

Estudo de Sistemas de Inferência Neuro-Fuzzy Adaptativo para Estimativa e Interpretação de Parâmetros na Modelagem de Doenças

Matheus Z. Monteiro¹, Vinícius F. Wasques²

Ilum Escola de Ciência, Centro Nacional de Pesquisa em Energia e Materiais (CNPEM), Campinas, SP

A área de Inteligência Artificial (IA) tem sofrido grandes avanços nos últimos anos, gerando grande influência na sociedade. Um dos fatores que possibilitou tais avanços foi o aprimoramento de modelos de aprendizado profundo, que tem como base as Redes Neurais Artificiais (RNAs) [1, 2]. As RNAs foram inspiradas em redes neurais biológicas, através do estudo do funcionamento dos neurônios, em que a sua ativação depende dos estímulos recebidos por outros neurônios.

As RNAs são modelos compostos por camadas, cada uma contendo um conjunto de neurônios, que por sua vez estão conectados com todos os outros neurônios da próxima camada através de sinapses. Os neurônios são unidades que armazenam valores, enquanto as sinapses armazenam pesos, que ponderam as conexões entre os neurônios. A Figura 1 apresenta um diagrama de uma RNA com três camadas:

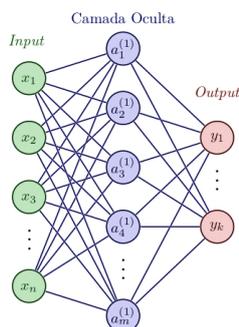


Figura 1: Diagrama de uma RNA com n inputs, m neurônios na camada oculta, e k outputs. Os inputs são representados por x_1, x_2, \dots, x_n , os valores armazenados nos neurônios da camada oculta são representados por $a_1^{(1)}, a_2^{(1)}, \dots, a_m^{(1)}$, e os outputs são representados por y_1, y_2, \dots, y_k . Fonte: Autoria própria.

Na Figura 1, os valores de entrada são denotados pelo vetor linha $\mathbf{x}_{1 \times n}$; os pesos que ponderam as conexões entre a camada de entrada e a camada oculta pela matriz $\mathbf{W}_{m \times n}$; os valores de viés pelo vetor coluna $\mathbf{b}_{m \times 1}$; e os valores armazenados pelos neurônios da camada oculta pelo vetor coluna $\mathbf{a}_{m \times 1}^{(1)}$. Dessa forma, temos que os valores armazenados na camada oculta são dados por:

$$\mathbf{a}^{(1)} = \sigma(\mathbf{W}\mathbf{x}^T + \mathbf{b}), \quad (1)$$

em que $\sigma(\cdot)$ é chamada de função de ativação.

¹matheus.z.monteiro@gmail.com

²vwasques@outlook.com

No paradigma de aprendizado supervisionado [1], o objetivo de uma RNA é encontrar o melhor conjunto de parâmetros que minimize uma função de perda. Dessa forma, sendo $\Phi_{\theta}(\cdot)$ a arquitetura da RNA; θ o conjunto de parâmetros da rede; \mathbf{x} as entradas; \mathbf{y} as saídas reais; $\hat{\mathbf{y}}$ as saídas geradas pela rede; e $\mathcal{L}(\cdot)$ a função de perda; podemos representar o objetivo de uma RNA como encontrar o melhor conjunto de parâmetros Θ :

$$\begin{cases} \Phi_{\theta}(\mathbf{x}) = \hat{\mathbf{y}} \\ \Theta = \arg \min_{\theta} \mathcal{L}(\mathbf{y}, \hat{\mathbf{y}}). \end{cases} \quad (2)$$

Depois de treinadas, as RNAs são capazes de gerar boas previsões para as saídas \mathbf{y} , porém, devido ao grande número de parâmetros da rede, se torna complexa a interpretação do modelo de forma a extrair conhecimento do conjunto Θ . Assim, RNAs são ditas não interpretáveis. Nesse contexto, diversas abordagens tentam contornar esse problema, e dentre elas, temos os Sistemas de Inferência Neuro-Fuzzy Adaptativo, no inglês *Adaptive Neuro Fuzzy Inference Systems* (ANFIS) [3], que unem os modelos de RNA com o campo da lógica fuzzy [4]. Estes modelos utilizam a capacidade da lógica fuzzy de trabalhar com variáveis linguísticas, a fim de gerar uma maior interpretabilidade no modelo final. A Figura 2 apresenta um diagrama com a arquitetura de um modelo ANFIS:



Figura 2: Diagrama representando as camadas de uma ANFIS. Fonte: Autoria própria.

Neste modelo, a camada de fuzzificação transforma as entradas em conjuntos fuzzy, representando variáveis linguísticas, combinadas em seguida através de métodos de inferência, gerando uma saída. O foco deste trabalho consiste em explorar o método ANFIS e suas consequências na interpretabilidade de modelos gerados por RNAs. No sentido de aplicação, buscaremos estimar e interpretar parâmetros na modelagem de doenças, bem como auxiliar a tomada de decisão em diagnósticos médicos.

Agradecimentos

Os autores agradecem o apoio da Ilum Escola de Ciência, Centro Nacional de Pesquisa em Energia e Materiais (CNPEM). O primeiro autor agradece o apoio financeiro da FAPESP processo nº 2024/03621-0, e o segundo autor agradece o apoio financeiro da FAPESP processo nº 2023/03927-0.

Referências

- [1] I. Goodfellow, Y. Bengio e A. Courville. **Deep Learning**. MIT Press, 2016.
- [2] S. Skansi. **Introduction to Deep Learning: From Logical Calculus to Artificial Intelligence**. Springer, 2018.
- [3] A. K. Varshney e V. Torra. “Literature Review of the Recent Trends and Applications in Various Fuzzy Rule-Based Systems”. Em: **International Journal of Fuzzy Systems** (2023), pp. 1–24.
- [4] L. A. Zadeh. “Fuzzy Sets”. Em: **Information and Control** 8.3 (1965), pp. 338–353.