

UTILIZAÇÃO DE REDES NEURAIS PARA PREVER TEOR DE HIDROGÊNIO EM AÇOS*

Raquel de Souza Correa¹
Daniel A. G. de Carvalho²
Bruno S. Cerchiar³
Joyce C. Ribeiro⁴
Euglacyo L. Moura⁵

Resumo

Ter um controle do teor de hidrogênio contido nos aços é vital para o funcionamento da aciaria, já que esse elemento pode provocar acidentes e prejudicar as propriedades mecânicas do aço. Por isso, a previsão do teor de hidrogênio é de grande interesse na indústria por meio de modelamentos matemáticos. Devido às complexas relações entre teor de hidrogênio e adição de materiais feitas durante diferentes fases no sopro do BOF, que causam incorporação de hidrogênio no banho, a utilização de redes neurais artificiais (RNA) se mostrou uma ferramenta computacional mais eficaz para conseguir fazer essa previsão do que o modelamento por regressão múltipla, pois possui habilidade de relacionar variáveis não lineares entre si e devido à sua capacidade de aprendizado.

Palavras-chave: Redes neurais artificiais; Hidrogênio; Previsão; Refino secundário.

ARTIFICIAL NEURAL NETWORKS TO PREDICT HYDROGEN 'S CONTENT IN STEELS

Abstract

The control of the hydrogen's content contained in steels is vital for the operation of the steel plant, because this element can be responsible for accidents and negatively affect the mechanical properties of the steel. Therefore, prediction of the hydrogen content through mathematical modeling is of great interest of the industry. Due to the complex relationships between hydrogen content and addition of materials made in the BOF during different phases that can cause hydrogen incorporation in the bath, the use of artificial neural networks (ANN) has proved to be a more efficient computational tool to attain this prediction than multiple linear regression models because it has the ability to relate non-linear variables and due to their learning capacity.

Keywords: Artificial neural networks; Hydrogen; Prediction; Secondary Steelmaking .

¹ Aluna de Graduação do Curso de Engenharia Metalúrgica da UFMG, Belo Horizonte, MG, Brasil

² Engenheiro Metalurgista, Consultor de Processos da Aciaria, Ternium BR, Rio de Janeiro, RJ, Brasil.

³ Engenheiro Metalurgista, Ternium BR, Rio de Janeiro, RJ, Brasil

⁴ Engenheiro Metalurgista, Ternium BR, Rio de Janeiro, RJ, Brasil

⁵ Engenheiro de Produção, Ternium BR, Rio de Janeiro, RJ, Brasil

1 INTRODUÇÃO

O hidrogênio é elemento residual presente no aço que, dependendo do seu teor, pode gerar grandes problemas, como: bolhas, trincas, fragilização, entre outros (Woodtli et al, [1]). Em casos mais extremos, em grandes quantidades pode gerar acidentes no lingotamento contínuo tais como rompimento do veio (breakout) (Kajitani et al.[2]). Por isso, é de extrema importância ter controle sobre o teor desse elemento no aço.

O refino secundário da Ternium Brasil é composto por dois LTS (*Ladle Treatment Station*), um AHF e por dois desgaseificadores RH. O AHF (*Aluminum Heating Facility*) é utilizado para ajuste de composição química e de temperatura, no qual se adiciona Al e se injeta O₂ sem a presença de escória em um ambiente inerte dentro do sino. Por apresentar um alto rendimento, também são adicionados ferro-ligas na região sem escória. Esse equipamento não realiza a desgaseificação diferentemente do RH, por isso é importante que o aço designado para a rota AHF tenha teor de hidrogênio dentro dos padrões para que ele possa ser lingotado com segurança, por isso utiliza-se sensores específicos para fazer a medição de hidrogênio.

Segundo Rodrigues B.(2010)[3], as adições feitas no BOF desde o seu carregamento até o vazamento influenciam no teor de hidrogênio final no aço. Ferro-ligas como: FeMn alto carbono, FeSi 75%, FeSiMn possuem alta afinidade com o oxigênio e por isso provocam um aumento da incorporação do hidrogênio no aço ao reagir com a umidade atmosférica. Outros materiais como a cal tem facilidade em se tornar hidratados sob condições atmosféricas e a água contida no hidróxido de cálcio (Ca(OH)₂) é liberada quando este se decompõe, e se dissocia em H e O, o que também contribui para o aumento do teor de hidrogênio.

Além da quantidade e do material que é adicionado (Figura 1), outro parâmetro que influencia o perfil de incorporação de hidrogênio é o momento em que o material é adicionado no banho metálico. Os materiais adicionados no carregamento do BOF não influenciam tanto no teor final de hidrogênio devido à intensa agitação do banho provocado pelo sopro de oxigênio, que induz a um abaixamento da pressão parcial de hidrogênio no reator devido ao fluxo de CO, o que garante a reação de desidrogenação dentro no convertedor. Em contrapartida, as adições feitas no final no banho, após o período de descarburização máxima, e as adições feitas no vazamento contribuem significativamente para o aumento do teor de hidrogênio, pois a carga metálica não passa por mais estágios em que a agitação é mais intensa.

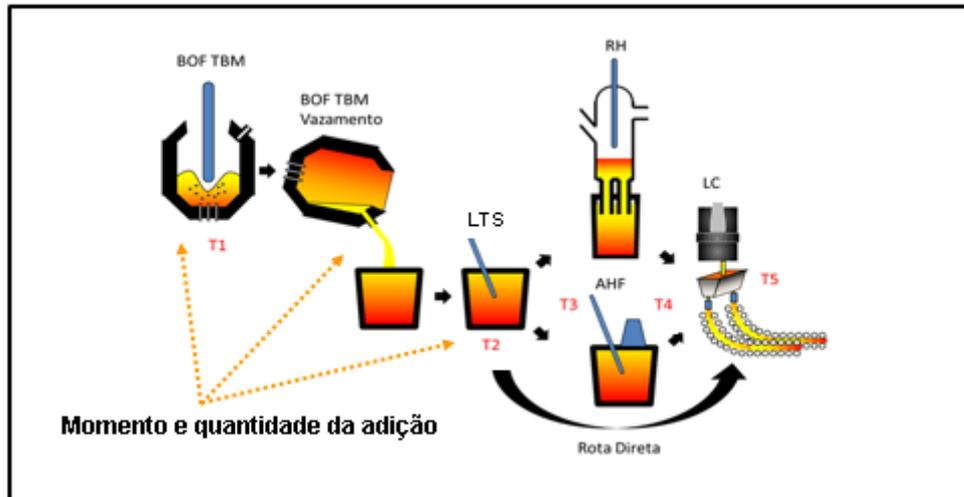


Figura 1. Momentos nos quais as adições de materiais influenciam no teor de hidrogênio no aço na aciaria[4].

Neste trabalho o objetivo foi criar um modelo matemático para prever o teor de hidrogênio no aço porém, devido ao alto grau de complexidade, foi criada uma rede neural para realizar essa previsão. A rede neural artificial é um sistema capaz de mimetizar o comportamento do cérebro humano sendo capaz de interagir com o meio externo e se adaptar à ele por meio de algoritmos de aprendizagem, possui a capacidade de receber inúmeros dados de entrada e fazer uma complexa malha de interconexão para obter um dado de saída. Esse recurso computacional tem tido diversos avanços nos últimos anos e são aplicados em sistemas de manutenção, controle de operações como também são utilizados para modelagem voltada para a indústria siderúrgica (Viana et al.[4],Pican et al.[5]).

2 DESENVOLVIMENTO

2.1 Materiais e Métodos

Para a determinação do teor de hidrogênio nos aços, por muitos anos, a indústria siderúrgica pesquisou diversos métodos práticos para se obter uma medição precisa. Atualmente existem sensores capazes de fazer uma medição rápida e direta através de imersão do sensor no banho metálico, abaixo da camada de escória. No AHF o sensor é imerso manualmente.

O mecanismo de funcionamento do sensor baseia-se na pressão parcial do hidrogênio na fase gasosa e na fase líquida através de um detector de condutividade térmica. A pressão parcial de hidrogênio é convertida a teor de hidrogênio por meio da lei de Sieverts (Equação 1):

$$[H] = \frac{K_H}{f_H} \sqrt{P_{H_2}} \quad (1)$$

Na qual:

[H]- Concentração de hidrogênio (em ppm)

K_H - Constante de equilíbrio

f_H - Coeficiente de atividade do hidrogênio

P_{H_2} - Pressão parcial de hidrogênio no aço (em mbar)

Inicialmente é soprado nitrogênio pelo tubo de borbulhamento do sensor no aço líquido, que depois é coletado pelo sino poroso, que permite somente a passagem de gás. Essa primeira etapa é feita para fazer a limpeza do sistema, posteriormente esse nitrogênio é recirculado no sistema e o hidrogênio presente no aço é difundido nas bolhas de nitrogênio gasoso que é novamente coletado pelo sino gasoso, que novamente é recirculado no sistema para se obter equilíbrio da pressão parcial de hidrogênio entre a mistura de gases e o aço líquido. Essa medição é rápida (entre 40 a 60 segundos) e uma curva de desidrogenação é construída pelo sistema.

Para avaliação dos teores contidos nos aços tratados via rota AHF foram coletados dados de medições de hidrogênio de todas as corridas do ano de 2018. Como a medição feita no AHF é pelo sensor Hydris, ela é feita de forma manual a cada vez que uma panela chega no equipamento. É importante considerar as inúmeras variáveis que possam interferir na precisão das medições levando em consideração a escala de produção industrial. Além dos valores de hidrogênio também foram coletados dados das adições feitas nas corridas e em qual momento essas adições foram feitas e de qual tipo e família o aço pertence.

A partir dos dados coletados, inicialmente foram feitas diversas tentativas de criar um modelo por meio de regressão múltipla através do *software* Minitab versão 17. Porém os dados não possuem relações lineares entre si, e as regressões não conseguiram relacionar muito bem o momento da adição com o valor de hidrogênio. Diante dessa dificuldade de estabelecer análise múltiplas de variáveis que possuem relações não lineares, optou-se por criar uma rede neural artificial.

Devido a uma grande variedade de parâmetros de entrada e suas respectivas relações com o teor de hidrogênio, foi criada uma rede neural artificial por meio do *software* Statistica versão 13.1. Existem diversos estudos (Azadeh et al.[6]; Chiang et al.[7], Indro et al.[8]) que observaram que a utilização de redes neurais para dados não lineares se mostrou mais eficaz do que regressão múltipla devido à sua capacidade de aprendizado. Diversas unidades de processamento denominadas neurônios (Figura 2) constituem a rede neural, no qual um peso é atribuído ao sinal de entrada, que pode ser descrito matematicamente como (Equação 2):

$$a=F(w*p + b) \quad (2)$$

No qual,
w-peso sináptico;
p-entrada de sinal;
b-bias (um termo linear que provê um grau de liberdade);
F-função do neurônio que soma as entradas;
a-sinal de saída.

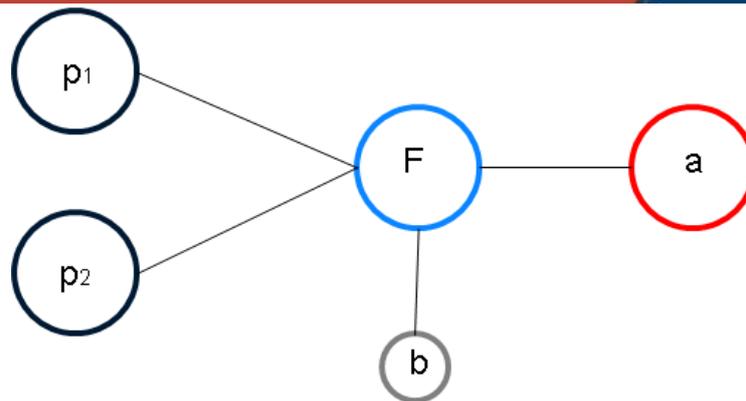


Figura 2. Figura esquemática de um neurônio

Porém, redes neurais compostas somente por uma camada de neurônios não são capazes de solucionar problemas que não são linearmente separáveis. Mas é possível montar uma rede que combina neurônios em camadas (Figura 3) denominada por Perceptron Multi-Camadas (MLP), que é capaz de desenvolver relações mais profundas e complexas entre os parâmetros de entrada e utiliza o algoritmo de *backpropagation* para realizar seu treinamento, que utiliza o erro na camada de saída para recalculá-lo e o peso do parâmetro de entrada.

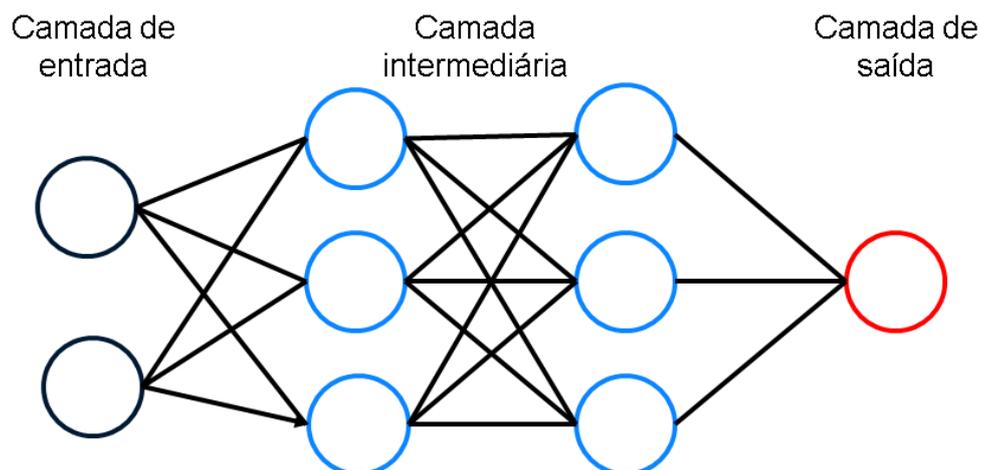


Figura 3. Figura esquemática de uma rede MLP

2.2 Resultados

Foram feitas diversas tentativas de regressão linear múltipla com base nas adições feitas (Modelo 01), de acordo com a faixa de manganês presente no aço (Modelo 02) e de acordo com o modelo de vazamento (Modelo 03). Foram criadas diversas curvas de valores de hidrogênio previstos pelo modelo em função dos valores reais. Para todos os modelos criados os gráficos obtidos mostraram que houve pouca aderência dos valores do modelo em relação aos dados reais, como pode ser observado na figura 4.

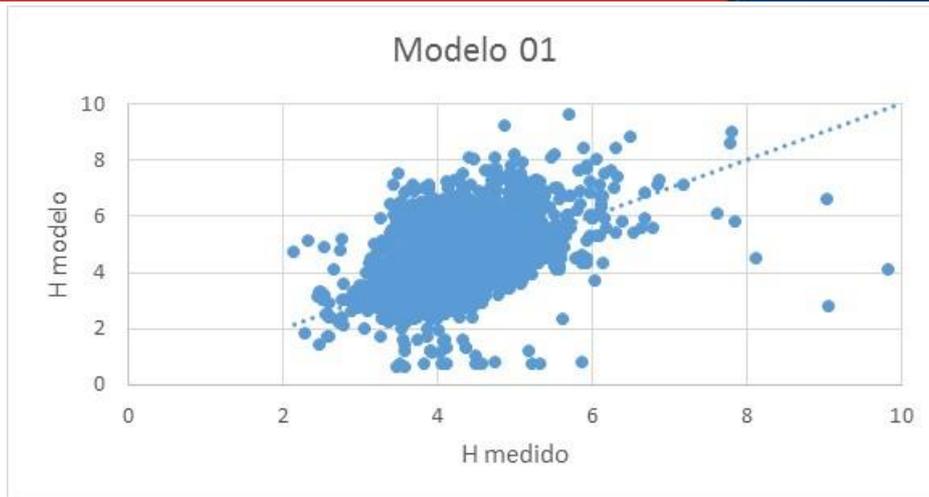


Figura 4. Teor de H do modelo versus H medido do modelo baseado nas adições de materiais

Os valores de R^2 obtidos para cada modelo são apresentados na tabela 1.

Tabela 1. Valores de R^2 para cada modelo de regressão linear múltipla

Modelo	R^2
01	0,3256
02	0,3798
03	0,2376

A rede neural criada pelo Statistica versão 13.1 foi gerada com base nas medições de hidrogênio feitas com o Hydris de todas as corridas via rota AHF de 2018 e suas respectivas adições. Ao todo foram utilizados os dados de 4106 corridas, dos quais 15% foram utilizados para teste da rede, 15% para validação e 70% para treinamento.

A partir desses dados foi criada uma rede MLP, com os resultados e parâmetros apresentados na tabela 2.

Tabela 2. Valores obtidos da rede neural

Resultados e parâmetros da rede neural	
<i>Training performance</i>	0,7105
<i>Test performance</i>	0,6304
<i>Validation performance</i>	0,6958
<i>Training algorithm</i>	BFGS 67
<i>Error function</i>	SOS
<i>Hidden activation</i>	Tanh

Valores referentes à rede neural MLP 71-21-1.

A partir dos valores obtidos na rede neural e dos valores reais de hidrogênio, foi plotada uma curva (Figura 5) valor de hidrogênio obtido pela RNA (*output*) versus teor de hidrogênio real (medido).

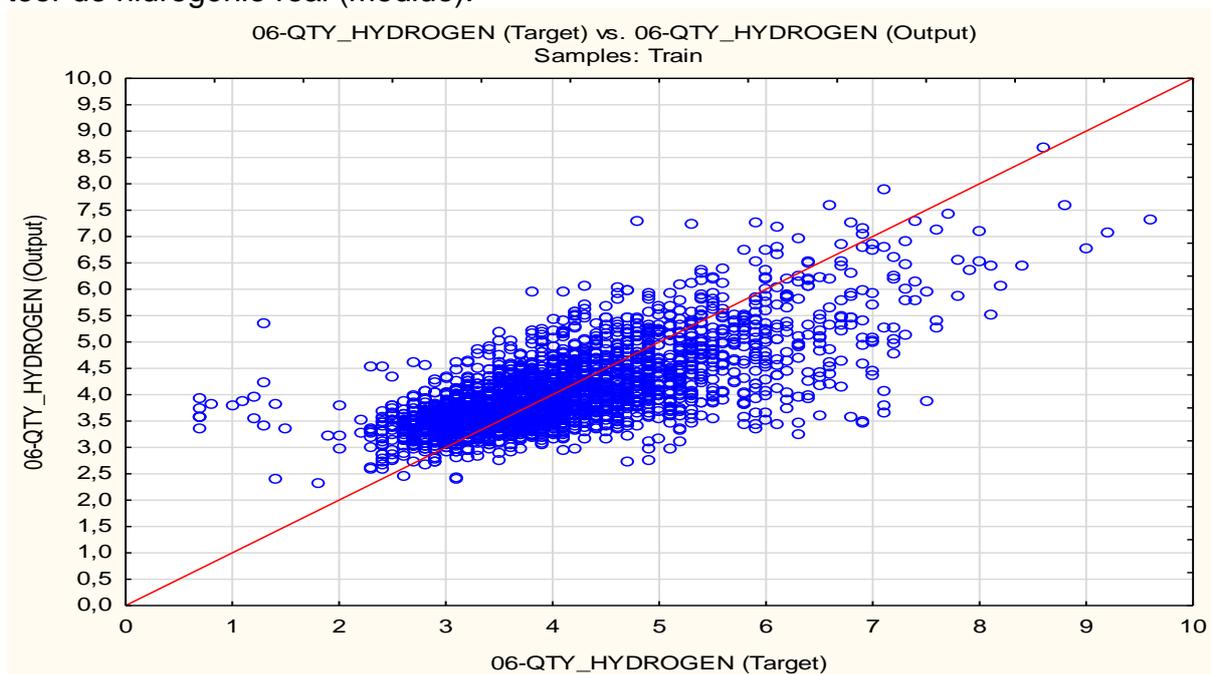


Figura 5. Curva valores de teores de hidrogênio obtidos pela RNA versus os valores medidos

A partir desses mesmos valores e da diferença entre eles, foi criado um histograma para avaliar como foi a distribuição do erro entre eles (Figura 6).

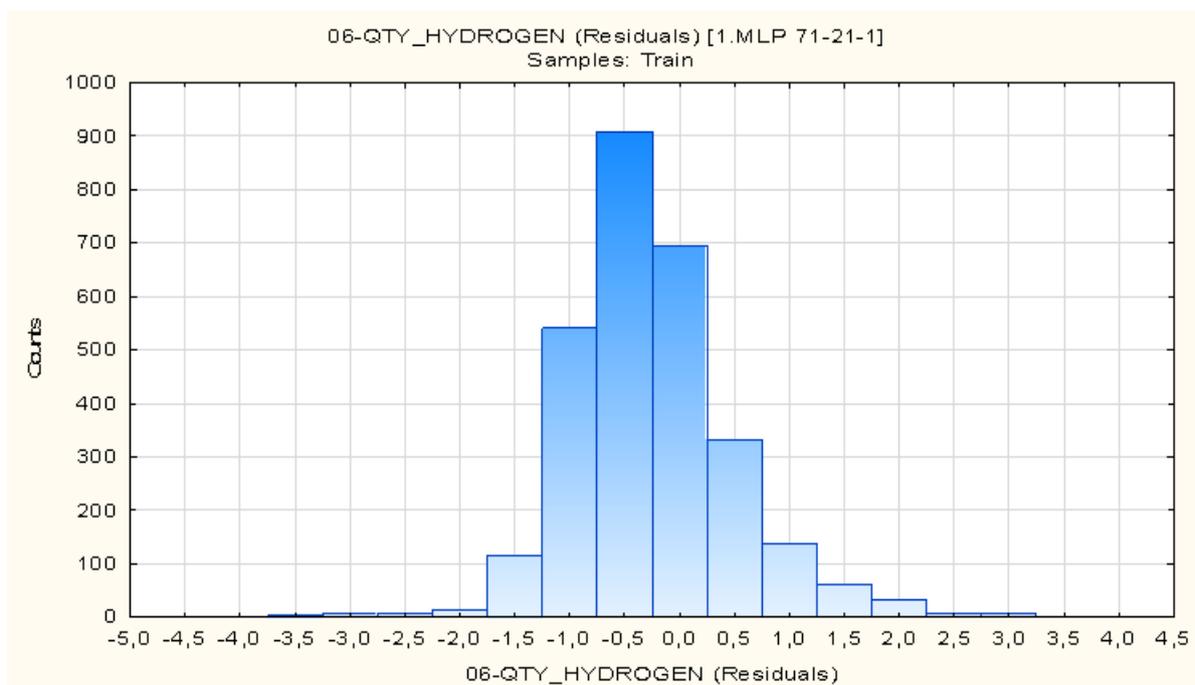


Figura 6. Gráfico de resíduos

A partir desses dados também foi possível determinar quais fatores que mais influenciam no valor final de hidrogênio (Tabela 3).

Tabela 3. Fatores que influenciam no hidrogênio final contido no aço

Fatores	Peso
Quantidades e materiais adicionados no vazamento	2,9774
Família do aço	1,6960
Mês em que ocorreu a corrida	1,4044
Momento em que é feita a adição dos materiais no vazamento	1,3514
Adição de pelota no BOF após sub-lança	1,1683
Adição de briquete no BOF após sub-lança	1,0756

Valores referentes à rede neural MLP 71-21-1.

2.3 Discussão

Os modelos criados por regressão linear múltipla não se mostraram adequados para prever o valor final de hidrogênio no aço, já que os valores de R^2 obtidos (Tabela 1) foram baixos, o que indica que o ajuste linear não foi adequado pois, valores de R^2 próximo de 1 indicam um bom ajuste dos dados obtidos pelo modelo com os teores reais medidos com o sensor. Os gráficos de teores de H previstos pelo modelo versus teores de H medidos mostram que os valores obtidos na regressão são muito diferentes do medido(como por exemplo, o gráfico da Figura 4), o que confirma que a regressão linear múltipla não foi eficaz para criar um modelo de previsão de hidrogênio, já que a relação entre as adições feitas e o teor final de hidrogênio não são relações lineares.

Já os resultados obtidos com a rede neural se mostraram mais satisfatórios em comparação com o de regressão linear múltipla. Os coeficientes de correlação de teste, treino e validação contidos na tabela 2 denominados por *test performance*, *training performance* e *validation performance* respectivamente, foram superiores ao coeficiente de correlação da regressão linear. O valor do coeficiente de *test performance* é o que determina a capacidade real da rede neural, valores acima de 0,7 indica que a rede é boa e entre 0,5 e 0,7 são valores intermediários. O valor do *test performance* da rede neural MLP 71-21-1 foi de 0,6304 , o de *training performance* foi de 0,7105 e o de *validation performance* foi de 0,6958 a partir desses valores observa-se que a rede criada ainda pode ser melhorada para por meio de mais treinamento, já que as redes neurais possuem capacidade de aprendizagem. Na figura 5 pode-se observar que os valores obtidos pela rede são próximos dos valores reais, ficando mais dispersos para maiores valores de hidrogênio. Observou-se que o erro segue uma distribuição normal e que a maior parte está contida em -1 e 0,5 ppm (Figura 6).

A Tabela 3 relaciona qual fator que influencia mais no teor de hidrogênio, quanto maior o peso maior a influência desse fator no teor final de hidrogênio. No vazamento do BOF geralmente são adicionados materiais que têm facilidade em

incorporar hidrogênio no banho, por isso o que mais influencia no teor final de hidrogênio é qual material é adicionado. O momento do vazamento em que essas adições são feitas também influenciam já que o material pode ter uma camada protetora de gás quente devido à alta temperatura do aço, que impede o contato desses materiais com o ar atmosférico com umidade. A família do aço também é de grande importância, já que ela define se há mais adições de liga ou não, tanto no BOF quanto no vazamento da panela. Para conseguir relacionar a umidade do ar com o teor de hidrogênio optou-se por considerar em qual mês é feita a corrida, já que o material é armazenado no silo e não é imediatamente consumido podendo ficar estocado no silo por dias ou semanas dependendo no material ficando exposto à umidade atmosférica ou à chuvas retendo umidade no material, pode-se observar que em corridas de meses mais chuvosos o teor de hidrogênio era um pouco maior.

3 CONCLUSÃO

Com base nos resultados gerados ao longo do projeto, foi possível concluir que:

1. Modelos criados por regressão linear múltipla não se mostraram eficazes para prever valor final de hidrogênio contido no aço com base nas adições feitas;
2. Redes neurais artificiais para prever teores de hidrogênio podem ser utilizadas para prever a quantidade de hidrogênio das corridas com base nas adições feitas;
3. A utilização de redes neurais MLP se mostrou uma ótima alternativa para modelamento matemático com grande número de dados de entrada;
4. Todos os fatores que mais influenciam no teor de hidrogênio são esperados de acordo com a teoria.

A implementação da rede para prever teor de hidrogênio em aços na Ternium Brasil ainda está sendo estudada.

Agradecimentos

Os autores agradecem à Ternium BR que permitiu desenvolver esse projeto que disponibilizou todos os equipamentos, pessoal e dados necessários. Em especial aos engenheiros: Daniel A. G de Carvalho, Bruno S. Cerchiarri, Joyce C. Ribeiro, Euglacyo L. Moura e toda a equipe da aciaria. Aos gerentes Leonardo Demuner e Evanildo Bernabe, ao coordenador Heber Segundo. À equipe da automação: Romulo Arruda e Herbert Filho. E aos operadores do BOF e do AHF, que permitiram a realização desse projeto.

REFERÊNCIAS

- 1 Woodtli, J., & Kieselbach, R.. Damage due to hydrogen embrittlement and stress corrosion cracking. *Engineering Failure Analysis*. 2000; 7(6), 427–450.
- 2 Kajitani T., Kato Y., Harada K., Saito K., Harashima K. & Yamada W.. Mechanism of a hydrogen-induced sticker breakout in continuous casting of steel: influence of hydroxyl ions in mould flux on heat transfer and lubrication in the continuous casting mould. *ISIJ International*. 2008; 48(9), pp. 1215–1224.

- 3 Rodrigues B., Estudo da Incorporação de Hidrogênio no Aço Líquido, Ouro Preto-Universidade Federal de Ouro Preto, 2010, (Dissertação, Mestrado em Engenharia de Materiais).
- 4 Viana Júnior, Marcos Antônio, Silva, Carlos Antônio, & Silva, Itavahn Alves. Hybrid model associating thermodynamic calculations and artificial neural network in order to predict molten steel temperature evolution from blowing end of a BOF for secondary metallurgy. *REM - International Engineering Journal*,. 2018; 71(4), 587-592
- 5 Pican, N., Alexandre, F., & Bresson, P.. Artificial neural networks for the presetting of a steel temper mill. *IEEE Expert*.1996; 11(1), 22–27.
- 6 Azadeh, A., Ghaderi, S. F., Tarverdian, S., & Saberi, M.. Integration of artificial neural networks and genetic algorithm to predict electrical energy consumption. *Applied Mathematics and Computation*.2007; 186(2): 1731–1741.
- 7 Chiang, W.-C., Urban, T. L., & Baldrige, G. W.. A neural network approach to mutual fund net asset value forecasting. *Omega*.1996, 24(2): 205–215.
- 8 Indro, D. C., Jiang, C. X., Patuwo, B. E., & Zhang, G. P.. Predicting mutual fund performance using artificial neural networks. *Omega*.1999; 27(3): 373–380.