

INVESTIGAÇÃO DO PODER CALORÍFICO SUPERIOR (PCS) DE DIFERENTES BIOMASSAS BASEADO EM ANÁLISE IMEDIATA UTILIZANDO REDES NEURAIAS ARTIFICIAIS (RNA'S)

Thalyssa Oliveira Monteiro, thalyssamonteiro@gmail.com¹
Glauber Cruz, cruz.glauber@ufma.br^{1,2}

¹Programa de Pós-Graduação em Engenharia Mecânica (PPGMEC), Instituto Federal de Educação, Ciência e Tecnologia do Maranhão (IFMA), São Luís, Maranhão, Brasil

²Departamento de Engenharia Mecânica, Laboratório de Processos e Sistemas Térmicos, Universidade Federal do Maranhão (UFMA), São Luís, Maranhão, Brasil

Resumo: O uso de biocombustíveis é uma alternativa eficiente para substituir mesmo que parcialmente os combustíveis fósseis na geração de bioenergia, reduzindo os índices que contribuem para a degradação ambiental do planeta. Para uma melhor utilização de biomassas ou materiais lignocelulósicos na produção de energia limpa, são necessários alguns processos termoquímicos que convertam os mesmos em biocombustíveis. Estes resíduos precisam apresentar um potencial energético suficiente para a produção de bioenergia. Alguns equipamentos e/ou processos específicos são empregados para a extração do biocombustível, bem como para quantificar o poder calorífico dessas biomassas. Entretanto, a aquisição dessas ferramentas torna os processos de termoconversão bastante onerosos. Por isso, algumas equações baseadas na análise imediata (teores de umidade, carbono fixo, materiais voláteis e cinzas, são empregadas para determinação teórica do potencial energético desses materiais lignocelulósicos. Por outro lado, diversos modelos numéricos são amplamente utilizados como uma alternativa promissora a esses empecilhos e considerados confiáveis, economizando tempo e recursos financeiros. Neste contexto, este estudo realizou a determinação do Poder Calorífico Superior (PCS) de diversas biomassas, utilizando um banco de dados com 115 materiais lignocelulósicos, por meio da modelagem numérica, empregando redes neurais artificiais (RNA's). Foram utilizadas 5 equações conhecidas na literatura especializada para o cálculo do PCS por meio da análise imediata das diferentes biomassas. Para avaliar o melhor modelo de predição estudado, foram estabelecidos 5 critérios de precisão: diferença entre as menores médias dos valores preditos e estimados, Average Absolute Error (AAE), Average Bias Error (ABE), Mean Absolute Error (MAE) e índice de regressão linear (R). Observou-se que uma das 5 equações escolhidas apresentou um melhor desempenho para os 4 critérios supramencionados, exceto para o índice de regressão linear, o qual apresentou uma precisão (84,20%). Por outro lado, o modelo RNA 8x4 obteve uma precisão de 99% em relação aos valores estimados e preditos dos PCS das amostras, $17,44 \pm 0,22 \text{ MJ kg}^{-1}$ e $17,44 \pm 0,04 \text{ MJ kg}^{-1}$, respectivamente, obtendo o melhor desempenho para os 5 critérios estabelecidos. Os resultados mostraram que a predição numérica aplicada apresentou um ótimo desempenho, boa acurácia e poderá servir como uma alternativa viável para obtenção do potencial energético de diferentes biomassas na falta de determinados processos experimentais e baseados em um conjunto de equações teóricas.

Palavras-chave: materiais lignocelulósicos, potencial energético, modelagem numérica, equações características

1. INTRODUÇÃO

A utilização de combustíveis fósseis na geração de energia nos últimos anos tem causado alta degradação ambiental, bem como na emissão irrefreável dos gases do efeito estufa (Lela *et al.*, 2016; EPE, 2021). Segundo Boumanchar *et al.* (2019), para reduzir os efeitos nocivos dos combustíveis fósseis, o uso de biomassas como biocombustíveis na geração de energia se tornou uma alternativa bastante atrativa. Para tanto, são necessários alguns processos termoquímicos para a extração/conversão do biocombustível proveniente de resíduos lignocelulósicos, como a combustão, pirólise e co-combustão (Bi *et al.*, 2020; Soler *et al.*, 2018; Oladosu *et al.*, 2021). Além disso, para que haja a consideração de certas biomassas na geração de energia, é um requisito essencial quantificar o potencial energético destas, por exemplo, o Poder Calorífico Superior (PCS), que determina o potencial energético interno destes resíduos (Ozyuguran *et al.*, 2018). No entanto, são necessários alguns equipamentos específicos para realizar essa operação, e estes instrumentos podem ser altamente dispendiosos (Mateus *et al.*, 2021).

De forma teórica, é possível determinar o PCS por meio de equações características, utilizando a análise elementar (teores de carbono, hidrogênio, nitrogênio, oxigênio e enxofre) e/ou análise imediata (teores de umidade, materiais voláteis, carbono fixo e cinzas) das amostras estudadas, as quais foram investigadas por diversos autores (Elneel *et al.*, 2013; Soponpongpiat *et al.*, 2015; Akkaya, 2009; Nhuchhen and Afzal, 2017). Ademais, modelos numéricos estão sendo cada vez mais utilizadas como alternativas promissoras para suprirem as necessidades operacionais na obtenção do potencial energético de biomassas, a fim de reduzir o tempo de trabalho experimental e economizar recursos financeiros (Santos e Bordado, 2018).

Diante do exposto, este estudo investiga a obtenção do poder calorífico superior (PCS) por meio do modelo preditivo de redes neurais artificiais (RNA's), bem como a utilização de equações características que têm como base a análise imediata de biomassas, como forma de garantir uma maior agilidade e precisão na aquisição dos resultados. Este trabalho utilizou um banco de dados com 100 biomassas ao redor do mundo para o treinamento do modelo numérico empregado e para a etapa de teste e validação das redes, aplicou-se 15 biomassas regionais.

2. MATERIAIS E MÉTODOS

2.1. Construção do Modelo Matemático

Um banco de dados com 115 biomassas foi utilizado na elaboração do modelo. Cerca de 100 amostras, disponíveis no estudo de García *et al.* (2012a), representaram os dados de treinamento e validação das RNA's, que contém o percentual da composição por análise imediata – teores de umidade (TU), materiais voláteis (MV), carbono fixo (CF) e cinzas (CZ) – e o PCS. As 15 biomassas restantes foram utilizadas para o teste final e validação dos modelos e estão presentes na Tabela 1.

Tabela 1. Banco de dados para testes e validação.

Biomassas	TU (%)	MV (%)	CF (%)	CZ (%)	Referências
Casca de amendoim	7,46	57,96	21,45	12,9	Braz (2014)
Casca de arroz	8,15	47,67	14,97	29,13	
Casca de café	9,32	61,21	22,63	6,6	
Talo de milho	7,53	76,79	16,02	7,19	
Serragem de pinus	7,32	70,23	18,29	4,05	Braz (2014), Cruz <i>et al.</i> (2018)
Casca de grão-de-bico	n.a.	79,7	16,32	3,98	Ozyuguran <i>et al.</i> (2018)
Casca de fava	n.a.	74,88	19,40	5,73	
Casca de cacau	n.a.	75,03	20,56	4,41	
Casca de noz	n.a.	82,98	16,12	0,90	
Resíduo de soja	n.a.	80,01	13,54	6,45	
Folha de poda urbana	8,68	66,43	21,71	3,17	Silva <i>et al.</i> (2021)
Galho de poda urbana	9,07	61,24	22,95	6,72	
Caule de milho	2,98	67,75	16,66	12,61	Liu <i>et al.</i> (2020)
Escama de peixe	11,34	35,16	7,59	45,91	Silva <i>et al.</i> (2019a)
Sementes de açaí	15,48.	79,93	18,68	1,39	Itai <i>et al.</i> (2014), Oliveira <i>et al.</i> (2021)

O modelo foi criado no *software* Matlab® versão 2020b, por meio da extensão *Deep Learning Machine*, na qual todas as redes tinham duas camadas de neurônios ocultas, pois segundo Silva *et al.* (2019b), tal configuração permite um maior mapeamento de informações das entradas para as saídas. A primeira camada oculta variou de 4 a 8 neurônios, e a segunda tinha 4 neurônios fixos. Desse modo, o modelo para a predição do PCS constitui-se de 5 RNA's, com 3 entradas da análise imediata das biomassas selecionadas, como mostrado na Figura 1.




Figura 1. Estrutura das RNA's onde n varia de 4 a 8 neurônios.

Como parâmetros de treinamento, utilizou-se a função de treinamento de *Levenberg-Marquardt* (*trainlm*) por ser considerada de alta precisão para estudos preditivos, conforme observada por Sharma e Venugopalan (2014). Além disso, foi definido um limite de 1000 iterações para o modelo, bem como uma função de ativação sigmoide, o que para Medeiros (2019) permitiu que as RNA's aprendessem e executassem tarefas mais complexas, como a predição de dados.

2.2. Análise Imediata

Para o cálculo teórico do PCS por análise imediata, foram analisadas 5 equações diferentes disponíveis no estudo de Braz (2014), as quais são mostradas na Tabela 2. As Eqs. (1), (2) e (3) estão no estudo de Nhuchhen e Salan (2012), e as Eqs. (4) e (5) nos estudos de Demirbas *et al.* (1997) e Parikh *et al.* (2005), respectivamente. De acordo com Braz (2014), o critério de escolha destas equações foi feito com base nos resultados obtidos na literatura e estimativa de erro relativo de aproximadamente 10%.

Tabela 2. Equações utilizadas para o cálculo do PCS teórico por meio de análise imediata (Adaptada de Braz, 2014).

#	Equações	Referências
1	$PCS (MJ kg^{-1}) = 20,7999 - 0,3214 \left(\frac{MV}{CF} \right) + 0,0051 \left(\frac{MV}{CF} \right)^2$ $- 11,2277 \left(\frac{CZ}{MV} \right) + 4,4953 \left(\frac{CZ}{MV} \right)^2$ $- 0,7223 \left(\frac{CZ}{MV} \right)^3 + 0,0383 \left(\frac{CZ}{MV} \right)^4$ $+ 0,0076 \left(\frac{CF}{CZ} \right)$	Nhuchhen e Salan (2012)
2	$PCS (MJ kg^{-1}) = 20,7623 - 0,4400 \left(\frac{MV}{CF} \right) + 0,0071 \left(\frac{MV}{CF} \right)^2$ $- 5,2902 \left(\frac{CZ}{MV} \right) + 4,4921 \left(\frac{CZ}{MV} \right)^2$ $+ 0,0143 \left(\frac{CF}{CZ} \right)$	Nhuchhen e Salan (2012)
3	$PCS (MJ kg^{-1}) = 19,2880 - 0,2135 \left(\frac{MV}{CF} \right) - 1,9584 \left(\frac{CZ}{MV} \right)$ $+ 0,0234 \left(\frac{CF}{CZ} \right)$	Nhuchhen e Salan (2012)
4	$PCS (MJ kg^{-1}) = 0,1905(MV) + 0,2521(CF)$	Demirbas <i>et al.</i> (1997)
5	$PCS (MJ kg^{-1}) = 0,1559(MV) + 0,3536(CF) - 0,0078(CZ)$	Parikh <i>et al.</i> (2005)

Segundo Nhuchhen e Salan (2012), e Parikh *et al.* (2005), para aplicar as equações que utilizam a análise imediata é necessário que as amostras estejam na base seca, ou seja, livres de umidade, exceto a umidade intrínseca das amostras. Dessa forma, o teor de umidade também não foi utilizado como informação de entrada no desenvolvimento das RNA's. Por outro lado, a Eq. (4) deve ser aplicada tanto na base seca como livre de cinzas.

2.3. Métricas de Avaliação

Para avaliar o desempenho das equações por análise imediata e das RNA's bem como a acurácia nos resultados obtidos após a etapa de teste final, foram utilizados vários tipos de erros: *Average Absolute Error* (AAE), *Average Bias Error* (ABE) e *Mean Absolute Error* (MAE), usados com o mesmo propósito por diversos autores (García *et al.*, 2014b; Nhuchhen e Afzal, 2017; Yin, 2011; Han *et al.*, 2017). O AAE avalia a acurácia do resultado e a proximidade deste ao valor estimado, ou seja, valores baixos do AAE indicam uma boa acurácia. Por outro lado, valores positivos para o ABE indicam valores superestimados e de forma análoga, os valores negativos sugerem valores subestimados. Já o MAE representa a quantidade de erro entre os valores estimados e preditos, na mesma unidade (Monteiro *et al.*, 2021).

Valores próximos a zero do AAE e ABE demonstram que o modelo é considerado confiável, bem como valores baixos do MAE indicam uma melhor precisão com o resultado estimado (Ozyuguran *et al.*, 2018). Os erros AAE, ABE e MAE são definidos por meio das Eqs. (6), (7) e (8), respectivamente.

$$AAE(\%) = \frac{1}{N} \sum_{i=1}^N \left| \frac{PCS_{(p)i} - PCS_{(e)i}}{PCS_{(e)i}} \right| \times 100 \quad (6)$$

$$ABE(\%) = \frac{1}{N} \sum_{i=1}^N \left(\frac{PCS_{(p)i} - PCS_{(e)i}}{PCS_{(e)i}} \right) \times 100 \quad (7)$$

$$MAE(MJ \text{ kg}^{-1}) = \frac{1}{N} \sum_{i=1}^N |PCS_{(p)i} - PCS_{(e)i}| \quad (8)$$

onde: N representa o número de amostras, e os índices p e e são os valores preditos e experimentais, respectivamente.

Os valores da regressão linear (R) extraídos pelo Matlab[®] também foram utilizados para avaliar a acurácia dos valores preditos, bem como foi analisado a diferença entre as médias dos valores preditos e experimentais mostrada por meio da Eq. (9).

$$\text{Diferença absoluta entre as médias (\%)} = \left| 1 - \frac{M_{(p)}}{M_{(e)}} \right| \times 100 \quad (9)$$

onde: $M_{(x)}$ representa a média dos valores preditos (p) ou experimentais (e).

3. RESULTADOS E DISCUSSÃO

A Tabela 3 mostra os resultados do poder calorífico superior (PCS) para as biomassas selecionadas, os quais foram obtidos pelas redes neurais artificiais após a etapa de teste e validação com os respectivos desvios padrão. Em média, o modelo RNA 8x4 (com 8 neurônios na primeira camada) foi o mais preciso dentre os 5 modelos verificados com um valor de 17,44 MJ kg⁻¹ para o PCS predito.

Tabela 3. Resultados dos testes e validação das RNA's.

Biomassas	PCS experimental (MJ kg ⁻¹)	PCS predito (MJ kg ⁻¹)				
		RNA 4x4	RNA 5x4	RNA 6x4	RNA 7x4	RNA 8x4
Casca de amendoim	16,52	16,53±0,01	16,00±0,37	15,71±0,57	18,18±1,17	16,81±0,21
Casca de arroz	15,39	15,31±0,06	15,92±0,37	13,13±1,59	17,10±1,21	15,41±0,02
Casca de café	17,28	15,88±0,99	17,89±0,43	15,69±1,12	18,17±0,63	17,29±0,01
Talo de milho	16,55	16,59±0,03	16,19±0,26	15,70±0,60	18,17±1,15	16,62±0,05
Serragem de pinus	20,13	19,43±0,49	20,84±0,50	15,75±3,10	18,17±1,39	20,08±0,04
Casca de grão-de-bico	18,26	18,41±0,10	18,23±0,02	15,70±1,81	18,17±0,06	18,03±0,16
Casca de fava	16,8	16,80±0,00	20,46±2,59	15,65±0,81	18,17±0,97	17,06±0,18
Casca de cacau	17,85	18,11±0,19	20,78±2,07	15,53±1,64	18,17±0,23	18,79±0,66
Casca de noz	20,03	20,05±0,01	18,42±1,14	15,73±3,04	18,17±1,31	20,18±0,11
Resíduo de soja	19,26	12,95±4,46	18,39±0,62	15,82±2,43	17,75±1,07	19,09±0,12
Folha de poda urbana	20,86	20,86±0,00	19,04±1,29	15,34±3,90	18,18±1,90	20,31±0,39
Galho de poda urbana	18,65	18,63±0,01	18,90±0,18	14,53±2,91	18,17±0,34	18,33±0,23
Caule de milho	16,79	16,72±0,05	18,58±1,27	15,74±0,74	18,18±0,98	16,81±0,01
Escama de peixe	9,08	9,28±0,14	13,23±2,93	10,59±1,07	9,08±0,00	9,08±0,00
Semente de açaí	18,14	17,99±0,10	18,36±0,16	16,11±1,44	18,26±0,09	17,70±0,31
Média	17,44±0,22	16,90±0,38	18,08±0,46	15,12±1,64	17,47±0,02	17,44±0,04

O desempenho das RNA's é mostrado na Tabela 4. Baseado na análise de erros estatísticos, o modelo RNA 8x4 apresentou um melhor desempenho, com os menores erros AAE (0,06 %), ABE (0,06%) e MAE (3,40×10⁻⁴ MJ kg⁻¹), indicando uma ótima acurácia dos resultados, com os valores preditos do PCS minimamente acima do estimado e excelente precisão, respectivamente. Além disso, o coeficiente de regressão linear R teve um valor de 0,99, indicando uma excelente relação entre os valores preditos e experimentais do poder calorífico superior (PCS).

Tabela 4. Análise do desempenho para o modelo matemático utilizado.

Tipos de erros	RNA 4x4	RNA 5x4	RNA 6x4	RNA 7x4	RNA 8x4
Diferença absoluta entre as médias (%)	3,08	3,69	13,33	0,19	0,00
AAE (%)	2,76	5,39	11,88	0,81	0,06
ABE (%)	-2,76	5,39	-11,88	0,81	0,06
MAE (MJ kg ⁻¹)	0,54	0,64	2,32	0,03	3,40×10⁻⁴
Regressão linear	0,83	0,77	0,82	0,85	0,99

A Figura 2 ilustra a regressão linear do modelo RNA 8x4, com 99% de precisão do PCS predito em relação ao PCS experimental. A maioria dos valores observados está sobre a linha de centro preta sólida e todos os valores estão dentro da margem de erro de $\pm 5\%$ demonstrada pelas linhas pretas tracejadas.




Figura 2. PCS experimental versus PCS predito com uma margem de 5% de erro.

A Tabela 5 mostra os resultados do cálculo teórico do poder calorífico superior (PCS) das biomassas, o qual foi obtido por meio das equações que utilizam como base a análise imediata. Em média, a Eq. (4) foi a mais precisa dentre as 5 equações apresentadas, ou seja, apresentou um valor de $17,40 \text{ MJ kg}^{-1}$ para o PCS calculado.

Tabela 5. Cálculo do PCS teórico por análise imediata.

Biomassas	PCS experimental (MJ kg^{-1})	PCS teórico (MJ kg^{-1})				
		Equação 1	Equação 2	Equação 3	Equação 4	Equação 5
Casca de amendoim	16,52	$17,70 \pm 0,83$	$18,69 \pm 1,54$	$18,32 \pm 1,27$	$16,45 \pm 0,05$	$16,52 \pm 0,00$
Casca de arroz	15,39	$14,49 \pm 0,64$	$17,89 \pm 1,76$	$17,44 \pm 1,45$	$12,86 \pm 1,79$	$12,50 \pm 2,05$
Casca de café	17,28	$18,83 \pm 1,10$	$19,16 \pm 1,33$	$18,58 \pm 0,92$	$17,37 \pm 0,06$	$17,49 \pm 0,15$
Talo de milho	16,55	$18,38 \pm 1,29$	$18,39 \pm 1,30$	$18,14 \pm 1,12$	$18,67 \pm 1,50$	$17,58 \pm 0,73$
Serragem de pinus	20,13	$19,04 \pm 0,77$	$18,95 \pm 0,83$	$18,46 \pm 1,18$	$17,99 \pm 1,51$	$17,38 \pm 1,94$
Casca de grão-de-bico	18,26	$18,83 \pm 0,41$	$18,59 \pm 0,23$	$18,25 \pm 0,01$	$19,30 \pm 0,73$	$18,16 \pm 0,07$
Casca de fava	16,8	$18,83 \pm 1,43$	$18,84 \pm 1,44$	$18,40 \pm 1,13$	$19,16 \pm 1,67$	$18,49 \pm 1,19$
Casca de cacau	17,85	$19,09 \pm 0,87$	$19,02 \pm 0,83$	$18,50 \pm 0,46$	$19,48 \pm 1,15$	$18,93 \pm 0,77$
Casca de noz	20,03	$19,30 \pm 0,52$	$18,88 \pm 0,81$	$18,59 \pm 1,02$	$19,87 \pm 0,11$	$18,63 \pm 0,99$
Resíduo de soja	19,26	$18,22 \pm 0,74$	$18,04 \pm 0,86$	$17,92 \pm 0,95$	$18,66 \pm 0,43$	$17,21 \pm 1,45$
Folha de poda urbana	20,86	$19,39 \pm 1,04$	$19,34 \pm 1,08$	$18,70 \pm 1,53$	$18,13 \pm 1,93$	$18,01 \pm 2,02$
Galho de poda urbana	18,65	$18,83 \pm 0,12$	$19,16 \pm 0,36$	$18,59 \pm 0,04$	$17,45 \pm 0,85$	$17,61 \pm 0,74$
Caule de milho	16,79	$17,65 \pm 0,61$	$18,28 \pm 1,05$	$18,09 \pm 0,92$	$17,11 \pm 0,22$	$16,35 \pm 0,31$
Escama de peixe	9,08	$10,93 \pm 1,31$	$19,63 \pm 7,46$	$15,78 \pm 4,74$	$8,61 \pm 0,33$	$7,81 \pm 0,90$
Semente de açaí	18,14	$19,43 \pm 0,91$	$19,11 \pm 0,69$	$18,66 \pm 0,36$	$19,94 \pm 1,27$	$19,06 \pm 0,65$
Média	$17,44 \pm 0,22$	$17,93 \pm 0,44$	$18,80 \pm 0,95$	$18,16 \pm 1,79$	$17,40 \pm 0,83$	$16,78 \pm 0,17$

Pela análise dos erros estatísticos das equações na Tabela 6, a Eq. (4) teve o melhor desempenho em 4 avaliações, obtendo a menor diferença entre as médias dos valores do PCS calculado e experimental, bem como os menores erros AAE (0,15 %), ABE (-0,15%) e MAE ($0,04 \text{ MJ kg}^{-1}$), indicando uma melhor equivalência em média dos valores calculados em comparação aos valores experimentais, boa acurácia dos resultados, valores ligeiramente abaixo do estimado e ótima precisão, respectivamente. Entretanto, o melhor coeficiente de regressão (R) foi obtido por meio da Eq. (1), com 90% de precisão entre os valores calculados e experimentais para o PCS.

Tabela 6. Avaliação do desempenho por meio da análise imediata.

Tipos de erros	Equação 1	Equação 2	Equação 3	Equação 4	Equação 5
Diferença absoluta entre as médias (%)	2,80	7,79	4,14	0,22	3,77
AAE (%)	3,70	11,99	7,05	0,15	3,85
ABE (%)	3,70	11,99	7,05	-0,15	-3,85
MAE (MJ kg ⁻¹)	0,49	1,36	0,72	0,04	0,66
Regressão linear	0,90	-0,14	0,89	0,84	0,86

4. CONCLUSÃO

Este estudo apresentou uma investigação do Poder Calorífico Superior (PCS) de diversas biomassas para serem utilizadas como biocombustíveis na geração de energia renovável, a partir de modelos numéricos preditivos como alternativa para o uso de equações características, que utilizam a análise imediata desses resíduos. Foram desenvolvidas modelagens numéricas, levando em consideração o percentual da análise imediata das amostras como dados de entrada. A análise de erros estatísticos demonstrou uma ótima acurácia de precisão da rede neural artificial (RNA), com baixos valores para o AAE e ABE (0,06%), e MAE ($3,40 \times 10^{-4}$ MJ kg⁻¹) bem como um excelente coeficiente de regressão linear (R) com precisão de 99% em relação aos valores preditos e experimentais.

De modo geral, o modelo RNA 8x4 (8 neurônios na primeira camada oculta e 4 neurônios na segunda camada) apresentou o melhor desempenho e uma excelente confiabilidade para estimar os valores para o PCS, com uma acurácia de resultados na margem de confiança de $\pm 5\%$. Portanto, justifica-se a utilização de modelos numéricos para a predição do PCS de biomassas como uma alternativa viável frente a métodos experimentais e teóricos, no qual a obtenção de tal potencial energético é essencial para a utilização desses biocombustíveis, tendo em vista que a rede neural artificial se mostrou confiável e com ótima precisão nos resultados.

5. AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES (88887.510222/2020-00 e 88887.621361/2021-00), Fundação de Apoio a Pesquisa, Desenvolvimento Científico e Tecnológico do Maranhão – FAPEMA (00957/19 e 01661/21) e Conselho Nacional para Desenvolvimento Científico e Tecnológico - CNPq (426162/2018-8) pelo suporte financeiro, à Universidade Federal do Maranhão (UFMA) e Instituto Federal de Educação, Ciência e Tecnologia do Maranhão (IFMA) pelo apoio técnico e profissional.

6. REFERÊNCIAS

- Akkaya, A.V., 2009. “Proximate analysis based multiple regression models for higher heating value estimation of low rank coals”. *Fuel Processing Technology*, Vol. 90, No. 2, pp. 165–170. doi:10.1016/j.fuproc.2008.08.016.
- Bi, H., Wang, C., Lin, Q., Jiang, X., Jiang, C. and Bao, L., 2020. “Combustion behavior, kinetics, gas emission characteristics and artificial neural network modeling of coal gangue and biomass TG-FTIR”. *Energy*, Vol. 213, pp. 1-13. doi:10.1016/j.energy.2020.118790.
- Boumanchar, I., Charafeddine, K., Chhiti, Y., M'hamdi, A.F., Sahibed-Dine, A. and Bentiss, F., 2019. “Biomass higher heating value prediction from ultimate analysis using multiple regression and genetic programming”. *Biomass Convers Biorefinery*, Vol. 9, No. 3, pp. 499–509. doi:10.1007/s13399-019-00386-5.
- Braz, C.E.M., 2014. “Caracterização de biomassa lignocelulósica para uso em processos térmicos de geração de energia”. Dissertação (Mestrado), Universidade Estadual Paulista, Instituto de Química, 116p.
- Cruz, G., Braz, C.E.M., Ávila, I., Crnkovic, P.M., 2018. “Physico-chemical properties of Brazilian biomass: potential applications as renewable energy source”. *African Journal of Biotechnology*, Vol. 1, pp. 1-19. doi:10.5897/AJB2017.16296.
- Dermirbas, A., Gullu, D., Çaglar, A. and Akdeniz, F., 1997. “Estimation of calorific values of fuels from lignocellulosics”. *Energy Sources*, Vol. 19, No. 8, pp. 765-770. doi:10.1080/00908319708908888.
- Elneel, R., Anwar, S. and Ariwahjoedi, B., 2013. “Prediction of heating values of oil palm fronds from ultimate analysis”. *Journal of Applied Sciences*, Vol. 13, No. 3, pp. 491–496. doi: 10.3923/jas.2013.491.496.
- EPE, Empresa de Pesquisa Energética. RELATÓRIO SÍNTESE 2020.2021. Disponível em: <<https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos>>.
- García, R., Pizarro, C., Lavín, A.G. and Bueno, J. L., 2012a. “Characterization of spanish biomass wastes for energy use”. *Bioresource Technology*, Vol. 103, p. 249-258. doi:10.1016/j.biortech.2011.10.004.
- Garcia, R., Pizarro, C., Lavín, A.G. and Bueno, J.L., 2014b. “Spanish biofuels heating value estimation. Part I: Ultimate analysis data”. *Fuel*, Vol. 117, No. Part B, pp. 1130-1138. doi:10.1016/j.fuel.2013.08.048.
- Han, J., Yao, X., Zhan, Y., Oh, S.-Y., Kim, L.-H. and Kim, H.-J., 2017. “A method for estimating higher heating value of biomass-plastic fuel”. *Journal of Energy Institute*, Vol. 90, No. 2, pp. 331-335. doi:10.1016/j.joei.2016.01.001.
- Itai, Y., Santos, R., Branquinho, M., Malico, I., Ghesti, G.F. and Brasil, A.M., 2014. “Numerical and experimental assessment of a downdraft gasifier for electric power in Amazon using açai seed (*Euterpe oleracea* Mart.) as a fuel”. *Renewable Energy*, Vol. 66, pp. 662-669. doi:10.1016/j.renene.2014.01.007.

- Lela, B., Barisic, M., and Nizetic, S., 2016. "Cardboard/sawdust briquettes as biomass fuel: Physical-mechanical and thermal characteristics". *Waste Management*, Vol. 47, No. Part B, pp. 236-245. doi:10.1016/j.wasman.2015.10.035.
- Liu, H., Zhang, S., Feng, S., Jia, C., Guo, S., Sun, B. and Wang, Q., 2020. "Combustion characteristics and typical pollutant emissions of cornstalk blending with municipal sewage sludge". *Environmental Science and Pollution Research*, Vol. 28, pp. 9792-9805. doi:10.1007/s11356-020-11463-y.
- Mateus, M.M., Bordado, J.M. and Santos, R.G., 2021. "Estimation of higher heating value (HHV) of bio-oils from thermochemical liquefaction by linear correlation". *Fuel*, Vol. 302, No. 121149, pp. 1-5. doi:10.1016/j.fuel.2021.121149.
- Medeiros, I.E.A., 2019. "Aplicação de redes neurais artificiais para a previsão de demanda em subestações de distribuição considerando a influência da temperatura". Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica), Universidade Federal da Paraíba, João Pessoa, 73p.
- Monteiro, T.O., Barradas Filho, A.O. and Cruz, G., 2021. "Determinação do poder calorífico de biomateriais energéticos empregando redes neurais artificiais". In *Proceedings of the 2nd (ICAIC) International Conference for Academia and Industry Co-operation & 2nd (IMMSEM) International Meeting in Materials Science and Engineering of Maranhão*. ICAIC, São Luís, Brasil. doi:10.29327/2ndicaic2ndimmsem2020.420149.
- Nhuchhen, D.R. and Afzal, M.T., 2017. "HHV Predicting Correlations for Torrefied Biomass Using Proximate and Ultimate Analyses". *Bioengineering*, Vol. 4, No. 7, pp. 1-15. doi:10.3390/bioengineering4010007.
- Nhuchhen, D.R. and Salan, P.A., 2012. "Estimation of higher heating value of biomass from proximate analysis: a new approach". *Fuel*, Vol. 99, pp. 55-63. doi:10.1016/j.fuel.2012.04.015.
- Oladosu, K.O., Asafa, T.B., Alade, A.O. and Erinsho, M.F., 2021. "Artificial neural network prediction of CO emission and ash yield from co-combustion of empty fruit bunch, palm kernel shell and kaolin". *Environmental Science and Pollution Research*, Vol. 28, pp. 42596-42608. doi:10.1007/s11356-021-13783-z.
- Oliveira, L.d.S., Silva, A.V.S., Conconi, C.C., Gomes, E.d.B., Bizzo, W.A., Cruz, G., 2021. "Thermal degradation of Açaí seeds and potential application in thermochemical processes". *Revista Produção e Desenvolvimento*, Vol. 7, No. 531, pp. 1-18. doi:10.32358/rpd.2021.v7.531.
- Ozyuguran, A., Yaman, S. and Kuçukbayrak, S., 2018. "Prediction of calorific value of biomass based on elemental analysis". *International Advanced Researches and Engineering Journal*, Vol. 2, No. 3, pp. 254-260. e-ISSN: 2618-575X.
- Parikh, J., Channiwalla, S.A. and Ghosal, G.K., 2005. "A correlation for calculating HHV from proximate analysis of solid fuels". *Fuel*, Vol. 84, No. 5, pp. 487-494. doi:10.1016/j.fuel.2004.10.010.
- Santos, R.G. and Bordado, J.M., 2018. "Design of simplified models for the estimation of higher heating value of refused derived fuels". *Fuel*, Vol. 212, pp. 431-436. doi:10.1016/j.fuel.2017.10.062.
- Silva, A.V., Torquato, L.D.M. and Cruz, G., 2019a. "Potential application of fish scales as feedstock in thermochemical processes for the clean energy generation". *Waste Management*, Vol. 100, pp. 91-100. doi:10.1016/j.wasman.2019.09.007.
- Silva, I., Spatti, D.H. and Flauzino, R.A., 2019b, Redes neurais artificiais para engenharia e ciências aplicadas. Ed. Artliber Ltda, São Paulo, Brasil, 429p.
- Silva, J.B., Torquato, L.D.M., Crnkovic, P.M. and Cruz, G., 2021. "Investigation of the urban pruning wastes as biofuels and possible utilization in thermal systems". *Brazilian Journal of Development*, Vol. 7, No. 3, pp. 24730-24750. doi:10.34117/bjdv7n3-265.
- Sharma, B. and Venugopalan, K., 2014. "Comparison of Neural Network Training Functions for Hematoma Classification in Brain CT Images". *IOSR Journal of Computer Engineering*, Vol. 16, No. 1, pp. 31-35. e-ISSN: 2278-0661.
- Soler, A., Conesa, J.A., Iñiguez, M.E. and Ortuño, N., 2018. "Pollutant formation in the pyrolysis and combustion of materials combining biomass and e-waste". *Science of the Total Environment*, Vol. 622, No. 623, pp. 1258-1264. doi:10.1016/j.scitotenv.2017.12.068.
- Soponpongpiat, N., Sittikul, D., Sae-Ueng, U., 2015. "Higher heating value prediction of torrefaction char produced from non-woody biomass". *Front. Energy*, Vol. 9, pp. 461-471. doi:10.1007/s11708-015-0377-3.
- Yin, C.-Y., 2011. "Prediction of higher heating values of biomass from proximate and ultimate analyses". *Fuel*, Vol. 90, No. 3, pp. 1128-1132. doi:10.1016/j.fuel.2010.11.031.

7. RESPONSABILIDADE AUTORAL

O(s) autor(es) é(são) o(s) único(s) responsável(is) pelo conteúdo deste trabalho.

INVESTIGATION OF HIGHER HEAT VALUE (HHV) OF DIFFERENT BIOMASSES BASED ON PROXIMATE ANALYSIS USING ARTIFICIAL NEURAL NETWORKS (ANN)

Thalyssa Monteiro, thalyssamonteiro@gmail.com¹

Glauber Cruz, cruz.glauber@ufma.br^{1,2}

¹Postgraduate Program in Mechanical Engineering (PPME), Federal Institute of Education, Science and Technology of Maranhao (IFMA), São Luis, Maranhão, Brazil

²Process and Thermal Systems Laboratory, Department of Mechanical Engineering, Federal University of Maranhao (UFMA), São Luis, Maranhão, Brazil

Abstract. *This study carried out the determination of the Higher Heat Value (HHV) of several biomasses, with a database composed by 115 lignocellulosic materials, through numerical modeling, and using artificial neural networks (ANN's). Five equations known in the specialized literature were used to calculate the HHV by means of proximate analysis of the different biomasses studied. For evaluating the better prediction model, five precision criteria were established: difference between the smallest averages of predicted and estimated values, Average Absolute Error (AAE), Average Bias Error (ABE), Mean Absolute Error (MAE) and linear regression coefficient (R). It was observed that one of the five chosen equations presented a better performance for the four criteria mentioned above, except for the linear regression coefficient, which presented a precision of 84.20%. On the other hand, the RNA 8x4 model obtained a precision of 99% in relation to the estimated and predicted values of the HHV of the samples, $17.44 \pm 0.22 \text{ MJ kg}^{-1}$ and $17.44 \pm 0.04 \text{ MJ kg}^{-1}$, respectively, obtaining the better performance for the five criteria. The results showed that the numerical prediction applied presented an excellent performance, good accuracy and can serve as a viable alternative to replace and obtain the HHV of different biomasses in the absence of certain experimental procedures and based on a set of equations.*

Keywords: *lignocellulosic materials, energetic power, numerical modeling, characteristic equations.*