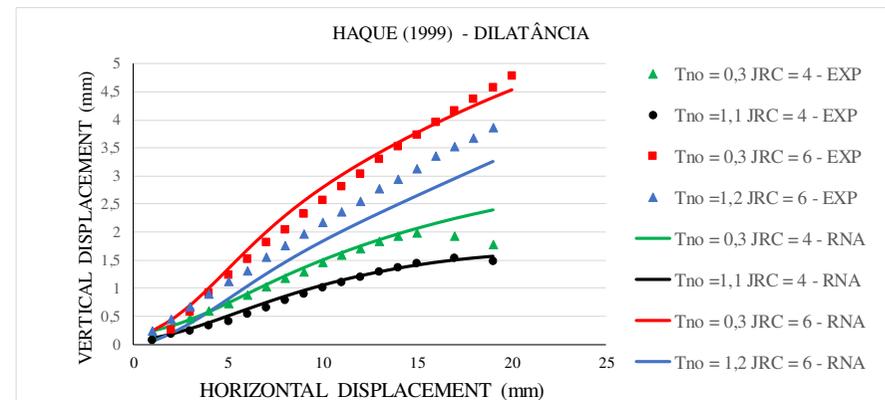
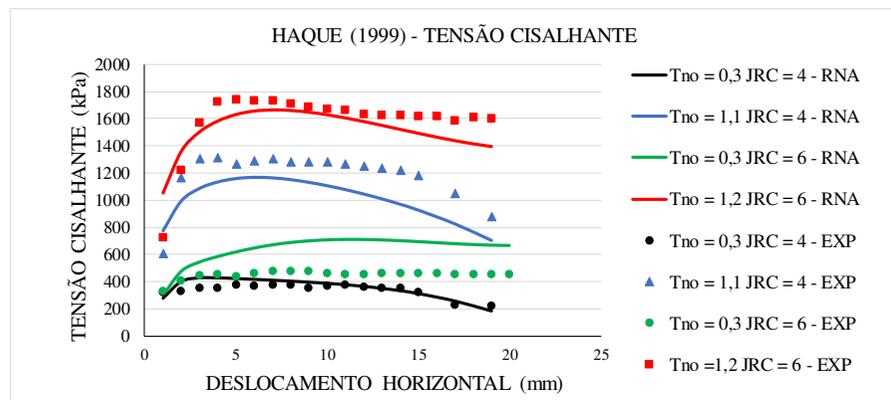
GRUPO A – ARQUITETURA: 8-20-10-5-2 – 500.000 ITERAÇÕES - GRÁFICOS

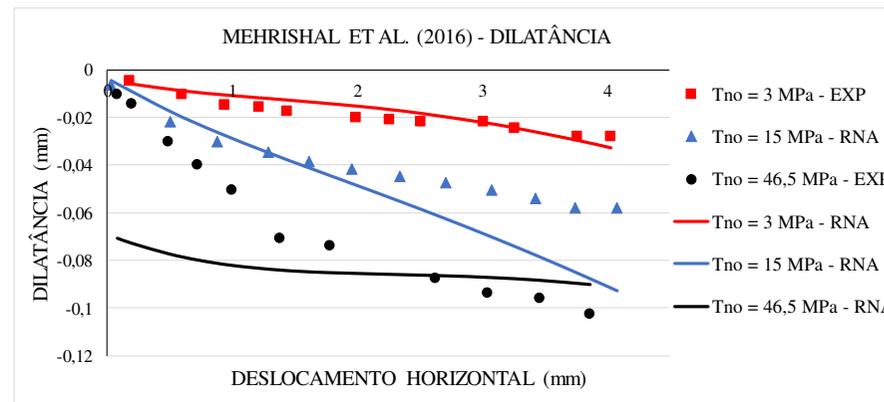
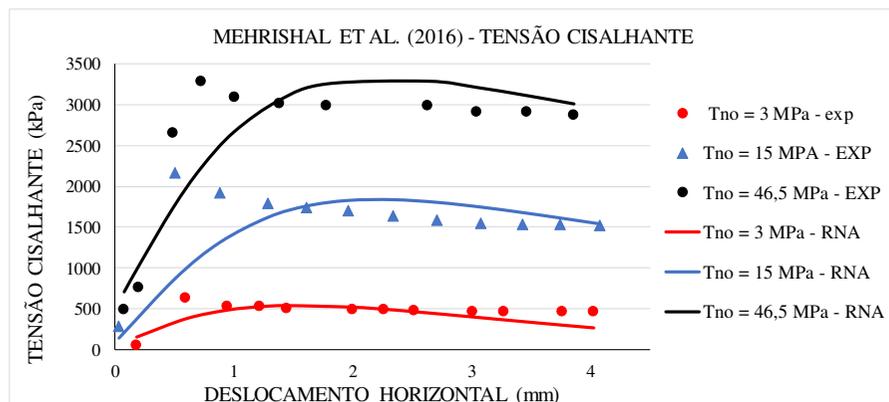
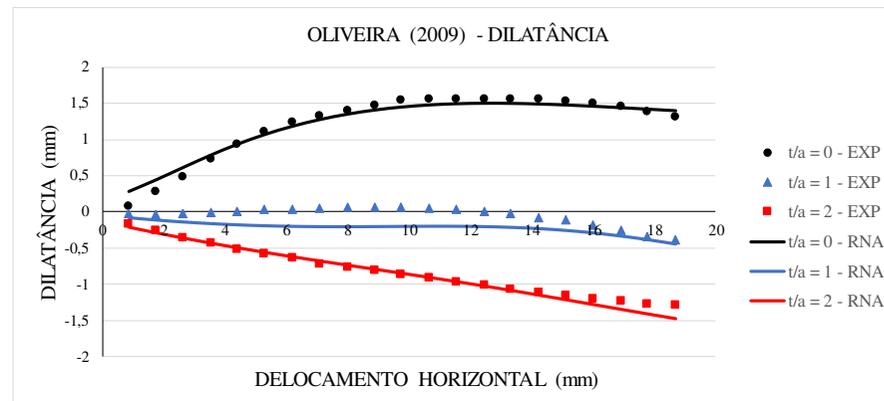
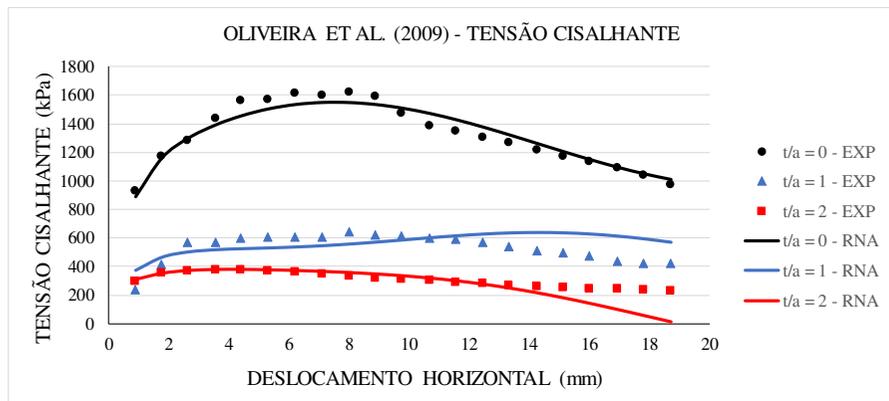


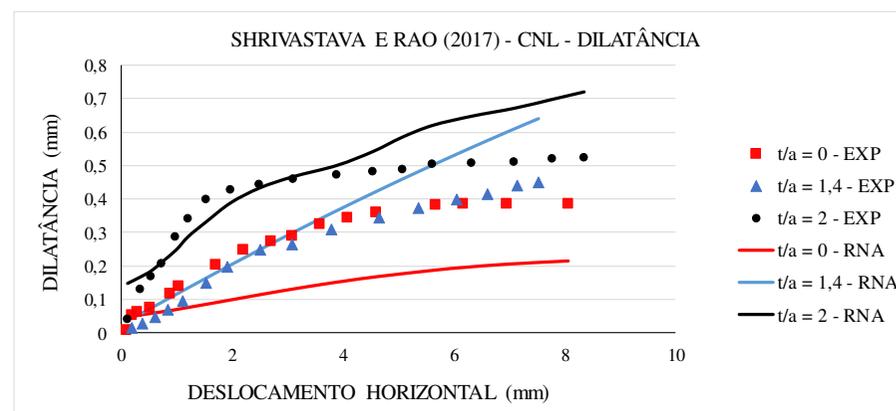
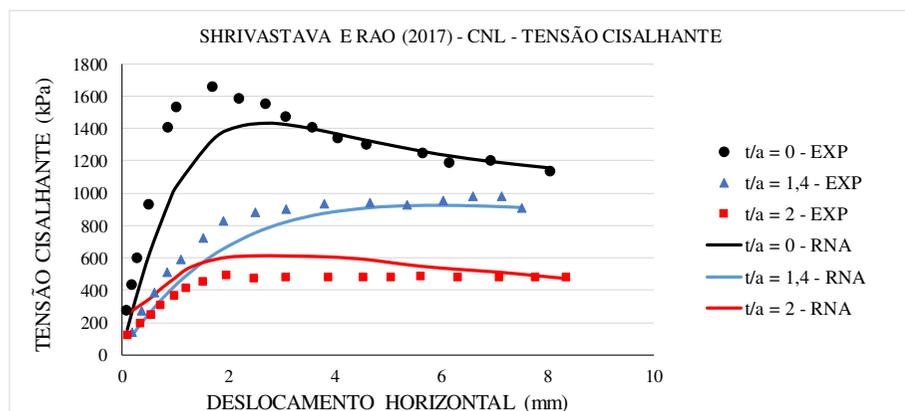
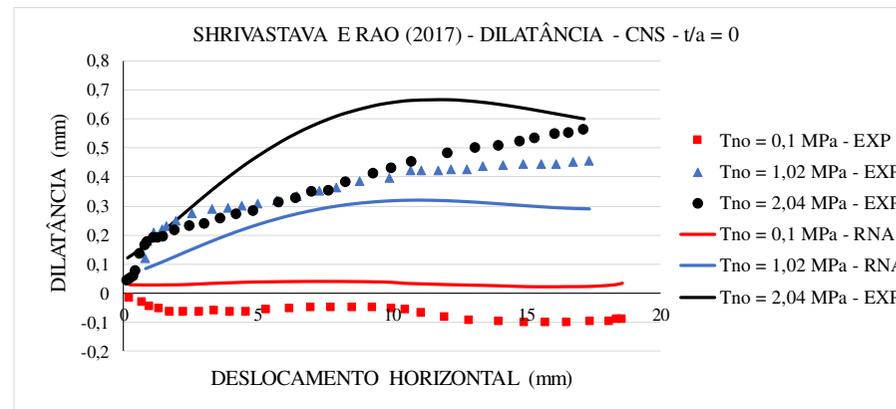
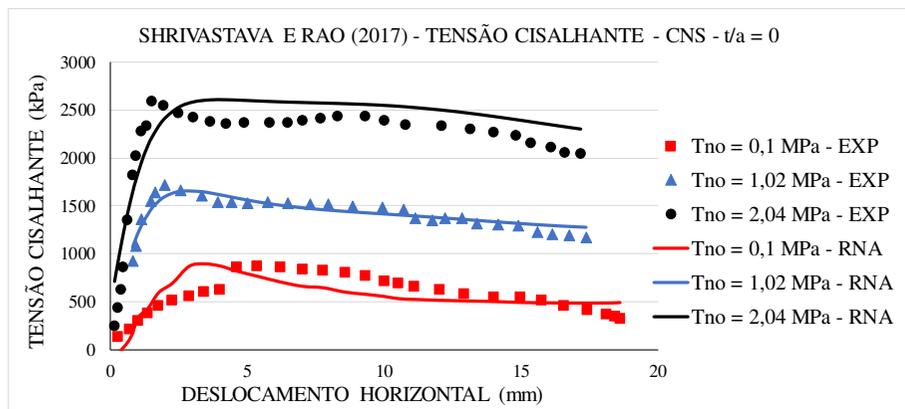




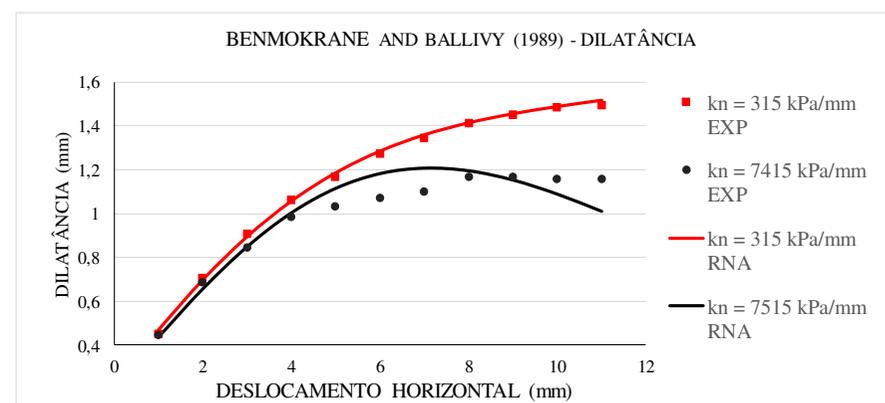
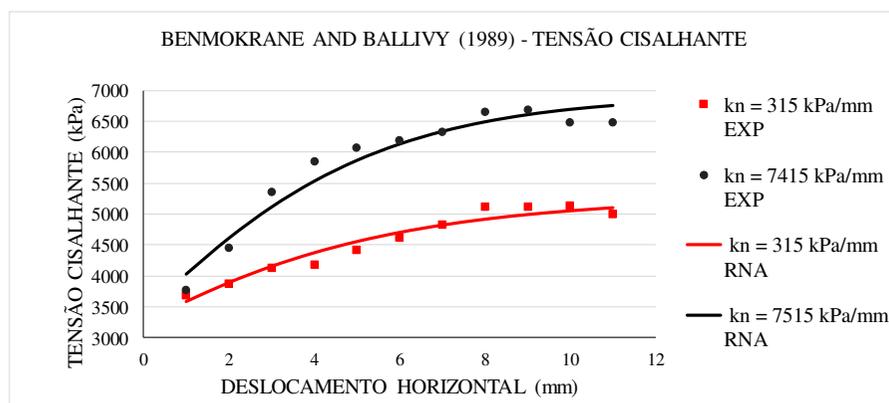
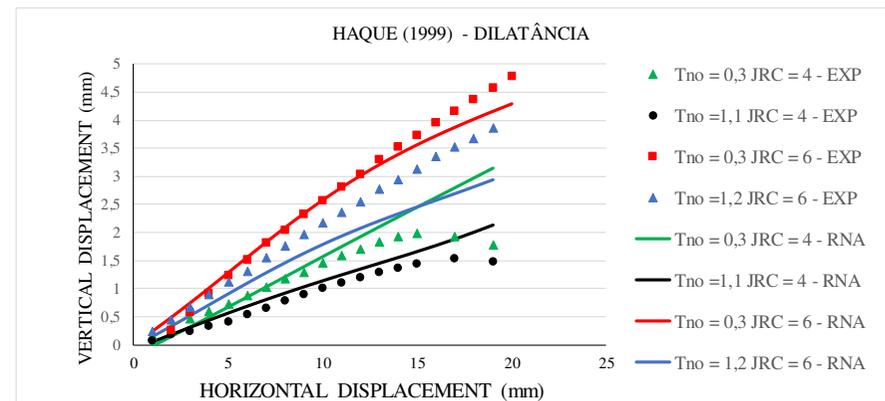
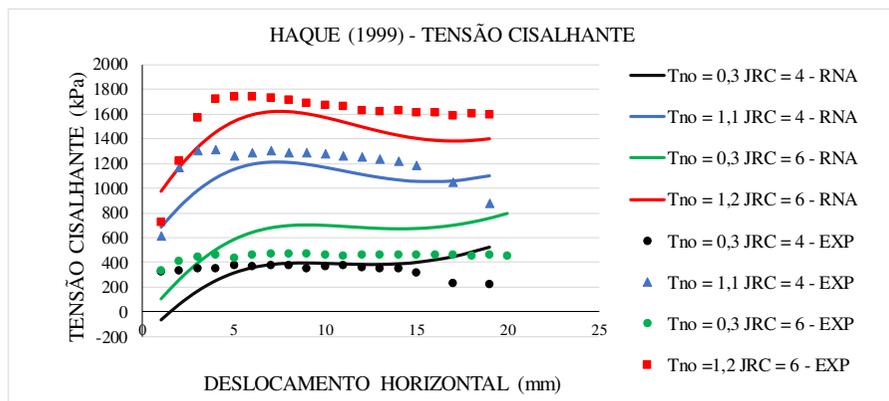
GRUPO A2 – ARQUITETURA: 8-30-10-2 – 500.000 ITERAÇÕES - GRÁFICOS

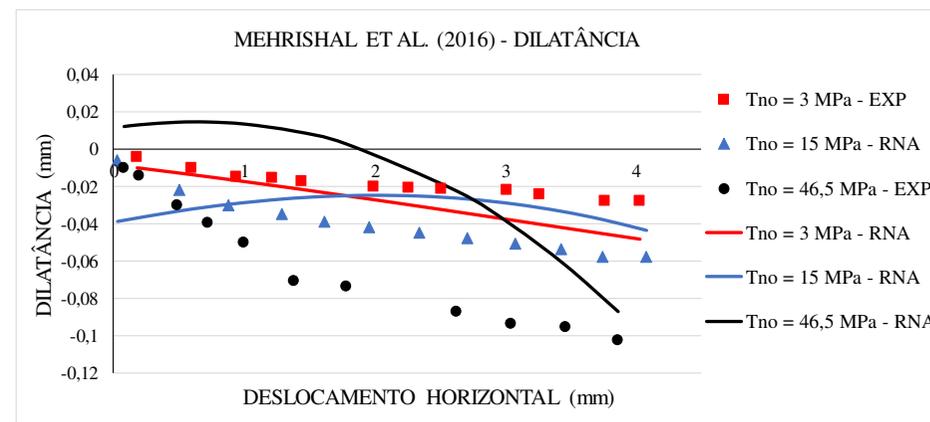
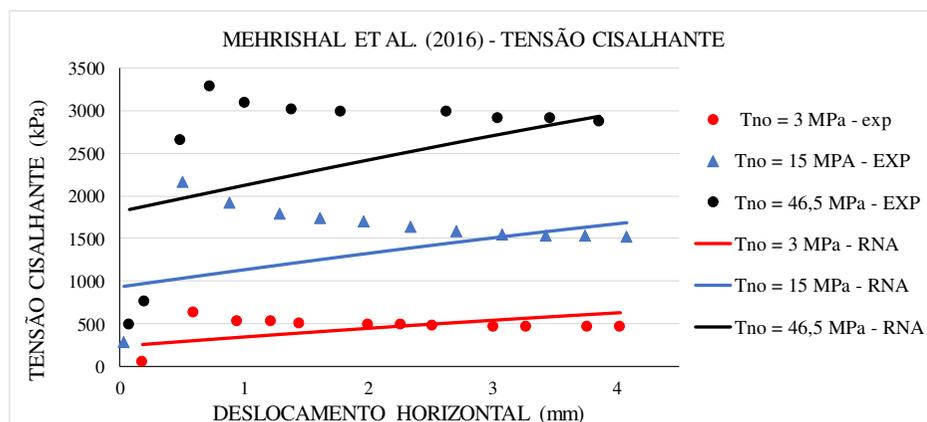
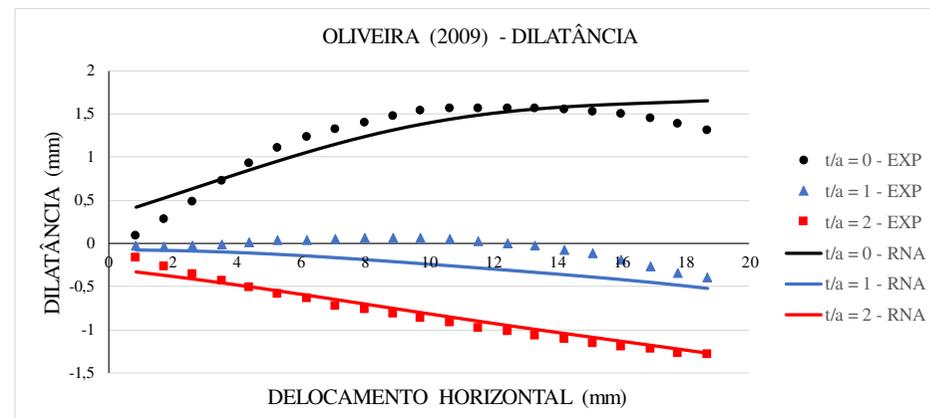
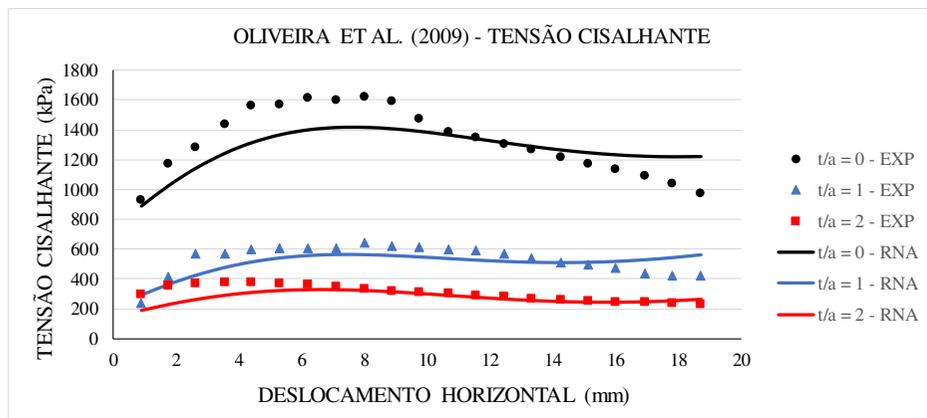


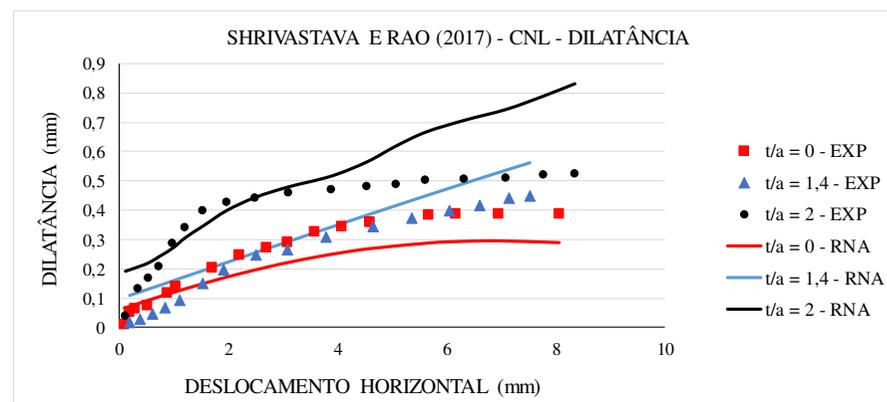
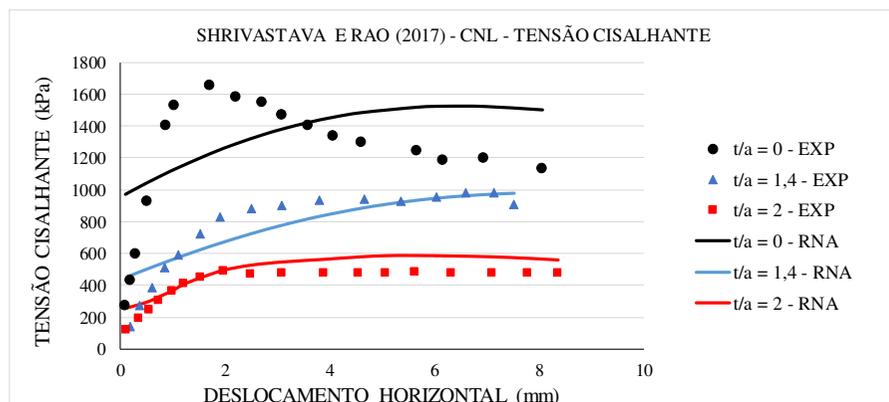
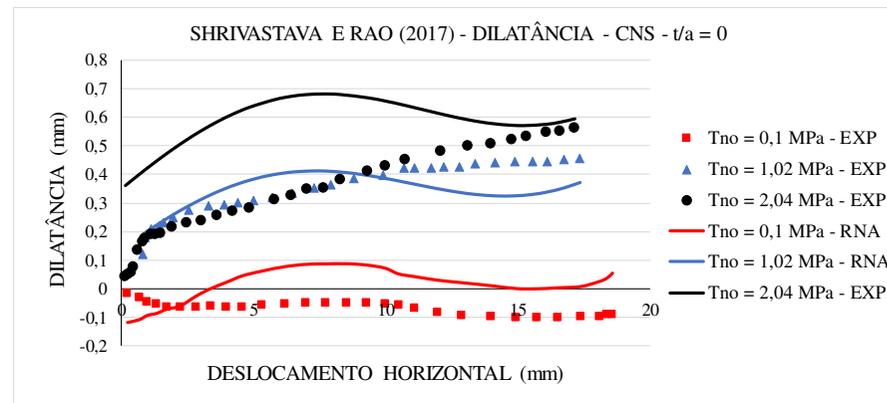
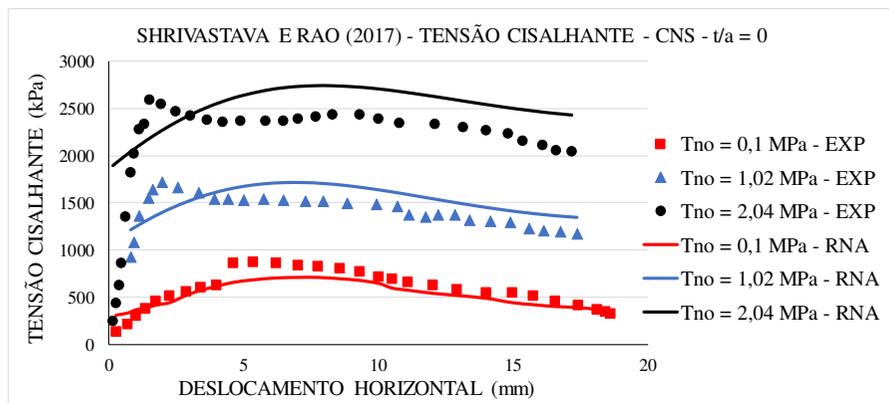




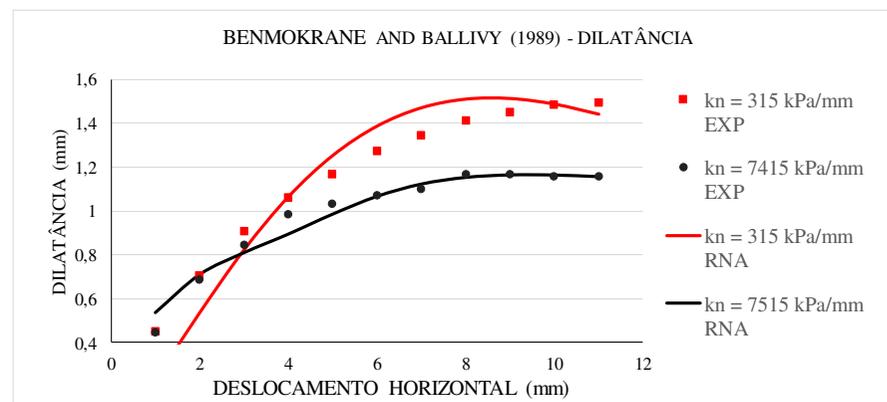
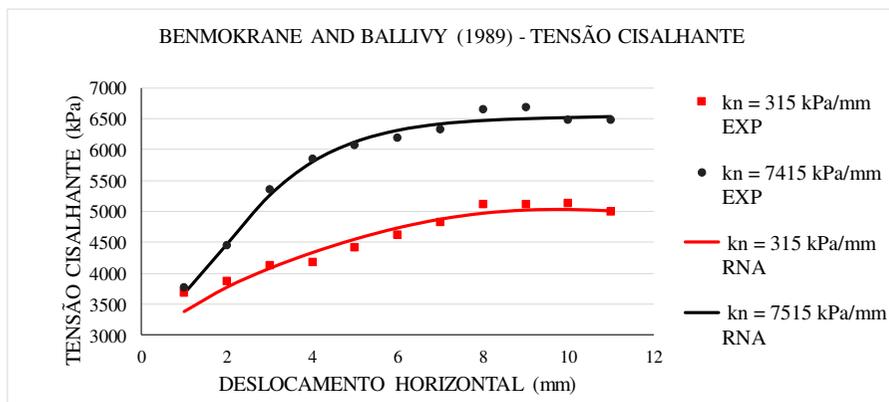
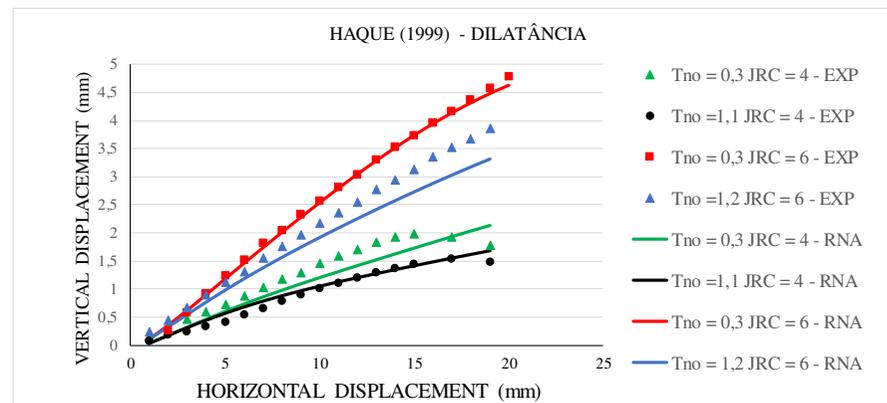
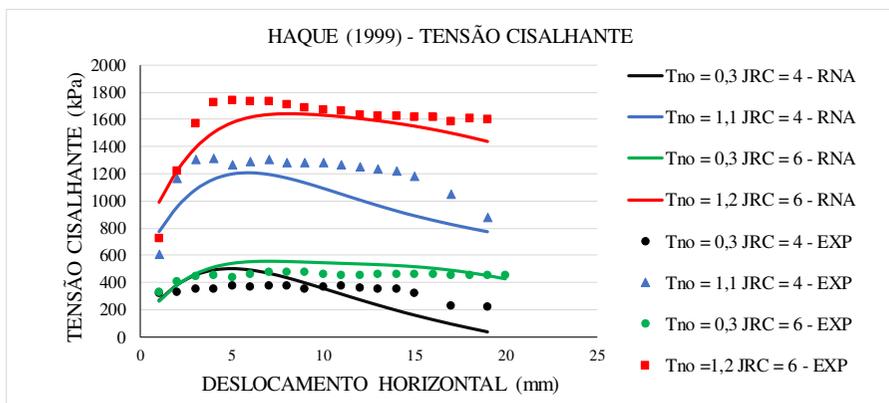
GRUPO B – ARQUITETURA: 8-30-15-2 – 200.000 ITERAÇÕES - GRÁFICOS

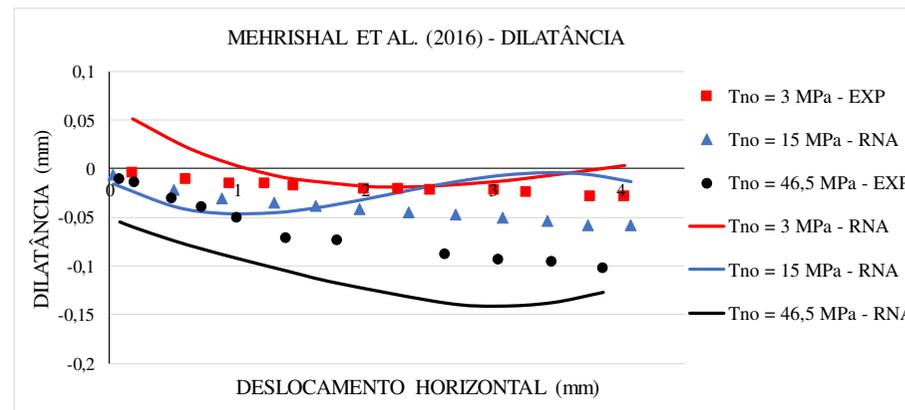
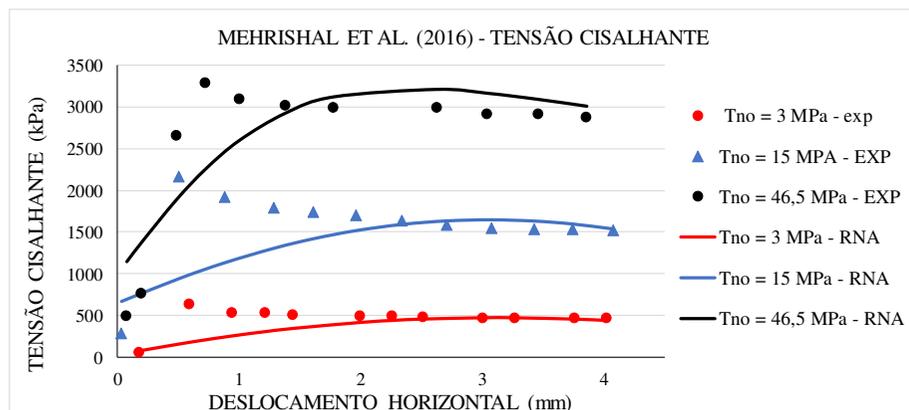
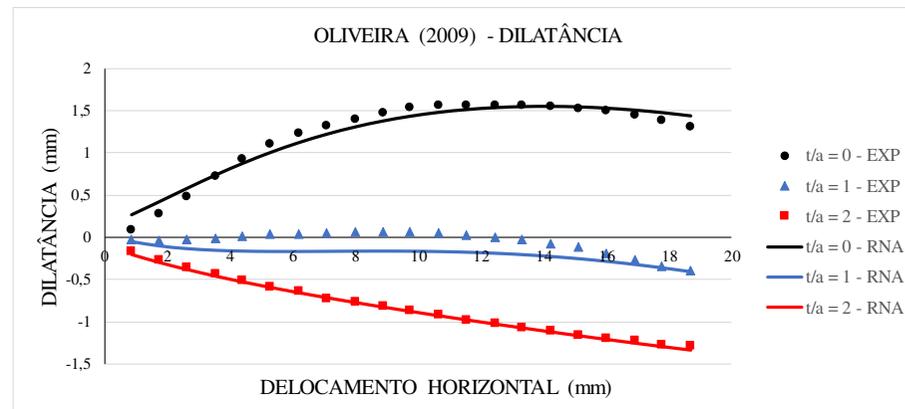
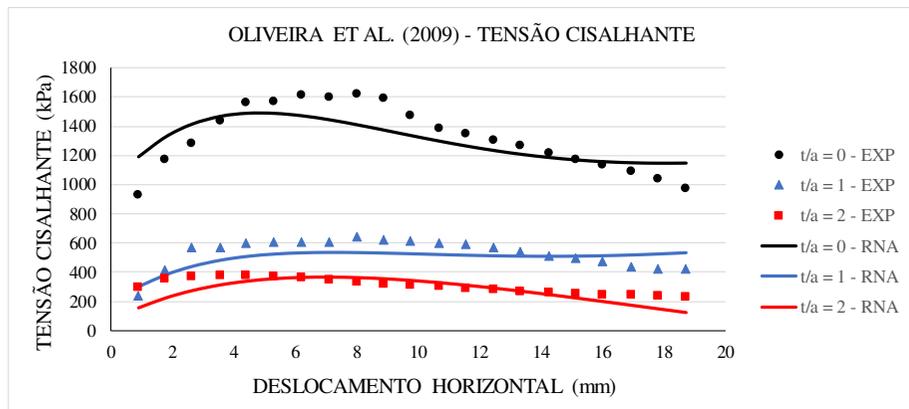


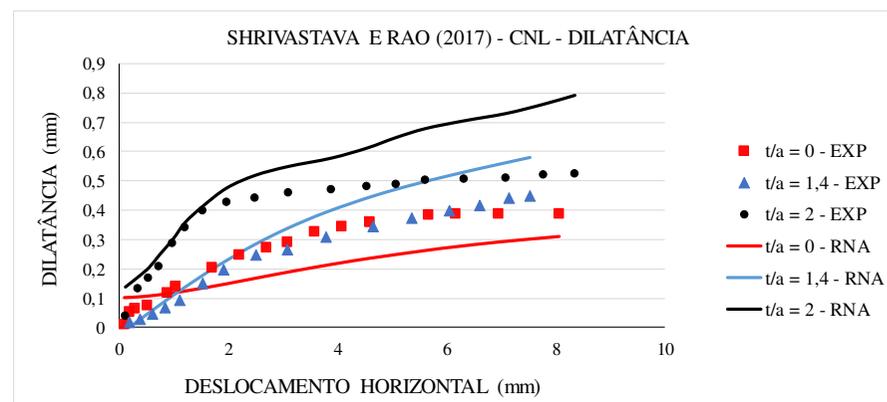
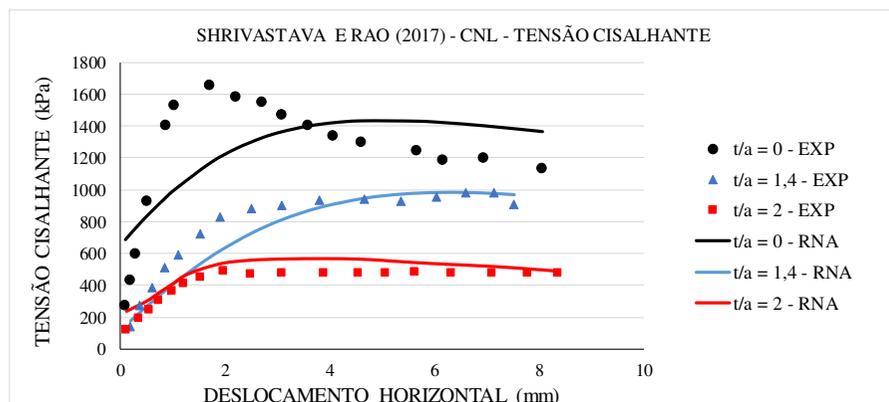
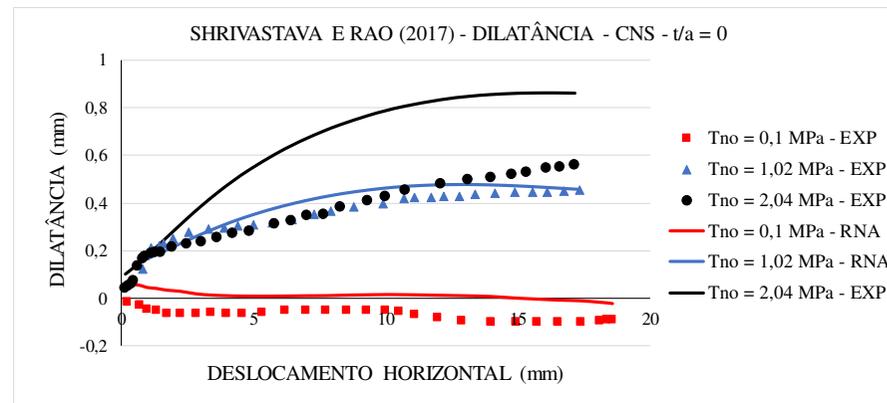
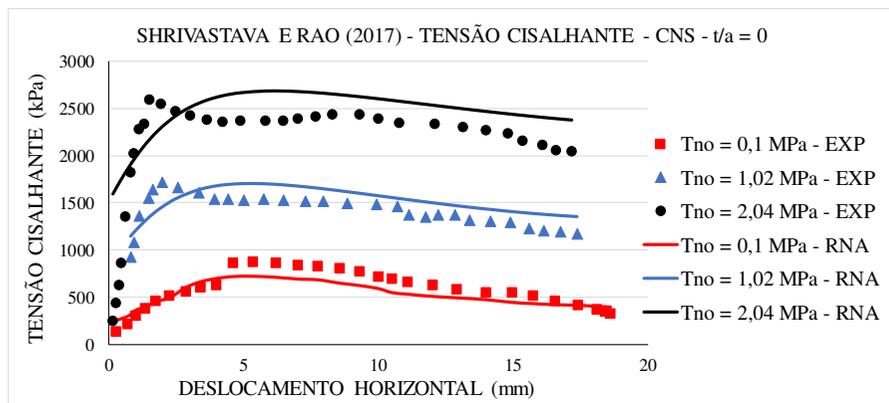




GRUPO B2 – ARQUITETURA: 8-30-15-5-2 – 500.000 ITERAÇÕES - GRÁFICOS







GRUPO C – ARQUITETURA: 8-30-15-2 – 300.000 ITERAÇÕES - GRÁFICOS

