

COMPARAÇÃO DE BASES DE DADOS DO SISTEMA Q POR MEIO DE MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN

Luiz Mateus Cotias Simões ¹; Leonardo Bonfim Reis ²; Paulo Gustavo Cavalcante Lins ³; Tarcísio Barreto Celestino ⁴

Resumo – Os mapas auto-organizáveis de Kohonen são um tipo de rede neural com treinamento não supervisionado. Neste tipo de rede neural é possível encontrar regularidades na base de dados utilizada no treinamento. No presente trabalho os dados da classificação do sistema Q foram representados em três espaços de feições bidimensionais ($\{\log_{10}(RQD/Jn), \log_{10}(Jr/Ja)\}$; $\{\log_{10}(RQD/Jn), \log_{10}(Jw/SRF)\}$; $\{\log_{10}(Jr/Ja), \log_{10}(Jw/SRF)\}$), e em um espaço de feições tridimensional ($\{\log_{10}(RQD/Jn), \log_{10}(Jr/Ja), \log_{10}(Jw/SRF)\}$). Um primeiro conjunto de simulações envolve a base de dados original do sistema Q com 212 casos. Um segundo conjunto de simulações envolve um subconjunto da base de dados original do sistema Q com 97 casos, de obras de engenharia civil, originados da península da Escandinávia. O contraste entre os diagramas permite comparar como se distribuem as condições geológicas nas duas bases de dados, refletindo particularidades dos locais das bases de dados.

Abstract – Kohonen self-organizing maps are a kind of neural network with unsupervised training. In this kind of neural network it is possible to find regularities in the database used in the training. In the present work the data of the classification of the Q system were represented in three spaces of two-dimensional features ($\{\log_{10}(RQD/Jn), \log_{10}(Jr/Ja)\}$; $\{\log_{10}(RQD/Jn), \log_{10}(Jw/SRF)\}$; $\{\log_{10}(Jr/Ja), \log_{10}(Jw/SRF)\}$), and in a three-dimensional feature space $\{\log_{10}(RQD/Jn), \log_{10}(Jr/Ja), \log_{10}(Jw/SRF)\}$. A first set of simulations involves the original Q system database with 212 cases. A second set of simulations involves a subset of the original Q system database with 97 cases of civil engineering works originating from the Scandinavian peninsula. The contrast between the diagrams allows comparing how the geological conditions are distributed in the two databases, reflecting particularities of the sites of the databases.

Palavras-Chave – Classificações geomecânicas; Sistema Q; Redes neurais.

¹ Eng., Universidade Federal da Bahia: Salvador - Ba, (71) 99115-6564, luicotias@gmail.com

² Eng., Universidade Federal da Bahia: Salvador - Ba, (71) 99982-1434, leonardobdreis@gmail.com

³ Prof., Eng., Dr, Universidade Federal da Bahia: Salvador - Ba, (71) 3283-9847, plins@ufba.br

⁴ Prof., Eng., PhD, THEMAG e Universidade de São Paulo, São Paulo - SP, (16) 3373-9501, tbcelest@usp.br

1. INTRODUÇÃO

As redes neurais artificiais podem ter os tipos de aprendizagens agrupados em supervisionado ou não supervisionado. Na aprendizagem supervisionada existe uma resposta anteriormente definida para uma entrada da rede. Na aprendizagem não supervisionada a rede neural pode encontrar uma regularidade na base de dados, sendo que, não existe uma resposta previamente definida para a rede. Na rede neural conhecida como mapas auto-organizáveis de Kohonen (SOM, Self-organized map) a distribuição dos dados no espaço de feições pode ser visualizada por meio de uma grade associada aos pesos das conexões da rede.

Aplicações de redes SOM em Mecânica das Rochas e Geologia de Engenharia são encontradas na literatura. MUSIL & PLENGER (1996) utilizaram redes neurais do tipo perceptron de múltiplas camadas combinadas com redes SOM para separar microssismos naturais do efeito de desmontes de rocha. SIRAT & TALBOT (2001) utilizaram redes SOM nas versões supervisionada e não supervisionada para classificação de famílias de discontinuidades. KLOSE et al. (2007) aplicaram redes SOM para prever propriedades do maciço rochoso no entorno de um túnel a partir de dados de sísmica. GHAFARI et al. (2009) combinaram redes SOM com técnicas de lógica difusa para interpretação de dados de permeabilidade do maciço rochoso nas fundações de uma barragem. HUANG et al. (2017) utilizaram redes SOM combinadas com aprendizagem de máquinas para mapeamento de susceptibilidade de deslizamento de taludes. LIN et al. (2017) utilizam redes similares as SOM para tratar o problema de mapeamento de susceptibilidade de deslizamento de taludes.

O sistema Q foi divulgado internacionalmente principalmente a partir do trabalho de BARTON et al. (1974b). A base de dados utilizado para a elaboração do sistema Q encontra-se registrada em um relatório interno do NGL, referido como BARTON et al. (1974a). No presente trabalho redes SOM são utilizadas para analisar regularidades na base de dados do Apêndice II de BARTON et al. (1974a).

2. MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN

O mapa auto-organizável de Kohonen, ou rede SOM, é um tipo de rede neural artificial que possui a propriedade de criar uma organização espacial das características intrínsecas aos dados de entrada e têm sido aplicadas principalmente para reconhecimento de padrões e categorização de dados, em classes que não necessariamente são conhecidas antes da análise. O algoritmo das redes SOM foi proposto por KOHONEN (1982). As melhorias e variações do algoritmo das redes SOM são discutidas em KOHONEN (1990) e KOHONEN (2001), inclusive sua versão supervisionada que é chamada de LVQ (Learning Vector Quantization).

Os mapas auto-organizáveis são modelos de redes neurais altamente inspirados no funcionamento do córtex cerebral humano, onde cada área é especializada em exercer funções específicas (RITTER et al, 1992). No cérebro humano, os estímulos, ou, as entradas sensoriais (visuais, auditivas, motoras, etc.) e demais funções cerebrais são mapeadas e processadas em diferentes áreas no córtex cerebral, porém em uma maneira topologicamente ordenada. Ou seja, os neurônios estão espacialmente ordenados de maneira que neurônios muito próximos tendem a processar estímulos e padrões semelhantes.

O processo de aprendizagem das redes SOM obedece ao paradigma de aprendizagem não-supervisionada, significando que a rede neural deve tentar descobrir, por conta própria, padrões nos dados de entrada sem a necessidade de influência ou interação humana no processo.

Geralmente as redes SOM possuem duas camadas, uma camada de entrada e uma camada onde ocorre a aprendizagem por competição. A camada de entrada recebe os dados. A camada de processamento representa o mapa auto-organizável. A Figura 1 ilustra duas arquiteturas de redes SOM, onde os neurônios da camada de processamento estão organizados em um gride (HERTZ et al, 1991).

No caso da rede com dois padrões de entrada (ξ_1, ξ_2) da Figura 1(a) espera-se um mapa no espaço de saída (x, y) gerado a partir dos dados de entrada (ξ_1, ξ_2) que pode ou não estar em um domínio quadrado (HERTZ et al, 1991).

A Figura 2 mostra um exemplo de um mapeamento de duas entradas (ξ_1, ξ_2) em uma matriz planar 10 x 10 de neurônios de saída. Os padrões de entrada foram escolhidos randomicamente, gerando dados regularmente distribuídos em um quadrado $\{0 \leq \xi_1 < 1, 0 \leq \xi_2 < 1\}$ que é mostrado na fronteira externa do diagrama. Os pesos (w_{11}, w_{12}) para cada neurônio de saída são mostrados no espaço de entradas pela interseção em um gride de linhas, que conecta com todos os pares dos vizinhos mais próximos. Os pesos se iniciam de valores aleatórios próximos de (0,5, 0,5) como mostrado na Figura 2(a). Com o progresso da aprendizagem, como indicado na Figura 2(b) e 2(c), os pesos vão sendo separados e organizados em um gride quadrado. Eventualmente, o gride torna-se mais retangular como pode ser observado na Figura 2(d) (HERTZ et al, 1991).




Figura 1. Dois tipos de arquiteturas de redes SOM. (a) Uma arquitetura convencional, com dois valores de entrada. (b) Uma arquitetura de inspiração biológica para mapeamento, por exemplo, da retina para o córtex. As camadas são completamente conectadas, entretanto apenas algumas conexões são mostradas (HERTZ et al, 1991).

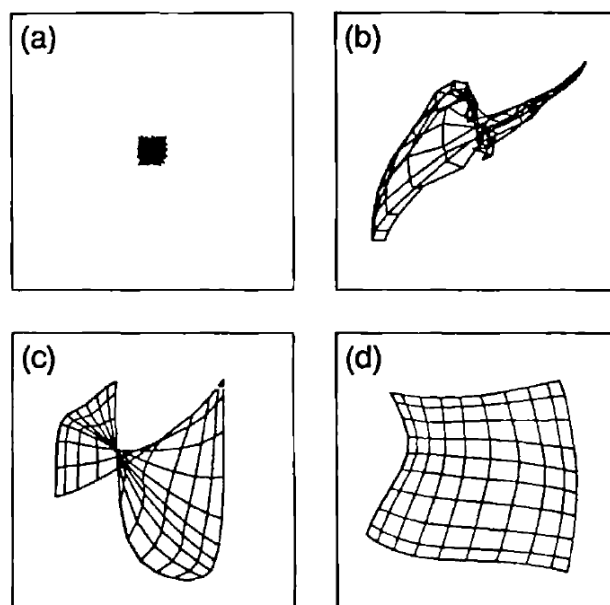


Figura 2. Mapeamento de feições de Kohonen de dados igualmente distribuídos em uma região quadrada em uma matriz quadrada de 10 x 10 de neurônios de saída (HERTZ et al, 1991).

A Figura 3 mostra três outros exemplos do mapeamento de duas unidades de entrada em uma matriz quadrada. Nestes exemplos os dados de entrada são uniformemente distribuídos em

um círculo (Figura 3(a)), um triângulo (Figura 3(b)) e uma região em forma de "L" (Figura 3(c)). Na Figura 3 estão representados apenas os mapas finais de cada treinamento. A forma do reticulado da matriz de saída possui um efeito claro no resultado (HERTZ et al, 1991). Os pesos das saídas se distribuem nas regiões onde os dados de entrada foram gerados. No caso da Figura 3(c) parte dos pesos estão fora da região onde foram geradas as entradas.




Figura 3. Mapeamento de feições de Kohonen de dados em regiões com várias formas em um uma matriz quadrada de 15 x 15 de neurônios de saída (HERTZ et al, 1991).

Uma rede SOM com três entradas (ξ_1, ξ_2, ξ_3), treinada com dados regularmente distribuídos em uma geometria similar a um "cacto" pode gerar um mapa bidimensional similar a esta geometria, conforme pode ser observado na Figura 4.




Figura 4. Representação de dados tridimensionais em mapa bidimensional (KOHONEN, 1990).

A formação do mapa é feita de maneira adaptativa e se dá através de um tipo de regra de aprendizagem conhecida por aprendizagem competitiva, que consiste numa competição entre os neurônios para responder a um padrão de entrada (BRAGA et al, 2000). Desta competição apenas um neurônio sairá vencedor para um determinado padrão de entrada e para um determinado instante da iteração, sendo que, ao passo que o mapa se desenvolve e começa a estabilizar, o mesmo neurônio tende a ser o vencedor para o mesmo padrão de entrada.

Para cada ocorrência da base de dados a rede SOM encontra o neurônio mais próximo, ou seja, o neurônio mais semelhante ao padrão de entrada apresentado. Ao longo do treinamento, a rede atualiza os pesos do neurônio vencedor (o mais próximo do padrão de entrada) e de seus vizinhos, de maneira a torná-los cada vez mais semelhantes. Desta forma, o mapa toma forma e, por consequência, os nodos semelhantes ficam espacialmente próximos (BRAGA et al, 2000). Desta maneira, cada neurônio da rede se especializa em padrões de entrada similares permitindo detectar as características das diferentes classes presentes na base de dados, ou camada de entrada.

3. REPRESENTAÇÃO DO SISTEMA Q

Um padrão pode ser visto como um ponto em um espaço de feições N-dimensional, assim pode-se esperar que estes padrões possuam alguma similaridade, com base a classe a qual pertençam ou aos valores de algum atributo, estando próximos, de acordo com algum critério no espaço de feições. Em determinadas situações pode ser apropriado descobrir como os padrões observados estão distribuídos no espaço de feições (PAO, 1989). Para definir similaridade é necessário estabelecer uma métrica. A métrica adotada pode-se ter influência no resultado.

Uma subjetividade existe no momento de atribuir uma descrição qualitativa para uma das categorias das tabelas do Sistema Q. Cada um dos quocientes do Sistema Q possui um significado. O primeiro quociente (RQD/J_n) representa a estrutura do maciço e é uma medida grosseira da dimensão dos blocos ou das partículas. O segundo quociente (J_r/J_a) representa as características de rugosidade e do atrito das paredes das discontinuidades. O terceiro quociente (J_w/SRF) representa o estado de tensão relativo da escavação.

A definição do espaço de feições a ser utilizado é uma atividade que conta com a Liberdade de escolha que pode ser guiada pelo conhecimento específico da aplicação. No Sistema Q o espaço de feições $\{\log_{10}(Q); \log_{10}(De)\}$ é a referência utilizada. Para o presente trabalho uma transformação algébrica é utilizada na definição do índice Q. Aplicando o logaritmo de base 10 nos dois lados da equação de Q e utilizando as propriedades do logaritmo, chega-se a expressão:

$$\log_{10}(Q) = \log_{10}\left(\frac{RQD}{J_n}\right) + \log_{10}\left(\frac{J_r}{J_a}\right) + \log_{10}\left(\frac{J_w}{SRF}\right) \quad (1)$$

Macios rochosos com características diferentes podem possuir o mesmo valor de Q. Entretanto, em um espaço de feições tridimensional definido por $\{\log_{10}(RQD/J_n), \log_{10}(J_r/J_a), \log_{10}(J_w/SRF)\}$, um valor constante de Q define um plano neste espaço. A Figura 5 representa uma interpretação para um espaço de feições similar utilizado por LINS (2001).

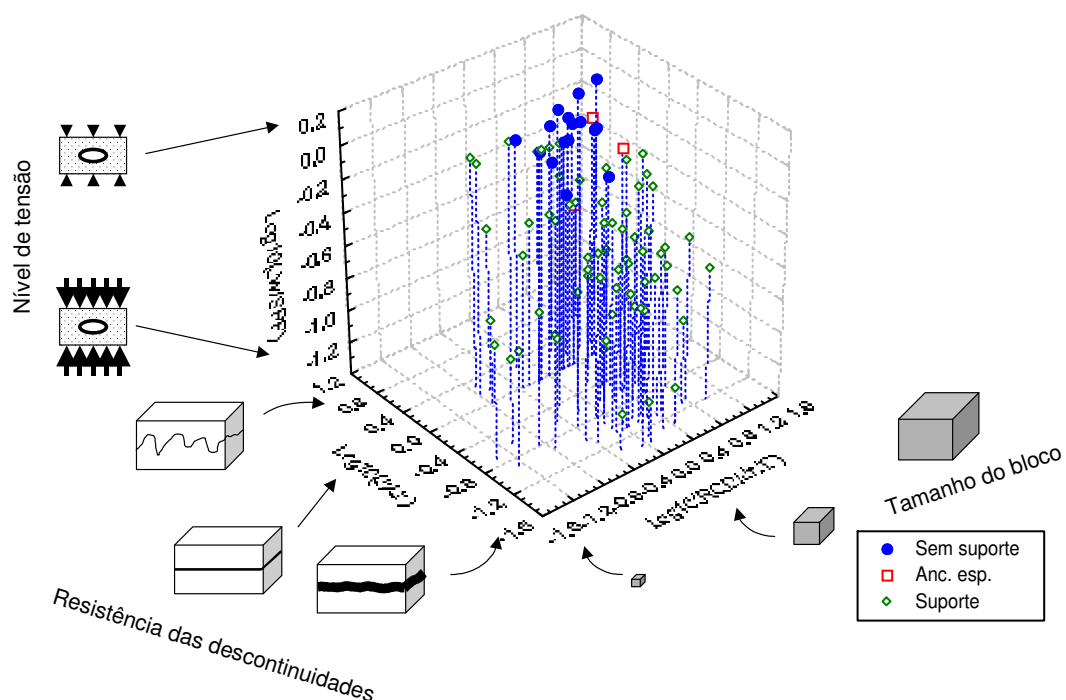


Figura 5. Espaço de feições tridimensional para o sistema Q proposto por LINS (2001).

4. BASE DE DADOS DO SISTEMA Q

A preparação da base de dados é um passo importante na modelagem por redes neurais. Os dados podem ser nominais ou ordinais ou intervalares ou números reais. Cada tipo de dado pode exigir uma representação diferente. Por vezes os dados disponíveis condicionam os modelos de redes. Uma discussão geral sobre a preparação de dados para alimentar análises por redes neurais pode ser encontrada em CROOKS (1992), STEIN (1993a) e STEIN (1993b).

O Apêndice II de BARTON et al. (1974) forneceu um total de 212 casos, que foram digitalizados em uma planilha eletrônica. No presente trabalho se buscou manter os dados o mais fiel possível ao registrado em BARTON et al. (1974). Um importante trabalho de conferência dos dados e revisão de erros de digitação foi realizado.

Os dados passaram por dois processos de normalização. O primeiro processo de normalização envolveu a utilização do logaritmo de base dez. Este primeiro passo possui relação com o fato do Sistema Q tratar dados de ordem de grandeza diferentes. O segundo processo de normalização envolveu deixar os dados em um intervalo entre zero e um. A Tabela 1 resume os limites de normalização utilizados no presente trabalho.

Tabela 1. Limites de normalização dos dados empregados na modelagem.

Parâmetro	Mínimo	Máximo
RDQ/Jn	$\text{Log}_{10}(10/(3 \cdot 20)) \approx -0,78$	$\text{Log}_{10}(100/0,5) \approx 2,31$
Jr/Ja	$\text{Log}_{10}(0,5/20) \approx -1,61$	$\text{Log}_{10}((4+1)/0,75) \approx 0,83$
Jw/SRF	$\text{Log}_{10}(0,5/20) \approx -2,61$	$\text{Log}_{10}(1/0,5) \approx 0,31$

5. RESULTADOS DAS MODELAGENS

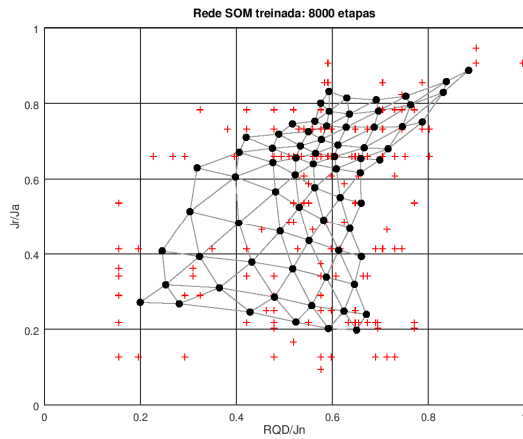
Em uma primeira modelagem todos os 212 casos de BARTON et al (1974) foram utilizados no treinamento das redes SOM. A modelagem foi realizada utilizando o *SOM Toolbox* modificado para *GNU Octave* (MACURA, 2016). Uma ferramenta de otimização foi utilizada para definir o gride em função da base de dados.

Um primeiro conjunto de simulações foi realizado com todos 212 casos da base de dados de BARTON et al., (1974a). Os pontos representados por cruces vermelhas são os dados de treinamento; os pontos representados por bolas pretas são os vértices do gride do mapa de Kohonen.


Um segundo conjunto de simulações foi realizado utilizando os 97 primeiros casos da base de dados de BARTON et al (1974a). Estes 97 casos correspondem aos que estão registrados na tese de CECIL (1970) e se referem a obras de Engenharia Civil na Noruega e Suécia.

Seis redes SOM com duas entradas foram treinadas. Estas seis redes correspondem aos espaços de feições bidimensionais ($\{\log_{10}(\text{RQD}/\text{Jn}), \log_{10}(\text{Jr}/\text{Ja})\}$; $\{\log_{10}(\text{RQD}/\text{Jn}), \log_{10}(\text{Jw}/\text{SRF})\}$; $\{\log_{10}(\text{Jr}/\text{Ja}), \log_{10}(\text{Jw}/\text{SRF})\}$) treinadas para as duas bases de dados. As entradas das redes bidimensionais estão respectivamente conectadas a grides de 12 x 6, 10 x 7 e 12 x 6 neurônios, para o treinamento com a base de dados de BARTON et al., (1974); e 10 x 5, 10 x 5 e 13 x 4 neurônios, para o treinamento com a base de dados de CECIL (1970). As Figuras 6(a), 7(a), 8(a) e 9 mostram os resultados dos treinamentos com todos 212 casos da base de dados de BARTON et al., (1974a).

Duas redes SOM com três entradas foram treinadas utilizando o espaço de feições tridimensional ($\{\log_{10}(\text{RQD}/\text{Jn}), \log_{10}(\text{Jr}/\text{Ja}), \log_{10}(\text{Jw}/\text{SRF})\}$). As três entradas das redes tridimensionais estão conectadas a grides de 12 x 6 neurônios, para o treinamento com a base de dados de BARTON et al., (1974a); e 10 x 5 neurônios, para o treinamento com a base de dados de CECIL (1970). As Figuras 6(b), 7(b), 8(b) e 10 mostram os resultados dos treinamentos com os 97 casos da tese de CECIL (1970).




(a) Barton et al., (1974a)




(b) Cecil (1970)

Figura 6. Entrada bidimensional $\{\log_{10}(RQD/Jn), \log_{10}(Jr/Ja)\}$.




(a) Barton et al., (1974a)

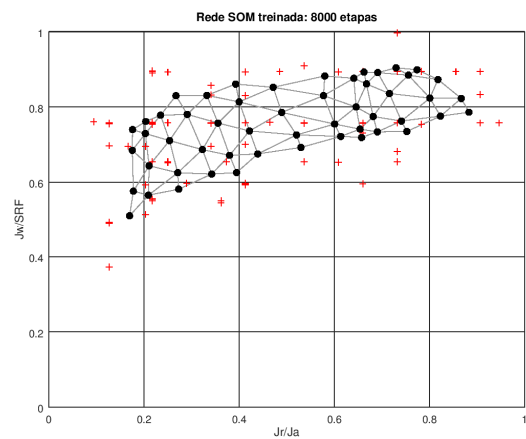


(b) Cecil (1970)

Figura 7. Entrada bidimensional $\{\log_{10}(RQD/Jn), \log_{10}(Jw/SRF)\}$.



(a) Barton et al., (1974a)



(b) Cecil (1970)

Figura 8. Entrada bidimensional $\{\log_{10}(Jr/Ja), \log_{10}(Jw/SRF)\}$.




Figura 9. Entrada tridimensional $\{\log_{10}(RQD/Jn), \log_{10}(Jr/Ja), \log_{10}(Jw/SRF)\}$ para a base de dados de Barton et al., (1974a).

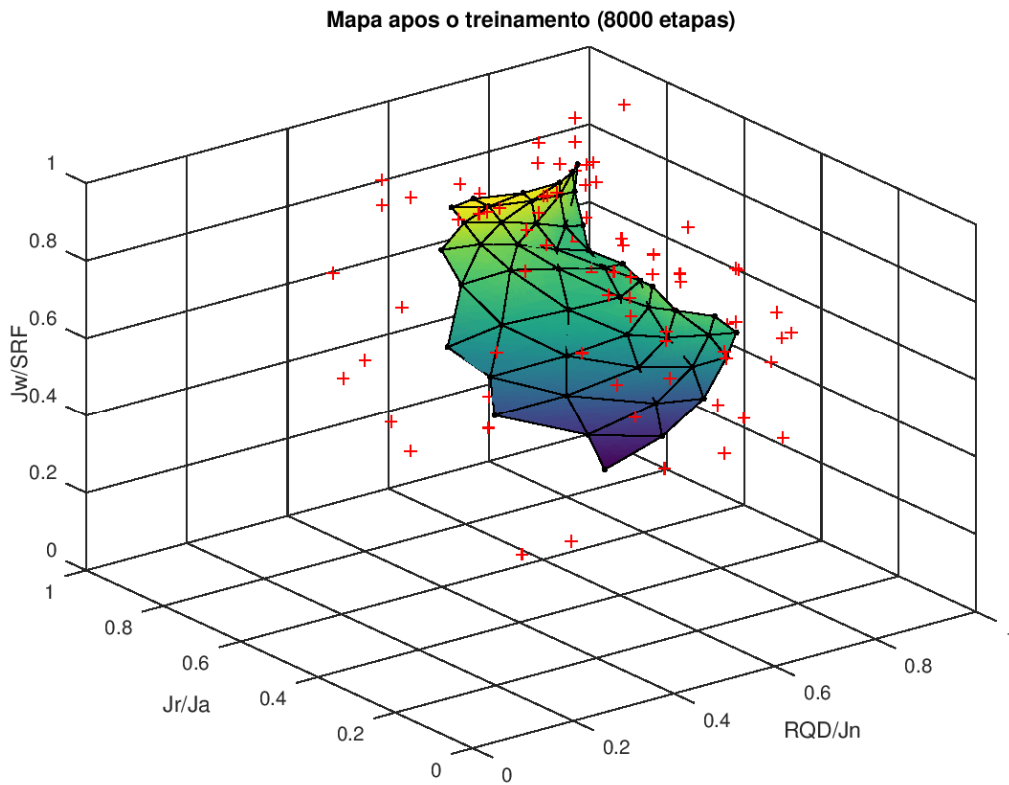


Figura 10. Entrada tridimensional $\{\log_{10}(RQD/Jn), \log_{10}(Jr/Ja), \log_{10}(Jw/SRF)\}$ para a base de dados de Cecil (1970).

6. ANÁLISE DOS RESULTADOS

A observação das Figuras 6, 7 e 8 permite uma primeira conclusão, de que, as bases de dados de BARTON et al., (1974a) e CECIL (1970) não se distribuem de forma homogênea nos espaços de feições. Uma distribuição homogênea, como ilustrado na Figura 2, seria desejável para que todas as possíveis combinações estejam presentes. Entretanto, deve ser lembrado que as bases de dados são representativas das geologias dos locais do levantamento.

De forma geral a base de dados de BARTON et al., (1974a) é mais bem distribuída no espaço de feições que a base de dados de CECIL (1970). As formas das distribuições são similares. Um polígono quase retangular com uma ponta para $\{\log_{10}(RQD/J_n), \log_{10}(J_r/J_a)\}$, (Figura 6). Um polígono quase retangular com reentrâncias para $\{\log_{10}(RQD/J_n), \log_{10}(J_w/SRF)\}$, (Figura 7). Também um polígono quase retangular com reentrâncias para $\{\log_{10}(J_r/J_a), \log_{10}(J_w/SRF)\}$, (Figura 8).

Nas Figuras 7 e 8 pode ser percebida a quase ausência de dados para um valor normalizado de J_w/SRF inferiores a 0,4. Este limite equivale a um valor de $\log_{10}(J_w/SRF)$ de -1,442, e a um valor de J_w/SRF de 0,04. Condição que nas tabelas do sistema Q poderia ser representado por uma “afluência excepcionalmente elevada de água” ($J_w = 0,1$) com “ocorrência de uma zona de fraqueza” ($SRF = 2,5$) ou “tensões baixas, superficiais” ($SRF = 2,5$). Em outras palavras, estão pouco presentes na base de dados situações que descrevam situações de campo piores que estas.

Nas representações tridimensionais do problema, vistas nas Figuras 9 e 10, também pode ser notado que a base de dados de BARTON et al., (1974a) é mais bem distribuída no espaço de feições que a base de dados de CECIL (1970).

7. CONCLUSÕES

Um dos objetivos das classificações geomecânicas envolve “relacionar a experiência das condições de um maciço em um local com a experiência encontrada em outros locais”. O presente trabalho apresenta uma métrica para a comparação entre as condições geomecânicas de dois locais diferentes. A rede SOM mostrou-se um instrumento efetivo para realizar esta comparação.

A base de dados de BARTON et al., (1974a) é mais bem distribuída que uma base de dados com um “ruído” da geologia da península da Escandinávia. Entretanto os dados de BARTON et al., (1974) não estão distribuídos de forma homogênea no espaço de feições.

Deve ser lembrado que o presente trabalho trata do espaço de feições definido dentro das condições representadas no sistema Q. A adequação do sistema Q a separação do tipo de suporte no espaço de feições exige outro tipo de arquitetura de redes neurais.

REFERÊNCIAS

- BARTON, N., LIEN, R. & LUNDE, J. (1974a) *Analysis of rock mass quality and support practice in tunneling, and a guide for estimating support requirements*. NGI Internal report 54206, 74p.
- BARTON, N., LIEN, R. & LUNDE, J. (1974b) Engineering classification of rock masses for the design of tunnel support. In *Rock Mechanics*, Vol.6, No.4, p.189-239.
- BRAGA, A.P.; CARVALHO, A.P.L.F. & LUDEMIR, T.B. (2000) *Redes Neurais Artificiais: Teoria e Aplicações*. Rio de Janeiro: LTC Editora. 262p.
- CECIL III, O.S. (1970) “*Correlation of rock bolt-shotcrete support and rock quality parameters in Scandinavian tunnels*”. PhD Thesis, University of Illinois, Urbana. 415p. (Republicado como

Swedish Geotechnical Institute, Proceedings No. 27, 275p. Disponível em: <<http://www.swedgeo.se/globalassets/publikationer/sgi-proceedings/sgi-pr27.pdf>>. Acesso em: 2 abr 2018).

CROOKS, T. (1992) Care and feeding of neural networks. In *AI Expert*, v.7, n.7, p.36-41.

GHAFFARI, H.O.; SHARIFZADEH, M.; SHAHRIAR, K. & PEDRYCZ, W. (2009) Application of soft granulation theory to permeability analysis. In *International Journal of Rock Mechanics & Mining Sciences*, Vol.46, p.577-589.

HERTZ, J.; KROGH, A. & PALMER, R.G. (1991) *Introduction to the theory of neural computation*. Redwood City: Addison-Wesley. 327p.

HUANG, F.; YIN, K.; HUANG, J.; GUIB, L. & WANG, P. (2017) Landslide susceptibility mapping based on self-organizing-map network and extreme learning machine. In *Engineering Geology*, Vol.223, p.11-22.

KLOSE, C.D.; LOEW, S.; GIESE, R. & BORM, G. (2007) Spatial predictions of geological rock mass properties based on in-situ interpretations of multi-dimensional seismic data. In *Engineering Geology*, Vol.93, p.99-116.

KOHONEN, T. (1982) Self-Organized Formation of Topologically Correct Feature Maps. In *Biological Cybernetics*, Vol.43, p.59-69.

KOHONEN, T. (1990) The Self-organizing Map. In *Proceedings of the IEEE*, Vol.78, No.9, p.1464-1480.

KOHONEN, T. (2001) *Self-Organizing Maps*. Third Edition. Berlin: Springer. 501p.

LIN, G.-F.; CHANG, M.-J.; HUANG, Y.-C. & HO, J.-Y. (2017) Assessment of susceptibility to rainfall-induced landslides using improved self-organizing linear output map, support vector machine, and logistic regression. In *Engineering Geology*, Vol.224, p.62-74.

LINS, P.G.C. (2001) “*Classificação de maciços rochosos: Uma abordagem por redes neurais*”. Tese (Doutorado). Escola de Engenharia de São Carlos, Universidade de São Paulo. 175p.

MACURA, L. (2016) *SOM Toolbox modified for GNU octave*. Disponível em: <<https://github.com/limosek/somtoolbox>>. Acesso em: 20 abr 2018.

MUSIL, M. & PLENGER, A. (1996) Discrimination between Local Microearthquakes and Quarry Blasts by Multi-Layer Perceptrons and Kohonen Maps. In *Bulletin of the Seismological Society of America*, Vol. 86, No. 4, p.1077-1090.

PAO, Y.-H. (1989) *Adaptive pattern recognition and neural networks*. Reading: Addison-Wesley. 309p.

RITTER, H.; MARTINETZ, T. & SCHULTEN, K. (1992) *Neural Computation and Self-Organizing Maps: An Introduction*. New York: Addison-Wesley. 350p.

SIRAT, M. & TALBOT, C.J. (2001) Application of artificial neural networks to fracture analysis at the Aspö HRL, Sweden: fracture sets classification. In *International Journal of Rock Mechanics & Mining Sciences*, Vol.38, p.621-639.

STEIN, R. (1993a) Selecting data for neural networks. In *AI Expert*, v.8, n.2, p.42-47.

STEIN, R. (1993b) Preprocessing data for neural networks. In *AI Expert*, v.8, n.3, p.32-37.