USO DE REDES NEURAIS NA ANÁLISE TÉRMICA DE OXICOMBUSTÃO

Diogo Henrique Martinelli Moreira (PIBIC/CNPq), Márcio Higa (Orientador). E-mail: (mhiga@uem.br)

Universidade Estadual de Maringá, Centro de Tecnologia, Maringá, PR.

Área e subárea do CNPq: Engenharias; Engenharia Mecânica; Engenharia Térmica e Aproveitamento da Energia.

Palavras-chave: Redes Neurais; Sistemas Térmicos; Oxicombustão.

RESUMO

Este trabalho desenvolve um gêmeo digital baseado em Redes Neurais Artificiais (RNA) para modelar e otimizar o desempenho termodinâmico do ciclo Clean Energy Systems (CES), operando com gás de síntese (syngas) de gaseificação a plasma, reduzindo o tempo e custo computacional de simulações iterativas em *software* comercial. A partir de dados gerados no *Aspen Plus*®, variando pressões e vazões das câmaras de combustão, treinou-se um *Perceptron* Multicamadas (MLP: *Multilayer Perceptron*) capaz de prever a potência líquida (□□□□) e a eficiência energética (η) com erro de 0,00139 ponto porcentual no conjunto de teste. Uma busca aleatória identificou um cenário com eficiência de 45,80% e potência líquida de 34,51 MW em 60 bar, validado no *Aspen Plus*® com erro inferior a 0,3%. Ganha-se 4,87 pontos percentuais de eficiência frente ao caso base da literatura, ao custo de ~1,72 MW, evidenciando um compromisso multiobjetivo entre os indicadores. Conclui-se que modelos substitutos de aprendizado profundo constituem ferramenta preditiva ágil e confiável para o dimensionamento de termelétricas de emissão zero.

INTRODUÇÃO

A crescente demanda por eficiência energética e a urgência na mitigação de gases de efeito estufa impulsionam o desenvolvimento de ciclos termodinâmicos avançados. A gaseificação a plasma de resíduos sólidos urbanos produz gás de síntese (syngas) livre de poluentes tóxicos, capaz de alimentar usinas de oxi-combustão como o ciclo Clean Energy Systems (CES), cuja exaustão é composta basicamente por H_2O e CO_2, facilita a captura de carbono (BAZOOYAR AND JOMEKIAN, 2024).

A otimização de sistemas energéticos exige a resolução iterativa de equações de estado não lineares, de elevado custo computacional em simuladores comerciais. Neste contexto, as Redes Neurais Artificiais consolidam-se como modelos substitutos capazes de reproduzir esse comportamento a uma fração desse custo (MOUSAEI et al., 2025). Este trabalho desenvolve um gêmeo digital baseado em RNA para o ciclo CES, capaz de prever a potência líquida e a eficiência energética e

de identificar cenários operacionais otimizados para as variáveis presentes neste sistema térmico.

MATERIAIS E MÉTODOS

Baseado nos princípios da 1ª Lei da Termodinâmica, o ciclo CES foi modelado no Aspen Plus®, considerando cada componente como um volume de controle operando em regime permanente (Figura 1). O gás de síntese (*syngas*) oriundo da gaseificação de Resíduos Sólidos Urbanos (RSU) utiliza plasma de O_2, sendo comprimido e utilizado como combustível nas duas câmaras de combustão, CC1 e CC2, respectivamente. A CC1 opera a 90 bar e 600º C, enquanto a CC2 opera com pressões variando entre 15 e 60 bar e 1200 e 1600º C. Considerando que nestas reações de combustão também é utilizado O_2 concentrado, é necessário um diluente capaz de reduzir as temperaturas adiabáticas de chama. Na CC2 o diluente é composto pelos próprios gases saindo da turbina a gás de alta pressão, (ST-HP), que são exauridos na mesma pressão de operação da CC2. Como o *syngas* é composto basicamente de CO e H_2, a sua reação produz quase que na totalidade apenas CO_2 e H_2O, sendo que o resfriamento destes gases permite a condensação da água no condensador (COND), e sua separação no separador (SEP-CO2), respectivamente. Enquanto o CO_2 é liberado para a atmosfera ou captura e armazenamento (CCS), a água recuperada é bombeada e aquecida para ser reciclada e utilizada como diluente na CC1.

Neste contexto, o controle das temperaturas na CC1 e CC2 ($T_{□□1}, T_{□□2}$) com a variação da pressão de operação ($p_{□□1}, p_{□□2}$) nos níveis desejados, depende das vazões de vapor de água reciclada, da fração de combustível dirigidas para CC1 e CC2 (□□□ – □□□□), e da vazão de oxigênio em cada câmara, além de um indicador categórico da câmara variada, totalizando oito variáveis de entrada. Assim, o controle das temperaturas ($□_{□□1}, □_{□□2}$) nas câmaras de combustão torna-se bastante complexo e iterativo, dificultando as simulações para a obtenção dos parâmetros de saída, que correspondem à potência líquida ($□_{□□□}$), à eficiência energética (η).

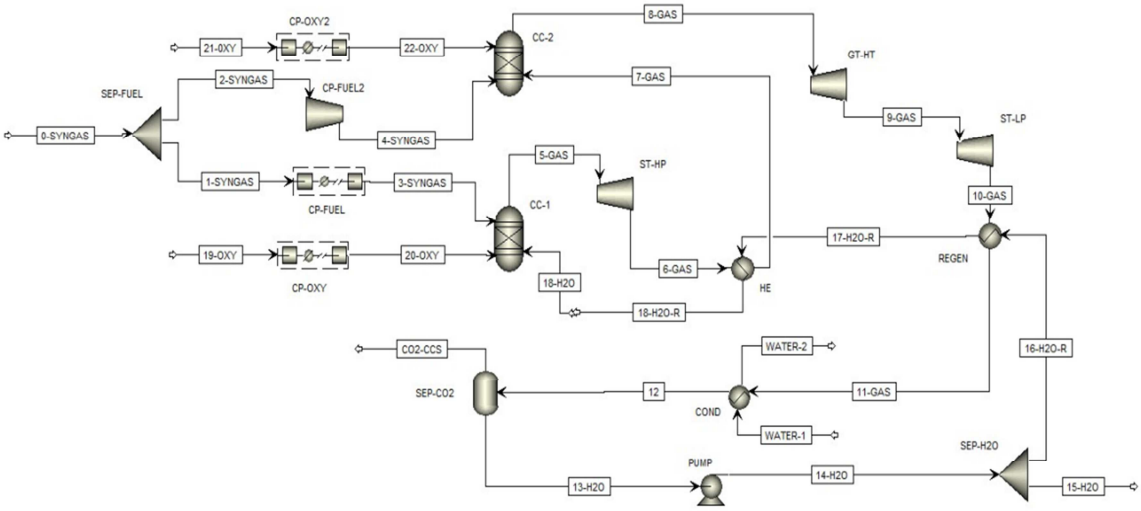
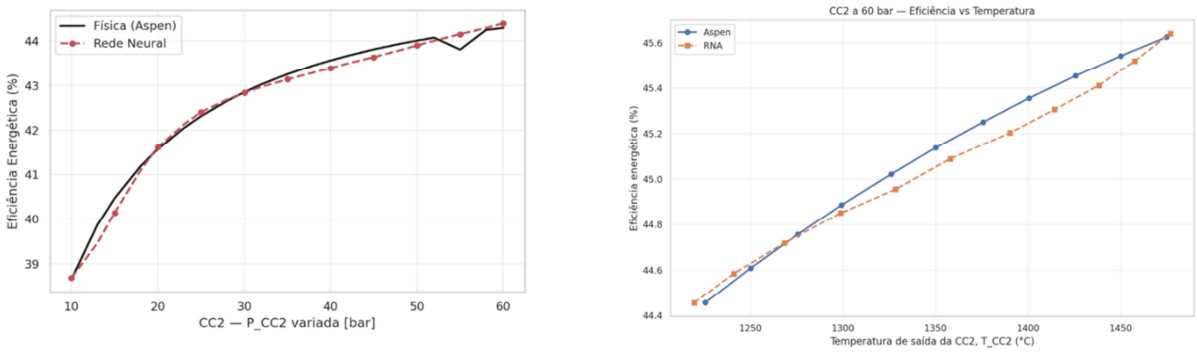


Figura 1 - Ciclos CES modelado no Aspen Plus

Desta forma, utilizou-se um MLP *feed-forward* com entradas normalizadas por Min-Max, três camadas ocultas (128, 128 e 64 neurônios, ReLU, Dropout 0,1) e saída linear para regressão de $\square_{\square\square\square}$ e η. Manteve-se como restrição, a relação ar/combustível entre $\dot{\square}_{1-\square\square\square}$,$\dot{\square}_{19-\square\square\square}$ e $\dot{\square}_{2-\square\square\square}$ e $\dot{\square}_{21-\square\square\square}$. O treinamento usou o otimizador Adam e *early stopping* (MSE). Aplicou-se então, sobre o modelo treinado, uma busca para localizar pontos ótimos ($\square_{\square\square\square}$,η) por meio de busca aleatória entre 50.000 cenários fisicamente possíveis.

RESULTADOS E DISCUSSÃO

A avaliação no conjunto de teste indicou MAE de 86,59 kW para $\square_{\square\square\square}$ e 0,00139 p.p. para η, com boa aderência entre a simulação do *Aspen Plus*® e a RNA na sensibilidade de η à pressão em CC2 (Figura 2a), mas um pequeno desvio da monotonicidade próximo a 55 bar, reproduzido pela RNA. Para validar o modelo no ponto ótimo ($\square_{\square\square 2} = 60\ \square\square\square$), avaliou-se a sensibilidade de η a $\square_{\square\square 2}$ nessa pressão fixa (Figura 2b). A RNA reproduziu com fidelidade o Aspen Plus® entre 1.225 e 1.475 °C, com η entre 44,45% e 45,65%, sem os desvios da curva de pressão. Como as vazões também variam com $\square_{\square\square 2}$, o resultado reflete o efeito conjunto de temperatura e vazões, reforçando a confiabilidade do modelo nesta região.



a) **b)**

Figura 2 – a) Sensibilidade da eficiência energética (η) com a pressão (a) e temperatura (b) em CC2

Nos extremos da curva, a busca identificou o melhor cenário para CC2: η de 45,80%, □□□□ de 34,51 MW e □□□2 com 1.475 °C , em 60 bar — limite superior do intervalo explorado, com a curva ainda ascendente (Figura 2b), apontando para extensão da faixa de pressões em trabalhos futuros.

Essa previsão foi validada no Aspen Plus®, com η de 45,67%, □□□□de 34,41 MW e □□□2 de 1.485,65 °C — ganho de 4,87 pontos percentuais frente ao caso base da literatura (HIGA et al., 2026), ao custo de ~1,72 MW de potência, compromisso relevante conforme a prioridade operacional da planta.

Além da pressão, SEP-FUEL ficou restrito entre 0,5093 e 0,513 na maior parte das amostras, sugerindo fracionamento praticamente fixo para maximizar a eficiência. Já a vazão de água reciclada (□̇18−□2□) variou mais, entre 38.180 e 41.360 kg/h, sem impacto proporcional sobre □□□□ e η, relação de compensação em que a moderação térmica pode ser ajustada nessa faixa sem penalizar o desempenho, ao contrário do observado para o SEP-FUEL.

CONCLUSÕES

O gêmeo digital baseado em RNA reproduziu com precisão o comportamento termodinâmico do ciclo CES, confirmada de forma independente em simulações no *Aspen Plus*® com erro inferior a 0,3% no ponto ótimo. Para a CC2, a busca aleatória identificou ganho de 4,87 pontos percentuais de eficiência frente ao caso base da literatura (HIGA *et al.*, 2026), ao custo de cerca de 1,72 MW de potência, evidenciando a influência de SEP-FUEL e da vazão de água reciclada sobre a eficiência — e a necessidade de ampliar o domínio de pressões investigado, já que os ótimos se situam em seu limite superior (□□□2 = *60* □□□). Confirma-se que modelos substitutos de aprendizado profundo são ferramentas preditivas ágil e validada para termelétricas de emissão zero.

AGRADECIMENTOS

Os autores agradecem ao CNPq pelo apoio financeiro por meio de bolsa de Iniciação Científica (PIBIC).

REFERÊNCIAS

BAZOOYAR, B.; JOMEKIAN, A. **Chapter twenty-one - Oxyfuel combustion as a carbon capture technique.** Advances and Technology Development in Greenhouse Gases: Emission, Capture and Conversion, p. 437-495, 2024. DOI: https://doi.org/10.1016/B978-0-443-19233-3.00023-7

HIGA, M.; OLIVEIRA, J. C. D.; GALLEGO, A. G.; OLIVEIRA JUNIOR, S. **Integration of advanced technologies for power generation using oxy-fuel combustion and syngas from municipal solid waste treatment through plasma gasification.** In: BRAZILIAN CONGRESS OF THERMAL SCIENCES AND ENGINEERING, 21., 2026, Santos. Anais [...]. Santos: ABCM, 2026. CIT26-#748. https://abcm.org.br/proceedings/index/CIT26

MOUSAEI, S.; OMIDI, A.; HOUSHFAR, E. **Energy, exergy, and exergoeconomic analysis and multi-objective optimization of an industrial waste heat-to-hydrogen multigeneration plant using neural network and genetic algorithm.** International Journal of Hydrogen Energy, v. 184, p. 151873, 2025. DOI: https://doi.org/10.1016/j.ijhydene.2025.151873 .