

SIMULAÇÃO DE MOAGEM SELETIVA POR REDES NEURAS ARTIFICIAIS¹

Germano Mendes Rosa²
José Aurélio Medeiros da Luz³

Resumo

Este artigo apresenta os resultados da aplicação de um simulador de moagem mista baseado em redes neurais artificiais (do tipo *perceptron* multicamadas com treinamento supervisionado com o algoritmo retropropagação com momento). Para verificar a estabilidade estatística do processo de simulação, utilizou-se a carta de controle Shewhart para valores individuais, a qual se mostrou útil para orientar a aceitação do treinamento. Os resultados mostraram um bom desempenho dessa ferramenta para simulação de moagem mista, de comum ocorrência no setor minero-metalúrgico.

Palavras-chave: Cominuição seletiva; Distribuição granulométrica; Rede neural artificial; Simulação.

SIMULATION OF SELECTIVE GRINDING BY NEURAL NETWORK

Abstract

This paper discusses the developing and implementation of a mix grinding simulator based on artificial neural network (multiple-layer perceptron using a backpropagation-like algorithm with momentum). Shewhart's control chart for individual values was used in order to verify the statistical stability of simulation results, which was useful to screening the acceptance criteria for convergence. The results proved that there were good agreement between experimental data and the simulated ones. This algorithm can be easily adapted as a day by day forecasting tool for similar mining and metallurgical grinding operations.

Key words: Selective grinding; Size distribution; Artificial neural network; Simulation.

¹ Contribuição técnica ao 65º Congresso Anual da ABM, 26 a 30 de julho de 2010, Rio de Janeiro, RJ, Brasil.

² Professor do Instituto Federal de Minas Gerais, Mestre em Engenharia de Minas

³ Professor da Universidade Federal de Ouro Preto, Doutor em Engenharia de Minas

1 INTRODUÇÃO

Estudou-se a moagem seletiva de mesclas binárias de dolomita e quartzo, acompanhando a evolução granulométrica dos produtos a partir das características de alimentação e do tempo de processamento. As distribuições granulométricas foram descritas em termos de diâmetro mediano e agudez da distribuição sigmoidal de Hill (praticamente equivalente à distribuição de Rosin-Rammler no sistema em estudo, com coeficiente de correlação mínimo de 97%). Os dados experimentais, provenientes de trabalho anterior dos autores, serviram para treinar e testar um simulador baseado em redes neurais artificiais (RNA).

A simulação é ferramenta que possibilita estimar o comportamento de um de sistema (discreto, contínuo ou misto de operação) por meio da sua modelagem lógico-matemática. Sua principal vantagem é que permite manipular as condições de operações das entidades modeladas quando, na prática, seriam muito difíceis de serem realizadas, devido limitações de naturezas diversas.

Um modelo é a representação do sistema de interesse que se presta ao estudo de possíveis melhorias no sistema real ou à análise do impacto de mudanças em estratégias operacionais.⁽¹⁾ Normalmente modelos são representações simplificadas do mundo real, que mantêm, para determinadas situações e enfoques, graus aceitáveis de equivalência.⁽²⁾

Trabalhos de modelagem e simulação de circuitos minero-metalúrgicos tiveram seu início de desenvolvimento na Austrália, pela *Mount Isa*, dando origem ao *JK Mineral Research*, por volta de 1960. Contudo, a simulação vem sendo estudada e aplicada pela indústria mineral em todo o mundo. Destaca-se o êxito obtido em simulações de cominuição fundamentada nos modelos de balanço populacional em diversos projetos de aplicação, fornecendo condições de simulação do circuito, gerando ganhos em vários aspectos de auditoria de planta.⁽³⁾

A concepção de RNA ocorreu na década de 40 pelo neurofisiologista Warren McCulloch e pelo matemático Walter Pitts, que estabeleceram analogia entre as células nervosas vivas e o processamento eletrônico. A partir da década de 80 surgiram inúmeros modelos para desenvolver e aplicar essa tecnologia.⁽⁴⁾ As RNA representam uma abordagem em inteligência artificial (IA), utilizada para implementar a inteligência em máquinas (computadores digitais) embasada em modelos que emulam a estrutura de funcionamento dos neurônios no cérebro animal.⁽⁵⁾ Sua origem remonta aos modelos matemáticos e de engenharia de neurônios biológicos.⁽⁶⁾

Uma RNA consta de um processador distribuído paralelamente, composto de unidades simples de processamento, possuindo tendência natural de acumular conhecimento empírico (aprendizagem) e disponibilizar mecanismos de recuperação de informação (memorização). As RNAs representam poderosa técnica de modelagem, permitindo modelar relações cuja descrição com a utilização de modelos físicos seria difícil.

Porém, para que as soluções derivadas do uso de RNA tenham desempenho satisfatório, os problemas devem ser tolerantes a uma determinada imprecisão, dispor de uma grande quantidade de dados de treinamento e não necessitar de regras de decisão discretas.⁽⁷⁾ Algumas aplicações clássicas das RNA são: reconhecimento de padrões em imagens, processamento de voz, processamento de sinais, análise de séries temporais, simulação de sistemas biológicos, diagnósticos médicos e previsões no mercado financeiro.

Mello *apud* Paula,⁽⁴⁾ destaca que as RNA são capazes de reconhecer padrões, obter regularidades e perceber relações subjacentes em uma massa de dados, *a priori* desconexa, apresentando, inclusive, habilidades de trabalhar com dados incompletos, com interferência ou imprecisos; e de prever sistemas não-lineares.

Uma RNA, similarmente ao seu paralelo biológico, é composta por determinado número de neurônios conectados por conexões sinápticas. Cada sinapse possui um peso associado, onde o conhecimento acumulado na rede depende diretamente da atualização desses pesos. Alguns desses neurônios são conectados ao ambiente externo, tratando-se das entradas e das saídas da rede. Cada neurônio possui um conjunto de entradas e de saídas ligadas a outros neurônios, exceto os neurônios de entrada e de saída que possuem um ou outro. Um neurônio possui um patamar de ativação que deriva da conjugação das entradas atuais recebidas com os pesos sinápticos das conexões, cujo valor resultante poderá ativar ou não as saídas deste neurônio.⁽⁸⁾

A Figura 1 apresenta um modelo de neurônio chamado de *perceptron*, pesquisado e desenvolvido por Rosenblatt nas décadas de 1950 e 1960.

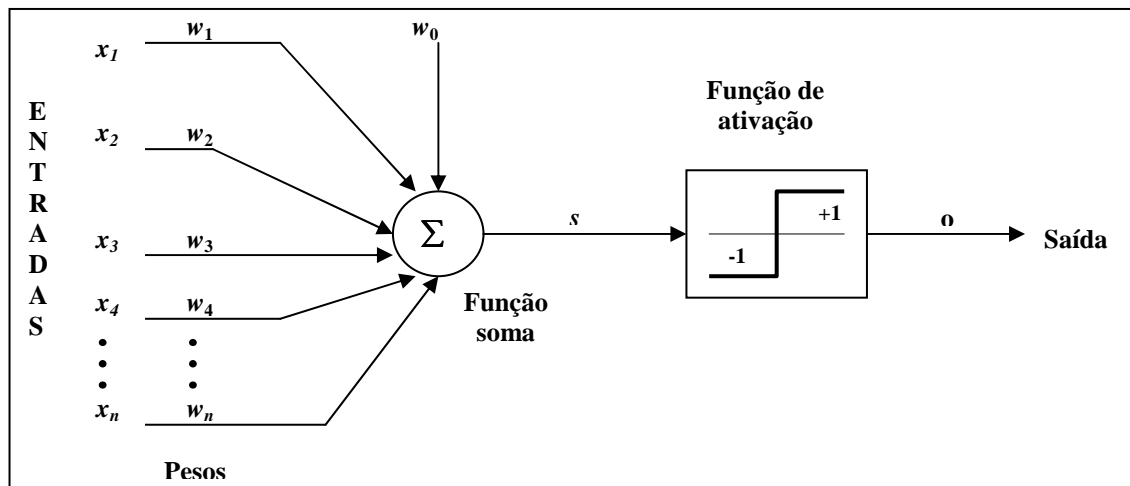


Figura 1 – Modelo de um neurônio perceptron de Rosenblatt.⁽⁸⁾

Nesse modelo de neurônio as variáveis apresentadas são as seguintes: x_i : entradas do neurônio ($i=1, 2, \dots, n$); w_i : pesos das sinapses ($i=1, 2, \dots, n$); w_0 : viés ou *bias*; s : saída intermediária; e o : saída ativada.

Através das entradas x_i são apresentados os valores que se desejam processar. Os pesos das sinapses w_i (que representam o aprendizado da rede) assumirão valores que, aplicados aos valores de entrada, resultarão numa saída intermediária s . Tais pesos são atualizados por meio de um processo de treinamento prévio. A variável w_0 , denominada viés (*bias*), não multiplica nenhuma entrada, possui valor fixo e funciona como uma espécie de ajuste fino.⁽⁸⁾

Para obter o valor da saída intermediária s , realiza-se o somatório da multiplicação entre as entradas e seus respectivos pesos numa função denominada soma, ou seja:

$$s = \sum(x_j w_{ij}) + w_0 \quad (01)$$

A função denominada função de ativação ou de transferência limita a amplitude do intervalo do sinal de saída do neurônio para algum valor finito, normalmente no intervalo $[-1, 1]$ ou $[0, 1]$.



Das funções de ativação utilizáveis, a de uso mais comum é a sigmoideal, por apresentar algumas características vantajosas tais como: continuidade, monotonicidade, não linearidade e diferenciabilidade em qualquer ponto. Sua expressão é dada por:

$$y_i = \frac{1}{1 + e^{(-\lambda s_i + \rho)}} \quad (02)$$

Onde: ρ : constante de translação da curva y_i e λ : constante de inclinação da curva y_i .

Característica muito importante das RNA é a capacidade de aprender por meio de treinamento e, com isso, poder melhorar seu desempenho de reproduzir saída desejada a partir de um conjunto de entrada. A aprendizagem se completa quando a RNA chega a uma solução generalizada para uma classe de problemas.

Os principais modelos de aprendizagem são: aprendizagem supervisionada ou associativa, aprendizagem não supervisionada e treinamento híbrido.

O denominado *perceptron* multicamadas consiste numa generalização do *perceptron* de camada única. Segundo Cybenko *apud* Rocha,⁽⁹⁾ uma RNA com uma camada oculta é capaz de implementar qualquer função contínua. Com duas camadas ocultas, a rede é capaz de aproximar qualquer função.

A capacidade que as RNA possuem de aproximar funções com grau arbitrário de precisão provavelmente justifica sua ampla aplicabilidade no campo da identificação e controle de processos.⁽¹⁰⁾

A rede neural do tipo retropropagação consiste numa rede neural tipo *feedforward* treinada com algoritmo de retropropagação. Motivada pela grande popularidade desse método para o treinamento de RNA, as redes treinadas por meio desse método são denominadas de redes com retropropagação.

A grande vantagem da utilização do método de retropropagação reside no fato de existirem uma quantidade de equações bem definidas e explícitas voltadas para a correção dos pesos na rede. A correção do erro nos pesos das sinapses é realizada por meio da retropropagação do erro obtido na comparação entre a saída gerada pela rede e aquela desejada, objetivando diminuir o erro total da saída gerada pela rede.⁽⁴⁾

Considerando uma rede com retropropagação, o ajuste do erro é feito pela retropropagação do erro, realizando uma distribuição do erro referente aos neurônios de saída para os demais neurônios da rede. Porém, apesar de ser possível conhecer o erro global, não há meio de se determinar com exatidão os pesos para corrigi-los. Entretanto, com base no erro global, é possível determinar as direções nas quais os pesos precisam ser ajustados no sentido de minimizar o erro quadrático total na saída da rede. De posse dessas direções, torna-se possível regular os pesos no sentido de atingir o menor erro global.

Com vistas a melhorar o desempenho do algoritmo de retropropagação, vários esforços na literatura foram feitos neste sentido, abordando o método de várias formas. Uma delas consistiu na consideração do termo momento.

De acordo com Krose e Smaght *apud* Lopes,⁽¹¹⁾ o processo de aprendizagem impõe que alterações nos pesos das sinapses sejam proporcionais a $\frac{\partial \varepsilon_i}{\partial V_i}$. Isso

garante que não haja oscilações excessivas para γ , evitando a falta de direcionamento. O acréscimo do termo momento permitiu que a atualização dos pesos dependesse da variação dos pesos anteriores, o que possibilitou tal proporção.



2 MATERIAIS E MÉTODOS

O sistema baseado em RNA foi construído a partir de uma componente MLP desenvolvida por Medeiros⁽⁸⁾ para o ambiente **Delphi 7®**, que depende de uma *unit* denominada *MLP.pas* que contém as funções e métodos básicos necessários à implementação de uma RNA perceptron multicamada com momento (disponível em: <http://www.visualbooks.com.br/shop/Downloads.asp>).

A análise topológica indicou que a configuração constituída por uma camada neuronal de entrada, duas camadas intermediárias e uma camada de saída mostrou-se adequada para a natureza do problema abordado, adotando-se o número de corridas igual a 1000.

Os dados experimentais utilizados provieram de trabalho anterior realizado por Rosa⁽¹²⁾ e por Rosa e Luz⁽¹³⁾. A RNA foi alimentada com as informações: percentual do mineral dolomita, percentual do mineral quartzo, diâmetro mediano da alimentação (diâmetro d_{50}), agudez da alimentação e ciclo de moagem, nessa ordem. Na camada de saída, obtiveram-se: diâmetro mediano da dolomita, coeficiente de agudez da dolomita, diâmetro mediano do quartzo e coeficiente de agudez do quartzo, nesta ordem. Foram utilizados conjuntos distintos de dados para treinar e testar a RNA, como mostra a Tabela 1.

Tabela 1 – Conjuntos de dados utilizados como padrões de treinamento e de teste da RNA⁽¹³⁾

Amostra (Padrão)	Proporção (dolomita:quartzo)	Tempo de moagem (minutos)	Agudez		d_{50}		Classificação dos Dados
			Dolomita	Quartzo	Dolomita	Quartzo	
T25D/75Q	25 % : 75 %	5	1,0219	1,7361	397	1010	TREINAMENTO
T25D/75Q	25 % : 75 %	15	1,5523	1,7659	174	808	TREINAMENTO
T25D/75Q	25 % : 75 %	30	2,1026	1,8611	154	507	TREINAMENTO
T25D/75Q	25 % : 75 %	50	2,5578	2,0406	142	397	TREINAMENTO
T25D/75Q	25 % : 75 %	75	3,2852	2,4255	158	330	TREINAMENTO
T50D/50Q	50 % : 50 %	5	1,0725	1,7461	382	1070	TREINAMENTO
T50D/50Q	50 % : 50 %	15	1,447	1,8145	200	860	TREINAMENTO
T50D/50Q	50 % : 50 %	30	2,2179	1,8646	138	625	TREINAMENTO
T50D/50Q	50 % : 50 %	50	2,2567	1,8101	114	449	TREINAMENTO
T50D/50Q	50 % : 50 %	75	3,1389	2,2308	145	355	TREINAMENTO
T75D/25Q	75 % : 25 %	5	1,0689	1,7913	364	1170	TREINAMENTO
T75D/25Q	75 % : 25 %	15	1,3862	1,7775	195	829	TREINAMENTO
T75D/25Q	75 % : 25 %	30	2,0301	1,877	140	625	TREINAMENTO
T75D/25Q	75 % : 25 %	50	2,4957	1,8219	124	417	TREINAMENTO
T75D/25Q	75 % : 25 %	75	2,843	2,1324	111	373	TREINAMENTO
T25D/75Q	25 % : 75 %	22	1,8064	1,8064	156	668	TESTE
T50D/50Q	50 % : 50 %	23	1,8423	1,8423	170	739	TESTE
T75D/25Q	75 % : 25 %	25	1,8459	1,8459	157	681	TESTE

Para analisar a qualidade das saídas do simulador, realizaram-se 30 simulações consecutivas, obedecendo aos parâmetros de simulação definidos, a fim de se obterem dados para testar estatisticamente o desempenho do processo de simulação. Utilizou-se, como critério de avaliação, o *índice qualitativo de simulação* (IQS), que corresponde à multiplicação do somatório dos módulos dos erros totais



dos parâmetros simulados: coeficiente de agudez (ETCA) e diâmetro d_{50} (ETD50). Para avaliar estatisticamente os resultados tomou-se o IQS obtido em cada conjunto de corridas de simulação como característica de interesse.

Analisando-se o IQS avaliou-se a estabilidade estatística do processo de simulação via ferramenta da qualidade denominada *carta de controle*, que determina, por meio do sistema 3σ , limites máximos dentro dos quais os valores gerados pelo processo podem oscilar de forma aleatória em torno de uma linha central, que representa o valor da média para o parâmetro. Essa ferramenta estatística pode ser utilizada caso se tenha um conjunto de amostras superior a 20 e se a distribuição de probabilidades dos valores das amostras siga o padrão da distribuição normal de Gauss.⁽¹⁴⁾

3 RESULTADOS E DISCUSSÃO

A Tabela 2 expõe os resultados das 30 simulações consecutivas configuradas com duas camadas ocultas, com 5 neurônios em cada uma.

Tabela 2 – Resultados de 30 simulações consecutivas⁽¹²⁾

SIMULAÇÃO	ERRO TOTAL		IQS[μm]
	ETCA [-]	ETD50 [μm]	
1	0,4142	328,96	136
2	0,3276	51,03	17
3	0,205	209,62	43
4	0,5722	439,73	252
5	0,6902	615,38	425
6	0,5396	328,72	177
7	0,3784	338,32	128
8	0,5015	159,86	80
9	0,4295	393,52	169
10	0,4379	357,41	157
11	0,3128	143,78	45
12	0,5672	259,48	147
13	0,5024	278,92	140
14	0,6502	467,98	304
15	0,396	312,74	124
16	0,3865	229,42	89
17	0,249	132,70	33
18	0,3909	175,54	69
19	0,2648	150,86	40
20	0,5921	284,12	168
21	0,2689	257,97	69
22	0,1928	243,53	47
23	0,1494	177,00	26
24	0,5418	284,44	154
25	0,3693	344,65	127
26	0,8241	544,81	449
27	0,4795	379,41	182
28	0,3499	157,21	55
29	0,3208	167,99	54
30	0,5237	410,38	215
MÉDIA	0,42761	287,516	137



O número de corridas adotadas foi de 1000. Conforme mostra a Figura 2, houve aderência satisfatória dos valores de IQS ao padrão normal. O pacote estatístico *MiniTab*®, versão 15, foi utilizado para realizar o teste.




Figura 2 – Teste de aderência realizado para os valores do IQS com relação ao padrão de distribuição normal.⁽¹²⁾

Devido às características dos dados, a utilização da carta de controle Shewhart para medidas individuais mostrou-se eficaz. A carta de controle preliminar é apresentada na Figura 3 e indica que a simulação se apresenta sob controle estatístico em termos de dispersão dos valores de IQS, porém, o mesmo não ocorre para avaliação da locação da média.

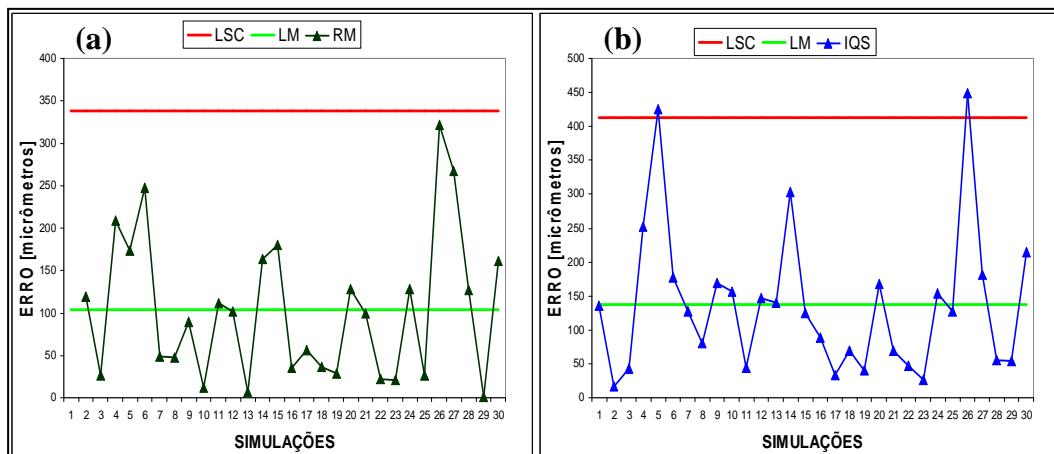


Figura 3 – Carta de Shewhart preliminar: (a) amplitudes móveis e (b) valores individuais.⁽¹²⁾

Como apenas dois pontos extrapolaram os limites de controle, uma medida usual permitiu desconsiderá-los, caracterizando-os como exceções do processo de simulação. Na carta de controle recalculada não se percebe pontos fora dos limites, nem tampouco indícios de falta de aleatoriedade na distribuição dos pontos em torno da linha central, indicando que o processo de simulação está sob controle estatístico, o que lhe confere previsibilidade. Após excluir os dados das simulações de números 5 e 26, os limites são recalculados com o restante das amostras, como mostra a Figura 4.

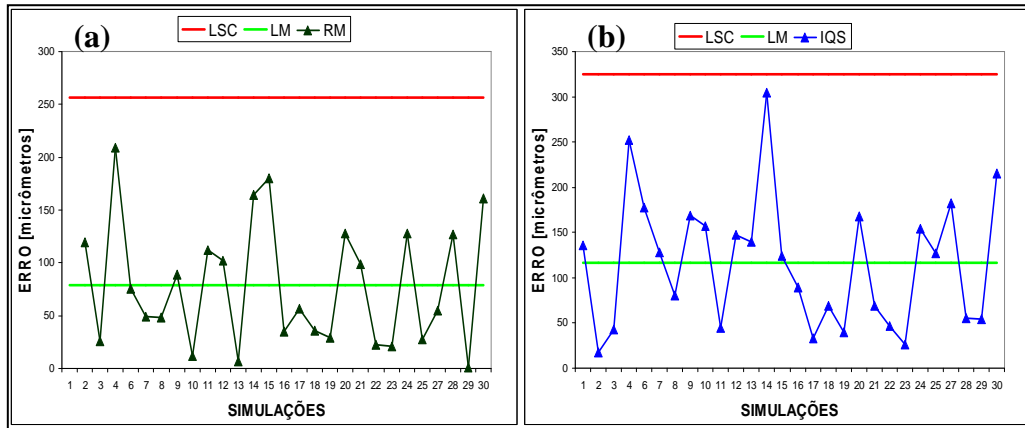


Figura 4 – Carta de Shewhart com expurgo: (a) amplitudes móveis e (b) valores individuais.⁽¹²⁾

As Figuras 6 e 7 ilustram as distribuições granulométricas simuladas de menor valor de IQS (simulação de número 2) e maior valor de IQS (simulação de número 14), respectivamente, para cada padrão de mescla com as respectivas curvas determinadas. A fração retida simples é plotada em função do diâmetro médio da classe granulométrica (média aritmética de peneiras contíguas da série ANBT/Tyler). Há proximidade satisfatória, com contrastes máximos da ordem de menos de 7%, exceto para o padrão T25D/75Q, que apresentou contraste máximo da ordem de 19%, na simulação de maior IQS.




Figura 6 – Curvas granulométricas simuladas (com menor IQS) e determinadas para os minerais no produto das moagens das mesclas (a) T25D/75Q-22, (b) T50D/50Q-23 e (c) T75D/25Q-25.⁽¹²⁾




Figura 7 – Curvas granulométricas simuladas (com maior IQS) e determinadas para os minerais no produto das moagens das mesclas (a) T25D/75Q-22, (b) T50D/50Q-23 e (c) T75D/25Q-25.⁽¹²⁾

A Figura 8 mostra o comportamento do indicador global de contraste granulométrico (IGCG) nas simulações de maior e menor IQS. O IGCG é calculado segundo a equação:⁽¹²⁾

$$IGCG = 0,5 \cdot \sum_{i=1}^n |x_{1i} - x_{2i}| \quad (03)$$

Onde:

x_{1i} : fração retida simples do mineral da espécie 1 na faixa granulométrica i [-]; x_{2i} : fração retida simples do mineral da espécie 2 na faixa granulométrica i [-]; $|\cdot|$: função módulo; n : número de faixas granulométricas.

Segundo o gráfico, as discrepâncias em termos de IGCG ocorreram no padrão T25D/75Q-22, segundo a simulação de maior IQS.

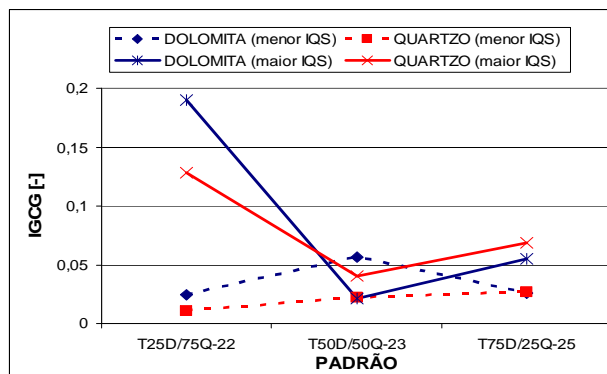


Figura 8 – Comportamento do IGCG nas simulações de maior e menor IQS.⁽¹²⁾

Como forma de se sistematizar a aceitação das atualizações das sinapses, pode-se desconsiderar as simulações que representam os maiores picos no gráfico de controle, estreitando a amplitude de variação dos erros totais. Outra forma de se priorizar melhores resultados seria a adoção de limites de controles arbitrários, desde que a maioria dos pontos na carta de controle se situe entre os mesmos.

4 CONCLUSÃO

O simulador de moagem mista baseado em RNA *perceptron* multicamada com momento se mostrou eficaz na maioria das simulações realizadas, apesar da escassez de dados de treinamento e de teste. A utilização de carta de controle permitiu verificar a estabilidade estatística do processo de simulação em relação à dispersão dos valores e locação da média dos erros, além de propiciar manipulação segura dos dados, sistematizando de forma mais eficiente a aceitação das atualizações de pesos geradas na fase de treinamento. Tomando como base o sucesso dos resultados alcançados nesse trabalho, percebe-se que novas aplicações utilizando simulador baseado em redes neurais artificiais e lógica nebulosa possam ser implementados na área de tratamento mineral, auxiliando nos seus variados processos.

Agradecimentos

Os autores agradecem ao Programa de Pós-Graduação em Engenharia Mineral da Escola de Minas da Universidade Federal de Ouro Preto pelo apoio e estrutura, e

aos técnicos de laboratório pelo auxílio na realização dos ensaios. O segundo autor agradece ao CNPq por seu suporte, sob forma de bolsa de produtividade em pesquisa.

REFERÊNCIAS

- 1 PIDD, M. *Computer simulation in management science* (4th ed.). Chichester: John Wiley & Sons, 1998. 311 p.
- 2 GOLDBARG, M. C. *Otimização combinatória e programação linear: modelos e algoritmos*. Rio de Janeiro: Campus, 2000. 649 p.
- 3 ALVES, V. K. *et alii*. Estudo de otimização de carga de moinho utilizando tecnologia de simulação. In: MENEZES, C. T. B. de *et alii* (Ed.). *XX Encontro Nacional de Tratamento de Minérios e Metalurgia Extrativa*. Florianópolis: Unesc; vol.2, 2004. pp.: 227-234.
- 4 PAULA, W. C. F. de. *Análise de superfície de peças retificadas com o uso de redes neurais artificiais* (dissertação de mestrado). Bauru: Universidade Estadual Paulista, 2007. 151 p.
- 5 LUGER, G. F. *Inteligência artificial: estruturas e estratégias para a resolução de problemas complexos* (4^a. ed.). Porto Alegre: Bookmann, 2004. 774 p.
- 6 PONTES, F. J. *Predição da vida de ferramentas e da rugosidade da peça por redes neurais RBF projetadas com uso da metodologia de projeto de experimentos* (dissertação de mestrado). Itajubá: Universidade Federal de Itajubá, 2006. 166 p.
- 7 MEDEIROS, J. S. de. *Banco de dados geográficos e redes neurais artificiais: tecnologias de apoio à gestão do território* (tese de doutoramento). São Paulo: Universidade de São Paulo, 1999. 221 p.
- 8 MEDEIROS, L. F. de. *Redes neurais em Delphi* (2^a ed.). Florianópolis: Visual Books, 2006. 210 p.
- 9 ROCHA, F. L. *Identificação de sistemas não-lineares multivariáveis usando redes neurais perceptron multicamadas e função de base radial* (dissertação de mestrado). Curitiba: Pontifícia Universidade Católica do Paraná, 2006. 103 p.
- 10 ROSSOMANDO, F. G. *Estabelecimento de estratégias de controle inteligente na laminação de produtos planos*. Vitória: Universidade Federal do Espírito Santo, 2006. 164 p.
- 11 LOPES, M. L. M. *Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica* (tese de doutoramento). Ilha Solteira (SP): Universidade Estadual Paulista, 2005. 149 p.
- 12 ROSA, G. M. *Cominuição seletiva de mesclas binárias e sua simulação por redes neurais artificiais* (dissertação de mestrado). Ouro Preto: Universidade Federal de Ouro Preto, 2009. 183 p.
- 13 ROSA, G. M.; LUZ, J. A. M. da. Seletividade na cominuição de mesclas de dolomita e quartzo. *Revista Escola de Minas*, vol. 62 (no prelo), 2010.
- 14 MONTGOMERY, Douglas C. *Introdução ao controle estatístico da qualidade*. 4. ed. Rio de Janeiro: LCT, 2001. 513 p.