

物理法則を考慮した深層学習による地熱貯留層モデリングの 自然状態数値モデルへの適用

石塚師也*・石須慶一**・山谷祐介***・渡邊教弘***・鈴木杏奈*4・大田優介*5・
小林洋介*6・宇津木充*7・茂木透*8・浅沼宏***・梶原竜哉*9・杉本健*9

Application of geothermal reservoir modeling by a physics-informed deep learning to natural-state numerical models

Kazuya Ishitsuka*, Keiichi Ishizu**, Yusuke Yamaya***, Norihiro Watanabe***,
Anna Suzuki*4, Yusuke Ohta*5, Yosuke Kobayashi*6, Mitsuru Utsugi*7, Toru Mogi*8,
Hiroshi Asanuma***, Tatsuya Kajiwara*9 and Takeshi Sugimoto*9

*京都大学大学院工学研究科 Graduate School of Engineering, Kyoto University,
Kyoto University Katsura, Nishikyo-ku, Kyoto 615-840, Japan.
E-mail: ishitsuka.kazuya.4w@kyoto-u.ac.jp

**兵庫県立大学理学部 Graduate School of Science, University of Hyogo

***産業技術総合研究所 National Institute of Advanced Industrial Science and Technology

*4 東北大学流体研究所 Institute of Fluid Science, Tohoku University

*5 海洋研究開発機構 Japan Agency for Marine-Earth Science and Technology

*6 室蘭工業大学しくみ解明系領域 College of Information and System Informatics Research Unit,
Muroran Institute of Technology

*7 京都大学大学院理学研究科 Graduate School of Science, Kyoto University

*8 名古屋大学大学院環境学研究科 Graduate School of Environmental Studies, Nagoya University

*9 地熱エンジニアリング株式会社 Geothermal Engineering Co., Ltd.

キーワード：地熱貯留層モデリング，深層学習，地磁気地電流法，自然状態モデル

Key words: Geothermal reservoir modeling, deep learning, Magnetotellurics, Natural-state model

1. はじめに

地熱資源開発において、地熱貯留層モデリングは、温度や透水構造の広がりモデル化し、地熱システムの特徴の理解や貯留層管理に役立てられる。熱水系シミュレーションのキャリブレーションにより、モデル化されることが一般的であるが、地熱地域で一般に見られる複雑な地下構造において、数値シミュレーションをキャリブレーションすることは、多くの時間と労力を要することが知られている。

近年、深層学習を用いた地球科学システムのモデリング手法が活発に研究されている。特に、近年提案された深層学習に物理法則を考慮する手法は、データに加えて、物理法則を考慮して、系の挙動を予測することができるため、特に地球科学分野で対象となりがちなデータ量が限定される条件下においても、より信頼性の高いモデリングが可能になる可能性がある (Raissi et al., 2019)。

地熱システムを対象とした研究においても、坑井で取得された温度、圧力、浸透率を基に、熱水系の保存則を用いて、これらの値の分布を予測する方法が提案されている (Ishitsuka and Lin, 2023)。一方、この手法の有効性の検証は、地熱システムを単純化したモデルに限られている。本研究では、物理法則を考慮した深層学習による地熱貯留層モデリングを実際の地熱地域への適用可能性を高めるため、手法の高度化を行い、葛根田地域 (Sakagawa et al., 2000) と大霧地域の自然状態の数値モデルに適用して、手法の有効性と特徴を評価した。

2. 手法

全結合型の深層ニューラルネットワークを用い、坑井で得られた温度、圧力、浸透率を観測値とした。物理法則を考慮した深層学習では、損失関数 (Loss) にデータとの誤差 (DataMisfit) に加え、物理法則 (Physics) および境界条件 (Bound) の誤差を組み込み、学習を行う。

$$\text{Loss} = \text{DataMisfit} + \text{Physics} + \text{Bound} \quad (1)$$

本研究では、自然状態の熱水系を対象として、物理則として、質量保存則とエネルギー保存則を考慮した。地殻流体は、純水とした。物理法則を計算するとき、通常は自動微分を用いた計算方法が適用されるが、本研究では、有限差分法による微分も実装し、予測誤差の比較を行った。また、坑井データに加え、地磁気地電流法 (Magnetotelluric: MT) の観測値 (MT 応答関数) を考慮して予測値が改善するか検討した。具体的には、ニューラルネットで予測した温度、圧力、浸透率から計算した MT 応答関数と数値モデルから計算される MT 応答関数との誤差に関する項を損失関数に追加した。

数値モデルとして、葛根田地域および大霧地域の自然状態の熱水系モデルを用いた。葛根田地域は、既開発貯留層を含む 4.5 km (南東-東西) × 2.7 km (南西-東北) × 2.5 km (深さ) の範囲を対象とし、大霧地域は、主断層を含む 2.3 km (東西) × 1.3 km (南北) × 1.3 km (深さ) の範囲を対象とした。これらの葛根田および大霧地域の数値モデルにおいては、それぞれ 10-50 本、5-20 本の坑井位置を乱数

で分布させ、その位置での温度、圧力、浸透率を疑似的な観測値とした。また、この領域および周辺において分布した100点の観測点において 10^{-2} – 10^3 Hzの見かけ比抵抗と位相が得られているとした。予測誤差は、次式で定量化した。

$$E = 100 \sum_n^N \frac{|X_{ans,n} - X_{pred,n}|}{|X_{ans,i}|} \quad (2)$$

ここで、 X_{ans} および X_{pred} は温度、圧力、浸透率の対数値いずれかの参照値と予測値を表し、 N は誤差の計算に用いたデータ数（領域のグリッド数）を表す。

3. 結果および考察

3.1 坑井数による予測誤差と学習方法の影響

異なる坑井数を想定して、予測した温度、圧力、浸透率の誤差を計算したところ、いずれの値においても坑井数の増加に伴う誤差の減少が見られた。これは一般的な深層学習の傾向と同様であると言える。特に温度において、坑井数の増加に伴う誤差の減少の傾向が顕著で、圧力は、坑井数に伴う誤差の減少の程度はそれほど顕著ではなかった。これは、圧力の全体的な空間構造は、少数の坑井でも捉えられている一方で、温度の空間構造を捉えるにはある程度の坑井数を要することを意味していると考えられる。

続いて、物理法則の計算方法に伴う予測誤差の違いを比較した。自動微分を用いて物理法則を計算した場合、葛根田地域の数値モデルにおいて、坑井数15本において、温度と圧力の誤差はそれぞれ15.1%と2.4%であったが、一方、有限差分法を用いた場合の誤差は13.4%（温度）と1.3%（圧力）に低下した。他の坑井数においても同様の傾向が見られ、有限差分法は温度と圧力の誤差を低減される影響があることが分かった。浸透率の誤差は、物理法則の計算方法に大きな影響を受けなかった。

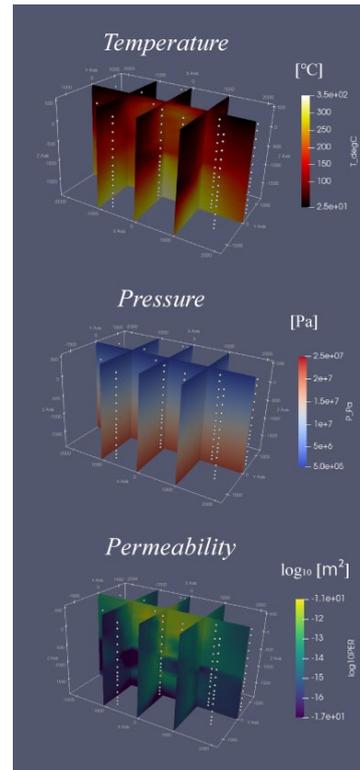
物理法則等を考慮した影響を調べるため、物理法則と境界条件を考慮せずに、同じ坑井数および位置で得られた値を基に、温度、圧力、浸透率を予測し、予測誤差を比較した。大霧地域の数値モデルを対象として、5本の坑井を考えた場合、温度、圧力、浸透率の対数値の誤差は、それぞれ32.0%、112.7%、9.4%であった。一方、本研究で提案する物理法則と境界条件を考慮する場合の誤差は、9.1%（温度）、5.8%（圧力）、8.5%（浸透率の対数値）であり、温度と圧力の誤差が大幅に低減していることが分かった。以上のことから、物理法則が主に温度や圧力を制約していると考えられる。

3.2 MT 応答関数を考慮した影響

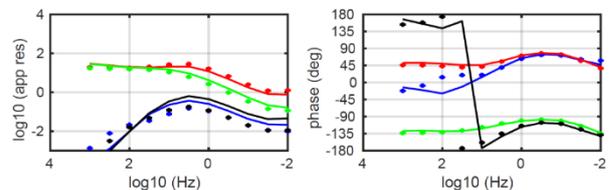
葛根田地域の数値モデルを対象として、15本の坑井を想定した場合に、MT 応答関数を考慮した予測した温度、圧力、浸透率の分布を第1図に示す。また、計算したMT 応答関数と熱水系モデルから得られた参照値との差を第2図に示す。MT 応答関数を考慮して予測した温度、圧力、浸透率の対数値の誤差は、それぞれ9.4%、1.3%、6.5%であった。一方、MT 応答関数を考慮しない場合、上述のように温度の誤差は13.4%であり、圧力、浸透率の対数値の誤差は、それぞれ1.3%、7.1%であった。このことから、MT 応答関数を観測値として、考慮することで、予測値を精緻化することができ、特に温度と浸透率に改善が見られた。

4. まとめ

本研究では、物理法則を考慮した深層学習の高度化を行い、葛根田地域と大霧地域の熱水系モデルに適用して手法の予測誤差や特徴を検証した。手法は、限られた坑井数でも適用できることが分かり、地熱開発の初期や中期のフェーズにおいても有効である可能性を示した。



第1図 坑井データに加えてMT 応答関数、物理法則、境界条件を考慮して予測された温度、圧力、浸透率。白点線は想定した坑井位置を表す。



第2図 予測結果から計算されるMT 応答関数（実線）と参照値（点）との比較の例。赤、緑、青、黒は、それぞれXY, YX, XX, YY成分（X,Yはそれぞれ南北・東西方向）を表す。

文 献

- Raissi, M., Perdikaris, P., Karniadakis, G.E. (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.
- Ishitsuka, K., Lin, W. (2023) Physics-informed neural network for inverse modeling of natural-state geothermal systems. *Applied Energy*, 337, 120855.
- Sakagawa Y, Aoyama K, Ikeuchi K, Takahashi M, Kato O, Doi N, Tosha T, Ominato T, Koide K (2000) Natural state simulation of the Kakkonda geothermal field, Japan, *Proceedings of World Geothermal Congress 2000*, 2839-2844.

謝辞

本研究はNEDO「地熱発電導入拡大研究開発/地熱発電高度利用化技術開発/AIを利用した在来型地熱貯留層の構造・状態推定」の支援を受けて行いました。石塚は、JSPS 科研費(23K26601)の支援も受けました。また、葛根田地域の数値モデルは、東北自然エネルギー株式会社より提供いただきました。ここに記して感謝申し上げます。