

熱水システムのモデリングのための Physics-informed ニューラルネットワークの開発

石塚師也*・嶋章裕**・林為人*

Development of a physics-informed neural network for modeling of hydrothermal systems

Kazuya Ishitsuka*, Akihiro Shima** and Weiren Lin*

*京都大学大学院工学研究科都市社会学専攻

Department of Urban Management, Graduate School of Engineering, Kyoto University
C-1-108 Kyoto University Katsura, Nishikyo-ku, Kyoto 615-8540, Japan.

E-mail: ishitsuka.kazuya.4w@kyoto-u.ac.jp

**京都大学大学院工学研究科都市社会学専攻 (現 日本電気株式会社)

Department of Urban Management, Graduate School of Engineering, Kyoto University
C-1-118 Kyoto University Katsura, Nishikyo-ku, Kyoto 615-8540, Japan.

キーワード: ニューラルネットワーク, 熱水システム, 温度, 圧力, 浸透率

Key words: Neural network, Hydrothermal systems, Temperature, Pressure, Permeability

1. はじめに

火山地域や地熱地域の熱水流動は、地下の温度や圧力といった状態量や浸透率などの地殻物性値の分布に影響を受ける。そのため、熱水システムの理解や地熱資源の開発において、これらの分布を把握することは重要である。しかしながら、地下を直接的に計測できるのは、坑井が掘削された位置のみであり、これらの限られた計測データから地下の温度や圧力、浸透率等の分布をモデル化する手法の開発が求められる。

このようなモデル化において、一般的に数値シミュレーションが用いられる。計測されたデータを基に数値シミュレーションの物性値や境界条件を調整する手法は、数値シミュレーションのキャリブレーションと呼ばれる。一方、近年では、ニューラルネットワーク等の機械学習を用いた方法が提案され、成果を挙げつつある (Ishitsuka et al., 2018)。機械学習を用いることで計測データを基に、より少ない仮定でモデル化を行うことができる点が特徴である。しかしながら、熱水システムのような物理的な現象をモデル化の対象とした場合、機械学習によって予測されたモデルが物理的な法則を満たすかどうかを述べることは難しいという課題があった。

そのため、本研究では、物理法則で得られた Physics-informed ニューラルネットワーク (PINN) を用いて熱水システムの温度、圧力、浸透率をモデリングする手法を開発した。PINN は、Raissi et al. (2019) で提案された手法で、ニューラルネットワークを用いて偏微分方程式で記述される物理法則を満たすような予測を得る手法である。また、開発した手法は、実際の地熱地域を模擬したデータを用いて検証を行った。この検証において、温度のモデル化精度は良好であるものの、坑井から離れた位置において

は、浸透率の分布を適切にモデル化することは難しいことが分かった。そのため、既知の地質・地球物理データから解釈される浸透率構造を事前学習し、この学習済ネットワークを用いて転移学習することで、この課題を解決できるか検討した。

2. 手法の概要および検証用データ

3.1 Physics-informed ニューラルネットワーク

PINN は、損失関数に偏微分方程式で記述される物理法則と境界条件を組み込むことによって、物理法則に従う予測を可能とする。本研究では、物理法則として、定常状態の熱水流動の質量保存則とエネルギー保存則を用いた。また、状態方程式として、純水の単相状態を仮定した。これらの方程式は、定常状態における熱水シミュレーションでも用いられるものである。境界条件は、Dirichlet 境界条件と Neumann 境界条件のどちらも考慮できるようにした。また、ニューラルネットワークのアーキテクチャとして、4層かつ各層 50 ノードの全結合型ニューラルネットワークを用い、入力を座標値とし、出力を温度、圧力、浸透率とした。

また、転移学習では、既存の地質データや地球物理データから、真の浸透率分布とは同一ではないが、類似している数値モデルを作成できるとし、数値モデルを事前学習してから、転移学習によって一部のネットワークを学習した。

3.2 検証に用いた数値モデル

検証には、インドネシアの Lahendong 地熱地域 (Brehme et al., 2016) を模擬したモデルを用いた。Lahendong 地域の浸透率構造は高傾斜の断層に規定されていることが知られており、断層に挟まれた領域は浸透率が周囲よりも高くなっている。この大局的な地質構造を参考に、各地質ブロックの浸透率の値や境界条件は本研究で独自に設定した。

また、転移学習を応用した手法の検証には、一般的な地熱地域を単純化した数値モデルを用いた。なお、定常状態の温度と圧力の計算は TOUGH2 (Pruess et al., 1999) を用いて行った。この数値モデルから、坑井位置を仮定し、その位置での温度、圧力、浸透率を疑似的な計測データとした。仮定した坑井は、地表から大よそ等間隔で、鉛直方向に掘削されているとした。

予測値の誤差を定量化するため、坑井を仮定した深度区間を内挿深度区間、それよりも深部の深度区間を外挿深度区間として、パーセント誤差で評価を行った。

$$E = 100 \sqrt{\frac{\sum_{i=1}^N (x_{\text{ans},i} - x_{\text{pred},i})^2}{\sum_{i=1}^N x_{\text{ans},i}^2}} \quad (1)$$

ここで、 x_{ans} および x_{pred} は、疑似データおよび予測値（温度、圧力、浸透率の対数値のいずれか）を表す。初期値を変えて 10 試行を行い、誤差の平均値を用いた。

3. 結果および考察

3.1 PINN で予測した温度・圧力・浸透率分布

Lahendong 地域を模擬した数値モデルを対象に PINN で予測した温度、圧力、浸透率を第 1 図に示す。これらの予測した物理量において、温度や圧力については、数値モデルの分布を大よそ再現できていることが分かる。一方、浸透率の分布は全体の傾向を予測できているものの、坑井が存在しない位置の地質境界を明瞭に予測することはできていない。

数値モデルと予測値とのずれを式(1)のパーセント誤差で定量化したところ、温度の内挿および外挿深度区間の誤差は、1.6%と 3.4%であり、圧力の内挿および外挿深度区間の誤差は、0.52%および 1.5%であった。また、浸透率の対数値の内挿および外挿深度区間の誤差は、それぞれ 0.82%と 2.1%であった。坑井データを基に分布の予測を行っている性質上、内挿深度区間と比較して、外挿深度区間の誤差が大きくなっていることが分かる。

PINN の予測値と比較を行うため、損失関数に物理法則や境界条件を考慮しないニューラルネットワークを用いて、同様に温度、圧力、浸透率の予測を行った。その結果、予測された温度の内挿および外挿深度区間の誤差は、1.6%および 7.8%であり、特に外挿深度区間において、物理法則および境界条件を用いることで温度の予測誤差が低減していることが分かる。また、圧力の内挿、外挿深度区間の誤差は 0.53%と 1.5%、浸透率の対数値の内挿、外挿深度区間の誤差は、0.69%および 2.0%であり、PINN と NN で大きな違いは見られなかった。

3.2 PINN への転移学習の応用


坑井が届いていない位置に特徴的な浸透率構造が存在する数値モデルに適用した場合、坑井データを用いるだけでは、その浸透率構造を十分に予測することができなかった。一方、転移学習を応用することで、それらの構造を予測することが可能となった。

具体的には、今回検証に用いた数値モデルでは、高傾斜の断層を模擬した高浸透率ゾーンと深部に位置する低浸透率の基盤には坑井が届いておらず、坑井データのみでは、これらの構造を予測することはできなかった。一方、類似する数値モデルを PINN で事前学習を行うことによって、これらの浸透率構造の存在を示唆することができた。

4. まとめ

本研究では、熱水システムをモデル化する physics-informed ニューラルネットワークを実際の地熱地

域を模擬した数値モデルを用いて検証した。この手法によって、物理的により妥当な温度、圧力、浸透率分布を得ることを示した。坑井データが存在しない位置での浸透率分布の予測精度は十分でないが、転移学習を応用することでこの課題を解決できる可能性を示した。



第 1 図 Physics-informed ニューラルネットワークで予測した a.温度、b.圧力、c.浸透率の分布。各図の白線は、坑井位置を表す。

文献

- Ishitsuka, K., Mogi, T., Sugano, K., Yamaya, Y., Uchida, T., Kajiwarra, T. (2018) Resistivity-Based Temperature Estimation of the Kakkonda Geothermal Field, Japan, Using a Neural Network and Neural Kriging. *IEEE Geoscience and Remote Sensing Letters*, 15, 1154–1158.
- Raissi M, Perdikaris P, Karniadakis GE. (2019) Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686–707.
- Brehme, M., Blocher, G., Cacace, M., Kamah, Y. (2016) Permeability distribution in the Lahendong geothermal field: A blind fault captured by thermal-hydraulic simulation, *Environ. Earth Sci.*, 75, 1088.
- Pruess, K, Oldenburg, CM, Moridis, GJ. (1999) TOUGH2 user's guide version 2. https://tough.lbl.gov/assets/docs/TOUGH2_V2_Users_Guide.pdf

謝辞

本研究の一部は JST ACT-X「AI 活用で挑む学問の革新と創成」(JPMJAX20A1) および JSPS 科研費 (23H01908) の支援を受けて行いました。感謝申し上げます。