

Estudo da implementação de Redes Neurais Informadas pela Física (PINN) para obtenção de soluções de equações diferenciais ordinárias

Julia Bueno Condal¹, Ramon de Attayde Barros de Souza²
UERJ-ZO, Rio de Janeiro, RJ

Dentro do estudo de redes neurais, aplicadas em equações diferenciais, a PINN (Rede Neural Informada pela Física) [1] caracteriza-se por conter em sua rotina computacional, a informação da lei física, i.e., a equação diferencial inerente ao problema estudado.

Considerando uma rede neural contruída, a equação diferencial é incluída diretamente na função de perda da rede, formando a rede PINN.

O algoritmo geral de uma rede neural [2], a cada iteração, considerando uma entrada x , n neurônios na camada hidden e uma saída \hat{x} , pode ser descrito por:

$$\hat{x} = \sigma\left(\sum_{i=1}^n w_i x + b\right) \quad (1)$$

onde \hat{x} representa a saída da rede, w_i o peso relativo ao neurônio i , b é chamado de viés (bias) e σ é uma aplicação, denominada função de ativação.

Na hipótese de equação diferencial ordinária [3] de 1^a ordem, podemos representar pela equação (2), conforme segue-se:

$$\frac{dx}{dt} - f(t, x) = F(x', x, t) = 0 \quad (2)$$

onde $x(t)$ e t variável independente.

As funções de perda, utilizadas nas redes neurais PINN, são descritas pelas equações (3), (4) e (5):

$$Loss_1 = \frac{1}{n} \sum_{i=1}^n (\hat{x} - x)^2 \quad (3)$$

$$Loss_2 = \frac{1}{n} \sum_{i=1}^n (F(\hat{x}', \hat{x}, t))^2 \quad (4)$$

$$Loss_{total} = Loss_1 + Loss_2 \quad (5)$$

sendo x representando valor de entrada, \hat{x} valor de saída, n a quantidade de iterações e $Loss_i$ representando a medida da perda, i.e., o erro de aproximação.

Este estudo objetiva avaliar a implementação de Redes Neurais Informadas pela Física (PINN), em equações diferenciais ordinárias [4], em busca de soluções tão próximas quanto possíveis das soluções analíticas.

¹juliabcondal@gmail.com

²ramon.souza@uerj.br

Para tal, serão comparadas os resultados obtidos por redes tradicionais, i.e., sem o conhecimento da equação diferencial, e por redes PINN.

Todas as rotinas computacionais, correspondentes às redes neurais, serão implementadas em linguagem Python [5].

A redes neurais serão treinadas, buscando a quantidade ideal de camadas de neurônios (hidden), bem como uma melhor taxa de aprendizagem.

Será considerado o erro médio quadrático, como critério de otimização, sendo este realizado pela minimização da função de perda da rede.

Considerando o escopo das redes neurais supervisionadas, a convergência será realizada, a partir do conhecimento da solução analítica.

Os resultados serão representados por gráficos comparativos, contendo a solução analítica e a solução obtida pela rede neural.

Referências

- [1] M. F. Raissi, P. Perdikaris e G.E Karniadakis. “Physics-informed neural networks: a deep framework for solving forward and inverse problems involving nonlinear partial differential equations”. Em: **Journal of Computational Physics** (2019). DOI: <https://doi.org/10.1016/j.jcp.2018.10.045>.
- [2] C. F. Higham. “Deep Learnig: An introduction for applied mathematicans”. Em: **SIAM** (2019). DOI: 10.1137/18M1165748.
- [3] J. Sotomayor. **Equações diferenciais ordinárias**. São Paulo: USP, 2011.
- [4] J. Chakraverty e S. Mall. **Artificial neural networks for engineers and scientists. Solving Ordinary Differential Equations**. CRC Press, 2017.
- [5] J. V. Guttag. **Introduction to computation and programming using Python**. Spring, 2013.