



XXI Congresso Brasileiro
de Engenharia Química

Fortaleza/CE
25 a 29 de setembro



XVI Encontro Brasileiro sobre o
Ensino de Engenharia Química
Fortaleza/CE
25 a 29 de setembro

ESTIMATIVA VIA REDES NEURONAIS DO PODER CALORÍFICO SUPERIOR DE BIOMASSAS USANDO DADOS DE ANÁLISE IMEDIATA

H. LANDI¹, FI. B. FREIRE², F. B. FREIRE¹ e J. T. FREIRE¹

¹ Universidade Federal de São Carlos, Departamento de Engenharia Química

² Universidade Tecnológica Federal do Paraná, Departamento Acadêmico de Construção Civil

E-mail para contato: bentes@ufscar.br

RESUMO – Resíduos sólidos biológicos são uma das matérias-primas de maior interesse como fonte de energia renovável. Existem três tipos principais de biomassas para se obter bioenergia: lipídios, açúcares/amidos e celulose/lignocelulose. A estimativa do poder calorífico superior (PSC), cujos métodos de determinação demandam longos períodos e são relativamente caros, é fundamental na análise e desenvolvimento de sistemas bioenergéticos. Existem correlações empíricas encontradas na literatura para o poder calorífico superior a partir de dados de análise elemental, mais exigente em termos de instrumentação, e de imediata, mais simples e de fácil obtenção experimental. Este trabalho avaliou o uso de redes neuronais artificiais (RNA) (Matlab 2013) para estimar o poder calorífico superior de biomassas a partir de treinamento com dados de análise imediata encontrados na literatura. Verificou-se, com dados adicionais gerados para este fim, que redes de 7 a 10 neurônios correlacionaram bem os dados de treinamento e estimaram igualmente bem os dados de verificação.

1. INTRODUÇÃO

Resíduos sólidos de origem biológica são, atualmente, uma das matérias primas de maior interesse como fonte de energia renovável, principalmente dentro do contexto de reduzir impactos ao meio ambiente. Existem três tipos principais de matérias orgânicas a partir das quais se derivam as matérias primas para se obter bioenergia: lipídios (gordura em geral, óleos e cera), açúcares/amidos e celulose/lignocelulose. Alguns grãos como soja e sementes como a de girassol e da mamona são ricos em lipídios e podem ser encontrados na produção, por exemplo, de biodiesel. Açúcares e amido costumam estar presentes nas partes comestíveis de cultivos alimentícios, como milho por exemplo. A celulose e lignocelulose que, por outro lado, possuem pouco ou nenhum valor na alimentação de seres humanos, também podem ser utilizadas como fonte de biocombustíveis e produtos de alto valor energético.

A matéria sólida orgânica proveniente do descarte, mais comumente chamada de resíduo sólido, é variada e possui diversas origens, desde industrial, como subprodutos a exemplo de bagaços e farelos, até agrícola e municipal, como restos de podas de árvores. Do ponto de vista químico,

PROMOÇÃO

REALIZAÇÃO

ORGANIZAÇÃO





XXI Congresso Brasileiro
de Engenharia Química

Fortaleza/CE
25 a 29 de setembro



XVI Encontro Brasileiro sobre o
Ensino de Engenharia Química
Fortaleza/CE
25 a 29 de setembro

resíduos sólidos geralmente são compostos contendo, invariavelmente, hemicelulose, celulose e lignina, e ainda, extratos dependendo do tipo e natureza de cada um. Fornecida a energia de ativação das moléculas componentes destes compostos, é possível reduzi-las, através de reações exotérmicas, em moléculas menores e com valor agregado como gases combustíveis (hidrogênio, por exemplo), óleos e carvão.

As tecnologias mais desenvolvidas para a obtenção de energia a partir de biomassa ou combustíveis são aquelas baseadas em tratamentos termoquímicos, como pirólise, gaseificação e combustão. Os níveis de eficiência e emissão desses processos dependem das propriedades da biomassa, das condições de operação e do tipo de equipamento utilizado. Uma vez que a biomassa é sazonal em muitos casos, a viabilidade de qualquer tratamento termoquímico requer a adaptação das condições de funcionamento para as características da alimentação e, portanto, a caracterização da biomassa deve ser rápida e confiável. Dentre os parâmetros de maior importância que afetam a cinética de degradação térmica, destaca-se o poder calorífico superior, calor (energia) produzido na combustão completa de uma quantidade fixa de combustível.

Existem na literatura diversas correlações empíricas e semi-empíricas (Saldarriaga, 2015) para cálculo do poder calorífico superior usando como entrada dados de análises elementais, que determinam a composição elementar (quantidade em massa de oxigênio, carbono, enxofre, etc.), como o próprio nome sugere, das biomassas, porém são medidas relativamente demoradas e feitas em aparatos experimentais sofisticados. A análise imediata, por outro lado, determina as propriedades como, carbono fixo, material volátil, cinzas e umidade presentes, de forma mais simples e rápida. Este trabalho teve como objetivo usar redes neuronais para estimar o poder calorífico superior a partir de dados de análise imediata de diferentes tipos de biomassa. Uma vez especificada, a rede neuronal foi treinada com a base de dados de Nhuchhen e Salam (2012), usando o *Neural Network Toolbox* do Matlab 2013. A verificação experimental da rede obtida foi feita com valores medidos especificamente para este fim no Departamento de Engenharia Química da Universidade do País Basco, em Bilbao, Espanha.

2. METODOLOGIA

2.1. Poder Calorífico Superior (PCS)

Para o aproveitamento racional e adequado de resíduos, tais como a biomassa, é necessário o estudo de suas propriedades energéticas (Protásio *et al.*, 2011). O poder calorífico de um material é expresso pelo conteúdo de energia que é liberada quando o material é queimado no ar. Sendo assim, o calor gerado durante a combustão de diferentes espécies de resíduos pode variar dependendo de suas propriedades físicas, químicas e anatômicas (Almeida *et al.*, 2010). Em outras palavras, é a quantidade de calor liberadas por um material em sua combustão completa, expresso em calorias por grama (cal/g) ou quilocaloria/quilograma (kcal/kg) (Quirino *et al.*, 2011). Quanto maior for este parâmetro, maior será a energia contida no combustível (Carvalho Júnior, 2010).

Pode-se determinar o PCS de um material combustível através de uma bomba calorimétrica, dado pela evaporação e condensação da água durante a combustão do material (Fontes, 1994). Esta

PROMOÇÃO

REALIZAÇÃO

ORGANIZAÇÃO



medida, além de lenta, requer condições específicas de preparo de amostra visando minimizar eventuais resultados errôneos. Além da via analítica, existe um número considerável de correlações disponíveis na literatura, entretanto, Nhuchhen e Salam (2012) mostraram que uma mesma correlação pode apresentar um erro de 1% para uma determinada substância e até 90% para outras matérias-primas, tendo, portanto pouca capacidade de generalização.

2.2. Redes Neurais Artificiais (RNAs)

As redes neurais artificiais são métodos computacionais de programação que imitam o cérebro humano, no sentido de que elas são formadas por várias unidades de processamento, chamadas neurônios artificiais, capazes de correlacionar bancos de dados entre si. O primeiro passo na concepção de uma rede neuronal é a escolha de sua estrutura, com o número de neurônios e camadas intermediárias entre a entrada e a saída. Uma relação típica de uma rede neuronal de entrada/saída é dada pela equação 1 (Himmelblau, 2008):

$$y = b_2 + LW.tansig(b_1 + IW.x) \quad (1)$$

Em que y é o vector de saída, x é o vector de entrada, LW é a matriz dos pesos correspondentes às conexões entre os neurônios da camada intermediária com os da saída, IW é a matriz dos pesos de ligação da camada de entrada para a camada intermediária, e b_1 e b_2 , são, respectivamente, vectores *bias* das camadas intermediária e de saída.

Numa rede tipo *feedforward*, o sinal recebido pela camada intermédia vai para os neurônios da camada de saída. Na camada intermédia, por sua vez, cada unidade (y_j) soma os valores de entrada ponderados e aplica-se a função de ativação para gerar o sinal de saída de acordo com a Equação 2:

$$Y_j = f_{act}(\sum_{i=1} W_{ij} X_i + b_j) \quad (2)$$

onde W_{ij} é o peso de ligação entre a entrada do i -ésimo e j -ésimo neurônio da camada intermediária e b_j é o valor de *bias* da unidade j . A função de ativação utilizada neste trabalho foi a tan-sigmoidal, dada pela Equação 3,

$$f_{act}(x) = \frac{1}{1+e^{-x}} \quad (3)$$

A saída do neurônio y_j é enviada para todas as unidades da camada de saída. Cada neurônio de saída O_k soma o sinal de entrada ponderada e aplica-se a função de ativação de acordo com a Equação 3,

$$O_k = f_{act}(\sum_{j=1} V_{jk} Y_j + b_k) \quad (4)$$

Os pesos W_{ij} de cada conexão entre os neurônios em camadas adjacentes são determinados durante o processo de aprendizagem da rede através de um algoritmo de otimização, como programação não-linear ou programação genérica, entre outros. A principal dificuldade com a

otimização para determinar os pesos de redes neuronais é que várias mínimos locais podem ocorrer na função objetivo utilizada. Embora o uso de um procedimento de otimização global pode, eventualmente, atingir o ótimo global, o tempo de execução para tal algoritmo em computadores de série normalmente é elevado. Dessa forma, deve-se buscar o melhor mínimo local que pode ser atingido num período de tempo aceitável.

A estimativa do poder calorífico superior (PSC) a partir de parâmetros de análise imediata da biomassa, carbono fixo (CF), material volátil (MV) e cinzas, foi feita pela rede neuronal artificial (RNA) cuja estrutura básica é mostrada na figura 1:

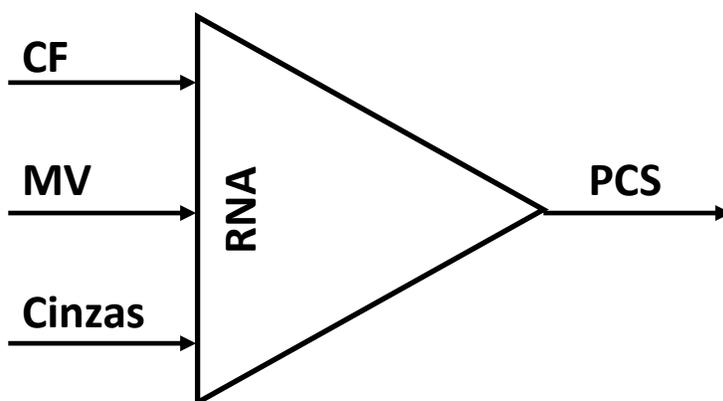


Figura 1 – Representação das entradas e saídas da RNA.

A RNA foi desenvolvida com o auxílio do *toolbox Neural Networks* do MatLab 2013, sendo do tipo *feedforward*, com o algoritmo de otimização de Levenber Marquart para determinar os pesos e o método de *back propagation* para o treinamento. Para treinamento, foi utilizada a base de dados disponível em Nhuchhen e Salam (2012), com 250 pontos experimentais.

3. RESULTADOS E DISCUSSÕES

O número de neurônios na camada intermediária foi escolhido por tentativa e erro, começando com um neurônio e adicionando-se mais neurônios até que o desempenho da rede em estimar a saída correta foi satisfatório. O objetivo principal é criar uma rede neural com o menor número possível de neurônios. No limite, em que o número de pesos é igual ao número de pontos experimentais, o coeficiente de correlação (R^2) atinge o valor 1, entretanto, a rede neuronal perde a capacidade de generalizar, tornando-se específica do conjunto de treino. A figura 2 mostra o comportamento do erro relativo médio cometido pela rede nas etapas de treinamento e verificação. A partir de 10 neurônios, apesar da melhora no ajuste aos dados de treinamento, a rede começa a perder sua capacidade de estimar valores fora dessa base. Um número razoável de neurônios para esta aplicação foi em torno de 7 e 10.

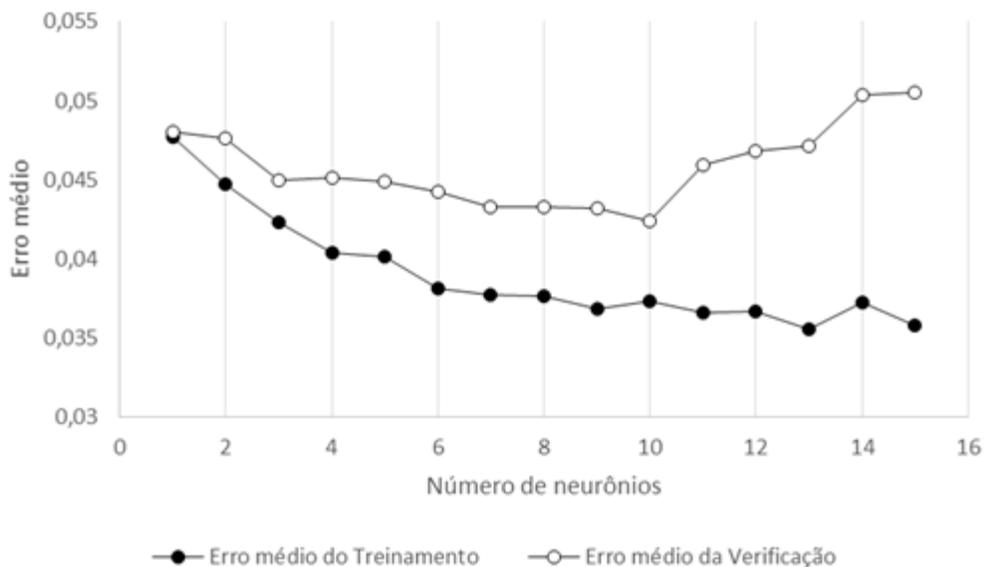
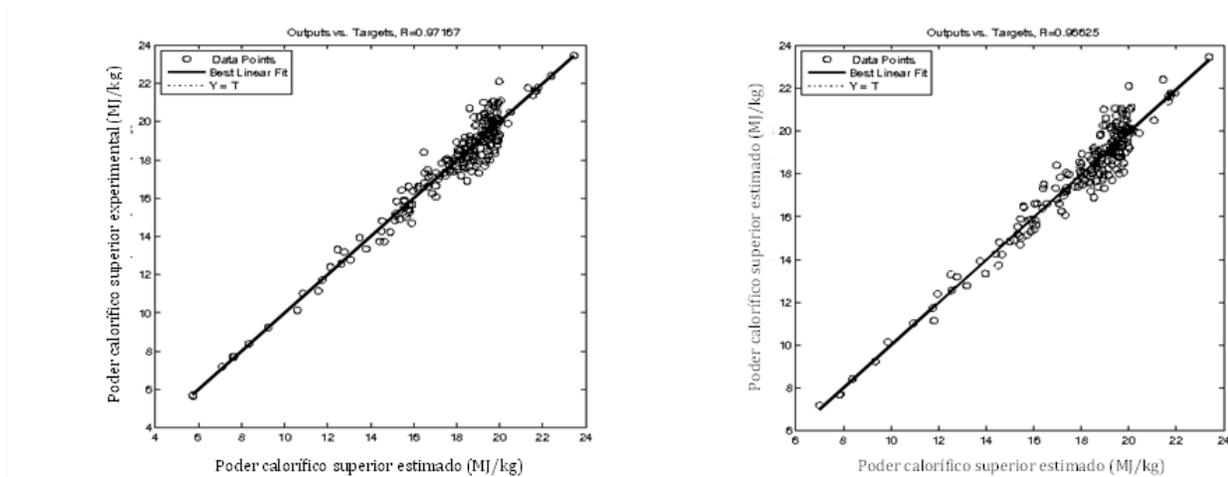


Figura 2 – Erros médios do treinamento e da verificação versus número de neurônios da rede

A Figura 3 mostra graficamente que houve uma boa aproximação entre os valores de PCS estimados pela rede frente aos medidos diretamente na fase de treinamento. Além disso, é possível ver que o banco de dados utilizado prioriza materiais com valores de PCS acima de 15 MJ/kg.



(a) 10 neurônios

(b) 7 neurônios

Figura 3 – PCS estimado e medido para os dados de treinamento

Como esperado, a Figura 3 mostra que o coeficiente de correlação linear (R^2) foi maior para a rede de 10 neurônios ($R^2=0.97167$) do que a de 7 neurônios ($R^2=0.96625$). Vale ressaltar que, como pode acontecer em qualquer ajuste, uma poda (do jargão em inglês, *pruning*) foi necessária, eliminando-se dados que sistematicamente prejudicavam a etapa de aprendizagem (treinamento) da rede. Dos 250 valores experimentais disponíveis em Nhuchhen e Salam (2012), 237 foram efetivamente utilizados.

A Tabela 1 mostra os valores experimentais utilizados para verificar a capacidade de generalização da rede obtida.

Tabela 1 – Análise imediata das biomassas da etapa de verificação da RNA

Biomassa	Umidade (% p/p, b.s.)	Material Volátil (% p/p, b.s.)	Carbono Fixo (% p/p, b.s.)	Cinzas (% p/p, b.s.)	PCS (MJ kg ⁻¹)
Pelets	7.86	87.04	12.25	0.71	18.74
Pinus insignis	8.69	85.85	12.79	1.35	18.84
Acacia dealbata	8.75	87.87	9.64	2.50	17.10
Eucalyptus plantio	9.09	91.24	6.95	1.81	18.87
Casca de arroz	8.40	65.33	10.04	24.63	13.76
Casca de noz	10.95	78.67	21.08	0.25	20.12
Caroço de azeitona	8.83	72.21	27.21	0.58	20.36
Cytisus multiflorus	7.21	94.36	4.17	1.46	17.30
Pterospartum tridentatum	7.71	87.60	10.68	1.71	18.50
Pteridium aquilinum	12.44	68.27	22.09	9.63	17.50
Miscanthus sinensis	11.32	83.32	12.27	4.41	18.26
Rumex tianschanicus	9.34	91.04	3.81	5.14	16.91

Os resultados das estimativas da etapa de verificação encontram-se na Tabela 2, juntamente com os respectivos percentuais de desvio encontrados. Apesar de ter um R^2 menor, a RNA com 7 neurônio mostrou-se ligeiramente superior à de 10 neurônios especificamente para a base de dados utilizada na verificação. Saldarriaga (2015) fez uma comparação entre os valores medidos de PCS de várias biomassas, incluindo as encontradas na Tabela 1, e os previstos por uma correlação empírica (Parikh, 2005), obtendo uma média dos desvios (para as biomassas da Tabela 1) de 4.86%. Além de ter generalizado melhor, a rede neuronal tem uma estrutura pré-pronta para uso, ao contrário de modelos de correlação que precisam ser concebidos e, além disso, ela se adapta a novos dados uma vez que eles estejam disponíveis. Uma vez projetada, é possível utilizar a rede neuronal em qualquer ambiente de programação através da relação entrada/saída dada pela equação 1.

Tabela 2 – Comparação dos valores de PCS medidos e estimados pela RNA e seus respectivos desvios.

Biomassa	Medido, MJ.kg ⁻¹	10 neurônios		7 neurônios	
		Estimado, MJ.kg ⁻¹ (RNA)	Desvio	Estimado, MJ.kg ⁻¹ (RNA)	Desvio
Pelets	18.74	19.11	1.98%	19.24	2.69%
Pinus insignis	18.84	19.08	1.25%	19.15	1.62%
Acacia dealbata	17.10	17.98	5.14%	18.28	6.89%
Eucalyptus plantio	18.87	17.17	9.03%	17.55	7.01%
Casca de Arroz	13.76	14.75	7.18%	14.41	4.75%
Casca de Noz	20.12	19.89	1.12%	19.98	0.70%
Caroço de azeitona	20.36	20.05	1.54%	20.18	0.87%
Cytisus multiflorus	17.30	16.21	6.32%	16.19	6.44%
Pterospartum tridentatum	18.50	18.47	0.18%	18.70	1.08%
Pteridium aquilinum	17.50	17.73	1.34%	18.04	3.07%
Miscanthus sinensis	18.26	18.27	0.07%	18.26	0.01%
Rumex tianschanicus	16.91	15.61	7.71%	15.76	6.81%
Média			3.57%		3.50%

4. CONCLUSÕES

Este trabalho mostrou que foi possível utilizar uma rede neuronal artificial (RNA) para estimar o poder calorífico superior de biomassas a partir de treinamento com dados de análise imediata encontrados na literatura. Verificou-se, com dados adicionais gerados para este fim, que redes de 7 a 10 neurônios correlacionaram bem os dados de treinamento e estimaram igualmente bem os dados de verificação. A rede neuronal simplifica a tarefa do ajuste a dados experimentais por utilizar uma estrutura de cálculo comum a qualquer aplicação, ao contrário de correlações empíricas, e, nesse trabalho, teve desempenho superior do que a correlação apresentada por Parikh (2005).

5. REFERÊNCIAS

ALMEIDA, G.; BRITO, J.O. e PERRÉ, P. Alterations in energy properties of eucalyptus wood and bark subjected to torrefaction: The potential of mass loss as a synthetic indicator. *Bioresource Technology*, v.101, n. 24, p. 9778–9784, 2010.

CARVALHO JÚNIOR, R.M. Desenvolvimento e análise energética do processo de obtenção do biodiesel de microalga por metanólise in situ. Dissertação (Mestrado) UFPR, Curitiba – PR, 2010.

FONTES, P.J.P. Auto-suficiência energética em serraria de Pinus e aproveitamento de resíduos. 93f. Dissertação (Mestrado em Ciências Florestais) – Setor de Ciências Agrárias, Universidade Federal do



XXI Congresso Brasileiro
de Engenharia Química

Fortaleza/CE
25 a 29 de setembro



XVI Encontro Brasileiro sobre o
Ensino de Engenharia Química
Fortaleza/CE
25 a 29 de setembro

Paraná. 1994

HIMMELBLAU, D. M. Accounts of Experiences in the Application of Artificial Neural Networks in Chemical Engineering. *Ind. Eng. Chem. Res.*, v.47, p. 5782-5796, 2008.

NHUCHHEN, D. R. e SALAM, A. P., Estimation of higher heating value of biomass from proximate analysis: A new approach *Fuel*, v. 99, p. 55-63, 2012.

PARIKH, P.P.; CHANNIWALA, S.A. e GHOSAL, G.K. A correlation for calculating HHV from proximate analysis of solid fuels. *Fuel*. V.84, pp. 487-494, 2005.

PROTÁSIO, T.P.; BUFALINO, L.; TONOLI, G.H.D.; COUTO, A.M.; TRUGILHO, P.F; e GUIMARÃES JÚNIOR, M. Relação entre o poder calorífico superior e os componentes elementares e minerais da biomassa vegetal. *Pesq. Flor. Bras.*, Colombo, v.31, n.66, p. 113-122, 2011.

QUIRINO, W. F.; do VALE, A. T.; de ANDRADE, A. P. A.; ABREU, V. L. S. e AZEVEDO, A. C. S. Poder calorífico da madeira e de materiais ligno-celulósicos. *Revista da Madeira*, n.89. abr. 2005, p. 100-106.

SALDARRIAGA, J. F., Avances en el modelado de la combustión de biomasa en spouted bed cónico. Tese (Doutorado) – Universidad del País Vasco, Bilbao, 2015.

PROMOÇÃO

REALIZAÇÃO

ORGANIZAÇÃO

