

IDENTIFICAÇÃO DAS VARIÁVEIS QUE INFLUENCIAM A PROJEÇÃO DE ESCÓRIA NO BOF POR MEIO DE ANÁLISE MULTIVARIADA DE DADOS*

Bruna Helena Malovini Loiola¹
Henrique Silva Furtado²
Johne Jesus Mol Peixoto³
Itavahn Alves da Silva³
Carlos Antônio da Silva³

Resumo

A projeção de escória do BOF (Basic Oxygen Furnace) ocorre a partir da formação da emulsão, a qual provoca expulsão de escória se o volume da mesma aumenta em demasia. Esse fenômeno gera algumas preocupações para uma aciaria, como diminuição da eficácia do refino, perdas financeiras, perda de material, riscos de acidentes e principalmente problemas ambientais. Arquivos de *Big Data* da ArcelorMittal Tubarão foram estudados para que fosse possível a identificação das causas principais das projeções a partir de estudos estatísticos de análises multivariadas, técnicas ainda pouco usuais para estudos na área de aciaria. Foram utilizados os softwares Statistica, Genes, e Rbio com novas propostas de utilização de ferramentas desta área, como a análise de componentes principais e a análise de trilha e análise de rede de correlações. Foi possível verificar, por exemplo, que o peso de briquete misto adicionado durante o sopro e o teor de silício no gusa carregado estão entre as principais causas de projeção.

Palavras-chave: Projeção, BOF; Big Data; Análise Multivariada.

IDENTIFICATION OF THE VARIABLES THAT INFLUENCE THE SLOPPING IN THE BOF USING MULTIVARIATE DATA ANALYSIS

Abstract

Slopping occurs when the emulsion inside the BOF (Basic Oxygen Furnace) increases its volume and portion of the slag is expelled. This phenomenon brings some concerns for steelmaking such as reduction of refining efficiency, material losses, health concerns and also environmental issues. Big Data files from ArcelorMittal Tubarão have been analysed in order to identify the main causes of the slopping. Statistical techniques such as multivariate analyzes, which are not very usual in the steelmaking field, have been employed for such. Statistica, Genes and Rbio softwares were used and principal components, path analysis, and correlation network were the chosen tools. It was possible to verify, for example, that the weight of mixed briquette added during the blowing and the content of silicon in the hot metal are among the causes of slopping.

Keywords: Slopping; BOF; Big Data; Multivariate Analysis.

¹ Engenheira Metalurgista e Mestranda em Engenharia de Materiais. REDEMAT (Escola de Minas – UFOP), Ouro Preto, MG, Brasil.

² Engenheiro Metalurgista, Dr. Especialista de Pesquisa e Desenvolvimento do Centro de Pesquisa da ArcelorMittal para a América do Sul. Vitória, ES, Brasil.

³ Professor PhD/DSc. Engenheiro Metalurgista. REDEMAT, DEMET (Escola de Minas – UFOP), Ouro Preto, MG, Brasil.

1 INTRODUÇÃO

Durante o processo de refino primário de gusa no BOF (*Basic Oxygen Furnace*) ocorre a formação de uma emulsão gás-metal-escória que é essencial para as reações de refino e é importante para elevada produtividade neste tipo de convertedor [1]. Este fenômeno é uma das principais preocupações durante produção de aço por oxigênio. Alguns sugerem que as projeções estão relacionadas a quantidades excessivas de gás geradas em uma escória altamente espumada [2]. A projeção está ligada com o volume da emulsão, que se aumentar além da capacidade do convertedor, leva à expulsão de grande porção da escória e metal. Assim, ela pode ser prejudicial ao meio ambiente devido à poluição que é gerada pelos gases, causando também redução de eficiência de refino e gerando um menor rendimento metálico, além de danos ao equipamento [3, 4].

De acordo com Evestedt *et al.* (2007) o fenômeno da projeção é caótico e imprevisível. A persistência desse problema em muitas empresas deu origem a estudos no intuito de se manter um volume de espuma adequado, evitando que a mesma ocorra. Assim, nas últimas décadas, ficou evidente que erradicar a projeção se tornou uma tarefa bastante desafiadora, e por isso, entender as suas causas se torna essencial [5].

Considerando a projeção, portanto, como um fenômeno complexo, Walker *et. al* (2005) documentaram algumas variáveis de influência, que incluem:

- Viscosidade da escória,
- Tensão superficial da escória,
- Densidade de escória,
- Quantidade de partículas de segunda fase dentro da escória líquida,
- Tamanho das bolhas de gás geradas no processo de descarburização,
- Altura, volume e forma do revestimento do convertedor,
- Taxa de geração de gás,
- Efeito de resfriamento ou aquecimento de adições,
- Altura da lança acima do banho,
- Taxa de sopro de oxigênio através da lança,
- Densidade da carga de sucata,
- Padrão de furos de lança,
- Desgaste do furo da lança,
- Penetração de jato de oxigênio e ângulo de dispersão,
- Química do gusa (P, Si, Ti),
- Composição da sucata (Al, Si, Ti, S, P),
- Instante de adição de fluxantes, minério e combustível,
- Velocidade de descarburização,
- Quantidade relativa de pós-combustão dentro ou perto da escória,
- Incrustações na lança,
- Pressão do gás perto da boca do convertedor,
- Introdução esporádica de materiais com química altamente variável e taxa de adição (sujeira na sucata, partículas refratárias).

É possível observar que o fenômeno de projeção é influenciado por muitos parâmetros de processo, altamente variáveis e imprevisíveis, o que torna o estudo de projeções, muitas vezes, difícil [6].

A proposta desse estudo é utilizar métodos de análises multivariadas, para efetuar uma análise de *Big Data* de tal forma a detectar as variáveis de influência nas ocorrências de projeções no convertedor número 1 da ArcelorMittal Tubarão. Para essa pesquisa são utilizadas propostas de técnicas clássicas, como as análises de trilha, análise de componentes principais (ACP), e análise de rede de correlações, técnicas estatísticas ainda pouco difundidas no assunto de aciaria.

2 DESENVOLVIMENTO

2.1 Materiais e Métodos

Informações de *Big Data* de corridas de aço do convertedor número 1 do BOF da empresa ArcelorMittal Tubarão (AMT) foram utilizadas para análise. Os dados estão contidos em uma planilha, com a identificação das corridas e as respectivas informações, dadas como variáveis. As variáveis, que são descrições de cada corrida, com indicações de data e hora de início e fim de sopro, teores de Si, P, Mn finais, se houve ou não projeção, dentre outras, formam um total de 160.

A partir dessa planilha, foi possível identificar as corridas com projeção, e assim, classificar as variáveis que mais se correlacionam com este fenômeno, a partir de análises multivariadas nos softwares *Statistica*, *Genes* e *Rbio*.

De início, foi feita uma filtragem das 160 informações, restando, por fim, 33 variáveis de interesse. Além disso, segundo estudos anteriores, a variável de interesse projeção, por ser a única não automática, muitas vezes não trazia a informação adequada; assim, foi feito um refino dos dados mais confiáveis, totalizando 6381 corridas. Foi construída, em seguida, uma matriz em planilha no Excel com as informações dos dados. Estes, assim, foram padronizados para poderem ser comparados sem interferências provocadas pela ordem de grandeza de suas informações (ex.: peso de cal adicionada durante o sopro, peso do minério, porcentagem de P no gusa) utilizando-se, para isso, a equação:

$$X_{a'} = \frac{X_a - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

Onde $X_{a'}$ é o valor padronizado, X_a é o valor do número a ser substituído, X_{\min} é o valor mínimo do conjunto de dados da variável que está sendo padronizada e X_{\max} é o respectivo valor máximo. Após a padronização aplicou-se as técnicas estatísticas de análise de componentes principais e de trilha, utilizando os softwares, respectivamente, *Statistica*, *Genes* e *Rbio*.

A ACP é uma técnica que transforma sistematicamente um conjunto original de variáveis em outro menor com variáveis que representa a maior parte das informações fundamentais do grupo original sem grande perda. Fundamentalmente, esse novo grupo, chamado de componentes principais (ou fatores) é a combinação linear das variáveis originais, e, dessa forma, a interpretação dos dados fica mais simplificada [7]. Sendo assim, a ACP foi empregada, principalmente para a identificação do número ideal de variáveis a serem analisadas, e, portanto, complementar as demais técnicas estatísticas utilizadas para este estudo.

Já sobre a análise de trilha, uma das fundamentais vantagens da sua utilização é permitir o conhecimento dos efeitos diretos e indiretos que variáveis explicativas exercem sobre uma variável principal, admitindo, assim, constituir qual estratégia será mais eficiente na seleção, para incrementar a melhora [8].

A análise da rede de correlação é uma ferramenta visual, onde é possível verificar a associação padrão entre as variáveis investigadas. Assim, as redes formadas entre uma variável e outra são representadas como nodos e as relações entre elas são representadas por linhas verdes, quando positivas, e vermelhas quando negativas [9]. Desse modo, com a aplicação dessas técnicas tornou-se possível verificar quais são as variáveis explicativas que mais afetam na ocorrência da projeção.

2.2 Resultado e discussão

2.2.1 Análise de Componentes Principais

Foram selecionadas 33 variáveis. Fez-se a ACP para obter um número próximo ao ideal, sem perdas de informação, para identificação de quantas variáveis seguiriam para análise de acordo com a técnica seguinte. Obteve-se a tabela da Figura 1.

Value	Extraction: Principal components			
	Eigenvalue	% Total variance	Cumulative Eigenvalue	Cumulative %
1	2.823844	8.557103	2.82384	8.5571
2	2.368869	7.178390	5.19271	15.7355
3	2.152129	6.521603	7.34484	22.2571
4	1.689088	5.118448	9.03393	27.3755
5	1.582423	4.795220	10.61635	32.1708
6	1.413338	4.282843	12.02969	36.4536
7	1.345221	4.076426	13.37491	40.5300
8	1.325129	4.015541	14.70004	44.5456
9	1.238476	3.752957	15.93852	48.2985
10	1.162874	3.523861	17.10139	51.8224
11	1.067909	3.236087	18.16930	55.0585
12	1.057934	3.205860	19.22723	58.2643
13	1.023972	3.102946	20.25120	61.3673
14	0.982196	2.976352	21.23340	64.3436
15	0.971077	2.942659	22.20448	67.2863
16	0.923907	2.799720	23.12839	70.0860
17	0.901184	2.730860	24.02957	72.8169
18	0.832467	2.522629	24.86204	75.3395
19	0.818427	2.480081	25.68046	77.8196
20	0.807205	2.446075	26.48767	80.2657
21	0.790022	2.394007	27.27769	82.6597
22	0.756758	2.293207	28.03445	84.9529
23	0.694897	2.105748	28.72935	87.0586
24	0.676805	2.050925	29.40615	89.1095
25	0.611078	1.851752	30.01723	90.9613
26	0.550237	1.667385	30.56747	92.6287
27	0.499788	1.514510	31.06725	94.1432
28	0.457099	1.385149	31.52435	95.5283
29	0.440003	1.333344	31.96436	96.8617
30	0.395665	1.198985	32.36002	98.0607
31	0.315588	0.956326	32.67561	99.0170
32	0.249607	0.756385	32.92522	99.7734
33	0.074783	0.226616	33.00000	100.0000

Figura 1. Tabela gerada no STATISTICA com o número de autovalores, variância total, autovalor acumulativo e porcentagem acumulativa de variância.

Assim sendo, para as 33 variáveis, o software gerou 33 componentes principais (CP), com 33 variáveis mais explicativas para cada uma; contudo, nem todas foram consideradas, pois o objetivo foi reduzir o número de variáveis. Na tabela, a primeira coluna (*eigenvalue*) representa os autovalores de cada CP, a segunda representa a variância total de cada uma, a terceira e a quarta representam os autovalores acumulados e a porcentagem acumulativa de cada CP, respectivamente. Para análises estatísticas, considera-se, geralmente, as CP's que possuam autovalor maior que 1. Logo, foram selecionadas as 13 primeiras, como destacado.

2.2.2 Análise de Trilha

Para a análise de trilha, todas as 33 variáveis foram consideradas, e logo, a partir do resultado do software *Genes*, foram selecionadas 13 variáveis, como indicado pela ACP, que mais influenciam a variável principal projeção, como demonstrado na Tabela 1.

Tabela 1. Variáveis em ordem de maior influência nas projeções

	Número da Variável	Nome
1	20	Peso de briquete misto adicionado durante o sopro
2	29	Análise do Si no gusa carregado (%)
3	15	Peso de dunito adicionado durante o sopro
4	24	Vida do convertedor (numero de corridas)
5	8	Peso de minério adicionado durante o sopro (t)
6	3	Peso de sucata de gusa moldado (t)
7	25	Peso de gusa líquido carregado (t)
8	19	Peso de sinter adicionado durante o sopro (t)
9	11	Peso de dolomita crua adicionado durante o sopro (t)
10	5	Peso sucata de aço tipo A (t)
11	21	Peso dolomita crua para proteção do refratário (t)
12	14	Peso de escória adicionado durante o sopro (t)
13	30	Análise do Mn no gusa líquido carregado (%)

2.2.3 Análise de Rede de Correlações

Como a análise de rede de correlação é basicamente visual, é possível verificar, a partir da Figura 2 que a variável projeção está mais bem conectada principalmente com as variáveis 20, 29, 15, 24 e 8 (identificadas na Tabela 1), o que confirma a análise de trilha.

Além disso, é viável constatar que a variável 24 (vida do convertedor) possui correlação negativa em relação à projeção, uma vez que a linha que faz a ligação entre ambas é vermelha.

Rede de Correlações

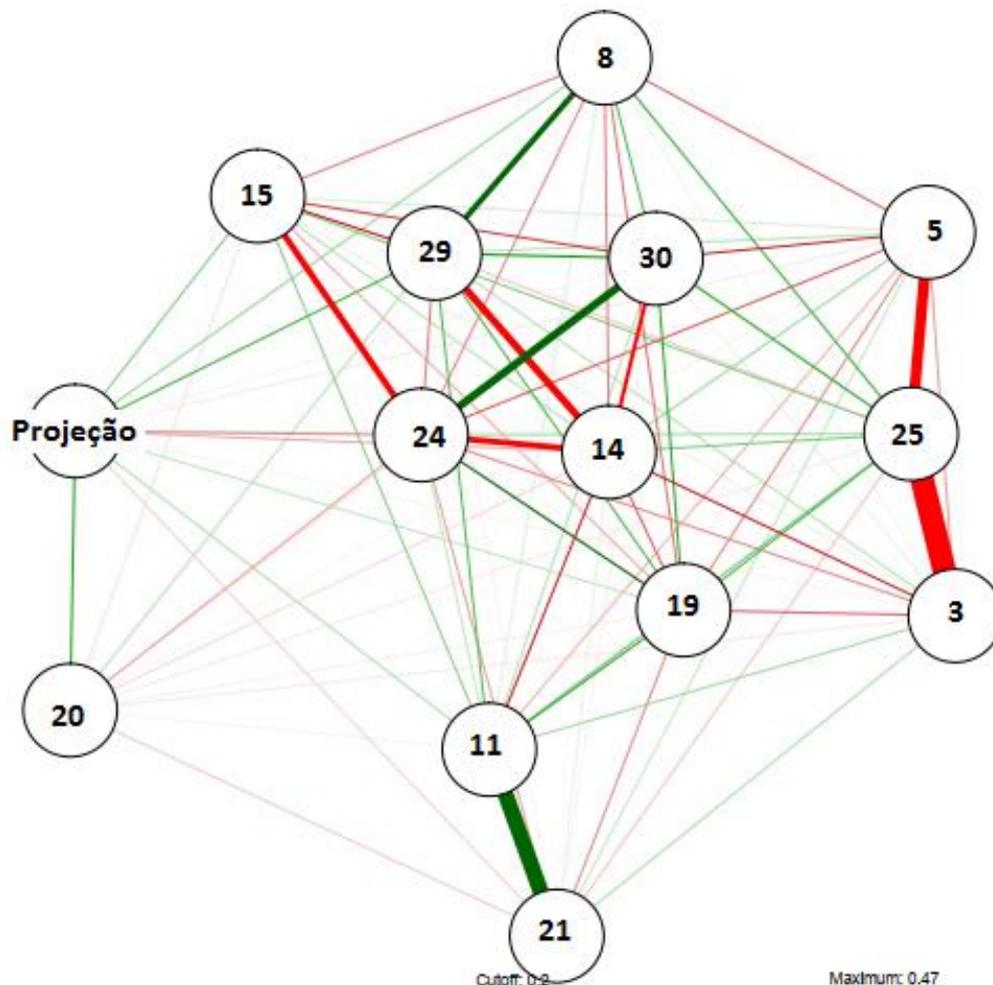


Figura 2. Rede de correlações gerada no Rbio das 13 variáveis com a variável projeção.

2.2.4 Análise das causas de projeção

A partir das análises multivariadas de dados foi possível identificar 13 variáveis que mais apresentam influência nas projeções. É possível destacar o aparecimento da variável 20 (peso de briquete misto). Percebeu-se que em todas as vezes que se adicionou esse tipo de briquete durante o sopro, houve projeção.

O efeito das adições de refrigerantes, que é o caso do briquete, do minério e do sínter, é endotérmico, o que favorece a diminuição da temperatura, e, portanto, o aumento da viscosidade da emulsão, provocando o seu crescimento, o que facilita a ocorrência de projeção.

Em relação ao silício argumenta-se que sua presença no gusa líquido está relacionada a projeção de acordo com sua quantidade. Quanto maior o percentual deste elemento, maior o volume de escória e de emulsão.

O excesso de adição de fundentes como dunito e dolomita pode contribuir para o acréscimo da viscosidade e para inibir a liberação dos gases das reações, o que também auxilia no crescimento da escória.

A vida do convertedor está diretamente ligada à quantidade de massa refratária contida em seu interior. Quanto mais novo o convertedor, menor o volume interno do

BOF, reflexo do menor desgaste do revestimento refratário. Dessa forma, quanto menor o tempo de vida de um convertedor, maiores são as chances de projeções.

Sobre as sucatas, vale a observação sobre a sua composição. Quanto maior o nível de impurezas, mais a geração de óxidos formados na escória e maior é a propensão à projeção devido ao aumento do volume da escória.

O peso de escória adicionado é um parâmetro importante a ser levado em consideração. A adição desta escória contribui para a formação da escória inicial, porém pode acarretar, em seguida, em um volume excessivo de escória, e gerar a projeção.

O manganês é um elemento de destaque na formação da escória. Contudo, seu teor elevado pode deixar a escória mais fluida do que o necessário, aumentando a emulsificação, com riscos de fortes projeções.

3 CONCLUSÃO

Por meio deste estudo foi possível identificar, a partir de análises multivariadas, as principais variáveis de influência das causas do fenômeno projeção de escória em um convertedor BOF. Essas variáveis estão de acordo com parâmetros comumente citados na literatura.

Assim, as variáveis que mais afetam a ocorrência do fenômeno projeção, em ordem de maior influência, são:

1. Peso de briquete misto adicionado durante o sopro
2. Análise do Si no gusa carregado (%)
3. Peso de dunito adicionado durante o sopro
4. Vida do convertedor (numero de corridas)
5. Peso de minério adicionado durante o sopro (t)
6. Peso de sucata de gusa moldado (t)
7. Peso de gusa líquido carregado (t)
8. Peso de sinter adicionado durante o sopro (t)
9. Peso de dolomita crua adicionado durante o sopro (t)
10. Peso sucata de aço tipo A (t)
11. Peso dolomita crua para proteção do refratário (t)
12. Peso de escória adicionado durante o sopro (t)
13. Análise do Mn no gusa líquido carregado (%)

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Os autores agradecem ao Centro de Pesquisa Global R&D ArcelorMittal e à planta de Tubarão por concederem os dados; a UFOP, a REDEMAT e a CAPES pela bolsa de mestrado e auxílio financeiro para apresentação do trabalho neste evento.

REFERÊNCIAS

- 1 Albani, C. B.; Furtado, H. S.; De Oliveira, J. R. Estudos das causas de projeção de escória no convertedor LD, ABM week, 2017. 289-298.
- 2 Jung, S. M.; Fruehan, R. J. Foaming Characteristics of BOF Slags. ISIJ International, Pittsburgo, v. 40, n. 2, p. 348–355, 2000.

- 3 Kostúr, K.; Futó, J. The Prediction of Metal Slopping in LD Converter on Base an Acoustic Signal. *Journal Metalurgija*, 30 setembro 2006. 97-101.
- 4 Birk, W. et al. Foam Level Control in a Water Model of the LD Converter Process. 10th IFAC Symposium on Automation in Mining, Mineral and Metal Processing. Tóquio: IFAC. 2001. p. 273-278.
- 5 Evestedt, M. et al. Slopping Warning System for the LD Converter Processe - An Extended Evaluation Study. Lulea University of Technology, Lulea, 2007.
- 6 Walker, D. I.; Kemeny, F. L.; Jones, J. A. T. Vessel Slopping Detection. AISTech 2005 Proceedings - Volume I. Pittsburgo: AIST. 2005. p. 711-720.
- 7 Dunteman, G. H. Principal Components Analysis. 69. ed. Califórnia: Sage, 1987.
- 8 Souza, T. V. D. Aspectos estatísticos da análise de trilha (Path Analysis) aplicada em experimentos agrícolas. Lavras: UFLA, 2013.
- 9 Zushi, K.; Matsuzoe, N. Metabolic profile of organoleptic and health-promoting qualities in two tomato cultivars subjected to salt stress and their interactions using correlation network analysis. *Scientia Horticulturae*, Miyazaki, 07 Janeiro 2015. 8-17.