

人工ニューラルネットワークを用いた 地球物理的データによる地下温度推定

Estimation of subsurface temperature by geophysical data using Artificial Neural Network

菅野倅大朗（北海道大学理学院）、茂木透（北海道大学工学研究院）、
内田利弘（産業技術総合研究所）、梶原竜哉（地熱エンジニアリング株式会社）

Kotaro Sugano (Graduate School of Science, Hokkaido University), Toru Mogi (Faculty of Engineering, Hokkaido University), Toshihiro Uchida (National Institute of Advanced Industrial Science and Technology), Tatsuya Kajiwara (Geothermal Engineering Co., Ltd)

Accurate estimation of the underground temperature is essential for the resource evaluation of a geothermal reservoir. However, the quantity of temperature data measured in boreholes is usually limited and therefore the estimation of temperature distribution at depth is often difficult. General relationship between resistivity and temperature has been studied in laboratory experiment by using drilling samples, but it is not always applicable because there are many factors that affect the resistivity value.

Here, we have tried to indirectly estimate the underground temperature by geophysical data. By using Artificial Neural Network (ANN) trained by geophysical data, this study aims to estimate underground temperature by resistivity data obtained from magnetotelluric (MT) sounding. We applied the method to the Kakkonda geothermal area, Iwate Prefecture, Japan. Many drillings and MT surveys were carried out before so we can get many data to educate the ANN.

We educated the ANN by position, depth and temperature data from well log temperature and resistivity data from MT sounding and seismic data from seismic survey. As a result, we obtained good agreement at up to about 3.1 km depth by several constructed ANN. However, fitness was not good at around sealing layer (around 3.1 km depth), because resolution of resistivity structure of deeper part is too coarse to emerge changing temperature.

1. はじめに

地熱資源を開発するにあたって、地下温度を正確に把握することは、その地熱資源を評価する上で最も重要なことである。現在、地下温度を正確に把握する方法はボーリング掘削による温度検層が主な手法であるが、深度は限られており、地下深部までの温度分布を正確に把握することは困難である。ボーリング掘削で

採取された岩石試料から、実験的に比抵抗と温度の関係が求め、それを利用して深部の温度を推定することもあるが、地下では様々な条件によって比抵抗と温度の関係が決まるため、その方法による推定には限界がある。

本研究では、人工ニューラルネットワーク (ANN) を用いて、比抵抗構造から地下深部温度を推定することを試みた。この方法は、地上付近で得られる地球物理的データと坑内温度を用いて ANN を教育し、地下深部の温度を間接的に推定しようとする方法が Spichak (2006)により提案され、いくつかの地熱地域において比抵抗構造から深部の温度推定が行われている。本研究は、岩手県葛根田地熱地域で得られた、深度 2500m までの坑内温度、MT 探査による比抵抗構造に加えて微小地震震源分布を ANN の教育データとして用いた。それらをもとに、多くの ANN の構成し、2500m までの推定温度が実測温度とよく合う ANN を選んだ。そのよい構成の ANN を用いてさらに深部の地下温度を推定した。この地域には、深度 3700m に達する WD1 があり、その孔底温度は約 500°C と測定されている (Doi et al.,1998)。従って、2500m までのデータから 3700m までの温度を推定し、その結果を測定値と比較することにより検証することが可能である。このように、本研究では、ANN を教育する地球物理学的データとして比抵抗構造に加えて、微小地震は通常約 350°C の温度を示す延性脆性境界以下では発生しないので、これも温度を推定するデータとして加えた。また、2500m 以下の推定結果を WD1 の実測値と比較し、推定の良悪を検証した。

2. ニューラルネットワークの構成と教育に用いるデータセット

本研究では、ニューラルネットワーク (ANN) の演算には Matlab ライブラリーにある Neural net Fitting というアプリケーションを使用している。この ANN では、それを構成するパラメータとして、Training, Validation, Testing に用いるデータの割合を選択できる。本研究では、これらの割合が 70 : 10 : 20 の場合と 80 : 05 : 10 の場合の 2 パターンを選択した。また、隠れ層の数も選択可能であり、今回は、いろいろテストした結果、5 層および 7 層の場合がよい動作が得られたので、それらを選択した。それらを合わせて 4 ケースの ANN の構成を用意した。

また、教育に用いるデータセットとして以下 4 ケースを用意した。ただし、本地域の比抵抗構造は Fig.1 に示すように Uchida et al. (2000)により、2 次元インバージョンと 3 次元インバージョンによる比抵抗構造が得られているが、ここでは構造の分解能がよい 2 次元インバージョンにより得られた比抵抗値を用いた。また、坑井内温度データは、葛根田地域にある Well-13, 18, 19, 31, 72, 85 および KKD 孔のデータを用いた (Hanano and Kajiwara., 1999)。これらのボーリングの掘削深度は 890m~2800m までであるが、このうち 2500m までの温度測定データを利用した。このようなデータ中から、以下の 4 ケースの教育用データセットを選択した。

ケース 1 : 比抵抗値、すべての坑井データ、微小地震発生数

ケース 2 : 比抵抗値、Well-18,19 を除いた坑井データ、微小地震発生数

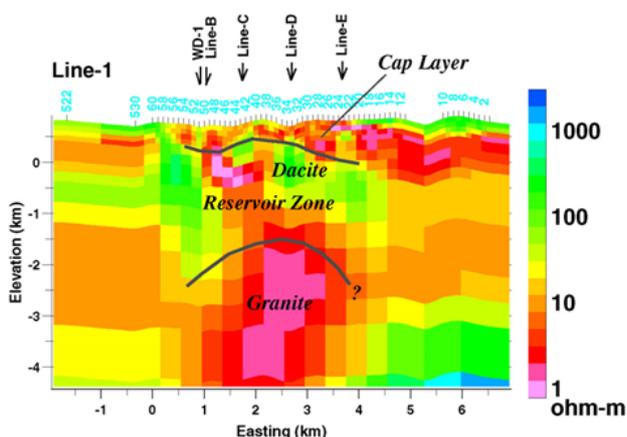


Fig.1 Resistivity cross section of Kakkonda geo-thermal field. Upper line shows lower boundary of Cap Rock Layer and Lower line shows upper boundary of Granitic rocks (Uchida et al., 2000).

ケース 3：比抵抗値、600m 以深の坑井データ、微小地震発生数

ケース 4：比抵抗値、600m 未満と Well-KKD を除いた坑井データ、微小地震発生数

18, 19 孔は WD1 孔の近傍であるため、WD1 項で検証することを考えてこれらのデータを外してみたのがケース 2 である。対象地域では、地表から約 600m までは主として熱変成岩類から構成されるキャップロック帯となっており、一般的な比抵抗と温度の関係とは異なった挙動を示す。そのため、地下深部を推定するにあたってネットワーク教育の弊害となると考え、ケース 3 では 600m までのデータを外した。また、Well-KKD 付近では微小地震がほとんど起こっておらず、延性脆性協境界が判別できないため、ケース 4 としてこのデータを外したネットワーク教育を行ってみた。以上よりパラメータ設定 4 ケース、データセット 4 ケースで計 16 ケースのニューラルネットワークを構築した。

3. ネットワークの動作テスト

それぞれのケースで教育されたネットワークを用いて WD1 の 2500m までを推定し、推定温度と WD1 の実測値をプロットした。その例を Fig.2 に示す。このような図を描いたとき、近似直線の傾き、切片、相関係数を用いて ANN の動作の良悪を判定した。ここでは、判定基準として、“傾き： 1 ± 0.1 以内”、“切片： ± 30 以内”、“相関係数：0.9 以上”とした。すべての値が基準値に達するまで再教育を繰り返し、30 回以上繰り返してもすべての値が基準値に達しなかった場合のみ、30 回の教育の中で一番成績の良かったものを採用した。それぞれのケースにおける傾き、切片、相関係数を Table 1 にまとめて示した。

4. 地下温度の推定結果

各ケースにおいて判定基準を上回った ANN を用いて、地下深部温度の推定を試みた。ここでは、2500m までのデータで教育された ANN を用いて 3700m までの WD1 孔の位置での温度分布を推定した。推定結果を Fig.3 に示す。まず、いくつかのケースにおいては、3100m の温度をほぼ正確に推定することができたが、すべてのケースで 3100m 以深の急激な温度変化を再現できなかった。浅部から深部までもっともよく推定できていたケースは、600m までと Well-KKD のデータを除いたものであった。Training, Validation, Testing の比と隠れ層の層数の違いによる推定結果には大きな違いは見られなかった。しかし、600m 以浅も含めてすべての坑井データを用いたケースの推定結果を見ると、深部の推定ができていないものがほとんどである。また、600m 以深のデータを使ったもの、600m までと Well-KKD のデータを除いたものはすべてのケースで 3100m までの温度をほぼ正確に推定できている。Well-18,19 を除いたものは、ケース②以外で全体的にあまりうまく推定できていないが、3100m ではすべての坑井データを用いた場合よりも正確に推定できている。

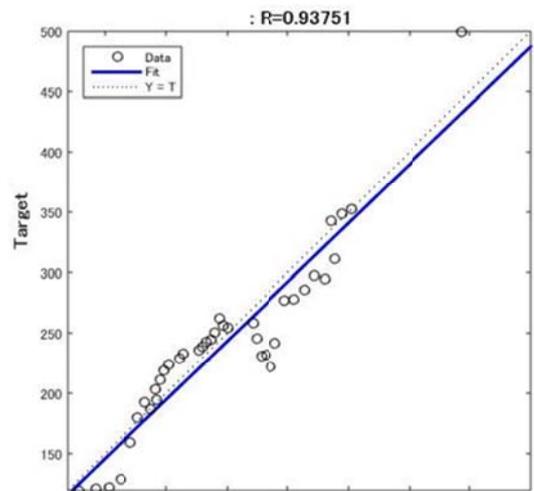


Fig. 2 Example of testing graph. Blue line indicate fitting and its formula is shown at below. R is correlation coefficients.

Training : Validation : Testing 80 05 15		Hidden layers 5					
Case	R	Fit Deg	Intercept	Case	R	Fit Deg	Intercept
①	0.93718	1.1	-15	⑨	0.86748	0.95	1.8
②	0.90379	0.95	12	⑩	0.93106	0.95	-7.1
③	0.90801	1	-0.25	⑪	0.91761	1	-0.37
④	0.91607	1.1	-8.6	⑫	0.96005	1.1	-18
Training : Validation : Testing 80 05 15		Hidden layers 7					
Case	R	Fit Deg	Intercept	Case	R	Fit Deg	Intercept
⑤	0.83655	1.1	0.88	⑬	0.92114	1	-5.1
⑥	0.91919	1.1	0.92	⑭	0.87733	0.92	18
⑦	0.90801	1	-0.25	⑮	0.93048	1	-9.1
⑧	0.95829	1.1	-13	⑯	0.97722	1.1	-13

Table 1 Testing result of each case. Cases, 1, 5, 9 and 13 were using all borehole data. Cases, 2, 6, 10 and 14 were not using borehole data at well-18,19. Cases 3, 7, 11 and 15 were using data below 600m only. Cases 4, 8,12 and 16 were using data below 600m and not using well-KKD data.

5. 議論

600m 以浅のデータも含むすべての坑井データを用いたケースで深部の推定結果が悪かった理由は、浅部にある低比抵抗のキャップロック帯でのデータが影響していると考えられる。キャップロックは、低比抵抗ながら浅部にあるので温度が低く、温度が高くなると比抵抗が下がるという地下深部では一般的な傾向が見られないので、ANN が深部でも比抵抗が下がっても高温ではないこともあると学習してしまっていると考えられる。逆に、キャップロック帯を除いている 600m以深のデータだけを使ったケースのうち、Well-KKD を除いたものでは、キャップロック帯の影響を受けなかったため、すべてのケースで 3100mまでの温度をほぼ正確に推定できていたと考えられる。

Well-18,19 を除いたケースでは、全体として比較的うまく温度を推定できていないが、これは単純に、教育に使用するデータ数が大幅に減ってしまったためであると考えられる。しかし、実測値の傾向から大きく外れるようなケースはなく、推定したい領域に隣接するような坑井がなくとも、大局的には温度変化を知ることにはできると考えられる。また、ケース②が Well-18,19 を除いたケース⑩よりもよく深部を推定できている理由は、Training の割合を 70 ではなく 80 と大きくしているため、Training に使用するデータ数がある程度確保できたためと考えられる。

すべてのケースにおいて、3100mにある温度変曲点以深の急激な温度上昇を推定できなかった。深度 3100m のところは、天水循環領域とマグマ性流体循環領域の境界であるシール層があり（最首・他，2016）、そこでの急激な温度上昇を再現できなかった理由は、そこで比抵抗値が大きく変化していないためと考えられる。そもそもシール層の上下で比抵抗の差がない可能性もあるが、地下深部での比抵抗値の分解能が低く、ここでの温度変化を比抵抗値の変化としてとらえられないことが原因とも考えられる。

6. まとめ

本研究では、葛根田地熱地域で得られた孔内温度と MT 法による比抵抗構造および微小地震の震源分布を用いて、地下深部温度の推定を試みた。その結果、この地域の深度 3100m 付近にあるシール層までは温度がよく推定されるケースがあったが、それより深部は推定ができなかった。その原因は、比抵抗構造の分解能である可能性もあるので、この方法により地下深部温度の推定精度向上のためには地下深部での分解を向上

させる必要がある。

謝辞

本研究の遂行にあたり、北海道大学大学院工学研究院・茂木透教授より貴重なご助言をいただきました。また、葛根田地熱地域の孔井データを東北自然エネルギー(株)に提供していただきました。記して深く感謝いたします。

参考文献

Doi, N., Kato, O., Ikeuchi, K., Komatsu, R., Miyazaki, S., Akaku, K. and Uchida, T., Genesis of the plutonic-hydrothermal system around quaternary granite in the Kakkonda geothermal system, Japan. *Geothermics*, 27, 663-690, 1998.

Hanano M. and T.Kajiwara, Permeability Associated With Natural Convection in the Kakkonda Geothermal Reservoir, *Geothermal Resources Council Transactions*, 23, 7-20, 1999.

最首花恵, 岡本敦, 土屋範芳, 地熱地域の地殻の透水-不透水境界と水の状態変化にともなう鉱物析出の関係性, *地熱学会誌*, 38, 17 - 25, 2016.

Spichak, V.V., Estimating temperature distributions in geothermal areas using a neuronet approach, *Geothermics* 35, 181-197, 2006

Uchida, T., Ogawa, Y., Takakura, S., and Mitsuhata, Y., Geoelectrical investigation the Kakkonda geothermal field, northern Japan: *Proceedings, World Geothermal Congress 2000, 1893-1898, 2000.*

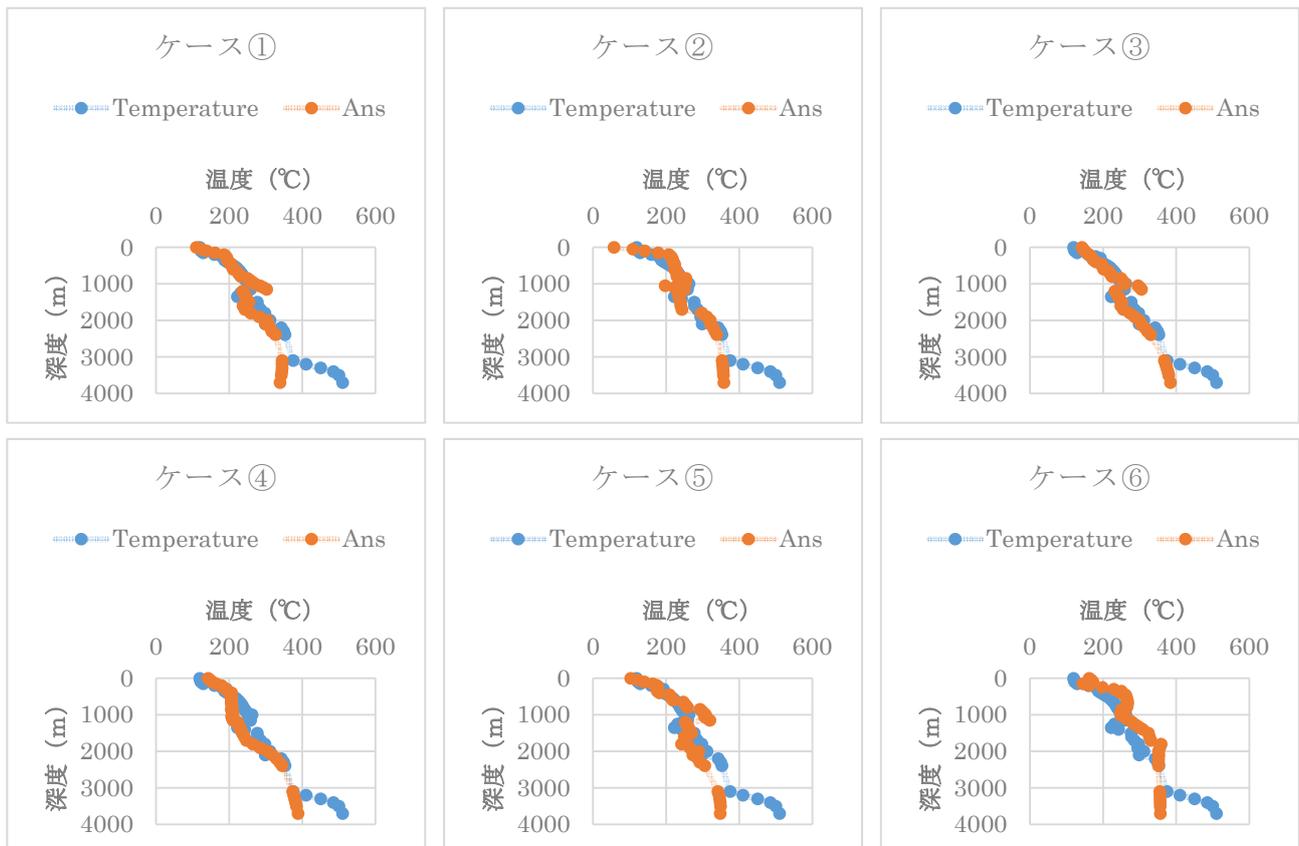




Fig. 3 Result of temperature estimation for all cases. Blue lines indicate measured temperature, red lines indicate estimation temperature using ANN.