

ESTIMATIVA POR REDE NEURAL DAS PROPRIEDADES A ALTAS TEMPERATURAS DE CARGA METÁLICA MISTA¹

Ângelo Guimarães Parreira²
Vinícius de Moraes Oliveira³
Débora Turon Wagner³
Eider Reis Dutra⁴
Reginaldo Narciso Ferreira⁵

Resumo

Dentre os equipamentos que suportam o desenvolvimento de novos produtos e soluções de carga metálica para clientes na Vale, um dos mais importantes é o Forno de Amolecimento e Fusão (A&F). Trata-se de um reator em escala de laboratório capaz de reproduzir o comportamento da carga metálica na zona coesiva do alto-forno. O ensaio de A&F apresenta custo elevado em função, principalmente, de consumíveis e energia elétrica. Neste contexto, objetivando a redução de custos com ensaios e maior disponibilidade do equipamento, foram desenvolvidos modelos de redes neurais capazes de prever os parâmetros de A&F a partir das composições químicas dos constituintes da carga metálica, pelota e sinter. Para desenvolver esses modelos foi formado um banco de dados a partir de ensaios de A&F realizados com dois tipos de pelotas comerciais da Vale e sinteres com variadas composições químicas, produzidos em escala piloto. A ferramenta utilizada para o desenvolvimento dos modelos foi um software de utilização livre e os parâmetros de entrada para os modelos são os elementos/compostos químicos Fe_T , FeO , CaO , SiO_2 , Al_2O_3 e MgO . Testes de verificação realizados demonstraram uma forte adesão entre os resultados previstos pelos modelos e os resultados experimentais.

Palavras-chave: Rede neural; Amolecimento e fusão; Cargas metálicas; Pelota; Sinter.

NEURAL NETWORK ESTIMATE OF HIGH TEMPERATURE OF MIXED FERROUS BURDEN PROPERTIES

Abstract

Among the facilities that support the development of new products and burden solutions to customers in Vale, one of the most important is the Softening and Melting Furnace (S&M). It is a laboratory scale reactor capable of reproducing the behavior of the metallic burden in the blast furnace cohesive zone. The S&M test is expensive due mainly consumables and electricity. In this context, in order to reduce S&M test costs and higher availability of equipment were developed neural network models capable of predicting the S&M parameters from the chemical compositions of the constituents of the metallic burden, such as pellet and sinter. The models were developed based on a database from S&M tests conducted with two types of commercial pellets from Vale and pilot sinters with varying chemical compositions. The tool used for developing the models was free software and the input parameters for the models are the chemical compounds Fe_T , FeO , CaO , SiO_2 , Al_2O_3 and MgO . Verification tests demonstrated a strong adhesion between the results predicted by the models and the experimental results.

Key words: Neural network; Softening and melting; Metallic burden; Pellet; Sinter.

¹ Contribuição técnica ao 43º Seminário de Redução de Minério de Ferro e Matérias-primas, 14º Simpósio Brasileiro de Minério de Ferro e 1º Simpósio Brasileiro de Aglomeração de Minério de Ferro, 1 a 4 de setembro de 2014, Belo Horizonte, MG, Brasil.

² Engenheiro metalúrgico, Engenheiro. Vale, Ferrous Technology Center, Nova Lima, MG, Brasil.

³ Engenheiro metalúrgico, M.Sc., Engenheiro. Vale, Ferrous Technology Center, Nova Lima, MG, Brasil.

⁴ Engenheiro químico, M.Sc., Engenheiro. Vale, Ferrous Technology Center, Nova Lima, MG, Brasil.

⁵ Técnico em mineração, Técnico em laboratório. Vale, Ferrous Technology Center, Nova Lima, MG, Brasil.

1 INTRODUÇÃO

A Vale, como fornecedora global de minério de ferro, destaca-se no mercado transoceânico tanto pelo volume quanto pela qualidade do minério de ferro que produz. Diante da forte concorrência, cada vez mais as empresas que atuam neste mercado buscam criar diferenciais competitivos que permitam fortalecer sua posição estratégica e comercial.

Neste contexto, o Centro de Tecnologia de Ferrosos - CTF, localizado em Nova Lima/MG, desempenha papel importante prestando suporte técnico às ações de marketing e comercial, e no desenvolvimento de novos produtos.

Dentre os recursos laboratoriais existentes, destaca-se o Forno de Amolecimento e Fusão (A&F). Trata-se de um reator em escala de laboratório capaz de reproduzir o comportamento da carga metálica na zona coesiva do alto-forno, suportando o desenvolvimento de novos produtos e de soluções de carga metálica de alto desempenho.

Entretanto, o ensaio de A&F apresenta custo elevado em função, principalmente, de consumíveis, mão-de-obra e energia elétrica. Dessa forma, objetivando a redução de custos com estes ensaios e para uma maior disponibilidade do equipamento, neste trabalho foram desenvolvidos, de forma pioneira, modelos de redes neurais capazes de prever os parâmetros de A&F de cargas mistas a partir das composições químicas de seus constituintes principais, pelota e sinter.

2 MATERIAIS E MÉTODOS

2.1 Ensaio de Amolecimento e Fusão

A metodologia Vale para avaliação das propriedades a altas temperaturas de cargas metálicas para alto-forno é baseada no Forno de Amolecimento & Fusão adquirido da *Nippon Steel Corporation*, em 2006. Este equipamento está instalado no Centro de Tecnologia de Ferrosos - CTF da Vale, em Nova Lima, MG. O equipamento e a metodologia estão bem detalhados nos trabalhos de Castro, Pimenta e Carneiro⁽¹⁾ e Castro⁽²⁾. A Figura 1 mostra um esquema do Forno de Amolecimento & Fusão da Vale.

No ensaio de A&F são monitorados diversos parâmetros relativos à carga metálica avaliada, os quais são mostrados no esquema da Figura 2, com destaque para:

- temperatura de início de amolecimento da carga (T_{s200}): Temperatura correspondente ao instante em que a queda de pressão atinge 200 mmH₂O durante o aquecimento da amostra. Esse também é um indicativo da posição relativa do início da zona coesiva dentro do alto-forno;
- temperatura de final de fusão da carga (T_{e200}): Temperatura correspondente ao instante em que a queda de pressão atinge novamente 200 mmH₂O após ter passado pelo pico de queda de pressão. Indicativo do fim da zona coesiva;
- diferença entre temperaturas de início de amolecimento e fim de fusão (ΔT): diferença entre as temperaturas que caracterizam o fim de fusão e o início de amolecimento da carga metálica. Serve de indicativo da espessura da zona coesiva no interior do alto-forno;
- perda total de carga do gás (Área S): trata-se de um indicador da permeabilidade global do leito durante o ensaio. Para sua quantificação calcula-se a área abaixo da curva de queda de pressão do gás ao longo do ensaio;

- perda máxima de pressão (ΔP_{max}): este é o valor máximo de queda de pressão do gás atingido durante o ensaio; e
- grau de redução em elevadas temperaturas (R_{s200} , R_{1000} , R_{1100} e R_{1200}): Determinada pela análise contínua dos gases de exaustão do fomo.

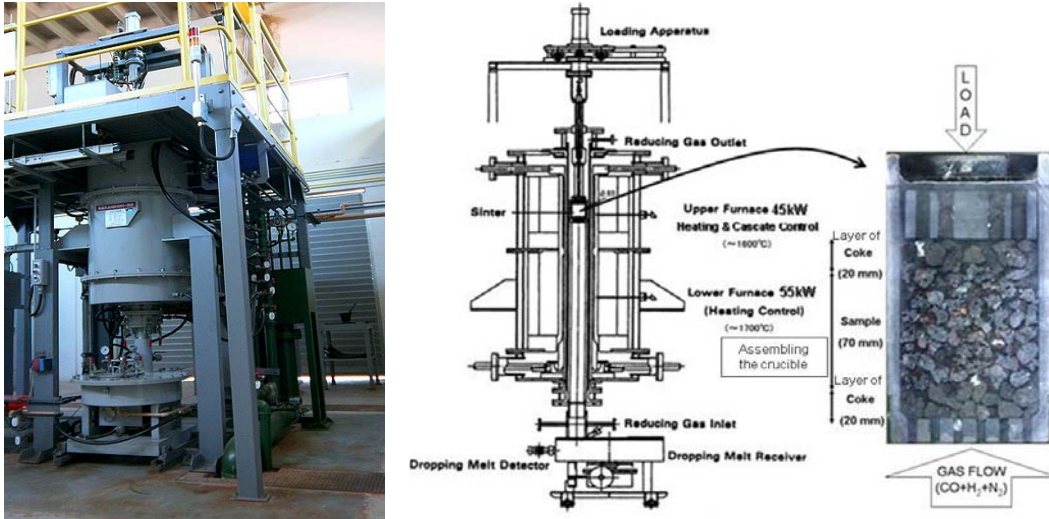


Figura 1. Imagem e esquema do forno de amolecimento e fusão existente no CTF da Vale S.A.

A Figura 2 apresenta, de forma esquemática, alguns dos parâmetros característicos de A&F que são monitorados durante o ensaio.




Figura 2. Esquema mostrando alguns dos parâmetros monitorados pelo ensaio de A&F.

2.2 Redes Neurais e Critérios de Aceitação

De acordo com Braga, Ludemir e Carvalho,⁽³⁾ as Redes Neurais Artificiais (RNAs) são sistemas paralelos distribuídos, compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e são interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. O procedimento usual na solução de problemas passa inicialmente por uma fase de aprendizagem, em que um conjunto de exemplos é apresentado para a rede, a qual extrai automaticamente as características necessárias para representar a informação fornecida. Estas características são utilizadas posteriormente para gerar respostas para o problema. Braga et.al.⁽³⁾ descrevem como principal atrativo dessa ferramenta a capacidade de aprender através de exemplos e de generalizar a informação aprendida. As RNAs são capazes de extrair informações não apresentadas de forma explícita através dos exemplos e de atuar como mapeadores universais de funções multivariáveis. Outra característica importante é a capacidade de auto-organização e de processamento temporal, que, aliada àquelas citadas anteriormente, faz das RNAs uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos.

A ferramenta utilizada para o desenvolvimento das redes neurais foi o software denominado *Tiberius Data Mining*, na versão 6.1.9, de utilização livre. Os parâmetros de entrada para os modelos são os elementos químicos Fet, FeO, CaO, SiO₂, Al₂O₃ e MgO, considerando a composição química global da carga metálica.

Para a definição dos limites de aceitação, realizou-se levantamento do histórico de todos os ensaios realizados em duplicata no forno de A&F da Vale, com carga metálica mista formada por sinter e pelotas do tipo A ou B. Considerando a diversidade de composições de carga existentes na base de dados, foi possível estabelecer os intervalos de aceitação das redes neurais geradas.

Metodologia semelhante à adotada por Nogueira⁽⁴⁾ foi utilizada para definição dos limites de aceitação. Partindo-se da hipótese de que o ensaio tem seus parâmetros operacionais sob controle e que as propriedades de A&F da carga metálica respeitam uma distribuição normal, pode-se usar o teorema central do limite para descrevê-lo. Dessa forma, tomando-se por base todos os ensaios realizados em duplicata e aceitando um intervalo de confiança com $\alpha = 5\%$, pode-se definir os Limites de Aceitação (LA) e Coeficiente de Variação (Cv) como na Equação 1.

$$LA = \pm 1,96 \times \left(\frac{Cv}{\sqrt{2}} \right) \times \bar{X} \quad \text{e} \quad Cv = 100 \times \left(\frac{s}{\bar{X}} \right) \quad (1)$$

Onde:

- LA: Limites de Aceitação;
- Cv: é o coeficiente de variação;
- \bar{X} : é a média dos dados;
- s: é o desvio padrão.

2.3 Planejamento Experimental

Para a geração das redes neurais, além dos resultados de ensaios realizados com estas duas pelotas A e B em cargas mistas com sinteres diversos, testes

complementares foram realizados em duas etapas distintas visando ampliar o domínio da rede. Na primeira fase do trabalho foram fabricados oito sinteres com diferentes composições químicas, sendo esses combinados com as pelotas do tipo A e submetidos à ensaios de A&F. Na segunda fase, mais sete sinteres com diferentes composições químicas foram produzidos e combinados com pelotas do tipo B, e submetidos à testes de A&F. No total, o banco de dados usado no estabelecimento das redes contemplou resultados de 58 condições distintas, totalizando 116 ensaios.

Na produção dos sinteres das etapas complementares utilizou-se somente um tipo de *sinter feed* nas misturas, e os ajustes de sílica e alumina necessários foram feitos pelo uso de quartzito e bauxita, respectivamente. Essa medida foi adotada para evitar efeitos secundários decorrentes de características diversas de diferentes minérios de ferro. A Tabela 1 mostra a proporção de sinter e pelota na carga metálica planejada pra os testes complementares de A&F.

Tabela 1. Proporção de sinter e pelotas na carga metálica para os ensaios de A&F

% Sinter	% Pelota
0	100
35	65
70	30
100	0

3 RESULTADOS E DISCUSSÃO

A Tabela 2 mostra a qualidade química das pelotas A e B e dos sinteres produzidos para o estudo, nas etapas complementares de formação do banco de dados.

Tabela 2. Qualidade química das pelotas e dos sinteres utilizados no trabalho (%)

Material	Fe	FeO	SiO ₂	Al ₂ O ₃	CaO	MgO	B ₂
Pelota A	65,00	0,69	2,70	0,54	2,56	0,04	0,95
Pelota B	64,79	0,06	2,61	1,41	2,46	0,08	0,94
Sinter 01	59,05	8,12	4,59	1,86	6,39	1,46	1,39
Sinter 02	56,12	7,34	6,96	1,94	7,85	1,73	1,13
Sinter 03	54,84	7,70	4,95	1,76	11,65	1,90	2,35
Sinter 04	57,26	4,09	4,37	1,61	9,23	1,09	2,11
Sinter 05	56,42	6,32	4,70	1,79	9,05	2,47	1,93
Sinter 06	58,65	4,31	4,17	1,16	8,19	1,46	1,96
Sinter 07	56,48	6,51	4,65	1,98	9,00	1,65	1,94
Sinter 08	55,04	4,49	5,02	1,37	11,08	2,20	2,21
Sinter 09	58,65	8,68	4,67	1,78	5,30	1,46	1,13
Sinter 10	56,57	4,94	4,61	1,74	8,51	1,51	1,85
Sinter 11	55,43	5,17	3,96	2,03	11,89	1,61	3,00
Sinter 12	56,33	3,93	5,12	1,68	8,58	0,77	1,68
Sinter 13	56,10	4,88	4,35	1,71	8,56	2,10	1,97
Sinter 14	55,39	4,56	4,43	1,31	8,64	1,50	1,95
Sinter 15	56,21	4,88	4,55	2,25	8,62	1,50	1,89

Os dados de entrada das redes neurais são a proporção e a qualidade química dos constituintes da carga metálica e os domínios para utilização das redes são apresentados na Tabela 3, considerando-se a composição química da carga metálica mista.

Tabela 3. Intervalos para utilização das redes neurais (química da carga metálica mista)

Elemento	Mínimo (%)	Máximo (%)
Fet	57,50	63,00
FeO	1,00	6,00
CaO	3,50	10,00
SiO ₂	3,00	6,00
Al ₂ O ₃	0,65	2,20
MgO	0,30	1,75

A Tabela 4 mostra os resultados dos limites de aceitação definidos para os resultados obtidos pela rede neural.

Tabela 4. Limite de aceitação para as estimativas da rede neural

Parâmetro		Limite de aceitação (%)
Perda de Carga	Área S	± 19,2
	ΔP_{\max}	± 11,3
Temperaturas	T _{s200}	± 1,0
	T _{e200}	± 0,7
	ΔT	± 8,1
	T _d	± 0,6
Grau de Redução	R _{s200}	± 3,1

Após o desenvolvimento das redes neurais, foram realizados testes de verificação nas mesmas a partir de ensaios com cargas mistas. Para isso, ensaios foram escolhidos aleatoriamente de um banco de ensaios que não fizeram parte do banco de dados utilizado para o desenvolvimento da rede. Foram selecionadas quatro alternativas de carga mista que foram ensaiadas em duplicata e a validação foi realizada a partir da média dos resultados obtidos.

A Tabela 5 mostra a qualidade química dos componentes individuais e das cargas mistas utilizadas para verificação.

Tabela 5. Qualidade química dos constituintes dos ensaios usados para verificação (%)

Carga	Constituinte	Fe	FeO	SiO ₂	Al ₂ O ₃	CaO	MgO
65% Pelota A + 35% Sinter 4	Pelota A	65,00	0,69	2,70	0,54	2,56	0,04
	Sinter 4	57,26	4,09	4,37	1,61	9,23	1,09
	Carga mista	62,29	1,88	3,28	0,91	4,89	0,41
30% Pelota A + 70% Sinter 7	Pelota A	65,00	0,69	2,70	0,54	2,56	0,04
	Sinter 7	56,48	6,51	4,65	1,98	9,00	1,65
	Carga mista	62,02	2,73	3,38	1,04	4,81	0,60
65% Pelota B + 35% Sinter X	Pelota A	64,79	0,06	2,61	1,41	2,46	0,08
	Sinter X	55,20	3,84	6,13	2,09	9,23	1,69
	Carga mista	61,43	1,38	3,84	1,65	4,83	0,64
25% Pelota B + 75% Sinter 6	Pelota A	64,79	0,06	2,61	1,41	2,46	0,08
	Sinter 6	58,65	4,31	4,17	1,16	8,19	1,46
	Carga mista	62,64	1,55	3,16	1,32	4,47	0,56

A Tabela 6 mostra um comparativo entre os resultados experimentais obtidos no ensaio de A&F e os resultados obtidos pelos modelos de rede neural.

Tabela 6. Resultados obtidos nos ensaios e nos modelos de rede neural

Parâmetro	Descrição	65% Pelota A + 35% Sinter 4	30% Pelota A + 70% Sinter 7	65% Pelota B + 35% Sinter X	25% Pelota B + 75% Sinter 6
Área S (kg.°C/cm ²)	Experimental	18,6	24,7	19,1	19,7
	Rede Neural	18,7	22,4	16,2	18,8
	Erro	-0,54%	9,31%	15,18%	4,57%
$\Delta P_{\text{máx}}$ (mmH ₂ O)	Experimental	2668	3471	3041	2420
	Rede Neural	2860	2447	2884	2640
	Erro	-7,19%	29,48%	5,18%	-9,12%
R _{s200} (%)	Experimental	65,6	79,8	74,1	85,0
	Rede Neural	75,2	79,3	75,4	82,8
	Erro	-14,63%	0,56%	-1,75%	2,59%
T _d (°C)	Experimental	1370	1405	1382	1419
	Rede Neural	1373	1409	1390	1419
	Erro	-0,22%	-0,34%	-0,59%	0,03%
T _{e200} (°C)	Experimental	1356	1383	1365	1401
	Rede Neural	1361	1388	1360	1401
	Erro	-0,38%	-0,39%	0,34%	-0,02%
T _{s200} (°C)	Experimental	1155	1204	1156	1201
	Rede Neural	1166	1202	1165	1199
	Erro	-0,96%	0,19%	-0,86%	0,19%
ΔT (°C)	Experimental	201,0	178,5	173,5	200,0
	Rede Neural	200,0	166,0	186,5	187,9
	Erro	0,50%	7,02%	-7,50%	6,03%

O termo “Erro” refere-se à diferença entre o valor “Experimental” e o valor calculado pela “Rede Neural” dividido pelo valor “Experimental”. Portanto, caso o valor do “Erro” seja inferior ao limite de aceitação definido para cada um dos parâmetros do ensaio de A&F, Tabela 4, o valor calculado pela rede neural pode ser considerado como válido.

Observando-se os resultados, nota-se que para quase todos os parâmetros, os “Erros” encontram-se dentro dos limites de aceitação estabelecidos para cargas metálicas mistas. Somente o resultado do parâmetro R_{s200}, para o ensaio realizado com 65% Pelota A + 35% Sinter 4 e o resultado do parâmetro $\Delta P_{\text{máx}}$, para o ensaio

30% Pelota A + 70% Sínter 7, é que apresentaram resultados fora dos limites de aceitação pré-estabelecidos.

4 CONCLUSÃO

Modelos de rede neural foram desenvolvidos objetivando estimar os valores dos parâmetros de amolecimento e fusão de cargas metálicas mistas constituídas por sínter e pelotas típicas da Vale, a partir das composições químicas destes constituintes. Os seguintes resultados foram obtidos neste trabalho:

- de maneira geral, os parâmetros de A&F previstos pelos modelos apresentam “Erros” dentro dos limites de aceitação estabelecidos;
- os parâmetros relativos à permeabilidade da carga (Área S, ΔP_{max}) foram os que apresentaram os maiores “Erros”, apesar de que em apenas duas das condições avaliadas estiveram fora dos limites;
- uma excelente adesão foi obtida para os parâmetros de temperatura característicos do fenômeno de A&F (T_{s200} , T_{e200} , ΔT , T_d), com “Erros” muito baixos em todos os casos avaliados;
- os parâmetros de redução (R_T e R_{s200}) apresentaram também boa adesão com os valores experimentais. Em apenas uma das condições de validação o “Erro” esteve fora dos limites de aceitação.

Por meio da comparação entre os resultados obtidos experimentalmente e pelo modelo de rede neural conclui-se que, para a maioria dos parâmetros, os “Erros” encontram-se dentro dos limites de aceitação estabelecidos para cargas metálicas mistas.

Assim, os modelos de rede neural desenvolvidos podem ser aplicados na estimativa das propriedades de amolecimento e fusão de cargas metálicas que estejam dentro dos domínios de qualidade e para as duas pelotas Vale consideradas no estudo.

À medida que novos dados experimentais forem incorporados ao banco de dados, uma melhoria pode ser esperada nas estimativas feitas pelos modelos de rede neural.

REFERÊNCIAS

- 1 CASTRO, A.; PIMENTA, H. e CARNEIRO, R. - Zona coesiva do alto-forno: a CVRD se capacita para abrir esta caixa preta. In: *Revista Metalurgia & Materiais- ABM*, vol. 60, 548, setembro, 2004, p.547-549.
- 2 CASTRO, Alex André. Avaliação de propriedade em altas temperaturas de pelotas para alto-forno. 2006. 107p. *Dissertação de Mestrado. Rede Temática em Engenharia de Materiais*. Escola de Minas da Universidade Federal de Ouro Preto, Ouro Preto, 2006.
- 3 BRAGA, A. P; LUDEMIR, T. B.; CARVALHO, A. C. P. L. F.. *Redes Neurais Artificiais – Teoria e aplicações. Livros Técnicos e Científicos Editora S. A.*. Rio de Janeiro, 2000, 262 p.
- 4 NOGUEIRA, P. F.. Avaliação do forno para medidas de propriedades a altas temperaturas. *Relatório Interno Vale*. Vitória - ES. Junho 2005.