

深層学習を用いた物理探査データからの地温分布推定：数値テスト事例

山本壮馬*・後藤忠徳**

Subsurface Temperature Distribution inferred from Geophysical Exploration Data using Deep Learning: Numerical Tests

Soma Yamamoto* and Tada-nori Goto **

* 兵庫県立大学大学院理学研究科 Faculty of Science, Univ. Hyogo, 2167, Shosha, Himeji, Hyogo, 671-2280, Japan. E-mail: syamamoto@earth-univ-hyogo.jp

** 兵庫県立大学大学院理学研究科 Graduate School of Science, Univ. Hyogo, 2167, Shosha, Himeji, Hyogo, 671-2280, Japan. E-mail: tgoto@earth-univ-hyogo.jp

キーワード： 深層学習, 地中温度分布, 比抵抗, 地震波速度

Key words: Deep learning, Subsurface Temperature, Resistivity, Seismic velocity

1. はじめに

地下の温度分布は、地熱開発において重要であり、熱源の発見や、地熱エネルギー開発時の規模の検討などに使用されている。特に、地熱発電開発前後の熱水循環パターンの変化や、地熱発電の持続性を議論するための基礎情報である。温度分布は主に、試掘時や開発時の坑井での直接的な温度測定に基づくことが多い。これらの坑井には深さ3000 mを超えるものも見られるが、掘削には多額の費用と環境負荷が伴うため、坑井数は限定されることが多い。そこでより高精度・高分解能での温度分布の推定を目的として、ニューラルネットワークを用いて温度を推定する試みが近年見受けられている。例えば Spichak and Zakharova (2012)や Maryadi and Mizunaga (2022)では、坑井位置で比抵抗と温度との関係を学習させて、地表で得られる比抵抗データから坑井以外の温度推定を行っている。Gu et al. (1997)では、ニューラルネットワークの学習にセミバリオグラムを加えることで、坑井の温度データのみを用いた地中温度の推定が提案されており、これによって坑井以外の温度を推定する手法に関する情報を得ることができる。しかしながら、既存データに対して物理探査で得られる地震波速度分布を加えたり、ニューラルネットワークの最適化によって、温度の推定精度の向上が期待されると考えられる。そこで本研究では、温度推定値の最適解が得られるようなニューラルネットワークの計算モデルを作成し、その手法に関する議論を試みた。また、地表観測で得られる比抵抗と地震波速度を用いて地中温度の推定を行い、この手法で坑井以外の地点での温度が推定できるかどうか検証を行った。

2. 手法

2.1 使用データ

深部流体の温度シミュレーションソフトである Hydrotherm (USGS 提供) とそれに含まれている温度データを用いた。水平距離が $x = -1.88 \sim 7.25$ km, 深さが $z = 0 \sim 1.97$ km であり (図 1), 高温岩体 (熱源) を $x = -0.73 \sim 0.73$ km, 深さ 2 km 以深に置いた。初期温度は 950 °C, 透

水係数は高温岩体を 1.0×10^{-14} cm/s, 岩盤を 1.0×10^{-11} cm/s とし, 10,000 年後の温度構造を使用した。比抵抗と地震波速度データは、この温度分布を基に、既存の岩石の室内測定結果に基づいて作成した (図 2 および 3)。さらに地下構造を実際の地熱地域に類似したものに近づけるために、より複雑な地下構造 (基盤+堆積層) に対する、温度推定も試みる。具体的には、数値シミュレーションにより温度分布を求め、室内実験結果から比抵抗・地震波速度といった観測データを作成して、ニューラルネットワークを用いて地温温度分布の推定を試みた。

2.2 ニューラルネットワーク

入力層(入力データ)は水平・鉛直位置の情報 (x と z) , 比抵抗 (ρ または $\log \rho$) , 地震波速度 (v_p) を採用し, 出力層(出力データ)は温度 T とした。中間層と出力層における活性化関数として ReLU 関数を用いた。使用した学習アルゴリズムは一般的な誤差逆伝播法と勾配降下法である。地中の各地点での温度や比抵抗などのデータセット 121 個のうち 22 個 (坑井 2 本分) を、その学習が上手く行われたか検証するテストデータとして (図 1) , 残る 99 個を学習データとして使用した。本研究では、地中の各点でのデータセット $\{x, z, \rho$ または $\log \rho\}$ に対して、入力データの組み合わせの変化や、ニューラルネットワークを構築するパーセプトロンの数 (中間層の数 & 中間層 1 層あたりのパーセプトロン数) を変化させた上で、地温分布推定に最も適切な計算モデルの議論を行った。さらにこれらのデータセットに v_p を追加して、同様に地中分布推定を行った。


3. 結果と考察

入力データが位置情報 x と z , 比抵抗 $\log \rho$ の場合について深層学習により温度推定を実施した。本研究の場合では、パーセプトロン数が 20 個のときに、最も地温分布推定の精度が高かった (図 4) 。 Cost function と RMS misfit の値はパーセプトロン数の変化によって変動が見られるが、パーセプトロン数 20 個のとき、両方の値が小さくなっていることから、このときが最適な計算条件であると考えられる。


さらに、地震波速度と比抵抗の両方の空間分布がある場合は、推定温度は合成温度とより良い一致を示した。この場合は、推定値と正解値の誤差は平均して 1 °C 未満であった。最適な中間層は 3 層であったため、いわゆる深層学習（ディープラーニング）と言える。このような高精度な温度推定に成功した理由は、本研究で作成した地震波速度データが温度と密接（線形）な関係を仮定したためであると考えられる。このような温度との関係が比較的単純な物性値を用いたために、想定した値と非常に似た地温温度分布が出力されたと考えられる。比抵抗は、温度のほかにも様々な因子に影響されて変化するため、位置情報と比抵抗だけでは、この方法を用いて温度推定を行うと精度が低下することが分かった。

4. まとめ


ニューラルネットワークのチューニングと、入力データに位置情報・比抵抗・地震波速度を適用して、どの計算モデルが地中温度分布を高い精度で出力できるか、また未知の温度を推定できるかについて議論を行った。パーセプトロン 20 個の計算モデルにおいてコスト関数, RMS 残差ともに小さくなることが分かった。また、地震波速度を追加して入力データを標準化して温度を推定し、入力データの組み合わせについて議論した。地震波速度を追加すると、推定温度は合成温度と良い一致を示した。今後は、地震波速度を温度以外の作用も追加して再度温度を推定する、あるいはディープラーニングと異なる機械学習の適用を検討していく必要があると考える。また実際の温度データや物理探査データに対して本手法の適用を行う予定である。




第 1 図 作成した地温分布. 点線部の温度は学習には使用していない



第 2 図 入力データの一つである比抵抗(log ρ)分布



第 3 図 Cost function & RMS misfit (log ρ 追加)



第 4 図 地温分布の推定 (x, z, log ρ を入力に使用)

文 献

Gu, B., Koike, K., & Ohmi, M. (1997). Distribution analysis of metalliferous vein using artificial neural network. *Geoinformatics*, 8 (1), 15-21.

Maryadi, M., & Mizunaga, H. (2022). Subsurface temperature estimation in a geothermal field based on audio-frequency magnetotelluric data. *Exploration Geophysics*, 53 (3), 275-288.

Spichak, V., & Zakharova, O. (2012). The subsurface temperature assessment by means of an indirect electromagnetic geothermometer. *Geophysics*, 77 (4), WB179-WB190.