ISSN: 2594-6153

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 1,1x10-3 comparada à RNA sigmoide (MSE de 3.3x10-3). Os pesos aprendidos de entre x_1x_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 1.1x10-3 compared to a Sigmoid Neural Network (MSE of 4x10-3). The learned weights between x_1x_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

ISSN: 2594-6153

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,...}, dispostas no intervalo de 0 a 1 [2], com parcela linear adotando o grau de evidencia resultante μ_E e função reativação não linear, baseada no grau de certeza resultante Real μ_{ER}. Considerando um neurônio com 2 entradas; μ e λ , 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, μ_E – grau de evidência e μ_{ER}-grau de evidencia resultante real.

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

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

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

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

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 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

ISSN: 2594-6153

transformadas em x_1, x_2 e x_1x_2. Através das equações (1) e (2) os graus μ_E e μ_{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.

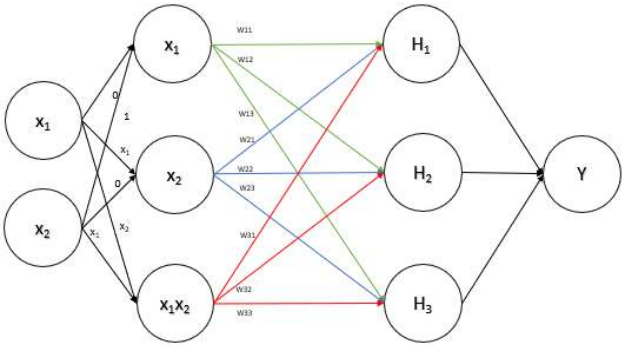


Figura 1. Estrutura da Rede Neural Paraconsistente-RNP.

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, $11x10^{-3}$ e $33x10^{-3}$. 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
MSE(treino)	0.003265234	0.002435
MSE(validação)	0.001081597	0.001125
treino/Validação	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				
H_2	0.163429	0.297277	0.901578	Y	0.21866	0.633433	0.712668
H_3	0.522244	0.59253	0.77969				

ISSN: 2594-6153

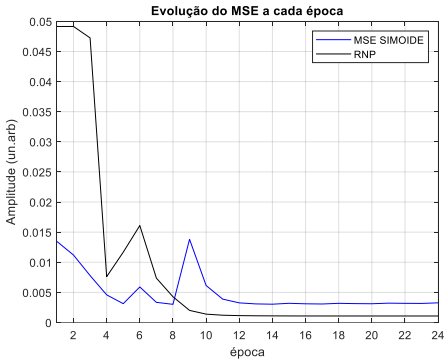


Figura 2. Evolução do MSE a cada época de treinamento.

A figura (3) representa a produção de NO_x normalizada (preto), comparando-a com a saída da RNP durante o treinamento (a) e validação (b).

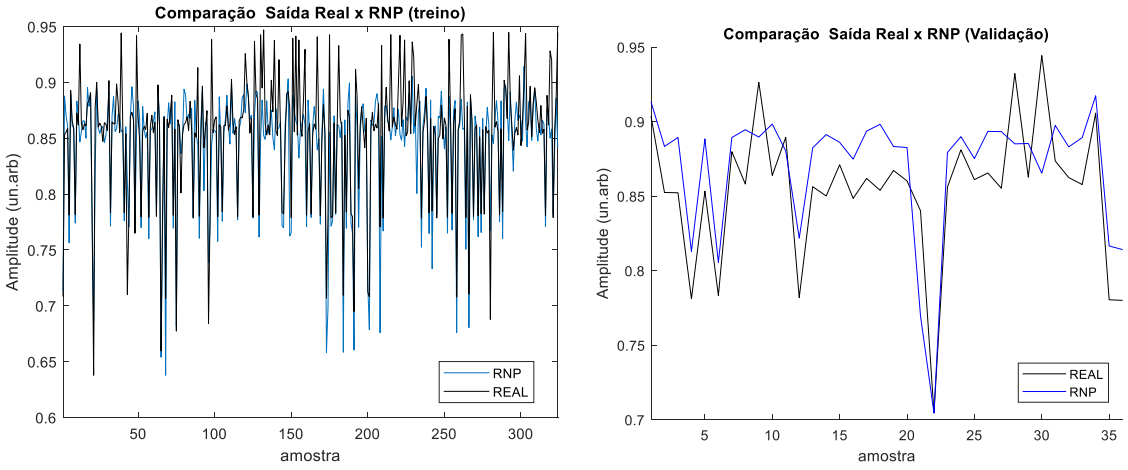


Figura 3. Comparação saída real x RNP (a): treino. (b): validação.

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 $1{,}1x10^{-3}$, enquanto a rede sigmoide atingiu $3{,}3x10^{-3}$. 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 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

ISSN: 2594-6153

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 (NO_x). Observou-se uma correlação inversa entre x_2 e a produção de NO_x, onde um aumento na vazão de Ar se correlaciona com uma redução na produção de NO_x, devido ao fato de x_2 ser conectado as entradas λ dos neurônios. Isso pode ser explicado pela influência da temperatura da chama no processo, que é reduzida pelo excesso de O_2, contribuindo para redução do 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 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 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.

ISSN: 2594-6153

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*