

DESENVOLVIMENTO DE MODELO DE PREVISIBILIDADE DA QUALIDADE DO COQUE INDUSTRIAL UTILIZANDO REDES NEURAS ARTIFICIAIS¹

Lorena da Costa Nascimento²
Henriquison Magela Bottrel Reis³
Marcello Barros Sabadini⁴
Bruno Alves Resende⁵

Resumo

Uma alternativa adotada pelas siderúrgicas, visando diminuir o custo de produção de gusa, é a injeção de carvão pelas ventaneiras de altos-fornos. Essa prática, por reduzir o *coke-rate*, requer um coque de melhor qualidade e com consistência em suas propriedades. Com o intuito de prever a qualidade de coque que atenda às especificações dos altos-fornos foi desenvolvido um modelo, utilizando Redes Neurais Artificiais (RNAs), baseado nas características dos carvões das misturas e nos parâmetros do processo de coqueificação. As correlações entre os valores de DI_{15-150} (índice de resistência à frio do coque), CRI (índice de reatividade do coque) e CSR (índice de resistência do coque após reação com dióxido de carbono) medidos e calculados pelo novo modelo foram melhores do que as obtidas com os modelos de regressão linear múltipla, atualmente utilizados. Baseado neste modelo foi desenvolvido e disponibilizado um programa em linguagem *Visual Basic*[®] para a predição *off line* dos parâmetros de qualidade do coque.

Palavras-chave: Qualidade de coque; Redes neurais artificiais; Parâmetros do processo de coqueria.

DEVELOPMENT OF A PREDICTABILITY MODEL OF INDUSTRIAL COKE QUALITY USING ARTIFICIAL NEURAL NETWORK

Abstract

To reduce the production costs of hot metal the ironmaking plants have adopted the alternative of coal injection through the blast furnace's tuyeres. As this method reduces the coke-rate, it requires a coke with better quality and consistent properties. In order to predict the coke quality that meets the blast furnace's specifications, a model using Artificial Neural Network was developed. It takes into account the characteristics of the coal used in the mixtures and the cokemaking process parameters. The correlations between measured and calculated values of DI_{15-150} (Drum Index), CRI (Coke Reactivity Index) and CSR (Coke Strength After Reaction With Carbon Dioxide) were better than those obtained with multiple linear regression models that are currently adopted. Based on the new model, a program using *Visual Basic*[®] language was developed and to make off-line predictions of the coke quality parameters.

Key-words: Coke quality; Artificial neural network; parameters of the coke oven.

¹ Contribuição técnica ao 39º Seminário de Redução de Minério de Ferro e Matérias-primas e 10º Seminário Brasileiro de Minério de Ferro, 22 a 26 de novembro de 2009, Ouro Preto, MG.

² Engenheira Química, M.Sc., Superintendência de Pesquisa e Desenvolvimento da USIMINAS; Ipatinga, MG.

³ Membro da ABM, Engenheiro Metalúrgico, M.Sc., Superintendência de Pesquisa e Desenvolvimento da USIMINAS; Ipatinga, MG.

⁴ Engenheiro Metalúrgico, Superintendência de Redução da USIMINAS; Ipatinga, MG.

⁵ Engenheiro Mecânico, M.Sc., Superintendência de Pesquisa e Desenvolvimento da USIMINAS; Ipatinga, MG.

1 INTRODUÇÃO

O coque metalúrgico, que desempenha importantes funções no processo de fabricação do ferro gusa, é responsável por, aproximadamente, 30% do custo de produção do aço. Buscando a diminuição do dispêndio desta produção, tem sido adotada, pelas indústrias siderúrgicas, a prática de injeção de combustíveis auxiliares pelas ventaneiras visando a redução do *coke-rate*.

Com a redução da quantidade de coque carregado pelo topo ocorre uma diminuição na espessura da sua camada na carga e na zona coesiva do alto-forno, aumentando o tempo de residência do coque e, por conseguinte, submetendo-o, por períodos mais longos, às solicitações mecânicas, térmicas e químicas que aumentam a sua degradação.⁽¹⁾ A fim de avaliar a magnitude desse aumento do tempo de residência em função da taxa de injeção tem-se, de acordo com a literatura, que variações de 100 kg/t de gusa para 200 kg/t de gusa naquela taxa elevam o tempo de residência do coque no alto-forno em mais de 30%.⁽²⁾ Nessas condições, para que o coque atenda o seu papel físico como suporte permeável para a carga, são necessárias algumas melhorias na sua qualidade (química, física e estrutural).

Os parâmetros de qualidade do coque utilizados atualmente na maioria das indústrias siderúrgicas nacionais como indicadores do seu desempenho no alto-forno são os índices DI_{15-150} (*Drum Index* – índice de resistência à frio do coque), CRI (*coke reactivity index* – índice de reatividade do coque) e CSR (*coke strength after reaction with carbon dioxide* – resistência do coque após reação com dióxido de carbono). Procurando atender às especificações do alto-forno para esses parâmetros e às exigências operacionais das coquearias, a maioria das siderúrgicas desenvolveu modelos de previsão da qualidade do coque, de forma a orientar a formulação de misturas e a aquisição de carvões.

Atualmente, a Usiminas utiliza um modelo de regressão linear múltipla baseado nas características individuais dos carvões componentes da mistura. Com o intuito de aumentar o índice de acerto entre a qualidade prevista e a obtida nas coquearias foi desenvolvido, neste trabalho, um novo modelo, com a técnica de Redes Neurais Artificiais (RNAs), que utilizam, além dos parâmetros já contemplados, parâmetros do processo de coqueificação, que são responsáveis por 10% a 20% da qualidade do coque.⁽³⁾

2 CONSIDERAÇÕES GERAIS

2.1 Características Químicas e Físicas e Fatores Operacionais que Influenciam a Qualidade Metalúrgica do Coque

A qualidade metalúrgica do coque pode ser definida como sendo sua capacidade de preencher os requisitos básicos exigidos no alto-forno, sendo determinada a partir da avaliação dos papéis que ele desempenha no processo e/ou fatores que atuam sobre ele durante seu tempo de residência no reator. As funções essenciais que o coque desempenha são a geração de energia e gases redutores para o processo de redução do minério de ferro, e fornecimento de uma matriz permeável, através da qual os gases redutores possam fluir e o material fundido possa percolar, fazendo com que o coque seja considerado insubstituível em altos-fornos com volume interno superior a 800 m^3 .⁽⁴⁾

Para preencher os requisitos necessários como permeabilizador, o coque deverá possuir distribuição granulométrica, tamanho e formato que permitam

adequada permeabilidade aos gases redutores, promovendo otimização da transferência de calor das reações químicas entre sólidos e gases, ou seja, o coque deverá suportar as degradações físicas devidas à abrasão, impacto e compressão e às reações químicas, especialmente as de gaseificação que envolvem carbono e dióxido de carbono.⁽⁴⁾

De maneira geral, os fatores de fabricação do coque aplicados às baterias de fornos horizontais que, direta ou indiretamente, agem sobre o tamanho médio e distribuição de tamanho, a resistência ao impacto, à abrasão e à resistência após reação com CO₂ do coque estão indicados na Tabela 1.

Tabela 1 - Características químicas e físicas e fatores operacionais que influenciam na qualidade metalúrgica do coque⁽⁵⁾

Tamanho Distribuição de Tamanhos Resistência ao Impacto	Resistência à Abrasão	CSR ou CRI
<i>Rank</i> da mistura Granulometria da mistura Temperatura de parede Tempo final de coqueificação Largura do forno Umidade do coque Estabilização mecânica	Fluidez da mistura Densidade de carga Tempo final de coqueificação Estabilização mecânica	<i>Rank</i> da mistura Densidade de carga Temperatura de parede Tempo final de coqueificação Composição química da cinza

2.2 Redes Neurais Artificiais

Redes Neurais Artificiais 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 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.^(6,7)

Em RNAs, 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 que extrai automaticamente as características necessárias para representar a informação fornecida. Estas características são utilizadas posteriormente para gerar respostas para o problema.^(6,7)

A capacidade de aprender através de exemplos e de generalizar a informação aprendida é, sem dúvida, o atrativo principal da solução de problemas através das RNAs. A generalização, que está associada à capacidade da rede aprender através de um conjunto reduzido de exemplos e posteriormente dar respostas coerentes para dados não conhecidos, é uma demonstração de que a capacidade das RNAs vai muito além do que simplesmente mapear relações de entrada e saída. 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.^(6,7)

A principal diferença entre redes neurais e as abordagens estatísticas é que as primeiras não estabelecem hipóteses ou suposições sobre a distribuição ou propriedades dos dados e, desta forma, tendem a ser mais úteis em situações

práticas. As RNAs constituem também uma abordagem inerentemente não-linear, fornecendo mais precisão quando modelando dados de padrões complexos.⁽⁸⁾

3 METODOLOGIA

3.1 Desenvolvimento dos Modelos Utilizando a Técnica Redes Neurais Artificiais

A rotina de modelagem por Redes Neurais Artificiais foi desenvolvida utilizando o *software Matlab*[®]. As etapas realizadas no desenvolvimento da modelagem foram:

- **Coleta de dados**

O objetivo da rede foi prever os parâmetros utilizados para o controle da qualidade do coque, o DI, o CSR e o CRI. A escolha das variáveis para montagem do banco de dados das Coquerias 1 e 2 foi baseada na revisão bibliográfica (item 2.1), contudo foram coletados dados de outras variáveis que se julgaram importantes. A aquisição dos dados compreendeu o período de janeiro de 2004 a julho de 2008.

Após a montagem do banco de dados, foi realizada uma filtragem dos dados. Foram desconsideradas as misturas utilizadas por menos de 4 dias e, para as demais, foram desconsiderados os dias extremos de sua utilização, com o intuito de evitar a fase de transição de uma mistura para outra. A idéia foi garantir que os valores disponíveis pertencessem realmente à mistura em questão. Além disso, foi realizado um tratamento estatístico dos dados visando eliminar possíveis dados estranhos ao conjunto (*outliers*).

- **Normalização**

Para o desenvolvimento da rede neural os valores das variáveis de entrada e saída foram normalizados com o objetivo de obter um banco de dados com valores compreendidos entre -1 e 1.

- **Estrutura da Rede Neural Artificial**

Foram utilizadas redes neurais do tipo MLP (*Multilayer Perceptron*), uma vez que redes multicamadas possuem maior habilidade em lidar com problemas mais complexos. A função de ativação utilizada foi a sigmoïdal tangente hiperbólica.

Na tentativa de um melhor ajuste do modelo para predição do DI₁₅₋₁₅₀, do CSR e do CRI várias configurações da rede foram consideradas. Foram testados:

- o número de neurônios da camada oculta, de (n/2) até (2n+1), sendo n o número de variáveis de entrada;
- o número de camadas ocultas, em uma e duas camadas;
- os algoritmos de treinamento *back-propagation*: (i) gradiente descendente (função *traingd* do *Matlab*[®]), (ii) gradiente de conjugado escalonado (função *trainscg* do *Matlab*[®]), (iii) *Levenberg-Marquardt* (função *trainlm* do *Matlab*[®]) e (iv) regularização *Bayesiana* (função *trainbr* do *Matlab*[®]).

- **Treinamento**

Para realização desta etapa dividiu-se o conjunto de dados de entrada e saída, do período de janeiro/04 a julho/08, em 3 subconjuntos, um de treinamento, correspondendo a 60% dos dados, outro de validação, contendo 20% dos dados e outro de teste, com os 20% restantes. Esta divisão foi realizada visando à utilização da técnica *Early Stopping*.⁽⁷⁾

Os parâmetros de treinamento, erro meta, número de inicializações para cada rede e número de épocas, foram, respectivamente, 0,0001, 100 e 400. Quando se

utilizou o algoritmo de treinamento *traingd* o número de épocas foi igual a 4000, pois este apresenta lentas taxas de convergência.

Na tentativa de um melhor ajuste do modelo para predição do DI_{15-150} , do CSR e do CRI alguns conjuntos de variáveis de entrada foram testados.

Um primeiro grupo (1º grupo) foi formado pelas principais variáveis que influenciam a qualidade do coque (Tabela 1). Assim, para predição do DI_{15-150} utilizaram-se os parâmetros de refletância (*rank*), matéria volátil, fluidez, granulometria da mistura (menor que 2,83 mm e menor que 0,105 mm), temperatura da parede e tempo de coqueificação (tempo líquido e tempo de supercoqueificação). Para predição do CSR utilizaram-se os parâmetros de refletância, matéria volátil, teor de álcalis, granulometria da mistura (menor que 2,83 mm e menor que 0,105 mm), umidade, temperatura da parede e tempo de coqueificação (tempo líquido e tempo de supercoqueificação). E para o CRI, apenas o parâmetro CSR.

Um segundo conjunto (2º grupo) foi obtido utilizando-se a ferramenta estatística PCA (Análise de Componentes Principais). O objetivo desta análise é verificar se alguns componentes podem explicar a maior parte da variação dos dados, permitindo, desta maneira, a visualização do problema a partir de um menor número de variáveis. Essa análise foi realizada empregando-se o *software* estatístico *Statgraphics Plus*®.

Por fim foram montados conjuntos (3º grupo) a partir da verificação da existência de alguma relação linear entre as variáveis que formaram o 1º grupo (explicado acima). Essa verificação também foi realizada com o *software* *Statgraphics Plus*® através de uma análise multivariável. A existência de uma relação entre duas variáveis diferentes permite excluir uma delas da entrada da rede, uma vez que ambas tem a mesma influência no parâmetro analisado.

- **Validação**

Para avaliação da rede treinada comparou-se os valores reais de DI_{15-150} , CSR e CRI (valores do banco de dados) com a saída gerada pela rede. Essa comparação foi realizada por uma técnica estatística denominada análise pareada dos dados utilizando o *software* *Statgraphics Plus*®.

Essa análise testa se há diferença entre duas amostras, x_i e y_i , dependentes (amostras que são relacionadas). Se há diferença, a média das diferenças dos valores d , sendo $d = \sum(x_i - y_i)$, é diferente de 0, o que, simbolicamente, se expressa como $\mu_d \neq 0$. Se a afirmação não é verdadeira, temos $\mu_d = 0$. A média dos valores da diferença ser igual a 0 significa, no caso deste trabalho, que a rede treinada é capaz de prever, com nível de significância de 95%, os parâmetros analisados DI_{15-150} , CSR e CRI.

Para se escolher a melhor configuração, dentre as redes treinadas que apresentaram $\mu_d = 0$, avaliou-se o valor do desvio padrão. Quanto menor esse valor, mais próximos os valores reais de DI_{15-150} , CSR e CRI (valores do banco de dados) estão dos valores gerados pela rede.

3.2 Programa Computacional

Esta etapa consistiu em desenvolver um programa computacional, em linguagem *Visual Basic*®, para facilitar e proporcionar um melhor ambiente para a utilização dos modelos obtidos.

4 RESULTADOS

4.1 Análise das variáveis de entrada e de saída

A estrutura do banco de dados, de ambas as coqueiras, foi composta pelas seguintes variáveis:

- parâmetros relativos às misturas de carvões: teor de cinza, matéria volátil, refletância, fluidez, teor de inertes, álcalis, umidade, granulometria menor que 2,83 mm e menor que 0,105 mm;
- parâmetros operacionais: temperatura média da bateria, tempo líquido de coqueificação médio da bateria, tempo de supercoqueificação médio da bateria e número de desenformamentos/dia; e
- parâmetros reais da qualidade do coque: DI_{15-150} , CSR e CRI.

A tabela original, para ambas as coqueiras, era formada por 4.906 registros, sendo esse número correspondente aos dados coletados nos turnos A, B e C. Após a triagem dos dados obteve-se um total de 1004 registros tanto para a Coqueira 1 quanto para a Coqueira 2.

Os limites, superior e inferior, encontrados para cada variável, das Coqueiras 1 e 2, utilizadas no desenvolvimento das redes neurais são mostrados nas Figuras 1 (a) e 1 (b), respectivamente.

Coqueira 1			Coqueira 2		
Variáveis	Mínimo	Máximo	Variáveis	Mínimo	Máximo
Refletância (%)	0,936	1,206	Refletância (%)	0,912	1,205
MV (%)	24,235	28,580	MV (%)	24,235	28,580
Fluidez (log ddpm)	2,200	3,590	Fluidez (log ddpm)	2,22	3,59
< 2,83 (mm)	75,98	84,92	< 2,83 (mm)	75,98	84,92
< 0,105 (mm)	6,4	14,3	< 0,105 (mm)	6,365	14,300
Álcalis (%)	0,136	0,290	Álcalis (%)	0,107	0,285
Umidade (%)	7,38	13,83	Umidade (%)	7,38	13,83
Temperatura (°C)	1214	1274	Temperatura (°C)	1258	1326
Tempo líquido (min)	690	813	Tempo líquido (min)	865	946
Tempo super (min)	96	285	Tempo super (min)	91	440

Figura 1 – Valor dos limites mínimo e máximo das variáveis (a) Coqueira 1; (b) Coqueira 2.

4.2 Desenvolvimento dos Modelos Utilizando a Técnica de Redes Neurais Artificiais

O conjunto de variáveis de entrada e os parâmetros das RNAs que geraram melhor resultado (menor desvio-padrão) para predição dos parâmetros de qualidade do coque para Coqueira 1 e Coqueira 2 são apresentados nas Tabelas 2 e 3, respectivamente.

Tabela 2 – Conjunto de variáveis de entrada e parâmetros das RNAs que geraram o melhor resultado para predição dos parâmetros de qualidade do coque da Coqueria 1

Parâmetro	Variáveis de entrada da RNA	Parâmetros das RNAs		
		Algoritmo de treinamento	Camadas ocultas	Neurônios na camada oculta
DI ₁₅₋₁₅₀	Refletância; matéria volátil; fluidez; granulometria menor que 2,83 mm e menor que 0,105 mm; temperatura; tempo liquido; tempo supercoqueificação	<i>trainscg</i>	1	13
CSR	Refletância; matéria volátil; álcalis; granulometria menor que 2,83 mm e menor que 0,105 mm; umidade; temperatura; tempo liquido; tempo supercoqueificação	<i>trainscg</i>	2	6 / 6
CRI	CSR	<i>trainlm</i>	1	2

Tabela 3 – Conjunto de variáveis de entrada e parâmetros das RNAs que geraram o melhor resultado para predição dos parâmetros de qualidade do coque da Coqueria 2

Parâmetro	Variáveis de entrada da RNA	Parâmetros das RNAs		
		Algoritmo de treinamento	Camadas ocultas	Neurônios na camada oculta
DI ₁₅₋₁₅₀	Refletância; matéria volátil; fluidez; granulometria menor que 2,83 mm e menor que 0,105 mm; temperatura; tempo liquido; tempo supercoqueificação	<i>trainlm</i>	1	5
CSR	Refletância; matéria volátil; álcalis; granulometria menor que 2,83 mm e menor que 0,105 mm; umidade; temperatura; tempo liquido; tempo supercoqueificação	<i>trainlm</i>	1	5
CRI	CSR	<i>trainlm</i>	1	3

Para verificar a viabilidade dos modelos propostos fez-se a comparação entre os erros de predição utilizando redes neurais e utilizando regressão linear múltipla (método atual). Nas Tabelas 4 e 5 encontram-se os resultados obtidos para as Coquerias 1 e 2, respectivamente.

Tabela 4 – Comparação entre os erros de predição utilizando regressão linear múltipla (método atual) e redes neurais para Coqueria 1

COQUERIA 1		Regressão linear múltipla	Redes neurais
DI ₁₅₋₁₅₀	Erro médio	0,67	0,31
	Erro relativo médio (%)	0,81	0,38
CSR	Erro médio	2,26	0,94
	Erro relativo médio (%)	3,39	1,43
CRI	Erro médio	6,07	0,64
	Erro relativo médio (%)	20,40	2,86

Tabela 5 – Comparação entre os erros de predição utilizando regressão linear múltipla (método atual) e redes neurais para Coqueria 2

COQUERIA 2		Regressão linear múltipla	Redes neurais
DI ₁₅₋₁₅₀	Erro médio	0,63	0,29
	Erro relativo médio (%)	0,75	0,35
CSR	Erro médio	1,42	0,90
	Erro relativo médio (%)	2,12	1,33
CRI	Erro médio	6,43	0,52
	Erro relativo médio (%)	22,87	2,50

Em que:

$$\text{Erro médio} = \frac{|\text{valor real} - \text{valor p}|}{n} \quad (1)$$

$$\text{Erro relativo médio} = \frac{|\text{valor previsto} - \text{valor real}|}{\text{valor previsto}} \quad (2)$$

n = número de testes

4.3 Programa Computacional

A máscara do programa computacional, desenvolvido em linguagem *Visual Basic*[®], pode ser observada nas Figuras 2 (a) e 2 (b).

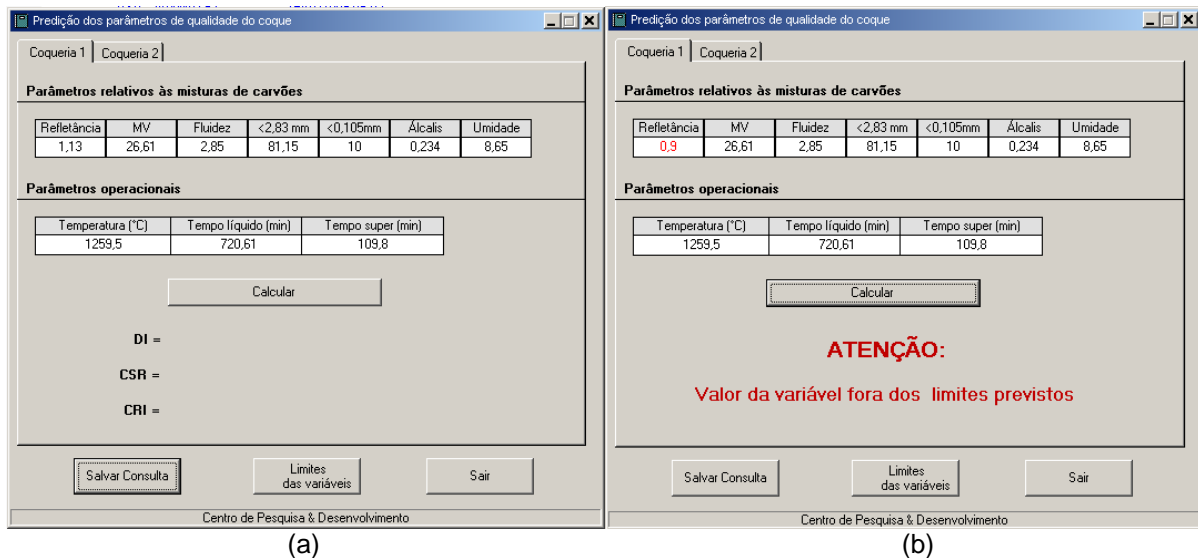


Figura 2 – (a) Janela principal do programa desenvolvido para a predição dos parâmetros de qualidade do coque. (b) Indicação de valor de variável fora dos limites estabelecidos.

5 DISCUSSÃO DOS RESULTADOS

5.1 Análise das Variáveis de Entrada e de Saída

O desenvolvimento de um modelo utilizando Redes Neurais Artificiais depende da obtenção de uma base de dados confiável e abrangente, de modo que todas as situações possíveis possam ser representadas, permitindo o aprendizado da rede. Um banco de dados (entradas e saídas) contendo alguns registros inconsistentes compromete, em maior ou menor grau, o treinamento e, conseqüentemente, a aplicação da RNA, sendo por isso necessário efetuar uma triagem dos dados obtidos.

A definição dos limites mínimos e máximos de cada variável utilizada para o desenvolvimento do modelo das Redes Neurais Artificiais é importante, pois as respostas geradas pela rede para variáveis de entrada fora dos limites estabelecidos não são confiáveis.

5.2 Desenvolvimento dos Modelos Utilizando a Técnica Redes Neurais Artificiais

Através da análise dos resultados observou-se que, dentre as três configurações de entrada da rede testadas a que apresentou melhor resultado (menor desvio-padrão) foi a que utilizou as principais variáveis que influenciam o DI_{15-150} (1º grupo testado). Os resultados obtidos quando se utilizaram o 2º e 3º grupos (componentes principais e grupo de variáveis de entrada baseado em uma relação entre duas variáveis) foram inferiores quando comparados com o 1º grupo.

Com relação às várias configurações da rede propostas foi observado que o número de camadas ocultas praticamente não influenciava no resultado e que dentre os algoritmos de treinamento utilizados o *traingd* e o *trainbr* requeriam um maior custo computacional, sendo que o *traingd* apresentava resultados bastante inferiores. Observou-se, também, que os melhores resultados eram conseguidos quando se utilizava o algoritmo de treinamento *trainlm* ou *trainscg*, sendo os desvios padrões, obtidos na análise pareada dos dados, praticamente iguais. Nas Tabelas 2 e 3 é possível observar o conjunto de variáveis de entrada e os

parâmetros das RNAs que geraram o melhor resultado para predição dos parâmetros de qualidade do coque para ambas as coquerias.

As divergências verificadas nas arquiteturas das redes das Coquerias 1 e 2, número de camadas ocultas e número de neurônios por camadas, para os parâmetros de DI_{15-150} , CSR e CRI, estão relacionadas ao fato dos dois bancos de dados finais não serem iguais devido ao processo de filtragem e às diferentes faixas de operação das duas coquerias.

De acordo com os resultados apresentados nas Tabelas 4 e 5, tem-se que, em todos os modelos desenvolvidos, as redes obtidas foram capazes de prever melhor os parâmetros de qualidade do coque (com erros de predição, médio e relativo, inferiores) do que os modelos de regressão linear múltipla atualmente utilizados.

Acredita-se que a maior causa da incerteza nos resultados dos modelos esteja no banco de dados utilizado, ou seja, na precisão dos dados de entrada utilizados para o treinamento da rede. Apesar de terem sido utilizadas técnicas estatísticas para eliminação de valores estranhos ao conjunto, alguns erros são praticamente impossíveis de serem contornados devido à própria variabilidade do processo, à necessidade de usar valores médios, entre outras. Entretanto, observou-se que essa incerteza não comprometeu os resultados obtidos, tornando as redes neurais uma ferramenta potencial de modelagem matemática dos parâmetros de qualidade do coque.

5.3 Programa Computacional

Foi desenvolvido em linguagem *Visual Basic*[®] um programa computacional para facilitar e proporcionar um melhor ambiente para a utilização dos modelos desenvolvidos. A janela inicial do programa é mostrada na Figura 2 (a). Através dela, o usuário tem acesso ao cálculo dos parâmetros de qualidade do coque DI_{15-150} (Índice de Resistência a Frio), CSR (Índice de Resistência após Reação com CO_2) e CRI (Índice de Reatividade do Coque) para as Coquerias 1 e 2.

No programa desenvolvido, o botão “Limites das variáveis” (figura 2a) informa os limites mínimos e máximos de cada variável utilizada para o desenvolvimento do modelo das Redes Neurais Artificiais.

Caso os valores colocados nos campos “parâmetros relativos às misturas de carvões” e “parâmetros operacionais” estejam fora desses limites, um aviso de “ATENÇÃO” aparece na tela por alguns segundos. Além disso, o valor da variável que foi modificada e que se encontra fora do limite fica em vermelho (figura 2b).

A opção “Salvar Consulta” permite que o usuário salve os dados gerados pelo modelo numa pasta do *Excel*[®].

A utilização desse modelo irá auxiliar na tomada de decisão durante a formulação das misturas de carvões, visando garantir uma qualidade satisfatória do coque, aliada a uma possibilidade de redução do custo das misturas.

6 CONCLUSÃO

O modelo de redes neurais apresentou melhor correlação entre os valores medidos e calculados quando comparado aos modelos de regressão linear múltipla, atualmente utilizados.

Os resultados encontrados para o modelo de redes neurais apresentaram redução do erro médio, quando comparado ao modelo de regressão linear múltipla,

de 54%, 58% e 89% para DI, CSR e CRI, respectivamente, com o banco de dados da Coqueria 1 e, para o banco de dados da Coqueria 2, redução de 54%, 37% e 92% para DI, CSR e CRI, respectivamente. Esses resultados foram considerados satisfatórios, devido ao grau de incerteza apresentado pelos dados de processo necessários para o desenvolvimento da rede. Destaque deve ser dado à elevação do índice de acerto para cálculo do CRI.

REFERÊNCIAS

- 1 DIÉZ, M. A.; ALVAREZ, R.; BARRIOCANAL, C. Coal for metallurgical coke production: prediction of coke quality and future requirements for cokemaking. *International Journal of Coal Geology*, 50, 2002, p. 389–412.
- 2 NEGRO, P.; STEILER, J. M.; BEPLER, E.; JAHUSEN, U.; BENNINGTON, C. R.; WILMERS, R. R. Assessment of coke degradation in the blast furnace from tuyère probing investigations. 3rd European Ironmaking Cong., CRM –VDEh, Gent, Belgium, 1996, pp. 20-27. Apud DIÉZ, M. A.; ALVAREZ, R.; BARRIOCANAL, C. Coal for metallurgical coke production: prediction of coke quality and future requirements for cokemaking. *International Journal of Coal Geology*, 50, 2002, p. 389–412.
- 3 NAKAMURA, N.; TOGINO, Y.; TATEOKA, T. Behaviour of coke in large blast furnace. *Coal, Coke and Blast Furnace*. The Metals Society, London, 1977. p. 1–18. Apud DIÉZ, M. A.; ALVAREZ, R.; BARRIOCANAL, C. Coal for metallurgical coke production: prediction of coke quality and future requirements for cokemaking. *International Journal of Coal Geology*, 50, 2002, p. 389–412.
- 4 ULHÔA, M. B.; CARNEIRO, R. T. S.; PINHEIRO, J. A. Carvão aplicado à fabricação de coque de alto-forno. Curso ABM, São Paulo-SP, 2003.
- 5 REIS, H. M. B.; ULHÔA, M. B.; CORREA, G. Qualidade de Coque de Alto-Forno. XXX Seminário de Redução de Minério de Ferro da ABM; Belo Horizonte, MG, 1999.
- 6 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.
- 7 HAYKIN, S. *Redes Neurais: Princípios e Prática*. Bookman, 2º ed, 2001.
- 8 SMITH, K. A.; GUPTA, J. N. D. Neural networks in business: techniques and applications for the operations researcher. *Computers & Operations Research*, pp. 1023-1044, 2000.

