

ニューラルネットワークを用いた 比抵抗データからの温度推定手法の精度に関する研究

石塚師也

北海道大学大学院 工学研究院
(元深田地質研究所)

Accuracy of Temperature estimation from resistivity data using neural network

ISHITSUKA Kazuya

Graduate School of Engineering, Hokkaido University
(former Fukada Geological Institute)

要旨：地熱地域における地下の温度分布は、貯留層の特徴や地下流体の流速分布と関係しているために、地熱開発において重要な情報の1つである。近年、このような温度分布を推定する手法として、ニューラルネットワークを用いて比抵抗データから温度を推定する手法が提案され、効果を上げつつある。この手法は、比抵抗が温度に関係するパラメータであることを利用し、坑井で取得された温度データと比抵抗の関係をニューラルネットワークで学習させ、温度データの無い箇所において、比抵抗データから温度を推定する手法である。本研究では、当手法を葛根田地熱地域に適用し、手法の特徴や精度について検討した。解析の結果、比抵抗データを用いずにニューラルネットワークを用いて温度を推定した場合と比較して、1-9%誤差が減少することが分かった。特に、教師データとして用いる温度データが少ない場合や教師データと温度を推定したい箇所の距離が離れている場合等、比抵抗を用いずにニューラルネットワークのみを用いる手法で誤差が大きくなる条件において、より小さな誤差で温度を推定できることが分かった。本解析結果は、ニューラルネットワークを用いて比抵抗データから温度分布を推定する手法の有効性を示している。

キーワード：地熱開発，温度推定，ニューラルネットワーク，比抵抗，葛根田地熱地域

Abstract: Subsurface temperature distribution beneath a geothermal field is a vital information for geothermal development, because temperature pattern is related to reservoir characteristics and subsurface fluid velocity. To estimate subsurface temperature distribution, it has recently been proposed that neural network is used to estimate temperature distribution based on resistivity. This method is based on the fact that resistivity is sensitive to temperature. Firstly, the method constructs an optimized feedforward neural network that relates the relationships between locations, resistivity and temperature at well locations. Then, temperature data are estimated at locations without well data based on resistivity measured by Magnetotelluric method. In this study, we examined the characteristics and the accuracy of the methodology by applying it to the Kakkonda geothermal field, Japan. As a result of analysis, we showed that the error decreased by 1-9% using the proposed method compared with the neural network approach without using resistivity data. Particularly, the error decreased, when the number of teaching data is small, and the distance of teaching data and a target site is not close. Since these conditions are not favorable conditions for neural network approach without using resistivity data, the results demonstrate the effectiveness of the neural network approach based on resistivity data.

Keyword: Geothermal development, Thermal estimation, Neural network, Resistivity, the Kakkonda geothermal field

1. はじめに

地熱地域における温度構造の推定は、対象地域の地熱システムの理解の観点から重要である。地下の温度の把握は、坑井内の温度検層によって行われることが一般的である。この温度プロファイルから、温度の空間分布（温度構造）を推定する場合は、クリギング等の地球統計学的手法やシミュレーション等の適用が行われる。しかし、シミュレーションでは対象地域の岩盤物性や境界条件が既知である必要がある。また、温度データが十分な数および分布で存在しない場合、精度の良い推定は難しい。また、その他の温度を推定する手法として、間接的に推定する手法も一般的に用いられる。例えば、鉱物の変質を用いる手法 (Harvey and Browne, 1991) や地下水の成分（溶解したシリカ量や Na/K 比等）を用いる方法 (Kharaka and Mariner, 1989), ガスの構成成分から貯留層温度を推定する手法 (Amorsson and Gunnlaugsson, 1985) 等が知られている。これらの間接的な温度推定手法は、一定の深さやある特徴的な箇所での地温の推定に有効性を示しているものの、基本的に地表や坑井の箇所での推定が行われるため、広域の地温構造を推定するには情報が不十分である。

一方、その他に温度を推定する手法として、比抵抗を用いる手法が提案されている。岩石の比抵抗は温度に感度があるパラメータとして知られている。横山ほか (1983) では、花崗岩や安山岩、斑禰岩、砂岩、大理石等の広範な種類の含水岩石を用いて、様々な温度条件における岩石の比抵抗を測定したところ、温度の上昇とともに比抵抗が減少することが観測された。この含水岩石の温度

比抵抗の関係は、水の比抵抗-温度曲線と類似した傾向を示しており、水の粘性（活性化エネルギー）の変化によるものと解釈されている。また、高倉 (2009) では、電気二重層が関係する電気伝導（表面伝導）の影響が考えられる粘土鉱物においても、間隙水のイオン濃度が高い場合には、粘土鉱物の比抵抗-温度の関係は、間隙水の比抵抗-温度関係に類似することが示されており、一般的な地熱地域には当てはまると考えられる。このように、比抵抗と温度の関係性は示されているものの、地質構造などが十分に明らかでない場合には、比抵抗から温度を推定することは難しい。

比抵抗を用いた温度推定を行うため、近年、ニューラルネットワークを用いた手法が知られている (Spichak and Zakharova, 2009; Spichak and Zakharova, 2012; Spichak et al., 2015)。この手法は、ニューラルネットワークを用いて、坑井位置で温度と比抵抗の関係を学習し、この構成したネットワークを用いてマグネトテルリク (MT) 法等で推定された比抵抗値から、坑井箇所以外での温度の推定を行う手法である。ニューラルネットワークと坑井の温度データを用いて地下の温度分布を推定する手法はこれまでも提案されているが (Koike et al., 2001; Spichak et al., 2006)、比抵抗を用いることで、坑井データが存在しない箇所でも比抵抗を指標にした温度推定ができると考えられる。

本研究では、本州最大の地熱開発地域である葛根田地熱地域を対象に、当手法を適用し、手法の適用限界を検証する。葛根田地熱地域では、貯留層が存在する深度 1500 m 程度まで複数の坑井データがある他、深度 3579 m まで掘削された坑井

の温度データを使用可能である。特に本研究では、この既存の坑井データを用いてこの深部の坑井データの温度構造が推定可能な検証を行った。

2 ニューラルネットワーク

ニューラルネットワークは、脳機能に見られるいくつかの特性を計算機上に表現することを目指した数学モデルである (van der Baan, 2000)。ニューラルネットワークは、脳の神経細胞を模したパーセプトロンと呼ばれる人工素子モデルを組み合わせることで構成される。パーセプトロンは、入力値に応じて出力を出す関数としての役割を持ち、パーセプトロンのモデルによっては入力と出力の間の非線形的な関係を表すことができる (図1)。また、入力データに重みをつけてパーセプトロンにデータを読み込ませることで、入力するデータがパーセプトロンで計算される際の感度を表現することができる。このように一般的なニューラルネットワークは、入力データへの重みとパーセプトロンのモデルで構成される。

$$y = f\left(\sum_i w_i x_i - h\right) \quad (1)$$

ここで、 w_i は重みを表し、 h は閾値を表す。関数 $f(x)$ を非線形モデルとした場合、このニューロンを多層にわたって配置し、重み等のパラメータを適切に決定することで、ニューラルネットワークは任意の関数を表現できることが知られている。これらのパラメータを最適に決定する指標として、一般的に、推定値と教師データの二乗誤差を最小化する方法が用いられる。

$$F_{NN} = \sum_i (y_{obs,i} - y_{est,i})^2 \quad (2)$$

そして、二乗誤差を最小化することによって重み




図1 (a)パーセプトロンの概念図、(b)本研究で用いたニューラルネットワーク(フィードフォワードニューラルネットワーク)の概念図。(b)の x, y, z は3次元の位置を表し、 R および T は比抵抗値、温度を表す。

等のパラメータを決定するアルゴリズムとして誤差逆伝播法が知られている (Rumelhart and McClelland, 1988)。この誤差逆伝播法を用いて、逐次的にパラメータを更新することで、入力データと出力データの関係を説明することが可能なネットワークを構築することができる。特に、データの流れが一方方向のものは、フィードフォワードニューラルネットワークと呼ばれ、本研究でもそのようなニューラルネットワークを用いた。以下では、フィードフォワードニューラルネットワークをニューラルネットワークと呼ぶ。用いたニューラルネットワークは、隠れ層が3層で、それぞれの層のパーセプトロンの数を20とした。

3. 葛根田地熱開発地域の概要

葛根田地熱開発地域は、岩手県に位置する日本最大級の地熱開発地域の1つである (図2a)。1

号機は1978年より運用され、約50MWの出力をもつ。また、2号機は1996年より運用され、30MWの出力をもつ。

3.1 地質構造

葛根田地熱地域は第四期火山に囲まれた北西から南東方向の谷に位置する。地質は上位から第四紀火山噴出物、玉川溶結凝灰岩類および新第三系中新統からなる(図2b)。地熱流体は主として新第三系中新統のフラクチャー内に胚胎している。本地域には、様々な構造的要因によるフラクチャーが認められるが、断層に伴うフラクチャー、向斜底部のフラクチャーおよび背斜翼部のフラクチャーが地熱流体にとって特に重要であることが指

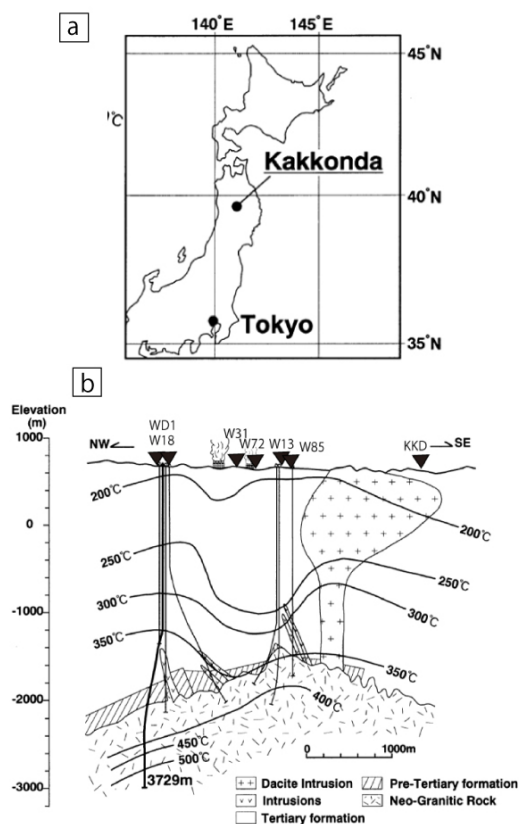


図2 (a) 葛根田地熱地域の位置。(b) 葛根田地熱地域の地質構造および解析に用いた坑井位置。(Kasai et al., 1998 を元に作成)。

摘されている(井出, 1985)。また、坑井データから、当該地域の地熱貯留層は2つに分けられることが知られている。1つは、深さ1500mより浅い層にある浸透率の高い貯留層であり、もう1つは、深さ1500m以深から花崗岩層までに位置する浸透率の低い貯留層である。この2つの貯留層は、水理学的に連続していることが知られている(Hanano, 1995)。

3.2 比抵抗構造

葛根田地熱地域の比抵抗構造は、Uchida et al. (2000) や Uchida et al. (2003) によるMT法の解析で示されている(図3)。この解析によると比抵抗構造の特徴は以下の3点である。(i) 地下約1kmまでに10Ωm以下の比抵抗域が存在する。(ii) 深さ1kmから3km程度まで、10–100Ωmの中一高比抵抗域が存在する。(iii) 地熱開発地域直下の深さ3km以深に10Ωm以下の高比抵抗体が存在する。深さ約1kmまでの低比抵抗域は粘土鉱物等の影響であり、キャップロック層が存在していると考えられている。また、深さ1–3kmに貯留層があると考えられている。深さ3km以深の低比抵抗域の原因は明らかではないが、塩水等による影響の可能性が指摘されている。

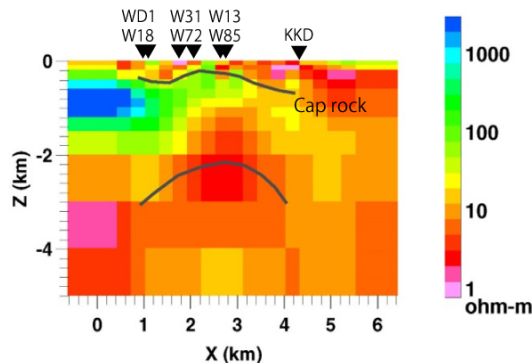


図3 葛根田地熱地域の比抵抗分布(Uchida et al., 2003 を元に作成)。

3.3 用いた温度データ

本研究では、7つの坑井から得られた温度データを用いた（表1）。用いた7本の坑井の深さは、892 m から 3729 m である。各坑井の深さは、表1に示す。最も深い坑井は、WD1 と呼ばれ、2860 m から当該地域の基盤である花崗岩層を貫いており、深部では約 500 °C を記録している。花崗岩層において、温度が急に上昇しており、単調に増加していることから、花崗岩層が伝熱型の温度構造を表しており、それより浅い層では、対流型の温度構造を示していることが示唆される。

表1 解析に用いた温度データの概要。

	W13	W18	W31	W72	W85	KKD	WD1
Maximum Depth [m]	2440	1890	1000	892	950	1150	3700
Maximum Temperature [deg]	355	345	229	234	227	259	510
The number of temperature data	35	17	13	18	19	19	45

4. ニューラルネットワークを用いた学習

当該地域のデータを用いたニューラルネットワークの感度を調べるために、教師データを変えて、検証データの精度を評価した。精度には、以下に示す二乗誤差の割合（%）で評価を行った。

$$100 \times \sqrt{\frac{\sum_i (T_{obs,i} - T_{est,i})^2}{\sum_i T_{obs,i}^2}} \quad (3)$$

ここで、 T_{obs} は、検証データの温度を示し、 T_{est} はニューラルネットワークで推定された温度を表す。この指標を用いて、(a) 教師データに用いるデー




図4 教師データ割合（数）による誤差の変化。黒破線は比抵抗を用いなかった場合の結果を示し、青実線は比抵抗を用いた場合の結果を表す。

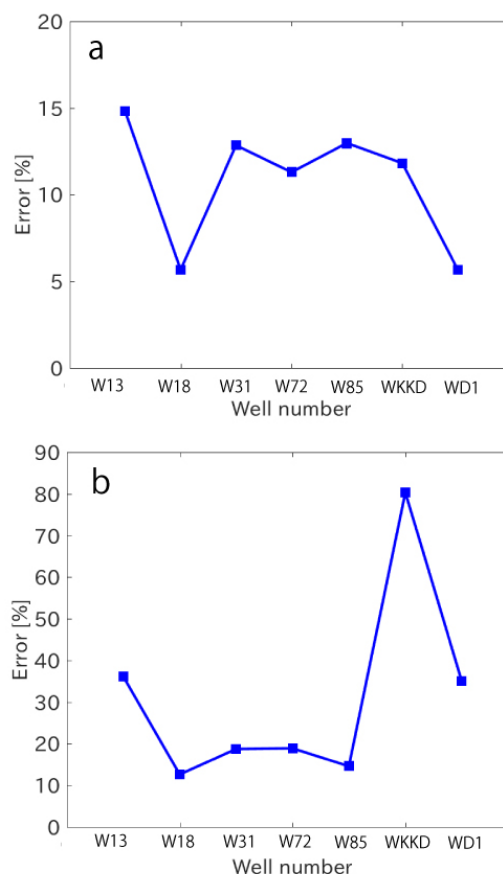


図5 教師データ・検証データを変えた場合の各坑井の温度推定精度。(a)教師データの再現誤差。(b)検証データの推定誤差。

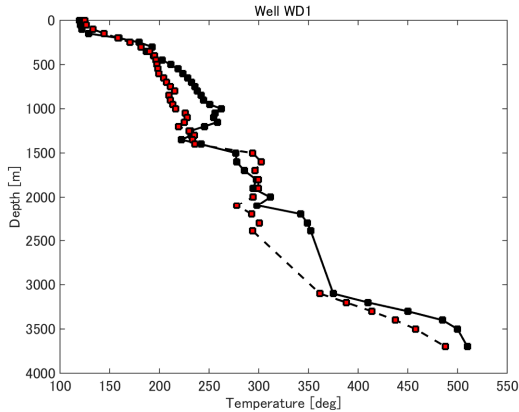


図6 WD1を検証データとして用いた場合の推定値と観測値の比較。実線は観測値、破線はニューラルネットワークによる推定値を表す。




図7 深さを変化させた場合の深部検証データの推定誤差。横軸は、教師データと検証データの閾値として用いた深さを表す。

タ数による誤差への影響、(b) 坑井データごとの誤差、(c) 深度を閾値として教師データと検証データを分類した場合の誤差を評価した。

まず、教師データに用いるデータ数による精度への影響を検討するため、全データのうち教師データに用いるデータの割合を変えて、温度構造の推定を行った。具体的には、教師データの割合を全温度データの10, 30, 50, 70, 90%として解析を行った。また、教師データに用いなかったデータを検証データとして、誤差を計算した。解析の結果、教師データの増加に伴い、誤差が減少することが分かった(図4)。ただし、ニューラルネットワークで比抵抗を用いた場合と、比抵抗を用いなかった場合を比較すると、特に10%や30%という少ない数の教師データを用いたとき、比抵抗を用いることにより、7-9%誤差が減少することが分かった(図4)。一方で、90%の数の教師データを用いた場合は、比抵抗を用いた場合と用いなかった場合の差は1%程度であり、ほとんど誤差に違いが見られなかった。これは、温度データの数が限られる場合に、比抵抗データを用いることで、特にニューラルネットワークの学習効率が向上することを示している。

続いて、坑井データごとの誤差を推定した。各坑井の温度データを検証データとし、それ以外の温度データを教師データとすることで、坑井ごとの誤差を計算した。図5aは、教師データの誤差を表し、図5bは、検証データの誤差を表す。教師データにおいては、誤差は5-15%の間に分布しており、同程度の誤差で学習を行うことができたと考えている。検証データにおいては、KKD以外の坑井データで40%以下の誤差で推定できることが分かった。一方で、坑井KKDを検証データとして用いた場合に誤差が大きくなることが分かった。これは、KKDは、学習に用いた他の坑井(教師データ)と比べて離れているためと考えられる。この結果は、教師データとして用いる温度データの位置が重要であることを示している。さらに、比抵抗データを用いずにニューラルネットワークを用いた場合にも、同様の傾向が見られたが、比抵抗データを用いることで、誤差は平均して4.5%小さくなった。これは、比抵抗データを用いることで、学習効率が向上したことを示している。図6はWD1を検証データとして用いた際の観測値と推定値を比較した図である。観測値の傾向を大よそ推定できていることが分かる。

最後に、教師データ以深の温度分布の推定精度を確かめるため、深度を閾値として、教師データと検証データを分類し、誤差を計算した(図7)。深度の閾値は、500, 1000, 1200, 1500, 1700, 2000, 2200, 2500 mとし、まず初めに500 mを閾値とし、500 mより浅い位置の温度データを全て教師データとしてニューラルネットワークを構築し、それ以深のデータを検証データとした。続いて、500 m以降の閾値を用いて教師データを選定したが、教師データの数を一定とするため、500 mを閾値とした際の教師データ数(58データ(全データの35%))の温度データをランダムに選び、教師データとした。解析の結果、500–1200 mまでは誤差がほぼ一定(32%)であったものの、1200–1700 mを閾値とした場合には、誤差がやや増加し、40%程度となった(図7)。一方、閾値が2000 m以下の場合には、誤差が減少し、30%以下となった。1200–1700 m以深を閾値として教師データとし、それ以深を検証データとした場合に誤差が増加した理由として、この深さに分布している貯留層の存在が関係していると考えられる。すなわち、この深さでは深部とは地質構造(比抵抗–温度関係)が異なるため、誤差が一時的に増加した可能性がある。一方、それ以深のデータを教師データとして用いた場合には、これは地質構造(比抵抗–温度関係)がある程度一定のために、誤差が減少したと考えられる。この結果は、教師データとして用いる温度データを対象地域の貯留層分布を考慮して選定する必要があることを示している。

5. まとめ

本研究では、ニューラルネットワークを用いて比抵抗と位置から、温度を推定するアルゴリズムの誤差の特性を検討した。まず、用いたデータの

中の教師データの割合を変化させて推定誤差を計算したところ、特に教師データの割合が少ない場合において、位置だけでなく比抵抗も用いた方が誤差は少なくなることを示した。続いて、検証データとして用いる坑井を変えて誤差を計算したところ、位置が離れている坑井(KKD)については誤差が大きくなったものの、それ以外の坑井の温度データについては、40%以下の誤差となることが分かった。また、教師データおよび検証データに用いる坑井の深さを変えて、誤差を計算したところ、貯留層が位置する1200–1700 mまでの温度データのみを使った場合には誤差が35–40%程度と大きな値となるものの、それ以深のデータを教師データとして用いた場合は、誤差は約30%以下となった。これらの結果は、本手法において教師データを選ぶ際に、温度を推定する箇所との位置関係や貯留層や地質構造を考慮することで、誤差を低減できることを示している。また、比抵抗を用いない従来の手法と比較して、特に少ない教師データ(50–150データ)において、誤差を低減できることを表しており、本手法の有効性を示していると考えている。

謝辞

本研究で用いた温度データは東北自然エネルギー株式会社様から提供頂きました。ここに記して感謝致します。

文献

Armorsson S. and Gunnlaugsson E. (1985): New gas geothermometers for geothermal exploration-calibration and application, *Geochimica et Cosmochimica Acta*, 49(6), 1307-1325.

- Hanano M. (1995): Hydrothermal convection system of the Kakkonda geothermal field, Japan, Proc. World Geothermal Congress 1995, 3, 1629-1634.
- Harvey C. C. and Browne P. R. C. (1991): Mixed-layer clay geothermometry in the Wairakei geothermal field, New Zealand, Clays and Clay minerals, 39, 614-621.
- 井出俊夫 (1985) : 松川および葛根田地域の地熱系モデル, 日本地熱学会誌, 7, 3, 201-213.
- Kasai, K. (1998): The origin of hypersaline liquid in the quaternary Kakkonda granite, sampled from well WD-1a, Kakkoda geothermal system, Japan. Geothermics, 27, 631 – 645.
- Kharaka Y. K. and Mariner R. H. (1989): Chemical geothermometers and their application to formation waters from sedimentary basin, Thermal history of sedimentary basins, Springer Verlag, 99-117.
- Koike, K., Matsuda, S. and Gu B. (2001): Evaluation of interpolation accuracy of neural kriging with application to temperature-distribution analysis, Math. Geol., 33, 421-448.
- Rumelhart D. and McClelland J. (1988): Parallel Distributed Processing, MIT Press, Cambridge USA.
- Spichak, V. V. (2006): Estimating temperature distributions in geothermal areas using neuronet approach, Geothermics, 35, 181-197.
- Spichak, V. V. and Zakharova O. K. (2009): The application of an indirect electromagnetic geothermometer to temperature extrapolation in depth, Geophysical prospecting, 57, 653-664.
- Spichak, V. V. and Zakharova O. K. (2012): The subsurface temperature assessment by means of an indirect electromagnetic geothermometer, Geophysics, 77 (4), 1-12.
- Spichak, V. V., Geiermann, J., Zakharova, O., Calcagno, P., Genter, A. and Schill, E. (2015): Estimating deep temperatures in the Soultz-sous-Forêts geothermal area (France) from magnetotelluric data, Near Surface Geophysics, 13, 397-408.
- 高倉伸一 (2009) : 粘土鉱物を含有する岩石の比抵抗-間隙水の塩分濃度と温度が及ぼす影響一, 物理探査, 62, 4, 385-396.
- Uchida T., Lee T.J. and Cerv V. (2003): 3-D inversion of magnetotelluric data in the Kakkonda geothermal field, northern Japan, Proc. 6th SEGJ international symposium, Japan, 274-280.
- Uchida T., Ogawa Y., Takakura S. and Mitsuhashi Y. (2000): Geoelectrical investigation of the Kakkonda geothermal field, northern Japan, Proc. World Geothermal Congress, 207-220.
- van der Baan, M. and Jutten, C. (2000): Neural networks in geophysical application. *Geophysics*, 65, 1032-1047.
- 横山秀吉・中塚勝人・阿部 司, 渡部賢一 (1983) : 含水岩石の比抵抗の温度依存性とその地下温度予測への応用について, 日本地熱学会誌, 5, 2, 103-120.