

## **Aplicação das Redes Neurais Paraconsistentes para investigação de sinergismo em Sistemas de Combustão**

Marcos Carneiro Rodrigues, João Inácio da Silva Filho

Universidade Santa Cecília (UNISANTA), Santos-SP, Brasil

**E-mail:** marcoscefetmg@gmail.com

**Resumo:** Redes Neurais são modelos inspirados no cérebro, reconhecendo padrões complexos a partir de dados, podendo lidar com problemas não lineares. A lógica paraconsistente maneja informações contraditórias, útil onde incerteza é inerente. Redes neurais paraconsistentes estendem as tradicionais, incorporando princípios da lógica paraconsistente. Este estudo explora a capacidade dessas redes em analisar interações entre variáveis. Uma RNP para 2 variáveis (5 entradas) é desenvolvida com MATLAB®, usando o método LM para treinamento. A RNP apresenta MSE de  $1,1 \times 10^{-3}$  comparada à RNA sigmoide (MSE de  $3,3 \times 10^{-3}$ ). Os pesos aprendidos de entre  $x_1 x_2$  e  $H_1$  indica sinergismo entre variáveis de entrada.

**Palavras-chave:** Paraconsistente, Redes Neurais, Sinergismo.

## **Application of Paraconsistent Neural Networks to investigate synergism in Combustion Systems**

**Abstract:** Artificial Neural Networks are brain-inspired models that recognize complex patterns from data and can handle nonlinear problems. Paraconsistent logic manages contradictory information, being useful in situations of inherent uncertainty. Paraconsistent Neural Networks extend traditional models by incorporating paraconsistent logic principles. This study explores the capacity of these networks to analyze interactions between variables. A Paraconsistent Neural Network for 2 variables (with 5 inputs) is developed using MATLAB®, employing the LM method for training. The network achieves a Mean Squared Error (MSE) of  $1.1 \times 10^{-3}$  compared to a Sigmoid Neural Network (MSE of  $3.3 \times 10^{-3}$ ). The learned weights between  $x_1 x_2$  and  $H_1$  indicates synergistic effect among input variables.

**Keywords:** Paraconsistent, Artificial Neural Networks, Synergistic effect

## **Introdução**

Sinergismo é o efeito onde a cooperação entre partes cria impactos maiores do que a mera soma de suas partes individuais. Isso reflete uma realidade fundamental em sistemas dinâmicos, pois as interações podem moldar comportamentos imprevisíveis e padrões emergentes difíceis de serem deduzidos ao se analisar as partes isoladamente [1].

O cerne das redes neurais paraconsistentes (RNP) reside na incorporação dos princípios da lógica paraconsistente [2]. Esta lógica, em contraste com as abordagens clássicas, busca rejeitar o princípio da não contradição [3]. Ela reconhece que, em muitos cenários reais, informações contraditórias podem coexistir e gerar graus de conhecimento, ao invés de invalidar completamente um sistema. Dessa forma a LP surge como uma melhoria das

Redes neurais Artificiais Paraconsistentes (RNAP), cuja memorização se dá por ajustes dos fatores de tolerância certeza e contradição [2]. As RNPs com este tipo de abordagem utilizam pesos sinápticos que são ajustados conforme são alimentados com valores de entrada (*inputs*) e alvos (*targets*). Seus neurônios podem possuir  $n$  entradas de ordem  $2^P$ , sendo  $P=\{1,2,3,\dots\}$ , dispostas no intervalo de 0 a 1 [2], com parcela linear adotando o grau de evidência resultante  $\mu_E$  e função reativação não linear, baseada no grau de certeza resultante Real  $\mu_{ER}$ . Considerando um neurônio com 2 entradas;  $\mu$  e  $\lambda$ , as equações (1) e (2) determinam os valores de  $G_C$  – grau de certeza e  $G_{CT}$  – grau de contradição e as equações (3) e (4) determinam, respectivamente,  $\mu_E$  – grau de evidência e  $\mu_{ER}$  – grau de evidência resultante real.

$$G_C = \mu - \lambda \quad (1)$$

$$G_{CT} = \mu + \lambda - 1 \quad (2)$$

$$\mu_E = \frac{G_C + 1}{2} = (\mu - \lambda + 1) \quad (3)$$

$$\mu_{ER} = \begin{cases} 1 - \frac{\sqrt{(1 - |G_C|)^2 + G_{CT}^2}}{2}, & \text{se } G_C > 0 \\ \frac{\sqrt{(1 - |G_C|)^2 + G_{CT}^2}}{2}, & \text{se } G_C < 0 \end{cases} \quad (4)$$

**Objetivos:** Este trabalho tem como objetivo principal investigar a capacidade das RNPs de identificar o efeito de Sinergismo entre duas variáveis, utilizando o método LM para treinamento. Portanto, é explorada as Redes Neurais Paraconsistentes (RNP) com uma abordagem inovadora na análise de interações entre variáveis considerando sistemas complexos.

## Materiais e Métodos

A situação de estudo abrange um sistema de combustão de forno industrial alimentado a gás natural. Para investigar a relação entre as variáveis nesse contexto, os dados foram utilizados normalizados e sorteados, sendo então selecionados 90% para treinamento e 10% validação. O conjunto de dados é composto por três variáveis principais: Vazão de Ar ( $x_1$ ), Vazão de Combustível ( $x_2$ ) e Produção de  $\text{NO}_x$ . Esses dados foram obtidos de experimentos em sistemas de combustão reais, garantindo a representatividade e relevância para o estudo.

A arquitetura das RNP's foi adaptada para refletir as interações no sistema de combustão. As entradas originais (Vazão de Combustível e Vazão de Ar) foram pré-processadas para compor a camada de entrada das redes treinadas. Essas entradas foram

transformadas em  $x_1$ ,  $x_2$  e  $x_1x_2$ . Através das equações (1) e (2) os graus  $\mu_E$  e  $\mu_{ER}$  são calculados para cada neurônio. A estrutura da RNP, portanto, é composta de 3 neurônios na camada de entrada, 3 na camada oculta e 1 na camada de saída, conforme a figura (1). Durante o treinamento, as RNPs receberam as entradas processadas e os pesos sinápticos foram ajustados utilizando o método Levenberg-Marquardt (LM). Para comparação, foi desenvolvida uma RNA com função de ativação sigmoide. Ambas as redes iniciam com o mesmo conjunto de pesos aleatórios, sendo que a RNP não possui bias. Como Métrica de avaliação, o Erro Médio Quadrático (MSE) foi usado para avaliar o desempenho da RNP.




Figura 1. Estrutura da Rede Neural Paraconsistente-RNP.

## Resultados

A figura (2) apresenta a evolução do MSE da RNP(preto) e da Sigmoide (Azul) ao decorrer das épocas de treinamento, onde foram encontrados, respectivamente,  $11 \times 10^{-3}$  e  $33 \times 10^{-3}$ . A tabela (1) apresenta os valores dos 12 pesos aprendidos na última época de treinamento e a tabela (2) compara o MSE da RNA Sigmoide e da RNP.

Tabela 1: Valores de MSE para RNA sigmoide e RNP

|                         | Sigmoide    | RNP      |
|-------------------------|-------------|----------|
| <b>MSE(treino)</b>      | 0.003265234 | 0.002435 |
| <b>MSE(validação)</b>   | 0.001081597 | 0.001125 |
| <b>treino/Validação</b> | 3.018899841 | 2.164274 |

Tabela 2: Pesos aprendidos na última época de treinamento

|       | $x_1$    | $x_2$    | $x_1x_2$ |   | $H_1$   | $H_2$    | $H_3$    |
|-------|----------|----------|----------|---|---------|----------|----------|
| $H_1$ | 0.498033 | 0.714613 | 0.844055 | Y | 0.21866 | 0.633433 | 0.712668 |
| $H_2$ | 0.163429 | 0.297277 | 0.901578 |   |         |          |          |
| $H_3$ | 0.522244 | 0.59253  | 0.77969  |   |         |          |          |




Figura 2. Evolução do MSE a cada época de treinamento.

A figura (3) representa a produção de  $\text{NO}_x$  normalizada (preto), comparando-a com a saída da RNP durante o treinamento (a) e validação (b).




Figura 3. Comparação saída real x RNP (a): treino. (b): validação.

## Discussão

A figura (2) revelou um início de treinamento desfavorável para a RNP, com um MSE inicialmente maior em comparação à rede sigmoide. No entanto, a RNP foi capaz de demonstrar uma notável capacidade de aprendizado, reduzindo gradualmente seu MSE para  $1,1 \times 10^{-3}$ , enquanto a rede sigmoide atingiu  $3,3 \times 10^{-3}$ . Isso ressalta a habilidade adaptativa da RNP, superando seu desempenho inicial e sugerindo vantagens no ajuste a padrões complexos de dados. A figura (3a) mostrou que a RNP soube adaptar variações bruscas na Produção de  $\text{NO}_x$ , e a figura (3b) apresenta razoável aproximação, onde nota-se que na RNP, houve mudanças bruscas na busca do Menor MSE pelo Método LM. A RNP demonstra, então, alta sensibilidade ao incremento da Matriz Hessiana inerente ao Método LM. Os resultados obtidos na tabela (1) revelam que a RNP foi capaz de

generalizar a saída de forma mais eficaz que a RNA sigmoide, uma vez que a razão de MSE treinamento/validação foi menor na RNP.

Na análise dos resultados expostos na Tabela (2), emerge uma dinâmica discernível nas relações entre as variáveis de entrada e a produção de óxidos de nitrogênio ( $\text{NO}_x$ ). Observou-se uma correlação inversa entre  $x_2$  e a produção de  $\text{NO}_x$ , onde um aumento na vazão de Ar se correlaciona com uma redução na produção de  $\text{NO}_x$ , devido ao fato de  $x_2$  ser conectado as entradas  $\lambda$  dos neurônios. Isso pode ser explicado pela influência da temperatura da chama no processo, que é reduzida pelo excesso de  $\text{O}_2$ , contribuindo para redução do  $\text{NO}_x$  térmico [4]. Adicionalmente, na exploração das interações entre o Combustível e a Vazão de Ar, representada como a entrada  $x_1x_2$ , evidenciou-se que o valor entre a camada oculta  $H_1$  e  $x_1x_2$  indica um efeito sinérgico entre  $x_1$  e  $x_2$ . A combinação entre a vazão de combustível e a Vazão de Ar revelou uma contribuição positiva para a produção de  $\text{NO}_x$ , uma vez que se houver combustível e oxigênio aumentando em razão estequiométrica, haverá proporcional geração de energia térmica. A análise dos pesos das variáveis de entrada proporciona uma base informada para a avaliação dos efeitos individuais e combinados, aprofundando a compreensão dos processos de combustão e suas implicações em termos ambientais e industriais.

## Conclusões

Os resultados obtidos no treinamento da RNP em comparação com a RNA sigmoide permitiu levantar as seguintes conclusões.

1. **Potencial das RNP's:** A integração da lógica paraconsistente demonstrou ser uma abordagem eficaz em generalizar a produção de  $\text{NO}_x$  a partir das vazões de combustível e ar.
2. **Sensibilidade ao Sinergismo:** A detecção de sinergismo entre variáveis  $x_1$  e  $x_2$  reforça a capacidade da RNP em capturar interações não lineares, essenciais para otimizar sistemas de combustão.

Em síntese, a aplicação das Redes Neurais Paraconsistentes oferece uma abordagem inovadora e robusta para analisar interações complexas em sistemas de combustão. Ao revelar relações sutis e sinergias não intuitivas, essas redes têm o potencial de melhorar a eficiência e a sustentabilidade em processos industriais cruciais. Este estudo não apenas explora as capacidades das RNPs, mas também aponta direções futuras para pesquisas que poderiam moldar soluções tecnológicas mais eficazes em aplicações industriais.

## Referências

1. Cheng, X; Ren, F;GAO, Z; Zhu, L. Huang, Zen. Synergistic effect analysis on sooting tendency based on soot-specialized artificial neural network algorithm with experimental and numerical validation. Fuel. 2022
2. De Carvalho Junior, A. Identificação e Controle de Sistemas Dinâmicos com Rede Neural Paraconsistente / A. De Carvalho Junior – versão corr. – São Paulo, 2021. (p.85, p.82, p.89,)
3. Da Silva Filho, J. I., Treatment of uncertainties with algorithms of the paraconsistent annotated logic. Journal of Intelligent Learning Systems and Applications. vol. 4, no. 2, pp.144–153
4. Liu, X., Guan, J., Wang, Z., & Qi, G. (2017). Calculation method of excess air ratio for blast furnace gas fired boiler. 2017 2nd International Conference Sustainable and Renewable Energy Engineering (ICSREE). p.20