

APLICAÇÃO DE REDES NEURONAIS ARTIFICIAIS NA DESCRIÇÃO DA RELAÇÃO ENTRE MICROESTRUTURA- PROPRIEDADES-DESEMPENHO DE MINÉRIOS EM PROCESSOS DE AGLOMERAÇÃO E REDUÇÃO⁽¹⁾

Lafayette Caporalli⁽²⁾

Rodrigo Ottoni⁽²⁾

Evandro Costa e Silva⁽³⁾

Arthur Napoleão Souza Neto⁽⁴⁾

RESUMO

São apresentadas as linhas gerais e o estágio de desenvolvimento do programa da CVRD de aplicação da ferramenta computacional denominada "Redes Neurais Artificiais - RNA" para descrição quantitativa da relação entre microestrutura-propriedades-desempenho de minérios em processos de aglomeração e redução. Nesta etapa, os índices operacionais de sinterização e de qualidade do sinter versus características dos minérios são modelados com precisão próxima àquela dos experimentos convencionais de sinterização.

Palavras Chave: Sinterização, Redes Neurais, Modelamento

⁽¹⁾ Trabalho a ser apresentado no 1º Simpósio Brasileiro de Minério de Ferro: Caracterização, Beneficiamento e Pelotização, 14 a 17 de outubro de 1996, Ouro Preto, MG.

⁽²⁾ Engenheiro Metalurgista, M.Sc., Pesquisador, Superintendência de Tecnologia da CVRD

⁽³⁾ Engenheiro de Minas, M.Sc., Pesquisador, Superintendência de Tecnologia da CVRD

⁽⁴⁾ Engenheiro Metalurgista, Gerente de Contas de Minério de Ferro, Superintendência de Tecnologia da CVRD

1 - INTRODUÇÃO

A Companhia Vale do Rio Doce - CVRD possui grande experiência em seleção de minérios finos para processos de sinterização e pelletização através de ensaios em modelos experimentais (usina piloto). Como não cabe normalizar esses ensaios por qualquer organização de padronização, seus resultados são relativos aos procedimentos adotados na simulação experimental, isto é, podem variar de laboratório para laboratório. A consequência mais imediata é que o grau de acuidade das informações geradas e suas relações com o processo industrial são fortemente dependentes do nível de amadurecimento científico e tecnológico do experimentador.

A abordagem da CVRD é a de simular, e não reproduzir, a prática industrial dos seus diversos clientes. Ao longo dos anos, um grande número de trabalhos foram realizados para desenvolvimento de métodos e procedimentos que resultassem em ensaios capazes de discriminar pequenas diferenças de comportamento entre os minérios em avaliação.

Na simulação do processo de sinterização, um elevado grau de mecanização e automação foi implantado para assegurar uniformidade das operações integrantes das etapas de condicionamento e tratamento térmico da mistura e tratamento mecânico do bolo e do sinter produto. Além disso, foi instalado um sistema de aquisição de dados e controle de operações através de um controlador lógico programável. Ao mesmo tempo, técnicas de caracterização mineralógica e microestrutural foram aprimoradas para minimizar o desvio entre as composições mineralógica e química dos minérios utilizados nos ensaios. Atualmente, procedimentos para medir algumas propriedades físicas relevantes aos processos de aglomeração ainda estão em fase de desenvolvimento e aprimoramento.

Nesse contexto, acredita-se que a CVRD tenha conquistado um bom conhecimento em simulação experimental para avaliação de comportamento de minérios nos processos de aglomeração e redução. De agora em diante, esforços estão sendo dirigidos para modelagem dos dados gerados nos estudos experimentais e conquista da condição de modelador desses processos.

O objetivo desse trabalho é apresentar o estágio de desenvolvimento do programa da CVRD, com a cooperação do Departamento de Ciência da Computação da UFMG, de aplicação da ferramenta computacional denominada "Redes Neurais Artificiais" para descrição quantitativa da relação entre microestrutura-propriedades-desempenho de minérios em processos de aglomeração e redução, explicitando, de forma menos trabalhosa, a relação clássica existente entre a estrutura dos minérios (em seus diversos níveis), o processo empregado na sua aglomeração, nessa etapa a sinterização, e as propriedades e desempenho do produto resultante (sinter).

2 - O MODELAMENTO DO PROCESSO DE SINTERIZAÇÃO

O processo de sinterização em esteira ou em panela poderia ser descrito por expressões matemáticas referentes a fenômenos de transferência de calor e massa, secagem e condensação de água, fusão e solidificação de minerais individuais e em misturas e variação na granulação e na fração de vazios do leito. As reações químicas envolvidas na modelagem matemática incluem a liberação de água quimicamente ligada, decomposição de calcário, combustão do coque e redução subsequente do dióxido de carbono, reações de redução e oxidação da hematita e magnetita envolvendo o monóxido de carbono, dióxido de carbono e oxigênio, formação de ferritos de cálcio e assimilação dos minerais da ganga e sílica no líquido^[1]. Assim, pode-se classificar a sinterização de minérios de ferro como um processo complexo que envolve numerosos fenômenos físicos e químicos.

Apesar dessa complexidade - o que resulta em modelos de difícil solução - e de ser um processo bem estabelecido - o que reduz o interesse para o modelamento - vários modelos da sinterização de minérios de ferro tem sido desenvolvidos, cada um com um grau de refinamento maior do que o do outro^[2-16]. Mesmo assim, a previsão da performance de uma determinada mistura e da qualidade do sinter ainda é difícil de ser obtida.

O modelamento matemático de processos baseado na interpretação e análise dos diversos fenômenos individuais e suas associações e interrelações em um dado processo pode demandar, por parte do construtor do modelo, elevado nível de esforço intelectual, assim como considerável volume de experimentos e dados relativos ao processo.

São características comuns aos processos de aglomeração: o grande número de variáveis envolvidas, tanto de entrada quanto de saída; a existência de um conjunto de correlações tipicamente lineares, normalmente relativas aos balanços de massas; e a existência de um conjunto, possivelmente maior do que o anterior, de correlações não-lineares.

Neste caso, a busca de modelos ou correlações matemáticas que possam quantificar de forma adequada o comportamento do processo e a qualidade do sinter pode ser inviável. Dessa forma, faz-se necessária a utilização de ferramentas e técnicas alternativas que permitam o modelamento desta classe de processos complexos com menores custos e prazos e que, mesmo assim, apresentem resultados consistentes com as condições reais observadas.

Dentre estas técnicas que vêm ganhando cada vez maior aceitação e ampliando de forma significativa seu campo de atuação destaca-se as Redes Neurais Artificiais - RNA. As RNA permitem o tratamento de processos de difícil formalização e de

relações tipicamente não-lineares. Na seção seguinte apresenta-se, de maneira breve e resumida, as principais características, pontos fortes e fracos das redes neuronais.

3 - REDES NEURONAIS ARTIFICIAIS - RNA¹⁷

O paradigma das redes neuronais artificiais surgiu como tentativa de se modelar e implementar em um ambiente computacional os princípios fundamentais de funcionamento do cérebro humano. As redes neuronais artificiais começaram a ser estudadas em 1943, mas o modelo adotado era incapaz de resolver uma série de problemas simples e seu poder computacional era extremamente restrito. A partir da década de 70 surgiram algoritmos que possibilitaram tratar problemas reconhecidamente complexos, tais como: reconhecimento de padrões, visão computacional, análise de voz, previsão de comportamento de mercados futuros (*commodities* e bolsas de valores), dentre vários outros.

As redes neuronais artificiais tentam explorar algumas características interessantes das redes de neurônios existentes no sistema nervoso humano:

- robustez e tolerância a falhas: milhares de células nervosas do cérebro morrem diariamente sem entretanto afetar de forma significativa o desempenho do cérebro ou ocasionar perda relevante das informações, conhecimentos, conceitos e critérios armazenados;
- flexibilidade: o cérebro humano pode adaptar-se rapidamente a novos ambientes, através de um processo de aprendizagem, sem a necessidade de uma “reprogramação” completa;
- capacidade de tratamento de informações imprecisas, probabilísticas, com ruídos ou mesmo inconsistentes;
- paralelismo inerente: o cérebro humano é composto por aproximadamente 10^{11} neurônios interconectados, cada um processando um “pequeno pedaço de informação” de forma distribuída e cooperativa.

Um dos principais motivos que torna as redes neuronais especialmente atraentes para o modelamento de fenômenos ou processos complexos é a sua capacidade, semelhantemente ao cérebro humano, de previsão de resultados baseado em um processo de “aprendizado” através de exemplos. Assim, não é necessário explicitar para o sistema as “regras” e equações matemáticas que definam com precisão o modelo do fenômeno ou processo. Esta característica permite que se obtenha um modelo que produza resultados confiáveis, mesmo na ausência parcial de dados.

O tratamento de um problema através de redes neuronais consiste portanto em: modelar a rede, isto é, determinar os parâmetros de entrada e saída do modelo; selecionar os tipos e funções dos neurônios e do mecanismo de aprendizado mais adequado para o problema em questão; coletar um conjunto representativo e suficiente de dados para a fase de treinamento; promover o treinamento propriamente dito (supervisionado e/ou não-supervisionado), em que estes dados são "apresentados" a rede; e, por fim, fazer a validação e aferição dos resultados.

O processo de treinamento supervisionado consiste em extrair de um universo de dados representativos do fenômeno ou processo uma parcela de 80-85% do total, de forma relativamente aleatória, porém visando cobrir todo o espectro do problema. Esta parcela é então "apresentada" à rede, que constrói uma matriz de conexões, atribuindo a cada uma das conexões (neurônio) um peso específico. Este processo de "aprendizado" de fato constitui-se em processos de classificação, regressões não-lineares através de interpolações de diversas famílias de curvas e determinação de mínimos.

Terminada a fase de treinamento, o conjunto restante dos dados é então "apresentado" à rede e os resultados obtidos comparados com os resultados reais. Determinam-se então os desvios para cada variável de saída. Caso estes desvios sejam superiores aos esperados inicia-se um processo de adaptação da rede (inclusão ou exclusão de informações, níveis, nodos ocultos, conexões, etc.) e novamente o processo de "aprendizado". Este processo se repete até que os desvios atinjam níveis aceitáveis.

As principais limitações da aplicação das redes neuronais residem na necessidade de um grande volume de dados que representem efetivamente as diversas situações do processo, o elevado custo computacional nas fases de treinamento e configuração e na ausência de um "modelo explícito de regras e equações" para o problema. Este último fator é considerado, em vários casos, a maior restrição por tratar o processo como uma "caixa preta".

Assim, através da ferramenta Rede Neuronal Artificial e utilizando a vasta gama de resultados de produção de sinter em modelo experimental disponíveis na CVRD, espera-se construir um modelo capaz de prever com um nível adequado de precisão o desempenho de misturas de minérios numa dada prática de sinterização e a qualidade do sinter produzido, em função das características dos minérios.

4 - CONCEPÇÃO GERAL DO MODELO

As variáveis experimentais consideradas no modelamento do processo de sinterização foram agrupadas de forma a permitir a descrição da relação clássica estrutura-propriedades existentes nos materiais. Essa relação, pode ser escrita como gênese dos

minérios-microestrutura-processo-desempenho do produto (sinter). Para cada elo da relação, podem ser selecionadas as seguintes variáveis:

Gênese-Microestrutura : % em peso de minério de cada tipo segundo a classificação CVRD, % em peso das fases mineralógicas presentes nos minérios, distribuição de tamanho dos cristais dos minerais de ferro e de silício (quartzo), morfologia da hematita, porosidade aberta, distribuição de tamanho das partículas dos minérios, composição química dos minérios.

Processo : altura do leito, depressão, taxa de retorno, taxa de combustível, densidade de carregamento, índices de avaliação do perfil térmico do processo, análise química visada para o sinter, rendimento total da mistura, tempo de sinterização, produtividade e consumo de combustível sólido.

Desempenho produto : distribuição granulométrica do sinter, resistência ao tamboramento, resistência a queda, susceptibilidade à degradação sob redução, redutibilidade.

No momento, 26 variáveis de entrada foram selecionadas para a confecção do modelo, o qual deverá gerar 7 variáveis de saída. As variáveis de entrada são independentes ou controláveis (características químicas, físicas, mineralógicas e microestruturais dos minérios de ferro, algumas condições de processo) e as de saída são dependentes (produtividade, consumo de combustível na sinterização e índices de qualidade do sinter).

5 - RESULTADOS E DISCUSSÃO

Na primeira fase do trabalho foram estudadas as seguintes variáveis de saída:

✓ produtividade de sinterização	(t/m ² /dia)
✓ consumo de combustível	(kg/t sinter)
✓ resistência a queda (JIS M 8711)	(% +9,53mm)
✓ resistência ao tamboramento (ISO 3271)	(% +6,35mm)
✓ degradação sob redução (RDI ISO 4696-2)	(% -2,83mm)
✓ redutibilidade (JIS M 8713)	(grau de redução)

Cada variável de saída foi calculada através de uma rede especificamente configurada e treinada para ela. Os treinamentos e seleção da rede foram feitos empregando-se uma base de dados de 43 exemplos (cada exemplo representa um experimento de sinterização) sendo que 38 desses exemplos foram utilizados no treinamento e 5 na validação da rede treinada. A rede foi aceita quando os resultados previstos

apresentaram uma diferença em relação aos resultados experimentais inferior ao grau de discriminação de cada variável para duas condições de ensaio diferentes, que pode ser calculado pela expressão $2,27 * S$, onde S é o desvio padrão estimado para a variável em questão.

A acuidade de previsão das redes para os índices de desempenho do processo de sinterização e do sinter é apresentada na Tabela I e nas Figuras 1 a 3.

TABELA I - Grau de ajuste do modelo de redes neuronais artificiais.

VARIÁVEL	EXPERIMENTAL	CALCULADO	DIFERENÇA
Produtividade (t/m ² /dia) (Discriminação = 2,70)	33,1	32,8	0,3
	32,7	33,7	1,0
	33,3	33,1	0,2
	31,9	33,3	1,4
	30,7	32,6	1,9
Consumo Combustível (kg/t sinter) (Discriminação = 0,50)	60,8	60,7	0,1
	60,7	61,1	0,4
	60,1	59,7	0,4
	63,0	63,3	0,3
	59,6	59,8	0,2
Tamboramento (ISO) (% +6,35mm) (Discriminação = 1,50)	70,5	71,2	0,7
	75,0	76,1	1,1
	74,0	75,4	1,4
	76,1	76,8	0,7
	76,3	76,6	0,3
Resistência a queda (JIS) (% +9,53mm) (Discriminação = 1,00)	88,4	88,5	0,1
	86,8	87,7	0,9
	85,7	86,1	0,4
	87,0	87,2	0,2
	86,2	87,2	1,0
Degradação sob redução (% -2,83mm) (Discriminação = 2,50)	28,5	27,2	1,3
	20,8	19,7	1,1
	21,7	19,5	2,2
	18,2	16,3	1,9
	23,4	23,6	0,2
Redutibilidade (JIS) (grau de redução) (Discriminação = 6,00)	68,5	70,9	2,4
	69,6	73,0	3,4
	69,4	72,6	3,2
	69,9	71,2	1,3
	73,2	72,6	0,6

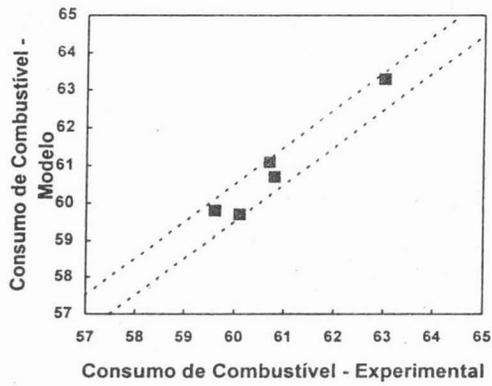
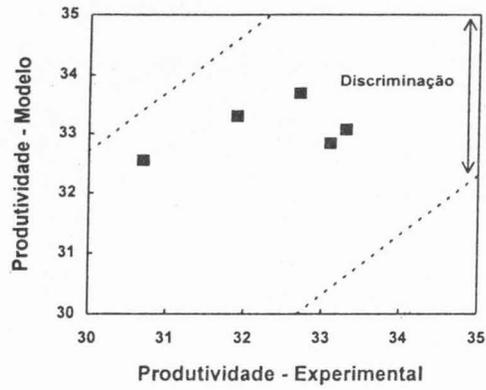


FIGURA 1 - Qualidade de ajuste do modelo para os índices operacionais de sinterização.

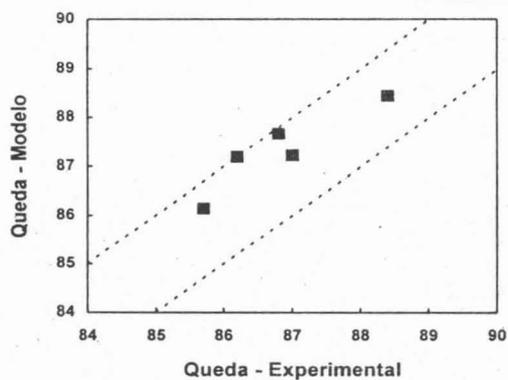
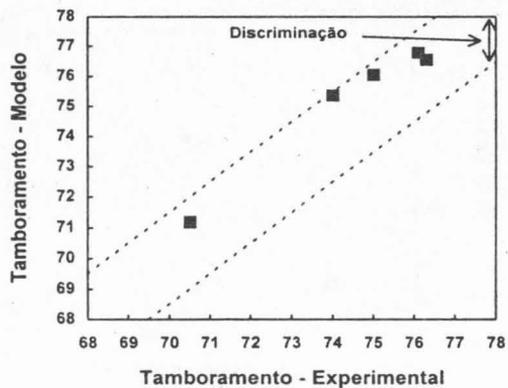


FIGURA 2 - Qualidade de ajuste do modelo para os índices de resistência mecânica do sinter.

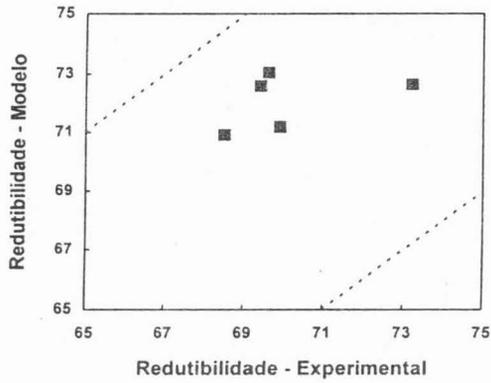
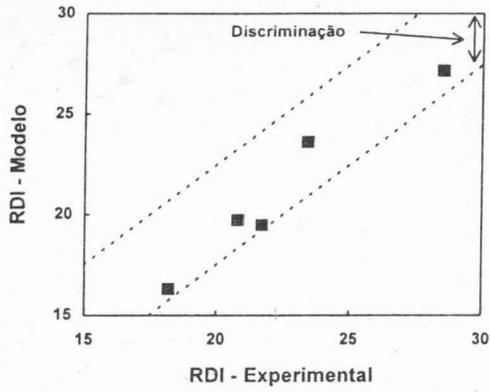


FIGURA 3 - Qualidade de ajuste do modelo para os índices de comportamento metalúrgico do sinter.

Como se observa, as Redes Neurais conseguiram aprender todos os exemplos apresentados, pois ao serem consultadas acerca de casos totalmente desconhecidos, elas estimaram valores que se aproximaram dos valores experimentais com um erro compatível com a precisão determinada para os ensaios de sinterização da CVRD.

Esse resultado mostra o poder de generalização da rede, que deverá ser ampliado à medida que novos exemplos sejam adicionados à sua base de conhecimento. Além disso, o modelo de redes poderá ser melhorado com a adoção de uma "família" de redes para o tratamento de cada variável ao invés de apenas uma rede. Com isso, o valor previsto pelo modelo será expresso como um valor estatístico, isto é, como média e desvio padrão. Nesse ponto, o modelo estará aperfeiçoado o suficiente para ser aplicado como ferramenta de quantificação da interdependência das variáveis relativas à gênese-microestrutura de minérios com o processo de sinterização e com o desempenho do sinter, que, se atingida, representará um grande passo no desenvolvimento das técnicas de seleção de minérios para sinterização.

6 - CONCLUSÕES

A utilização de redes neurais é especialmente atraente para o modelamento de fenômenos complexos, pois se baseia num processo de aprendizagem através de exemplos, sendo desnecessário explicitar regras ou equações matemáticas para o sistema para a definição do modelo.

Os resultados do modelamento para os índices operacionais de sinterização e de qualidade do sinter através de redes neurais se mostraram aceitáveis. O próximo passo é o aperfeiçoamento do modelo para estendê-lo à quantificação do efeito das características químicas, físicas, mineralógicas e microestruturais dos minérios sobre o desempenho do processo de sinterização e do sinter.

7 - REFERÊNCIAS BIBLIOGRÁFICAS

- [1] CUMMING, M.J. & THURLBY, J.A. Ironmaking and Steelmaking, v. 17, 1990, p. 245-254.
- [2] RANKIN, W.J. & BATTERHAM, R.J. Proceedings of the Extractive Metallurgy Symposium, Melbourne, 1984, p. 261-267, Australasian Institute of Mining and Metallurgy.
- [3] MUCHI, I. & HIGUCHI, J. Transactions of the Iron and Steel Institute of Japan, v. 12, 1972, p. 54-63.
- [4] RANZ, E. Chemical Engineering Prog., v. 48, 1952, p. 247-253.
- [5] HAMADA, T. & KOITABASHI, T. & OKABE, K. Tetsu-to-Hagané, v. 58, 1972, p. 1567-1578.
- [6] YOSHINAGA, M. & KUBO, T. Sumitomo Search, n.20, 1978, p. 1-14.

- [7] ERGUN, S. *Chemical Engineering Prog.*, v. 48, 1952, p. 89-94.
- [8] DASH, I.R. & CARTER, C.E. & ROSE, E. *Proceedings of Symposium "Measurement and control of quality in steel industry"*, Sheffield, 1974, Institute of Measurement and Control, p. 8/1-8/7.
- [9] DASH, I.R. & ROSE, E. *Ironmaking and Steelmaking*, v. 5, 1978, p. 25-31.
- [10] ROSE, E. & DASH, I.R. *Industrial Engineering Chemistry*, v. 18, 1979, p.67-72.
- [11] YOUNG, R.W. *Ironmaking and Steelmaking*, v. 4, 1977, p. 321-328.
- [12] TODA, H. & KATO, K. *Transactions of Iron and Steel Institute of Japan*, v. 24, 1984, p. 178-186.
- [13] KASAI, E. & YAGI, J. & OMORI, Y. *Proceedings of Ironmaking Conference of AIME*, 43, 1984, p. 241-249.
- [14] KASAI, E. & YAGI, J. & OMORI, Y. *Proceedings of 4. International Symposium on Agglomeration*, p. 777-785, Iron and Steel Society of AIME, Warrendale, 1985.
- [15] MAKOVSKII, V.A. & VLASY, Y.N. UK: *Izv. VUZ Chernaya Metall.*, v. 8, 1976, p. 136-139.
- [16] CUMMING, M.J. et al. *Proceedings of 4. International Symposium on Agglomeration*, p. 763-776, Iron and Steel Society of AIME, Warrendale, 1985.
- [17] FREEMAN, JAMES A. and SKAPURA, DAVID M. *Neural networks: algorithms, applications, and programming techniques*, Addison-Wesley Publishing Company, Inc., 1991.

**APPLICATION OF ARTIFICIAL NEURAL NETWORKS TO
DESCRIBE THE MICROSTRUCTURE-PROPERTIES-
PERFORMANCE RELATIONSHIP IN IRON ORE
AGGLOMERATION AND REDUCTION PROCESSES**

Abstract

This paper presents an overview of the CVRD ongoing work of applying Artificial Neural Networks to quantitatively describe the relationship microstructure-properties-performance of iron ores in agglomeration and reduction processes. In this part, sintering operational indexes and sinter quality indexes versus iron ore characteristics are modeled with an agreement close to that of sintering pot tests discrimination degree.

Key words: Iron ore sintering, Neural Networks, Modeling.

