

# ANÁLISE DA INFLUÊNCIA DAS CARACTERÍSTICAS GRANULOMÉTRICAS NA PERMEABILIDADE DO LEITO DE PELOTAS ATRAVÉS DO MÉTODO DAS REDES NEURAIIS ARTIFICIAIS\*

Marcelo Chagas<sup>1</sup>  
Marcelo Lucas Pereira Machado<sup>2</sup>  
João Batista Conti de Souza<sup>3</sup>  
Eduardo Frigini de Jesus<sup>4</sup>

## Resumo

A fase de secagem de pelotas de minério de ferro no processo de pelotização, é uma etapa decisiva na qualidade do produto final, bem como o conhecimento de suas características é de fundamental importância na otimização de processos. Este estudo avaliou as sensibilidades de variáveis que intervêm na fase de secagem de pelotas verdes usando o método artificial redes neurais. O modelo mostrou que principalmente desvios de diâmetro e altura de leito de pelotas afetam a permeabilidade do leito. O modelo computacional foi capaz de prever a contra pressão da câmara de secagem por meios de características geométricas das pelotas, permitindo, assim, melhorar a geração de pelotas verdes, a fim de diminuir o consumo de combustível e energia, além de buscar melhoria da qualidade final e uma melhor produtividade.

**Palavras-chave:** Pelotização; Minério de ferro; Redes neurais.

## ANALYSIS OF THE INFLUENCE OF THE GRANULOMETRIC CHARACTERISTICS OF PELLETS ON BED PERMEABILITY THROUGH THE METHOD OF ARTIFICIAL NEURAL NETWORKS

### Abstract

The drying stage of iron ore pellets in the iron ore pelletizing plants is a decisive stage in the quality of the final product as well as the knowledge of its characteristics has a fundamental importance in the process optimization. This study evaluated the variables sensitivity involved in the drying stage of green pellets using the artificial neural networks method. The model stated that diameter deviations and pellet bed height mostly affects bed permeability. The computational model was able to predict the drying chamber backpressure by means of pellets geometrical features, thus allowing improving green pellets generation, in order to ensure fuel and energy consumption reduction, final quality improvement and better productivity.

**Keywords:** Pelletizing; Iron ore; Neural network.

<sup>1</sup> Engenheiro Mecânico, mestrando em metalurgia e materiais, Instituto Federal do Espírito Santo (IFES), Vitória, ES, Brasil.

<sup>2</sup> Professor titular e coordenador, programa de mestrado em metalurgia e materiais, IFES, Vitória, ES, Brasil.

<sup>3</sup> Professor Doutor em metalurgia, IFES, Vitória, ES, Brasil.

<sup>4</sup> Mestre em engenharia elétrica, Engenheiro de Processo, Cia. Vale S/A, Vitória, ES, Brasil.

## 1 INTRODUÇÃO

### 1.1 O processo Pelotização

A aglomeração de minério de ferro surgiu com a necessidade de tornar mais eficiente o processo de produção de matérias-primas ligadas à indústria do aço, usando a parte mais fina gerada durante o processo de extração e subsequente beneficiamento do minério, transformando assim, um material rico em ferro, que, até então seria um desperdício do processo, em um produto com alto valor agregado [1]. A pelota de minério de ferro é um aglomerado de forma aproximada de uma esfera com algumas propriedades notáveis como: diâmetros distribuídos entre 9 mm e 15 mm, alto teor de ferro (em torno de 66%), características mineralógicas uniformes, alta resistência mecânica, baixa tendência à abrasão e bom comportamento durante o transporte [2]. O processo de produção de pelotas de minério de ferro compreende várias etapas como a separação de matéria-prima, moagem, classificação de acordo com o tamanho das partículas, aglomeração, processos de secagem, queima e resfriamento.

A fase de secagem na produção pelotas de minério de ferro é a primeira fase de processo de queima realizada em um forno de grelha móvel, em que um fluxo ascendente de ar quente é soprado através do leito de pelotas removendo a água presente nas pelotas verdes na forma de umidade em uma taxa controlada [3]. Controlar a velocidade de secagem é de fundamental importância, uma vez que afeta diretamente parâmetros de qualidade final das pelotas, tais como resistência à compressão e resistência à abrasão. Caso a secagem aconteça em uma taxa superior ao recomendado ocorrerão rachaduras devido ao encolhimento acelerado. A uma taxa inferior, a umidade deve permanecer durante a queima, levando também a diminuição da resistência à compressão e fenômeno como fragmentação, recondensação e oxidação [4]. O parâmetro escolhido para assegurar um fluxo uniforme e eficaz através do leito de pelotas, caracterizando um parâmetro de permeabilidade do leito é a pressão negativa antes das câmaras de secagem. A fim de assegurar a eficácia de fase de secagem e menor consumo de combustível e energia, esta pressão deve ser mantida tão baixa quanto possível.

### 1.2 A permeabilidade do Leito de Pelotas

Para fornos de grelha movel, objeto de estudo do presente trabalho, 90% do transporte de calor em processamento térmico é feito por convecção. Assim, o fluxo de gás através do leito de pelotas é de fundamental importância [2].

O fluxo de gás depende da força e permeabilidade ao gás do leito, e altamente influenciada pela consistência física das pelotas [2].

A resistência ao fluxo de um gás através de um leito estático de pelotes esféricas de tamanho uniforme é equacionado da seguinte forma [2]:

$$\Delta P_{CH} = H \cdot \psi \cdot \frac{1-\varepsilon}{\varepsilon^3} \cdot \frac{Q_G \cdot w^2}{d \cdot \varphi} \quad (1)$$

Onde:

$\Delta P_{CH}$	Resistência ao fluxo
H	Altura do leito
$\varepsilon$	Volume vazio do leito
$Q_G$	Densidade específica do gás
$\psi$	Coeficiente Aerodinâmico relacionado com o número de Reynolds

w Velocidade do gás  
d Diâmetro das pelotas

Se existe uma grande variação no diâmetro de aglomerados, a equação seguinte deve ser considerada:

$$\Delta P_{mCH} = H \cdot \psi \cdot \frac{1-\varepsilon_m}{\varepsilon_m^3} \cdot \frac{Q_G \cdot w^2}{d \cdot \varphi} \cdot \left(\frac{\varepsilon_k}{\varepsilon_m}\right)^{0,75} \quad (2)$$

Onde:

$\Delta P_{mCH}$  Resistência ao fluxo  
H Altura do leito  
 $\varepsilon_m$  Volume vazio do leito considerando as pelotas maiores  
 $\varepsilon_k$  Volume vazio considerando partes mais finas  
 $Q_G$  Densidade específica do gás  
 $\psi$  Coeficiente Aerodinâmico relacionado com o número de Reynolds  
w Velocidade do gás  
d Diâmetro médio das pelotas

Deve ser ainda adicionada a resistência das barras do forno:

$$\Delta P_{GR} = \zeta \cdot \frac{Q_G \cdot w^2}{2} \quad (3)$$

Onde:

$\Delta P_{GR}$  Resistência ao fluxo gasoso  
 $Q_G$  Gas densidade específica  
 $\zeta$  Coeficiente de resistência  
w Velocidade do gás

Assim, resultando na resistência total.

$$\Delta P = \Delta P_{GR} + \Delta P_{CH} \quad (4)$$

Onde:

$\Delta P_{GR}$  resistência ao fluxo de gás através das barras de forno  
 $\Delta P_{CH}$  resistência ao fluxo de gás através do leito pelotas

A variação da pressão é substancialmente elevada como uma grande variação em diâmetros pelotas, e varia linearmente com o aumento da altura de carga. A queda de pressão também é responsável pelo funcionamento dos ventiladores que levam o ar aquecido para as várias fases do processo de queima.

Pelotas com diâmetros distribuídos numa faixa estreita, com forma esférica e uma boa resistência mecânica e baixa geração de partículas finas, produz um leito na etapa de secagem com permeabilidade elevada, reduzindo assim os custos de produção, melhoria da produtividade e aumentando a qualidade do produto final [5].

Por conseguinte, é evidente que a resistência encontrada pelo fluxo de ar de leito de pelotas pode ser entendida como uma medição do fator de qualidade das pelotas cruas produzidas e uma oportunidade para a redução do consumo de energia e para o processo global, bem como um ponto que oferece a melhoria da qualidade do produto final.

### 1.3 O Método das Redes Neurais Artificiais (RNA)

A rede neural artificial é um modelo matemático desenvolvido para análise de dados de mapeamento de entradas e saídas com aplicações em parâmetros de predição, variáveis de mapeamento e classificação de padrões. Para este fim, está disposta

uma sequência de neurônios artificiais que com o auxílio do algoritmo de treinamento mapeia grandes sequências de dados. A Figura 1 mostra esquematicamente uma arquitetura de rede neural [6].

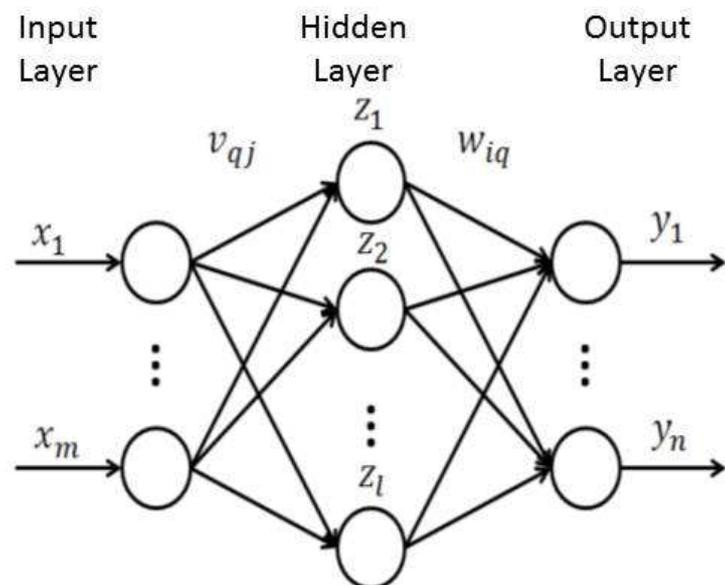


Figura 1. RNA com arquitetura alimentada adiante [5]

A complexidade do equipamento, a grande quantidade de fatores inter-relacionados no processo e a dificuldade de desenvolver experiências em condições fabris, levam-nos ao modelamento matemático, que tem grande aplicação na metalurgia [7].

O método de redes neurais artificiais tem mostrado grande confiabilidade e respostas rápidas em diversas áreas, provando ser uma escolha apropriada quando se necessita uma análise geral de predição que incluiu uma grande série de variáveis [8]. As redes neurais têm a capacidade de capturar relações não lineares e altamente complexas entre entradas e saídas do processo. São computacionalmente eficientes e não requer conhecimento prévio do processo a ser modelado [8].

## 2 MATERIAIS E MÉTODOS

Uma sequência de 1.000 dados industriais do processo de pelotização foi usado para criar uma rede neural artificial (RNA) com a arquitetura *Perceptron* multicamadas (MLP), tipo alimentada adiante, com uma camada composta de variáveis de entrada de processo contendo sete neurônios.

Neste trabalho foi analisada a importância das características granulométricas das pelotas cruas durante a fase de secagem no interior do forno de grelha móvel, por meio da análise de variáveis de entrada, tais como o diâmetro médio das pelotas verdes, desvio padrão, esfericidade e faixas de distribuição de diâmetro. O parâmetro de produção de pelotas está relacionado com a altura do leito. A correlação de variáveis de entrada, com a pressão na fase de secagem no interior do forno grelha móvel foi feita.

A Tabela 1 mostra os valores médios do fluxo de dados do processo, bem como o desvio padrão para cada.

**Tabela1.** Variáveis de entrada

Variáveis	Média	Desvio Padrão
Diâmetro médio	11,74	0,705040051
Desvio padrão do diâmetro	2,29	0,146561353
Produção de Pelotas Crua	683,34	53,52324852
Porcentagem com diâmetro entre 10 e 16 mm	74,96	4,97736091
Porcentagem com diâmetro abaixo de 10 mm	16,45	2,499374767
Porcentagem com diâmetro acima de 16 mm	3,96	1,131992654
Esfericidade	78,02	4,616887991

Fatores geométricos das pelotas como diâmetro médio, esfericidade e desvio padrão de diâmetro são indicados para desempenhar um papel decisivo na permeabilidade do leito.

Como visto na equação (2), a permeabilidade do leito tem uma relação direta com a altura do leito, que por sua vez está ligado à produção de pelotas. A média dos diâmetros e desvio padrão destes estão também relacionados na equação (2). As faixas de distribuição, abaixo de 10 mm e acima de 16 mm estão ligados ao último termo da eq. (2) que inclui a porosidade considerando pelotas em um diâmetro regular e porosidade considerando partes mais finas.

A equação (2) considera pelotas em forma esférica. O modelo matemático proposto inclui o desvio de forma das pelotas usando a variável de esfericidade.

A rede neural é depois seguida por uma camada implícita com 15 neurónios definidas pela expressão de Kolmogorov:

$$N = 2n + 1 \quad (5)$$

Onde:

N número de neurónios na camada implícita.

n Número de entradas

A camada de saída é composta por um único neurónio relacionado a contra pressão na pressão da câmara de secagem, que nos leva à permeabilidade do leito.

Foram utilizados: o algoritmo de treinamento BFGS, a função de aprendizagem de gradiente descendente e a função do desempenho SOS.

A função de transferência usado dentro de neurónios foi a tangente hiperbólica para a camada implícita e saída como descrito na equação. (6)

$$f_k = \frac{1 - e^{-2s_k}}{1 + e^{-2s_k}} \quad (6)$$

A análise de sensibilidade foi realizada para inferir sobre a importância relativa de cada variável. A contribuição de cada uma é estimada considerando a relação entre o erro quadrático médio dos resultados de RNA na condição original, com o erro quadrático médio em uma condição onde uma das variáveis é considerado indisponível. Esta relação indica a deterioração no desempenho de RNA para cada variável [9], demonstrando assim a sua contribuição para o resultado global. Para uma melhor ilustração dos resultados de sensibilidade são normalizados, mostrando a contribuição percentual de resultado global.

A rede neural artificial modelada para esta aplicação se resume na Figura 2

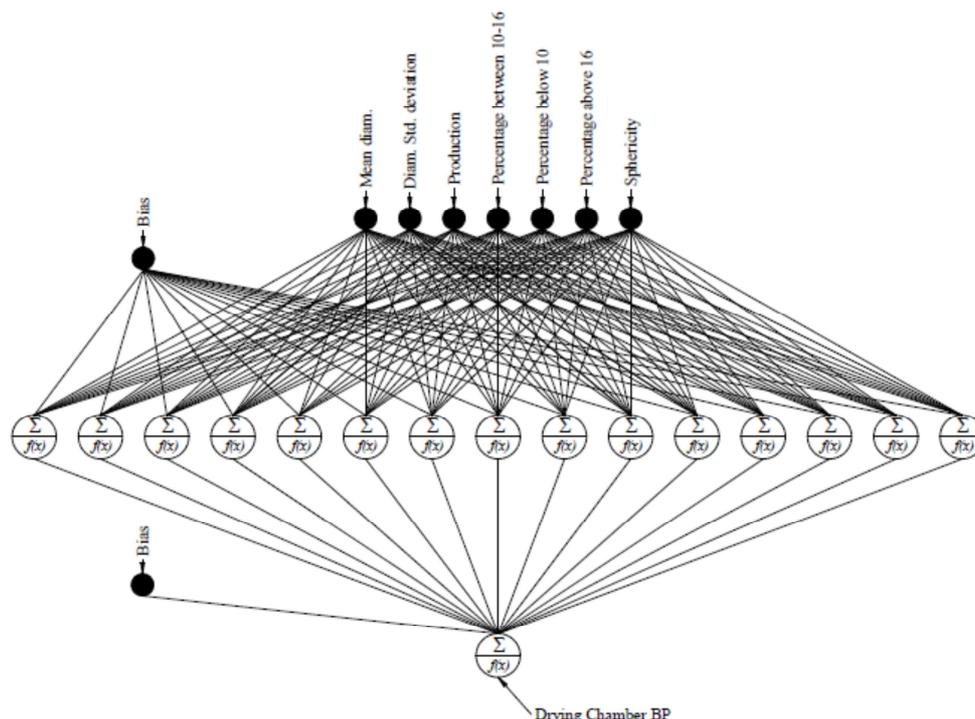


Figura 2. Rede Neural Artificial, 7-15-1

### 3 RESULTADOS E DISCUSSÃO

Após a validação da rede neural artificial com dados industriais, houve uma convergência, como mostrado na tabela 2 com o modelo matemático.

Tabela2. Índices de correlação R<sup>2</sup>

Variável	Treino	Teste	Validação
Contra pressão	0,904738	0,884284	0,852932

Regressão entre valores alvo do banco de dados e resultados preditos pela Rede Neural Artificial são plotados na figura 3.

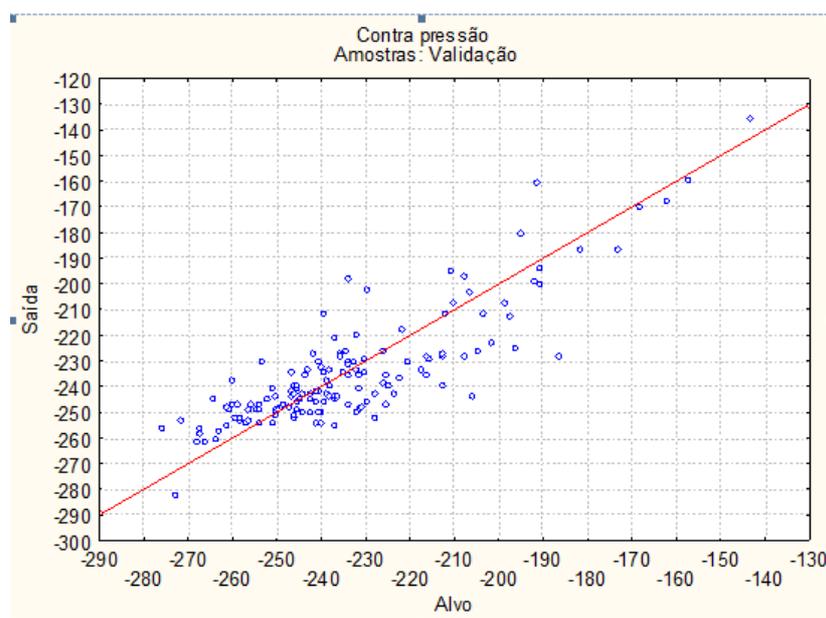
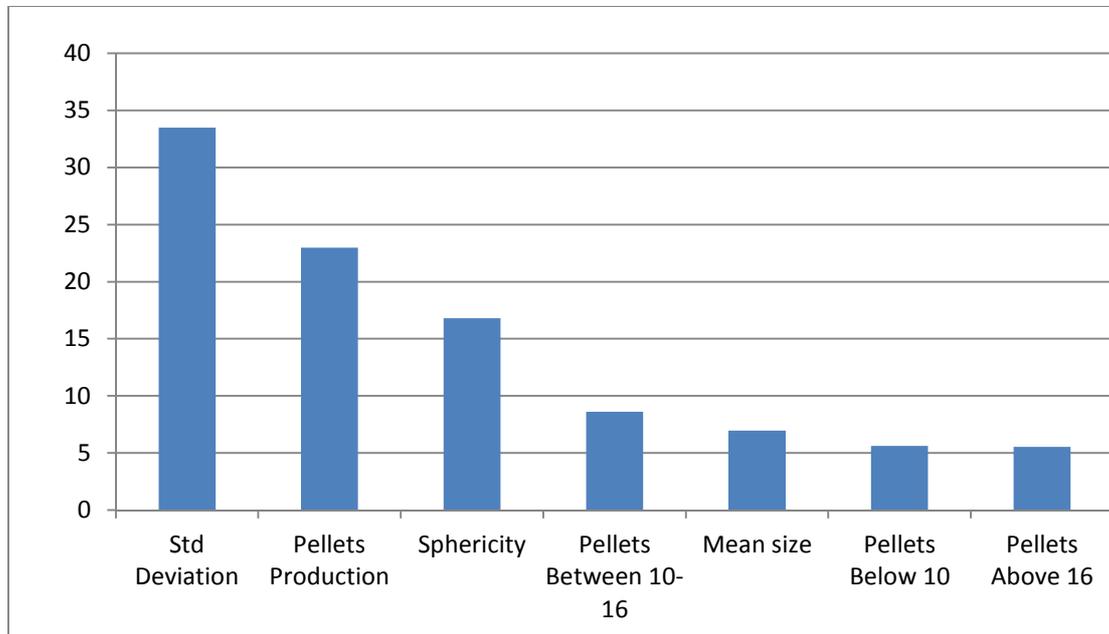


Figura 3. Regressão para amostras de validação

A análise de sensibilidade das variáveis foi realizada apresentando índices na figura 4. Observou-se que as variáveis de maior influência sobre a pressão da câmara de secagem e, conseqüentemente, na permeabilidade de leito de pelotas foi o desvio padrão do diâmetro, seguido pela produção de pelotas cruas e esfericidade das pelotas.



**Figura 4.** Índices de sensibilidade normalizados

O desvio padrão do diâmetro das pelotas tem um papel principal na permeabilidade do leito, uma vez que pelotas menores ocupam sítios intersticiais entre pelotas maiores decrescendo a porosidade do leito. Desta forma uma distribuição de diâmetro mais ampla bloqueia o fluxo de ar através do leito, causando uma deficiência de secagem no lado oposto. Um melhor controle da distribuição de diâmetro somente pode ser executado durante a etapa de pelletização, mostrando a importância dos parâmetros de controle durante esta fase.

De acordo com a teoria apresentada, a altura do leito tem uma proporção direta sobre a permeabilidade do leito, porém, controlar este fator a fim de reduzir a contra pressão afeta o rendimento levando a uma redução da produtividade, neste caso, apesar da grande influência no resultado final, a altura do leito não deve ser o parâmetro a ser controlado.

Esfericidade também afeta a permeabilidade, uma vez que a forma da pelota é decisiva para a formação e empacotamento do leito. A baixa esfericidade aponta uma baixa resistência à compressão das pelotas verdes. Tal característica é causada por características da matéria prima e o excesso de água na polpa. Pelotas de baixa resistência à compressão tende a deformar-se facilmente em contato com outras pelotas e / ou em contato com o forno de grelha móvel, formando um único bloco de pelotas, bloqueando o fluxo de ar através do leito. Uma alta esfericidade permite uma maior porosidade do leito, permitindo deste modo, inclusive, que o ar flua facilmente provocando uma pressão mais baixa na câmara de secagem.

Diâmetro médio, pelotas acima de 16 milímetros e abaixo 10 milímetros mostraram pouca influência no resultado final, provando que a distribuição de diâmetro e forma tem uma influência maior sobre a permeabilidade do leito. Pelotas distribuídas em um diâmetro estreito com forma esférica leva a uma melhor formação do leito.

Tanto a distribuição de diâmetro das pelotas quanto a esfericidade são medidas por captura de vídeo e posterior processamento de imagem, após as pelotas deixarem o disco granulador e caírem em uma correia transportadora.

O modelo de predição para contrapressão na câmara de secagem tem seus resultados plotados na figura 5, apresentando uma boa correlação considerando as condições em que os dados de fábrica foram obtidos.

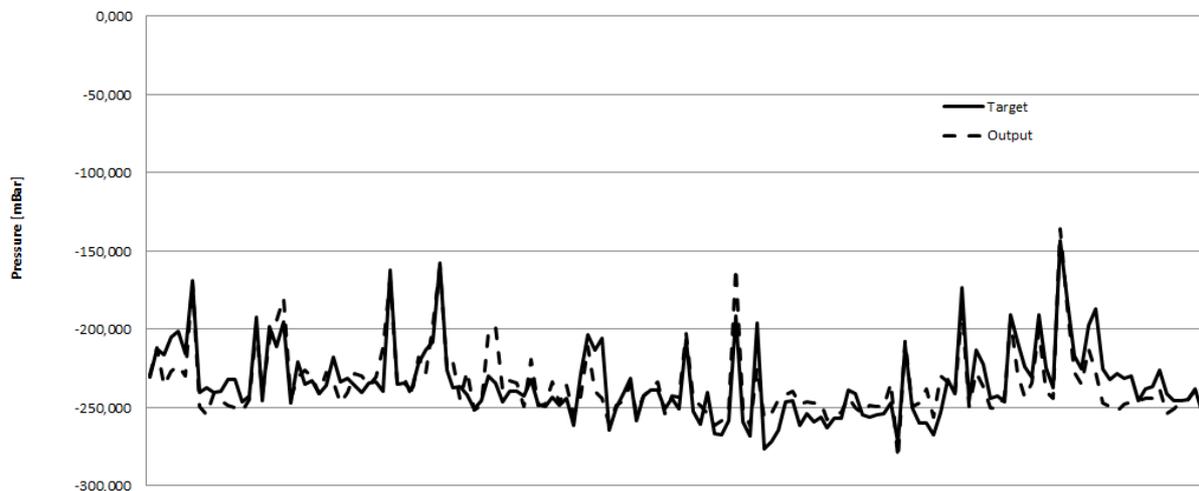


Figura 5. Predição dos valores de contra pressão.

#### 4 CONCLUSÃO

O modelo apontou variáveis que afetam significativamente a permeabilidade do leito no estágio de secagem da produção de pelotas de minério de ferro. Desvio padrão do diâmetro, produção de pelotas e esfericidade das pelotas foram identificados como as principais variáveis de entrada que afetam significativamente a permeabilidade do leito durante a secagem e, conseqüentemente, a qualidade do produto final.

O método das redes neurais artificiais mostrou-se uma opção adequada para a modelagem matemática de um processo complexo, que envolve uma série de variáveis em ambiente de produção real. O modelo computacional foi capaz de prever otimizações na preparação, produção e controle de qualidade no processo de produção de pelotas, apesar de todos os fatores inter-relacionados de uma planta de produção.

Um maior desvio padrão do diâmetro afeta a contra pressão dentro da câmara de secagem, onde as partículas menores ocupam sítios intersticiais entre pelotas maiores.

Esfericidade mostrou um aspecto semelhante à distribuição de diâmetro, mas uma direção oposta. Esfericidade mais elevada tende a uma contra pressão mais baixa na câmara de secagem.

Outro aspecto a considerar é uma seleção mais crítica das pelotas após processo de aglomeração.

#### Agradecimentos

Este trabalho conta com o apoio do CNPq e VALE S/A.

## REFERÊNCIAS

- 1 THELLA, J. S.; VENUGOPAL, R. Modeling of iron ore pelletization using 3 \*\* (k-p) factorial design of experiments and polynomial surface regression methodology. Powder Technology, v.211, p. 54–59, 2011.
- 2 MEYER, K. Pelletizing of Iron Ores, Springer-Verlag Berlin, Heidelberg, and Verlag Stahleisen mbH, Dusseldorf, 1980.
- 3 Majunder, S.et. al,; Virtual Indurator: A tool for simulation of induration of wet iron ore pellets on a moving grate. Computers and Chemical Engineering 33 (2009) 1141 - 1152.
- 4 Ljung, A.L. et al,; Convective drying of an individual iron ore pellet – Analysis with CFD. International Journal of heat and mass transfer, 54 (2011)
- 5 MATOS, A. P. Influência da Temperatura, Pressão, Produção e Granulometria no Processo de Secagem das Pelotas Cruas. Dissertação de mestrado, 2007.
- 6 HAYKIN, S. Redes Neurais: Princípio e Prática. São Paulo: Bookman, 2007.
- 7 TIMOFEEVA, A. S. et al. Optimizing the granulometric composition of pellets obtained on a disc pelletizer. Metallurgist, v. 57, n. 5–6, 2013.
- 8 DWARAPUDI, S.; GUPTA, P.K.; RAO, S.M. Prediction of Iron Ore Pellet Strength Using Artificial Neural Network Model. ISIJ International, v. 47, n. 1, p. 67–72, 2007.
- 9 STATSOFT. Sensitivity analysis (in Neural Network). Available at: <http://www.statsoft.com/textbook/statistics-glossary/s#Sensitivity Analysis>. Accessed: Sept. 13, 2014.