

低計数率条件下における Physics-informed Neural Networks を用いた 未臨界度監視手法に関する検討

名古屋大学大学院工学研究科

森部 太陽

1. はじめに

この度は、優秀講演賞という名誉ある賞を賜り、大変光栄に存じます。本研究を進めるにあたりご指導いただいた先生方ならびに関係者の皆様に、この場を借りて深く御礼申し上げます。

東京電力福島第一原子力発電所における燃料デブリ取り出し作業では、作業中の臨界近接監視が重要となります。本研究では、この臨界近接監視を目的として、Physics-informed Neural Networks (PINNs)を用いた反応度推定手法を新たに考案しました。本手法では、中性子計数率測定データから算出可能な量のみを入力とし、反応度過渡変化後の定常状態における反応度および実効外部中性子源強度を推定します。

本稿では、提案した PINNs を用いた臨界近接監視手法の概要について説明します。

2. 研究概要：Physics-informed Neural Networks を用いた臨界近接監視手法

本章では、燃料デブリ取り出し作業時における臨界近接監視を目的として提案した、Physics-informed Neural Networks (PINNs)[1]を用いた反応度推定手法の概要について説明します。本手法では、中性子計数率測定データから算出可能な量のみを入力として、反応度過渡変化後の定常状態における反応度および実効外部中性子源強度を推定します。

入力データには、中性子計数率 P_n および実効遅発中性子先行核数 \bar{A}_n [2]を用います。反応度過渡変化後の一定時間区間を切り出した時系列データを入力とします。出力は、過渡変化後の反応度 ρ_{after} および実効外部中性子源強度 S_0 [2]の定常値とします。

本研究で用いた予測モデルの層構造の概略を図 1 に示します。入力された (P_n, \bar{A}_n) の時系列データを重み付け処理により特徴量へ変換し、複数の隠れ層を通じて最終的に ρ_{after} および S_0 を出力する構造としています。

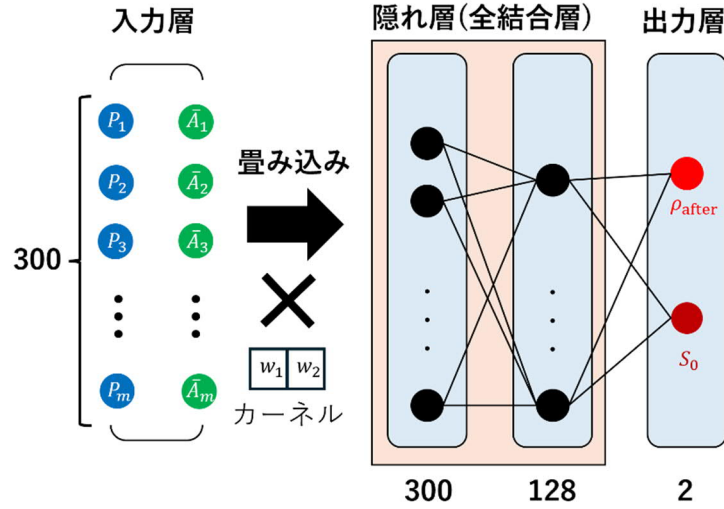


図 1 予測モデルの層構造の概要

本研究では、物理法則を学習に組み込むことのできる PINNs を適用しました。PINNs では、入力と出力の関係を記述する物理法則に基づく関数を定義し、その残差を損失関数へ導入します。本研究では、最小二乗逆動特性法[2]の関係式に基づき、反応度過渡変化後の定常値に対して次式で表される物理関数を定義しました。

$$f(\rho, S_0, P_m, \bar{A}_m) = \frac{\rho_{\text{after}}}{\beta_{\text{eff}}} - \left(1 - \frac{\bar{A}_m + S_0}{P_m}\right) \quad (1)$$

ここで、 ρ_{after} および S_0 は予測モデルの出力値であり、 P_m, \bar{A}_m は入力として与える時系列データです。

ρ_{after} および S_0 はスカラー値であるのに対し、右辺は時間区間にわたる配列となるため、物理法則に基づく損失項は対象区間における平均値を用いて定義しました。すなわち、物理損失 $LOSS_p$ は次式で与えられます。

$$LOSS_p = \frac{1}{l} \sum_{k=1}^l \left| \frac{\rho_{\text{after},k}}{\beta_{\text{eff}}} - \frac{1}{300} \sum_{m=1}^{300} \left(1 - \frac{\bar{A}_{m,k} + S_{0,k}}{P_{m,k}}\right) \right|^2 \quad (2)$$

最終的な損失関数は、反応度および外部中性子源強度に対する平均二乗誤差と、この物理損失を加算した形で定義します。ここで、 $MSE_{\rho_{\text{after}}}$ および MSE_{S_0} は、それぞれ過渡変化後反応度および実効外部中性子源強度の推定値と参照値との差に対する平均二乗誤差を表します。

$$LOSS = MSE_{\rho_{\text{after}}} + MSE_{S_0} + LOSS_p \quad (3)$$

以上のように、本研究では中性子計数率測定データから算出可能な量のみを入力とし、逆動特性解析に基づく関係式を物理制約として導入した PINNs を構築し、反応度推定手法を提案しました。

3. 最後に

本研究を始めた当初は、機械学習について十分な知識がなく、基礎的な内容の理解から取り組みを始めました。学会に参加するたびに関連講演を積極的に聴講し、専門書を通じて学習を重ねました。また、同研究室において卒業論文で機械学習を扱っていた笠間陸斗さんには、多くの助言をいただきました。山本章夫教授、遠藤知弘准教授のご指導に加え、笠間さんからの助言も本研究を進めるうえで大きな支えとなりました。

さらに、学会にて成果を発表した際には、炉物理部会の皆様より貴重なご意見やご助言をいただきました。多くの方々のご支援のもとで本研究を進めることができましたことに、心より感謝申し上げます。

私は本年度をもって大学院を修了し、来年度より原子力分野において社会人として歩み始めます。本研究で得た知識や経験を大切にしながら、原子力分野に貢献できるよう今後も努力を重ねてまいります。

参考文献

- [1] M. Raissi, P. Perdikaris, and G. E. Karniadakis, "Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations," *J. Comput. Phys.*, vol. 378, p. 686, 2019, doi: 10.1016/j.jcp.2018.10.045.
- [2] T. Moribe, T. Endo, A. Yamamoto, et al., "Investigation of Subcriticality Monitoring Method Using Improved Simplest Reactivity Estimator with Bilateral Filter," in Proc. PHYSOR 2024, San Francisco, CA, USA, 2024.