

MODELO PREDITIVO PARA AVALIAÇÃO DO POTENCIAL ENERGÉTICO DE BLENDAS (ESCAMAS DE PEIXES E RESÍDUOS ALIMENTARES) UTILIZANDO REDES NEURAS ARTIFICIAIS

PREDICTIVE MODEL FOR EVALUATION OF THE ENERGY POTENTIAL OF BLENDS (FISH SCALES AND FOOD RESIDUES) USING ARTIFICIAL NEURAL NETWORKS

Mariana da Silva Melo¹

Thalyssa Oliveira Monteiro²

Glauber Cruz³

Resumo: Considerando o cenário pandêmico, a fome agravou-se, e uma grande parcela dos brasileiros vive em situação de extrema insegurança alimentar. Paralelamente, a piscicultura é evidente no litoral brasileiro e a comercialização desta evidencia um descarte inadequado desses resíduos, sendo uma alternativa a aplicabilidade como biomassa na produção de energia renovável. 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. A aquisição dessas ferramentas torna os processos de termoconversão bastante onerosos. Por outro lado, diversos modelos numéricos são amplamente utilizados, como uma alternativa promissora a esses empecilhos e considerados confiáveis. O presente trabalho objetiva uma análise comparativa entre o modelo experimental e as redes neurais artificiais (RNAs) para aquisição do poder calorífico das amostras puras de escamas de peixes (100%EP) e resíduos alimentares (100%RA) e as misturas nas proporções: 75%EP:25%RA, 50%EP:50%RA e 25%EP:75%RA. Para avaliar o melhor modelo de predição foram estabelecidos quatro critérios: Average Absolute Error (AAE), Average Bias Error (ABE), Mean Absolute Error (MAE) e o coeficiente de regressão linear (R). O modelo preditivo apresentou 98,02% de exatidão em relação ao PCS experimental (13,61±0,20 e 13,68±1,42 MJ kg⁻¹, respectivamente), obtendo um melhor desempenho para os quatro critérios estabelecidos. Os resultados mostraram que a RNA obteve um excelente desempenho, podendo servir como alternativa viável para determinação do poder calorífico superior de biomassas.

Palavras-chave: Biomassas. Insegurança Alimentar. Energias Renováveis.

Abstract: Considering the pandemic scenario, hunger has worsened, with a large portion of Brazilians in a situation of extreme food insecurity. At the same time, fish farming is evident on the Brazilian coast and commercialization shows an inadequate disposal of these residues, being an alternative to the applicability as biomass in the renewable energy production. These residues need to present a sufficient energy potential for the bioenergy production. Some specific equipment or processes are used to extract biofuel, as well as to quantify the calorific value of these biomasses. The acquisition of these tools makes the thermoconversion processes quite expensive. On the other hand, several numerical models are widely used, as a promising alternative to these obstacles and considered reliable. The present work aims at a comparative analysis between the theoretical model (Dulong Equation) and artificial neural networks (ANNs) for the acquisition of the calorific value of pure samples of fish scales (100%FS) and food residues (100%FR), and mixtures in the proportions: 75%FS:25%FR, 50%FS:50%FR, and 25%FS:75%FR. To evaluate the better prediction model, four criteria were established: Average Absolute Error (AAE), Average Bias Error (ABE), Mean Absolute Error (MAE) and the linear regression coefficient (R). The predictive model showed 98.02% accuracy in relation to the PCS experimental (13.61±0.20 and 13.68±1.42 MJ kg⁻¹, respectively), obtaining a better performance for the four established criteria. The results showed that the ANN obtained an excellent performance, being able to serve as a viable alternative for the determination of higher heat value of biomasses.

Keywords: Biomasses. Food Insecurity. Renewable Energies.

1 - Graduada em Engenharia Química pela Universidade Federal do Maranhão (UFMA). Lattes: 6122007345010711.
E-mail: melo.mariana@discente.ufma.br.

2 - Engenheira Mecânica pela Universidade Estadual do Maranhão (UEMA); Mestranda em Engenharia Mecânica pelo Instituto Federal de Educação, Ciência e Tecnologia do Maranhão (IFMA). Lattes: 6234437371051992.
ORCID: <https://orcid.org/0000-0002-2099-6891>. E-mail: thalyssamonteiro@acad.ifma.br.

3 -Doutor em Engenharia Mecânica pela Universidade de São Paulo (USP). Professor Adjunto III do Departamento de Engenharia Mecânica da Universidade Federal do Maranhão (UFMA). Lattes: 5194234696644344.
ORCID: <https://orcid.org/0000-0003-0468-0553X>. E-mail: cruz.glauber@ufma.br.

Introdução

É de conhecimento geral que o Brasil exibe dentre as principais mazelas da sociedade moderna, o cenário do desperdício alimentar, sendo este um fator somático em meio à situação de extrema pobreza e a desvalorização do preservacionismo dos recursos naturais (DE OLIVEIRA RIGAUD *et al.*, 2019).

O consumo dos recursos naturais pelos seres humanos sempre foi o fundamento da sobrevivência material dos povos, uma vez que não apresentavam maiores preocupações ou ações para a promoção de um tratamento adequado, além da ausência de uma redução ou eliminação de resíduos. Nesse sentido, o inovador é que desde a Revolução Industrial, presencia-se uma passagem do consumo necessário para a sobrevivência e bem-estar para a cultura do consumismo (COSTA *et al.*, 2018).

A fome sempre foi um problema grave no Brasil, todavia, com a pandemia da COVID-19, o cenário foi fortemente agravado (DE ALIMENTOS BANCO, 2022). Antes da disseminação do SARS-CoV-2, havia 57 milhões de pessoas vivendo em insegurança alimentar no país, ou seja, desprovidas de acesso pleno e permanente à alimentos (SCHAPPO, 2021). Ademais, em abril de 2021, cerca de 116,8 milhões de pessoas passaram a viver em insegurança alimentar, sendo que 43,3 milhões não possuíam acesso aos alimentos em uma quantidade suficiente (insegurança alimentar moderada) e 19 milhões passavam fome (insegurança alimentar grave) (DE PAULA *et al.*, 2021).

Paralelo ao cenário apresentado destaca-se a produção de pescados no litoral do Estado do Maranhão, como uma das principais fontes de renda de uma parcela significativa da população, sendo esta prática representativa econômica e culturalmente como símbolo de riqueza e resistência local (DINIZ *et al.*, 2020). Contudo, o consumo de pescados na região Nordeste gera enormes quantidades de resíduos (vísceras, nadadeiras e/ou escamas de peixes), sendo esses resíduos orgânicos descartados de forma desordenada ou não planejada em lugares ermos (SILVA *et al.*, 2019).

Nesse contexto, o ramo das energias renováveis, atrelado aos processos termoquímicos como a combustão, pirólise e/ou gaseificação, enfatiza a possibilidade do aproveitamento de resíduos orgânicos, como possíveis fontes geradoras de energias renováveis. O conceito de bioenergia vem sendo empregado na obtenção de energia a partir das diferentes biomassas, que podem ser transformadas em biocombustíveis, biogás, carvão vegetal ou mesmo por meio da queima direta de resíduos vegetais, dentre outras formas possíveis. 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; SOPONPONGPIPAT *et al.*, 2015; AKKAYA, 2009; NHUCHHEN, AFZAL, 2017). Ademais, modelos numéricos estão sendo cada vez mais utilizados 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, BORDADO, 2018).

Diante do exposto, este estudo investigou a obtenção do poder calorífico superior (PCS) por meio de um modelo preditivo de redes neurais artificiais (RNAs), bem como a utilização de equações

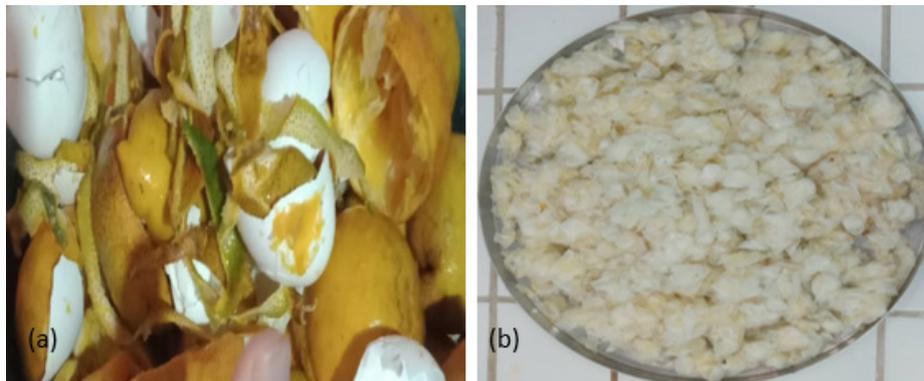
características que têm como base a análise elementar das misturas (blendas) de resíduos pesqueiros e alimentícios, como forma de garantir uma maior agilidade e precisão na aquisição dos resultados. Este trabalho utilizou um banco de dados com 27 (vinte e sete) biomassas ao redor do mundo para o treinamento do modelo numérico empregado e para a etapa de teste e validação das redes, aplicou-se 5 (cinco) amostras regionais constituídas de blendas de escamas de peixes (EP) e resíduos alimentícios (RA) nas seguintes proporções: 100% EP; 75%EP:25%RA; 50%EP:50%RA; 25%EP:75%RA e 100% RA.

Metodologia

Coleta e preparação das amostras

Para a realização das análises, realizou-se a etapa de coleta das amostras puras em locais com grande disposição e distribuição. As escamas de peixes (Figura 1) foram coletadas no Mercado do Peixe, localizado na região central da cidade de São Luís (Estado do Maranhão - Brasil), e os resíduos de alimentos na CEASA (Centrais de Abastecimento S/A) da capital maranhense, por intermédio da colaboração dos trabalhadores locais que realizaram uma seleção diária de cascas, bagaços e resíduos gerais de frutas e legumes.

Figura 1. Etapas de tratamento para as amostras de escamas de peixes e resíduos alimentícios, respectivamente: (a) lavagem e (b) secagem



Fonte: Os autores (2021).

A fim de deixar o conteúdo mais heterogêneo, os resíduos pesqueiros e alimentícios utilizados nesta pesquisa não foram previamente definidos. As amostras coletadas passaram separadamente por três lavagens em água corrente para eliminação total das impurezas existentes. A seguir, foram levadas à estufa para secagem (temperatura média $\approx 60^\circ\text{C}$ por 48 h) e para liberação do excedente de umidade; foram também submetidas à moagem em um moinho de facas por 2 h para redução da granulometria e posterior peneiramento para seleção das amostras em tamanhos médios de partículas ($\approx 328\ \mu\text{m}$) e por fim, o preparo das blendas nas seguintes proporções: 100%EP; 75%EP:25%RA; 50%EP:50%RA; 25%EP:75%RA e 100%RA.

Preparação do banco de dados

Um banco de dados com 60 (sessenta) biomassas foi utilizado na elaboração do modelo. Cerca de 55 (cinquenta e cinco) amostras, disponíveis no estudo de García *et al.* (2012a), representaram os dados de treinamento das RNAs, que contém o percentual da composição por análise elementar – teores de carbono (C), hidrogênio (H), nitrogênio (N), enxofre (S) e oxigênio (O) – e o PCS.

O modelo foi criado no *software* Matlab® versão 2020b, por meio da extensão *nntool*, na qual todas as redes neurais tinham duas camadas de neurônios ocultas, pois tal configuração permite um maior mapeamento de informações das entradas para as saídas (SILVA *et al.*, 2019).

As 5 (cinco) amostras restantes foram utilizadas para o teste final e validação dos modelos e estão presentes na Tabela 1 com as proporções de biomassas utilizadas.

Tabela 1. Análise Elementar das *blends* utilizadas no banco de dados de teste para predição do PCS

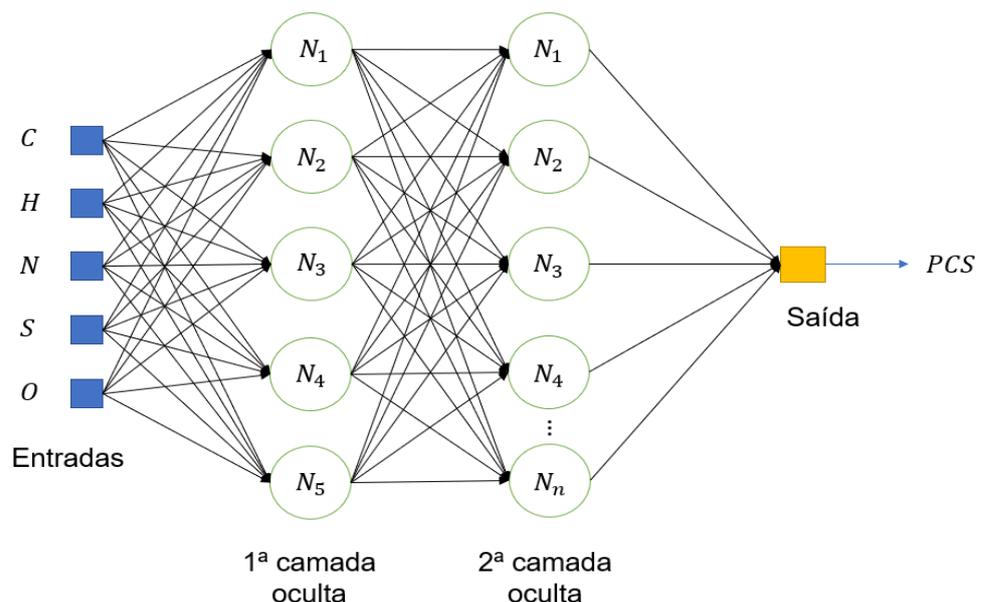
Amostras	C (%)	H (%)	N (%)	S (%)	O (%)
100%RA	39,87	6,25	1,67	n.d.	52,21
75%RA:25%EP	36,98	5,89	4,09	n.d.	53,04
50%RA:50%EP	33,26	4,91	6,88	0,11	54,84
25%RA:75%EP	33,64	4,72	7,96	0,09	53,59
100%EP	20,32	3,52	6,31	0,79	69,06

n.d.: não detectado ou abaixo do limite de detecção do equipamento.

Fonte: Os autores (2022).

Tal configuração permite um maior mapeamento de informações das entradas para as saídas. A primeira camada oculta apresenta 5 (cinco) neurônios e a segunda variava de 5 (cinco) a 9 (nove) neurônios fixos. Desse modo, o modelo para a predição do PCS constitui-se de 5 (cinco) RNAs, com 5 (cinco) entradas da análise elementar das biomassas selecionadas, como mostrado na Figura 2.

Figura 2. Estrutura das RNAs criadas para predição do PCS, onde *n* é o número de neurônios, variando de 5 a 9 neurônios na camada oculta



Fonte: Os autores (2022).

Como parâmetros de treinamento, utilizou-se a função de treinamento de *Levenberg-Marquardt* (*trainlm*) por ser considerada de alta precisão para os estudos preditivos (SHARMA;

VENUGOPALAN, 2014). Além disso, foi definido um limite de 1000 (um mil) iterações para o modelo, bem como uma função de ativação sigmoide, o que para Medeiros (2019) permitiu que as RNAs aprendessem e executassem as tarefas mais complexas, como a predição de dados.

Métricas de avaliação

Para avaliar o desempenho da Equação de Dulong e das RNAs 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, 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, segundo Monteiro *et al.* (2021), representa uma magnitude média do erro entre os valores estimados e preditos.

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 Equações 2, 3 e 4, respectivamente.

$$AAE [\%] = \frac{1}{N} \sum_{i=1}^N \left| \frac{PCS_{(p)i} - PCS_{(e)i}}{PCS_{(e)i}} \right| \times 100 \quad (2)$$

$$ABE [\%] = \frac{1}{N} \sum_{i=1}^N \left(\frac{PCS_{(p)i} - PCS_{(e)i}}{PCS_{(e)i}} \right) \times 100 \quad (3)$$

$$MAE [MJ \text{ kg}^{-1}] = \frac{1}{N} \sum_{i=1}^N |PCS_{(p)i} - PCS_{(e)i}| \quad (4)$$

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 exatidão dos valores preditos.

Resultados e discussão

A Tabela 2 mostra os resultados do PCS para as blendas selecionadas, os quais foram obtidos experimentalmente e pelas RNAs após a etapa de teste e validação com os respectivos desvios-padrão. Em média, o modelo F5x9 (5 neurônios na primeira e 9 na segunda camada) foi o mais preciso dentre os 5 modelos verificados com os valores médios da ordem de $13,61 \pm 0,20$ MJ kg⁻¹, respectivamente, para o PCS predito.

Tabela 2. Resultados dos valores de PCS experimental e das RNAs

Amostras	PCS experimental (MJ kg ⁻¹)	PCS predito (MJ kg ⁻¹)				
		F5x5	F5x6	F5x7	F5x8	F5x9
100%RA	15,97±0,07	16,76±0,26	12,44±0,48	14,91±0,65	15,12±0,64	15,23±0,52
75%RA: 25%EP	15,21±0,06	14,50±0,81	12,57±0,77	11,69±2,15	15,22±0,01	15,33±0,09
50%RA: 50%EP	14,45±0,04	16,30±1,16	8,94±0,29	13,50±0,69	13,73±0,55	14,29±0,11
25%RA: 75%EP	13,70±0,01	12,60±0,76	8,88±0,20	10,08±2,34	12,73±0,89	13,86±0,11
100%EP	9,08±0,02	10,12±1,03	9,19±0,08	8,35±0,84	8,26±0,58	9,33±0,18
Média	13,68±1,42	16,09±2,05	10,40±0,44	11,71±0,05	13,01±0,47	13,61±0,20

Fonte: Os autores (2022).

O desempenho das RNAs é mostrado na Tabela 3. Baseado na análise de erros estatísticos, o modelo F5x9 apresentou um melhor desempenho, com os menores erros AAE (0,30 %), ABE (-0,30%) e MAE (0,06 MJ kg⁻¹), indicando uma ótima exatidão dos resultados, com os valores preditos do PCS minimamente abaixo do estimado e excelente precisão, respectivamente. Além disso, o coeficiente de regressão linear (R) teve um valor de 0,9802, indicando uma ótima relação entre os valores preditos e experimentais do PCS.

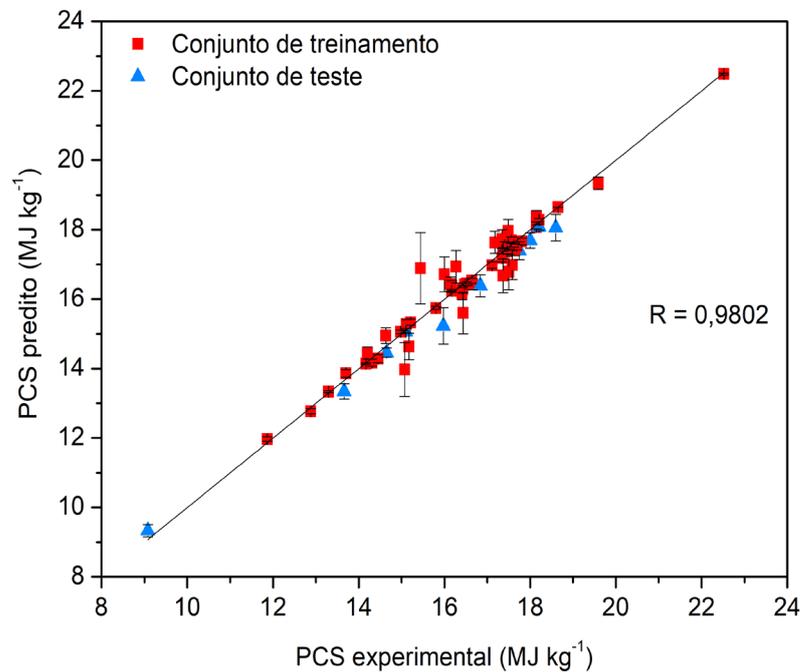
Tabela 3. Análise do desempenho para o modelo matemático utilizado

Tipos de erros	F5x5	F5x6	F5x7	F5x8	F5x9
AAE (%)	2,03	6,42	1,22	0,64	0,30
ABE (%)	-2,03	6,42	1,22	0,64	-0,30
MAE (MJ kg ⁻¹)	0,15	0,62	0,07	0,09	0,06
Regressão linear (R)	0,9404	0,8632	0,9342	0,9604	0,9802

Fonte: Os autores (2022).

A Figura 3 ilustra a regressão linear do modelo F5x9, com 98,02% de precisão do PCS predito em relação ao PCS experimental. A maioria dos valores observados (conjuntos de treinamento e teste) está sobre a linha de centro (cor preta sólida), ressaltando a alta precisão avaliada pelos erros AAE, ABE e MAE.

Figura 3. Relação do PCS experimental *versus* o PCS predito pelo modelo RNA F5x9



Fonte: Os autores (2022).

Conclusão

Este estudo apresentou uma investigação do Poder Calorífico Superior (PCS) de diversas blendas 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 utilizaram a análise elementar desses resíduos. Foram desenvolvidas modelagens numéricas, levando em consideração o percentual da análise elementar das amostras como dados de entrada com as seguintes proporções: 100%EP; 75%EP:25%RA; 50%EP:50%RA; 25%EP:75%RA e 100%RA. A análise de erros estatísticos demonstrou uma ótima precisão da rede neural artificial (RNA), com baixos valores para o AAE (0,30%), ABE (-0,30%), e MAE (0,06 MJ kg⁻¹), bem como um excelente coeficiente de regressão linear (R) com precisão de 98,02% em relação aos valores preditos e teóricos.

De modo geral, o modelo F5x9 (5 neurônios na primeira e 9 na segunda camada oculta) 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 blendas de biomassas como uma alternativa viável frente a métodos 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 uma ótima precisão nos resultados.

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.

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.

DE OLIVEIRA RIGAUD, JOÃO PAULO; TAVARES FILHO, RAFAEL ARCANJO. Desperdício alimentar: impactos e simbolismos do consumo globalizado. *Revista Ingesta*, v. 1, n. 2, p. 109-110, 2019.

DE PAULA, NILSON MACIEL; ZIMMERMANN, SILVIA A. A insegurança alimentar no contexto da pandemia da covid-19 no Brasil. *Revista NECAT-Revista do Núcleo de Estudos de Economia Catarinense*, v. 10, n. 19, p. 56-67, 2021.

DINIZ, ANA LUIZA CALDAS *et al.* O uso múltiplo da área de pesca do município de Raposa, Maranhão/Brasil/The multiple use of the fishing area in the municipality of Raposa, Maranhão/Brazil. *Brazilian Journal of Development*, v. 6, n. 2, p. 6999-7010, 2020.

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.

GARCÍA, R., PIZARRO, C., LAVÍN, A.G. and BUENO, J. L., 2012. "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., 2014. "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.

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.

OZYUGURAN, Ayse; AKTURK, Aysen; YAMAN, Serdar. **Optimal use of condensed parameters of ultimate analysis to predict the calorific value of biomass.** *Fuel*, v. 214, p. 640-646, 2018.

SANTOS, R. G. DOS, BORDADO, J. C., & MATEUS, M. M. **Estimation of HHV of lignocellulosic biomass towards hierarchical cluster analysis by Euclidean's distance method.** *Fuel*, 221,

72-77, 2018.

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.

SILVA, A. V. S. *et al.*, 2019. "**Potential application of fish scales as feedstock in thermochemical processes for the clean energy generation**". *Waste Management*, Vol. 100, pp. 91-100.

SOPONPONGPIPAT, 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.

Recebido em: 30 de novembro de 2022.

Aceito em: 20 de janeiro de 2023.