

# 地熱貯留層モデリングへの機械学習の適用

鈴木杏奈\*・Shi Shuokun\*\*・橋田俊之\*\*

## Application of Machine Learning to Geothermal Reservoir Modeling

Anna Suzuki\*, Shi Shuokun\*\*, and Toshiyuki Hashida\*\*

\*東北大学流体科学研究所 Institute of Fluid Science, Tohoku University, 2-1-1 Katahira, Aoba-ku, Sendai 980-8577, Japan. E-mail: anna.suzuki@tohoku.ac.jp

\*\*東北大学大学院工学研究科 Fracture and Reliability Research Institute, Tohoku University, 6-6-11-709 Aza-Aoba, Aramaki, Aoba-ku, Sendai 980-8579, Japan. E-mail: hashida@rift.mech.tohoku.ac.jp

キーワード：地熱開発，貯留層評価，自然状態シミュレーション，機械学習

Key words：Geothermal development, Reservoir evaluation, Natural state simulation, Machine learning

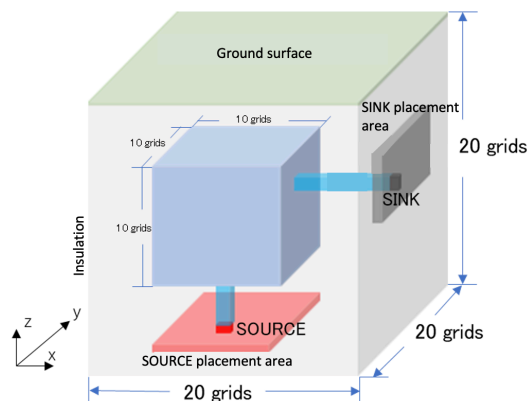
### 1. はじめに

地熱発電では，地下の熱で温められた熱水や蒸気を利用して発電を行うため，貯留層内における熱水の流動を把握することが重要である。貯留層評価では，資源調査や掘削・試験の結果を総合解析し，開発と管理のための貯留層シミュレーションを実施する。開発の初期段階では，開発前の貯留層の状況を把握する自然状態シミュレーションが行われるが，はじめに，地質や物理探査による計測結果に基づき概念モデルを作成し，貯留層の構造や境界条件を含めた数値モデルを構築する。そして，数値計算によって得られた結果と実測データを比較し，数値モデルを修正していく。数値モデルの更新は，限られたデータのもとで膨大な試行錯誤が必要で，また，解析者の主観に委ねられてしまうため，数値モデルのパラメータを効率的・客観的に推定できる手法が求められる。そこで本研究では，膨大な試行錯誤を事前に学習できる機械学習を利用し，自然状態シミュレーションの入力パラメータの効率的な推定手法の開発を目的とした。開発初期段階に得られる自然状態の温度・圧力分布を用いて，貯留層の境界条件と浸透率分布を推定する機械学習手法を検討した。

### 2. 手法

#### 2.1 学習データの生成

多孔質媒体中の気液二相流と熱の流れを解析する貯留層シミュレータ TOUGH2 を用い，機械学習の学習データを作成した。手法の検証のため，2次元/3次元の貯留層領域を用意した。2次元の計算領域を第1図に，TOUGH2の入力パラメータを第1表に示す。領域中央の貯留層(高透水領域)，熱水の流入域(SOURCE)，流出域(SINK)，それらをつなぐ断層帯を配置し，上面は温度圧力一定，周囲と底面は断熱境界とした。貯留層の浸透率と，SOURCE および SINK の条件を推定の対象とし，それらは乱数を用いて，5000パターンを用意した。浸透率と境界条件をターゲットとし，計算した温度分布，圧力分布から得られる値を特徴量として，学習用のデータセットを生成した。学習率は0.75とした。



第1図 シミュレーション領域。

第1表 入力パラメータ。

Data set	5000	Top temperature	25°C
Region	2 km x 2 km x 2 km	Top pressure	0.1MPa
Grid number	20 x 20 x 20	Bottom temperature	200°C
Density	2250kg/m <sup>3</sup>	Bottom pressure	2MPa
Porosity	0.1	Permeability	
Heat conductivity	2.5w/m·k	Surrounding rock	10 <sup>-18</sup> m <sup>2</sup>
Heat capacity	1000kJ/m <sup>3</sup> ·°C	Fault	10 <sup>-15</sup> m <sup>2</sup>
		Reservoir	10 <sup>-13</sup> - 10 <sup>-17</sup> m <sup>2</sup> (random)
		SOURCE flow rate	0.2 - 0.8 kg/s
		SOURCE enthalpy	852-1345 MJ/kg

#### 2.2 SOURCE/SINK の条件推定モデルの開発

Suzuki et al. (2022)では，固定した SOURCE/SINK の条件のもと，浸透率の推定に成功している。ここでは，SOURCE と SINK についての条件を推定する学習モデルを開発した。SOURCE と SINK の位置については，三つの分類の機械学習手法(K-近傍法(KNN)，ロジスティック回帰(LR)，ランダムフォレスト(RF))を用い，SOURCE の

比エンタルピーと SOURCE の流量については、回帰の機械学習手法（決定木の勾配ブースティングの一つである LightGBM）を用いた。

### 2.3 境界条件推定モデルの開発

特徴量には、温度分布、圧力分布の他、2.3 で推定した SOURCE, SINK の条件を含めた。機械学習手法には、2.3 同様、LightGBM を用いた。推定モデルの精度を上げるため、特徴量の入力方法として one-hot エンコーディング (Harris and Harris, 2012) を導入した。one-hot エンコーディングとは、カテゴリ変数を数値化する表現方法であり、決定木の使用頻度に基づいた重要な特徴量を選定し、計算量を大幅に低減することができる。

### 3. 結果および考察

テストデータを用いた推定精度の検証結果を第 2 表に示す。精度 (Precision) は、推定範囲の総グリッド数 (SOURCE の場合は下面のグリッド数, SINK の場合は側面のグリッド数) に対する推定に成功したグリッド数の割合であり、再現率 (Recall) は、SOURCE (または SINK) の総グリッド数に対する推定に成功したグリッド数である。両者とも、1 に近いほど精度が高いことを示している。検証結果より、三つの分類の機械学習手法 (KNN, LR, RF) はどれも精度が高いことを確認し、機械学習で SOURCE と SINK の位置を推定できる可能性が示された。また、回帰問題である SOURCE の比エンタルピーと流量の評価には、決定係数 ( $R^2$ ) を用いた。検証結果より、比エンタルピーはよい精度で推定できることが確認できたが、流量はあまり良い精度が得られなかった。また、浸透率の推定も同様に行い、一定の精度が出ること確かめた。2次元のテストデータを用いた推定結果の一例を第 2 図に示す。SOURCE/SINK の位置は一致しており、また、浸透率の分布もよく推定ができていことがわかる。

続いて、模擬フィールドデータに対して、開発した推定モデルを適用した。模擬フィールドデータの浸透率分布の一断面と推定した浸透率分布を第 3 図に示す。推定結果は、模擬フィールドデータの傾向を捉えており、特に浸透率分布の輪郭を捉えることができてい。今回の学習データでは乱数によってモザイク模様のような浸透率分布を用いたが (第 2 図参照)、第 3 図に示されるような高透水性領域と低透水性領域が区別されるような任意の浸透率分布に対しても学習モデルが適用できる可能性がある。一方で、今回の学習モデルでは、3次元の温度分布、圧力分布を入力値とする必要がある。実際のフィールドでは、井戸での計測結果は必ず離散的となることから、離散的なデータでも推定が可能かどうかを検証することが今後の課題である。

### 4. 結言

本研究では、地下温度分布および圧力分布に基づく地下境界条件及び浸透率分布推定手法を提案し、その実現可能性を検討した。定常状態の 2次元/3次元の温度および圧力分布により SOURCE/SINK の条件と浸透率分布を推定する機械学習推定モデルの開発に成功した。模擬フィールドデータの検証により、学習データと異なる分布を有するフィールドデータに対しても適用できる可能性を示した。本研究では、汎用的な機械学習手法を適用したが、深層学習を用いた貯留層パラメータの推定も試みられている (Ishitsuka et al., 2021)。多様な手法を適用し、よりよい

第 2 表 SOURCE/SINK の条件の推定精度。


(a) SOURCE		2D	3D
Position (RF)	Precision	0.988	0.998
	Recall	0.990	0.960
Enthalpy (LightGBM)	$R^2$	0.984	0.830
Flow rate (LightGBM)	$R^2$	0.717	0.568


(b) SINK		2D	3D
Position (KNN)	Precision	1.000	0.999
	Recall	1.000	0.996

(c)		2D	3D
Permeability (LightGBM)	$R^2$	0.866	0.760



第 2 図 SOURCE/SINK 位置ならびに浸透率分布の推定結果. (a)真値, (b) 推定値.



第 3 図 SOURCE/SINK 位置ならびに浸透率分布の推定結果. (a)真値, (b) 推定値.

貯留層評価の可能性を検討することが期待される。

### 文 献

- Harris and Harris (2012) Digital design and computer architecture (2nd ed. ed.).
- Ishitsuka et al. (2021) Bayesian and neural network approaches to estimate deep temperature distribution for assessing a supercritical geothermal system: evaluation using a numerical model, Natural Resources Research, 30(5), 3289-3314.
- Suzuki et al. (2022) Data-driven geothermal reservoir modeling: estimating permeability distributions by machine learning, Geosciences, 12(3), 130.