

PREVISÃO DE RESISTÊNCIA À COMPRESSÃO DE PELOTAS DE MINÉRIO DE FERRO USANDO REDE NEURAL ARTIFICIAL *

Alan Santos¹
Flávio Augusto Ribeiro Sabará²
Letícia Pereira Teixeira³
Rafael Motta Neiva⁴
Ramon Bonela Andrade⁵

Resumo

Um modelo de rede neural artificial de duas camadas *feed-forward* foi usado para prever a resistência à compressão (CCS) das pelotas, de acordo com os dados de produção da usina de Pelotização da Vallourec Soluções Tubulares do Brasil S.A. de Jeceaba. O algoritmo de otimização utilizado para o treinamento de rede foi o de Levenberg-Marquardt, obtendo resultados satisfatórios para o peso das variáveis inseridas como entradas, onde suas respostas se apresentavam dentro do desvio padrão obtidos na planta, com a vantagem de apresentar os valores em tempo real.

Palavras-chave: Resistência à compressão; Pelota; Rede Neural Artificial.

PREDICTION OF THE COLD CRUSHING STRENGTH OF IRON ORE PELLETS USING AN ARTIFICIAL NEURAL NETWORK

Abstract

A two-layered feedforward neural network model was developed in order to predict the cold crushing strength (CCS) of iron ore pellets, according to the laboratory results of the pellets produced in the Pelletizing Plant of Vallourec Soluções Tubulares do Brasil S.A. in Jeceaba. The optimization algorithm used to train the network was Levenberg-Marquardt, which showed satisfactory results for the variable weights inserted as inputs, with outputs between the standard deviations of the plant data, and giving the advantage of presenting real-time results of the produced iron ore pellets.

Keywords: Cold Crushing Strength; Iron Ore Pellets; Artificial Neural Network.

¹ Engenharia de Energia, Engenheiro de Energia, estagiário, Engenharia de Processos/ Pelotização, Vallourec Soluções Tubulares do Brasil, Jeceaba, Minas Gerais, Brasil.

² Engenharia de Controle e Automação, Engenheiro de Controle e Automação, Coordenador de Operação/ Pelotização, Vallourec Soluções Tubulares do Brasil, Jeceaba, Minas Gerais, Brasil.

³ Engenharia de Controle e Automação, Engenheira de Controle e Automação, Auxiliar Técnico em Melhoria e Projetos/ Pelotização, Vallourec Soluções Tubulares do Brasil, Jeceaba, Minas Gerais, Brasil.

⁴ Engenharia Química, Engenheiro Químico, Gerente de Pelotização/ Pelotização Vallourec Soluções Tubulares do Brasil, Jeceaba, Minas Gerais, Brasil.

⁵ Engenharia Química, graduando, estagiário, Engenharia de Processos/ Pelotização, Vallourec Soluções Tubulares do Brasil, Jeceaba, Minas Gerais, Brasil.

1 INTRODUÇÃO

A pelletização do minério de ferro é uma técnica de moldagem e aglomeração de *pellet feed* de minério em pó. Nesse processo, as frações ultrafinas em proporções abaixo de 0,15mm, encontradas na natureza ou geradas pelo beneficiamento de minério, são transformadas em esferas de tamanhos na faixa de 8 a 16 mm, com características distintas ao minério puro devido à adição de fundentes no processo (1).

Estas esferas, denominadas pelotas, são utilizadas por altos-fornos para a produção do ferro-gusa, onde ocorre a fusão e redução do ferro, sendo posteriormente refinado para obtenção de ferro forjado ou aço em aciarias (2).

Sendo este fluxo de produção contínuo, onde o resultado do aço depende das qualidades do elemento primário, faz-se necessário observar algumas propriedades do processo da pelletização. A resistência à compressão é um parâmetro fundamental nessa avaliação, pois pelotas com resistência à compressão muito baixa podem não suportar o peso da carga na camada do alto-forno e, pelotas com resistência à compressão muito alta representam um alto custo de produção, uma vez que consomem um valor excessivo de energia e reduzem o lucro (3).

Este presente trabalho foi desenvolvido ao analisar as necessidades da Planta de Pelotização da Vallourec Soluções Tubulares do Brasil em Jeceaba, Minas Gerais, e tem por objetivo encontrar as condições operacionais ideais para que se atinja a resistência à compressão ideal com o menor custo possível.

1.1 Processo de Pelotização

O processo de beneficiamento do minério é dividido em duas áreas denominadas de Área Fria e Área Quente.

A Área Fria consiste na preparação do minério para a formação de pelotas e nela o *pellet feed* e aditivos recebidos são depositados no pátio de matérias primas. Estes materiais são então transportados para silos onde são pré-dosados e direcionados à moagem para serem moídos e posteriormente diluídos em água. Após serem esse processo, são levados para tanques de homogeneização, filtrados e dosados com novos aditivos.

Já a Área Quente consiste no tratamento térmico das pelotas verdes e nela, esse material advindo da área fria é armazenado em silos onde passará pelos discos de pelletamento a fim de formar aglomerados de forma esférica, denominados pelotas verde. Para a queima de pelota verde da planta em questão é utilizado o sistema Grate-Kiln-Cooler conforme apresentado na Figura 1.




Figura 1. Estrutura Grate-Kiln-Cooler.

Nessa estrutura, os discos formam a pelota esférica que é transportada por correias que alimentam o Forno Grelha. Neste forno, têm-se aremoção da água superficial na etapa de secagem. Na etapa da Pré-Queima I ocorre a remoção da água retida na estrutura cristalina do minério e início da calcinação dos constituintes da mistura, que continua na Pré-Queima II iniciando também a oxidação do ferro. Após todas estas fases no Grelha, as pelotas são encaminhadas à zona de queima realizada pelo Forno Rotativo, onde são submetidas a elevadas temperaturas que consolidam a oxidação do ferro e formam uma pelota com maior resistência à compressão. Na planta em questão, estas elevadas temperaturas são adquiridas através da combustão do gás natural e carvão vegetal e, após esta queima, as pelotas são levadas à zona de resfriamento no Resfriador Circular para que a temperatura final não danifique as correias transportadoras. Após serem resfriadas, as pelotas queimadas passam então por uma peneira onde são classificadas ao remover o material fino que foi gerado para se obter o produto final dentro das especificações.

1.2 Teste de Compressão

O teste de resistência à compressão é realizado pelo laboratório físico a cada 2 horas, aproximadamente. Inicialmente são recolhidas amostras de pelota em uma correia no final do processo (4).

Para o ensaio são selecionadas 60 pelotas que em seguida são posicionadas em um alimentador vibratório conforme figura 2 e transportadas individualmente ao local de ensaio, onde o equipamento realiza um processo de compressão até a ruptura da pelota.



Figura 2. Imagem do alimentador vibratório e prensa (4).

Cada uma das pelotas analisadas passa por uma prensa robotizada para a aplicação da carga com velocidade constante, onde também é possível se medir o tamanho da esfera, tendo em vista que o servo motor possui um controle de posição (4).

O resultado do teste é dado pela média geral dos valores medidos de cada uma das 60 pelotas e pelo desvio padrão destes resultados. Esses valores são então inseridos e disponibilizados no banco de dados PIMS (*Plant Information Management System*).

A figura 3 mostra os resultados médios de compressão e os valores de desvio padrão obtidos durante um mês de operação.




Figura 3. Variabilidade do Teste de Compressão.

1.3 Rede Neural Artificial

A Rede Neural Artificial (RNA) surgiu como uma técnica computacional baseada na estrutura biológica de processamento de informação que adquire conhecimento por meio de experimentação e aprendizagem, apresentando então um processamento evolutivo e inteligente de adaptação. Essas características dão a ela uma potencialidade em resolver problemas complexos que ajustam a relação entre entradas e saídas com alta eficiência (5).

Suas unidades de processamento são conectadas por canais de comunicações e associadas a um ganho ou peso, onde esses canais interagem entre si para obter o resultado objetivado. O mais interessante de utilizar esse meio é a sua habilidade em aprender e se adaptar ao ambiente que é colocada, melhorando seu desempenho (5).

Para a criação da RNA é necessário selecionar um algoritmo que calcula valores de saída em detrimento dos de entrada, onde, na visão computacional, é necessário estimar um modelo onde os parâmetros se ajustem da melhor forma aos dados experimentais. O algoritmo de Levenberg-Marquardt (LMA), também conhecido por método de mínimos quadrados amortecidos é usado para resolver problemas não-lineares, ou comumente conhecido como problemas genéricos de ajuste de curva (6). No entanto, o LMA encontra um mínimo local, que não é necessariamente o mínimo global, o que justifica o fato de um treinamento de rede apresentar um desempenho diferente de outro. A LMA interpola entre o algoritmo de Gauss-Newton (GNA) e o método de gradiente descendente, tornando-o mais robusto que o GNA, onde, em muitos casos, é possível encontrar uma solução mesmo começando muito longe do mínimo final (5).

2 DESENVOLVIMENTO

2.1 MATERIAIS E MÉTODOS

Inicialmente foi realizado um estudo das variáveis que afetavam a propriedade da compressão e posteriormente utilizou-se uma rede neural artificial para definir os ganhos das variáveis de entrada e prever a compressão das pelotas em tempo real, uma vez que os testes eram feitos a cada 2 horas pelo laboratório físico, em testes que duravam cerca de 1:30h para serem realizados.

A ferramenta PIMS (*Plant Information Management System*) foi aplicada para obter os dados históricos de comportamento das variáveis definidas como chave para a compressão. Por meio desse histórico desenvolveu-se uma planilha eletrônica para o treinamento da rede neural, e os tempos das entradas foram definidos conforme o *tracking* da pelota conforme mostrado na Tabela 1.

Tabela 1. Cronograma do Processo com base no horário do teste de resistência à compressão

Dados	Tracking	Horário Amostra
Bentonita	2 horas antes	00:00
Umidade	1:40 horas antes	00:20
Teste De Queda	1:40 horas antes	00:20
Alimentação Grelha	1:30 horas antes	00:30
Vel. Grelha	1:30 horas antes	00:30
EXAU209A	1:30 horas antes	00:30
EXAU209B	1:30 horas antes	00:30
EXAU214	1:15 horas antes	00:45
TE0915	1:15 horas antes	00:45
TE0916	1:15 horas antes	00:45
TE1004B	1:15 horas antes	00:45
PT1002	1:15 horas antes	00:45
Vel. Rotativo	1 hora antes	01:00
TT1002	40 minutos antes	01:20
TT1003	40 minutos antes	01:20
PT1001	40 minutos antes	01:20
PT1105	40 minutos antes	01:20
TE1101	40 minutos antes	01:20
PT1106	30 minutos antes	01:30
PT1107	20 minutos antes	01:40
TE1103	20 minutos antes	01:40
CAO	Horário Teste	02:00
SIO2	Horário Teste	02:00
MGO	Horário Teste	02:00
WT1202	Horário Teste	02:00

Utilizando as variáveis pré-tratadas, estruturadas e filtradas de acordo com os comportamentos de produção considerados ideais ou comuns, 432 grupos de dados foram selecionados para o modelo de implementação de Rede Neural Artificial (RNA) dos quais 80% do grupo foi usado para o treinamento e 20% para a validação e mais 363 dados foram usados para teste da rede montada.

2.2 Estrutura e Treinamento da Rede Neural

Duas redes com camadas *feed-forward* camada oculta (*hidden*) sigmoidal contendo neurônios ocultos e uma saída linear (*output1*) foram desenvolvidas. Ambas as redes, no primeiro bloco, apresentavam as 25 entradas (*inputs*) discutidas acima, resultando no último boco de saída (*output2*). Para definir os parâmetros e separar duas faixas de compressão realizou-se uma análise estatística observando as características de uma curva normal.

O treinamento foi realizado utilizando o algoritmo de Levenberg-Marquardt, e selecionados grupos de dados aleatórios. Os dados de treinamento são apresentados a rede durante o treinamento para que ela se ajuste de acordo com os erros no resultado, uma vez que o treinamento é supervisionado.

Respeitando o gráfico da figura 4, a primeira RNA continha valores de compressão inferiores a 340 daN e a segunda com valores superiores à essa faixa. Os resultados obtidos com o treinamento estão mostrados nas figuras 4 e 5 abaixo.




Figura 4. Regressão e Histograma da RNA para valores menores que 340daN.




Figura 5. Regressão e Histograma da RNA para valores maiores que 340daN.

Os histogramas de erros demonstram que aproximadamente todos os resultados obtiveram erro absoluto variando entre -25 a 19 daN do valor desejado. Isso se mostra satisfatório porque além de estar dentro do desvio padrão apresentado pelo laboratório permite a aplicabilidade em tempo real do modelo.

2.3 RESULTADOS E DISCUSSÃO

Com a rede pronta para a implementação, uma planilha eletrônica auxiliada por *Visual Basic for Applications (VBA)* foi novamente elaborada para facilitar a compressão dos dados em forma de gráficos. A fase de testes foi iniciada observando inicialmente se a rede retornava resultados compatíveis com os de laboratório e posteriormente colocada na sala de controle para auxiliar os operadores nos parâmetros que influenciam na compressão.

Com base nas análises dos resultados retornados por ambas as redes criadas e os obtidos para a compressão do laboratório, percebeu-se que as redes apresentavam valores próximos aos dados reais quando combinadas.

A figura 6 mostra a RNA em teste, já implementada, comparando os resultados do teste de laboratório com as amostras encontradas, bem como o erro entre elas. É possível ver que o erro também permaneceu dentro do desvio padrão da rede.




Figura6. Resultados da RNA na fase de teste.

A fase de controle então foi iniciada e, com os resultados finais, poderão ser padronizadas ações do operador para ajustar a compressão da pelota na faixa desejada.

3 CONCLUSÃO

Operações instáveis que apresentam distúrbios em variáveis da base de entrada e dificultam a definição de pesos das mesmas e conseqüentemente a qualidade do produto final justificam o uso da rede neural, onde a quantidade de neurônios utilizadas na estrutura da rede evidencia a complexidade na previsão dos resultados. No artigo apresentado por Feng J.eQiao Y., ambos da Universidade de Ciência e Tecnologia de Beijing, na China (7), que propuseram uma rede neural semelhante à apresentada neste artigo, o resultado do coeficiente de regressão foi de $R = 0,906$, enquanto a RNA apresentada neste artigo alcançou um R superior a 0,93. Por isso pode-se dizer que os resultados obtidos com modelo criado foram extremamente satisfatórios. Isso permitiu também classificar a qualidade da pelota em tempo hábil

e interagir diretamente com o laboratório de análise, onde os testes de compressão são realizados.

REFERÊNCIAS

- 1 Meyer K. Pelletizing of Iron Ores. Berlin: Springer-Verlag, 1980.
- 2 Sampaio JA, Luz AB, Lins FF. Usinas de Beneficiamento de Minérios do Brasil. Rio de Janeiro: CETEM/MCT, 2001.
- 3 Biswas AK. Principles of Blast Furnace Ironmaking. Austrália: Cootha Publishing House, 1981.
- 4 ControlVix Controle e Automação. Prensa Eletrônica de Bancada. [acesso em 03 de maio de 2018]. Disponível em: <http://www.controlvix.com.br/pages/Prensa-Eletr%C3%B4nica-de-Bancada.html>
- 5 Moré JJ, Sorensen DC. Computing a Trust-Region Step. SIAM J. Sci. and Stat. Comput. 1983; 4(3): 553-572.
- 6 Gill PE, Murray W. Algorithms for the solution of the nonlinear least-squares problem. SIAM J. Numer. Anal. 1978; 15(5): 977-992.
- 7 Junxiao F, Yang Q. The Quality Prediction of Iron Ore Pellets in Grate-Kiln-Cooler System Using Artificial Neural Network. ICNC 2010. 4: 1906-1909..