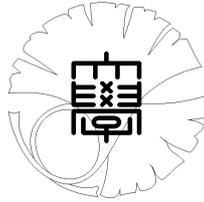


数理科学実践研究レター 2021-15 September 22, 2021

表面波を用いた地下構造推定への  
ニューラルネットワークの適用

by

山谷 里奈



**UNIVERSITY OF TOKYO**

GRADUATE SCHOOL OF MATHEMATICAL SCIENCES

KOMABA, TOKYO, JAPAN

# 表面波を用いた地下構造推定へのニューラルネットワークの適用

山谷里奈<sup>1</sup> (東京大学大学院理学系研究科)

Lina Yamaya (Graduate School of Sciences, The University of Tokyo)

## 概要

地震波を用いた地下構造推定は、地球内部の組成解明に限らず地盤強度の測定や石油探査などに用いられている。地震波の1種であるレイリー波も、地下構造推定によく用いられている。レイリー波には分散性があり、一般に高周波ほど浅部に、低周波ほど深部に感度がある。この性質を用いて逆問題を解くことで、地下構造を推定することができる。本研究では、この逆問題の解法にニューラルネットワークを適用した。

## 1 はじめに

地球内部の組成解明に限らず地盤強度の測定や石油探査などの目的で、地下の物質の推定が求められている。地下構造推定の有用な手段の1つに、地震波を用いたものがある。地震波の伝搬速度は地下の物質の密度や弾性定数によって決定されるため、地下を伝搬してきた地震波の速度を調べることで、地下構造を推定することができる。

本研究では、地震波のうちレイリー波を用いた地下構造推定を対象とする。レイリー波は、地表面に沿って伝播する表面波の一種である。レイリー波には分散性があり、一般に高周波ほど浅部に、低周波ほど深部に感度がある。この性質を用いることで、地下構造推定が行われてきた。この推定には逆問題を解く必要があり、これまでは線形近似の反復 (例: Herrmann, 2013) や MCMC 法 (例: Bodin et al., 2012) などで最適化されてきた。しかし、線形近似の反復では解が局所最小値になる可能性がある。MCMC 法では解が局所最小値にはならないが、計算コストが高い。本研究では、この逆問題の解法にニューラルネットを適用することで、計算コストを抑えた解法を探った。

## 2 レイリー波を用いた構造推定

レイリー波は分散性を持ち、高周波ほど浅部の構造に、低周波ほど深部の構造に感度を持つ。ある地下の構造が  $n$  層であると仮定したとき、レイリー波の位相速度は以下のように書ける (斎藤 & 梶沢 [1993] 式 (1), (6), (8) 参照)。

$$c(\omega) = F(\{V_s^1, V_s^2, \dots, V_s^n\}). \quad (1)$$

ここで、 $c(\omega)$  は角周波数  $\omega$  でのレイリー波の位相速度、 $V_s^i$  は  $i$  番目の層の S 波速度であり、S 波速度  $V_s^i$  は

$$V_s^i = \sqrt{\frac{\mu^i}{\rho^i}} \quad (2)$$

と書ける。ここで、 $\mu^i$  は  $i$  番目の層の物質の剛性率を、 $\rho^i$  は密度をそれぞれ示す。実際に観測されるデータは  $c(\omega)$  であり、推定量は  $V_s$  であるが、

$$V_s^i = F^{-1}(c(\omega)). \quad (3)$$

となる逆関数  $F^{-1}$  は解析的には解けない。そのため、この逆関数  $F^{-1}$  をニューラルネットで推定することを考える。

<sup>1</sup>lina@eri.u-tokyo.ac.jp

### 3 ニューラルネットの適用

ニューラルネットの適用にあたり、7000 個の地下構造を仮定してレイリー波の分散を計算し、データセットを作成した。次に、5000 個を教師データとしてモデルを作成した。最後に、2000 個をテストデータとし、モデルの検証を行なった。

#### 3.1 データセット

地下の構造が 8 層であると仮定し、各層の厚さ及び S 波速度をランダムに仮定した (図 1)。各々の地下構造に対してレイリー波の分散を計算した (図 2)。地下構造は、Yamaya et al. (2021) の対象領域である茨城沖を想定し、深さ 2.3 km の海底であると設定した。また、レイリー波の分散も、Yamaya et al. (2021) で得られた範囲の周波数帯域及びモード (基本モード：0.1–0.25 Hz, 1 次高次モード：0.175–0.3 Hz) に設定している。ここで、基本モードはレイリー波のうち表層への感度が大きく、高次モードはそれより深部への感度が大きい (Yamaya et al., [2021] Figure S10 参照)。

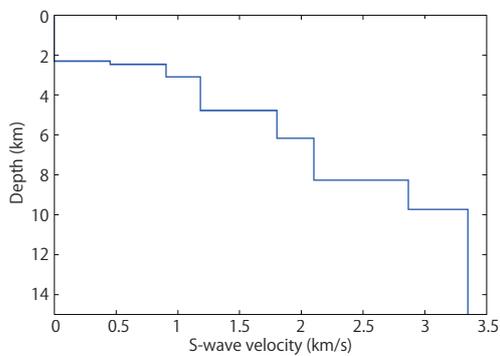


図 1: 仮定した地下構造の例.

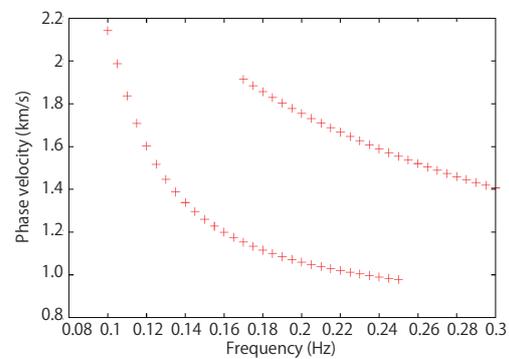


図 2: 仮定した地下構造に対して計算されたレイリー波の分散の例.

#### 3.2 モデル作成

モデルは 3 層とし、隠れ層のノード数は 100 とした。損失関数は平均自乗誤差、損失関数の最適化手法には ADAM (Kingma & Ba, 2014) をそれぞれ用いた。また、活性化関数には ReLU を用いた。Epoch 数は 1000 とした。Epoch 数に対する教師データの損失関数を図 3 に示す。Epoch 数が増えるごとに損失関数が減少しているのがわかる。損失関数は収束しきれないが、これは後述のテスト結果の場合と同様に、レイリー波の分散が深部構造に持つ感度が小さいため、地下深部の構造を推定しきれず、損失関数が収束しきれないと考えられる。これを収束させるためには、より広い周波数帯のデータを用意することが必要であると予想される。

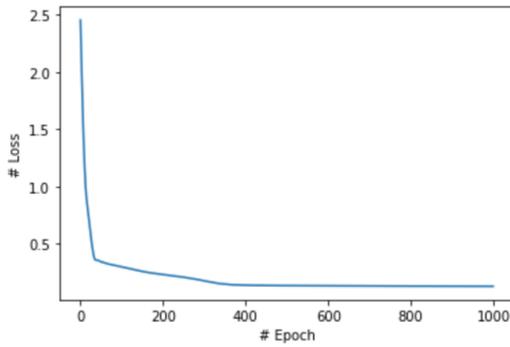


図 3: 教師データの損失関数.

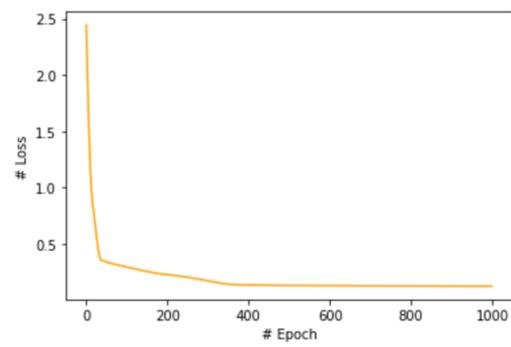


図 4: テストデータの損失関数.

### 3.3 テスト結果

各 Epoch 数ごとに、得られたモデルを用いてテストデータの損失関数を計算した (図 4). 教師データを用いた場合と同様に、Epoch 数が増えるごとに損失関数が減少した。また、ニューラルネットにより得られた地下構造とテストデータの真の地下構造を比較すると、浅部ではよく一致するのに対し、深部では一致度合いが低下した (図 5)。これは、従来法による推定の傾向と一致する。レイリー波の感度は、基本的には地表面付近で最大になるため、地下構造推定においても地表面付近がよく推定できたのだと考えられる。

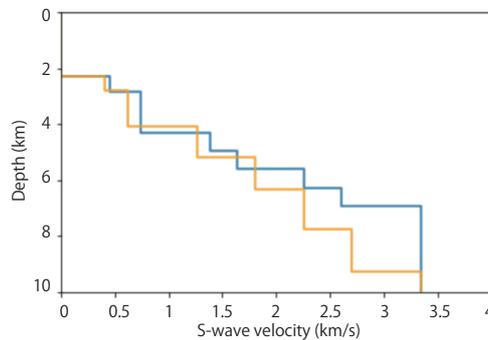


図 5: テスト結果例. 青線がニューラルネットによる推定, 橙線が真の地下構造をそれぞれ示す.

## 4 終わりに

本論文では、レイリー波を用いた地下構造推定の逆問題の解法にニューラルネットを適用した。今回はランダムに作成した地下構造を学習させた。推定した地下構造は、浅部では真の構造とよく一致した。また、深部よりも浅部に感度があった。これは、従来法とよく一致する特徴であり、レイリー波を用いた地下構造推定の特徴をよく示していると考えられる。

また、今回の設定におけるニューラルネットの計算コストは、Yamaya et al. (2021) において MCMC 法を用いた場合より 3 桁以上小さいオーダーであった。線形近似の反復を用いた場合と比較すると、計算コストは同程度であったが、初期モデル依存性がない利点がある。以上より、ニューラルネットを用いた逆問題の解法は、有用な手法となる可能性が考えられる。今後は実際のデータにも適用し、MCMC 法による推定結果などと比較をしていきたい。

最後になるが、アドバイスをいただいた、東京大学数理科学研究科の柏原崇人先生、東京海上日動リスクコンサルティングの矢野良輔様、また災害班のメンバーに感謝する。

## 参考文献

- [1] Bodin, T., Sambridge, M., Tkalčić, H., Arroucau, P., Gallagher, K., & Rawlinson, N. (2012). Transdimensional inversion of receiver functions and surface wave dispersion. *Journal of Geophysical Research: Solid Earth*, 117(B2).
- [2] Herrmann, R. B.: Computer programs in seismology: An evolving tool for instruction and research, *Seism. Res. Lettr.*, 84, p1081—1088, doi:10.1785/0220110096, 2013.
- [3] Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980.
- [4] 斎藤正徳, & 梶沢宏之. (1993). 成層構造に対する反射率, 表面波分散曲線の計算-2-レーリー波の計算. *物理探査*, 46(4), p283-298.
- [5] Yamaya, L., Mochizuki, K., Akuhara, T., & Nishida, K. (2021). Sedimentary structure derived from multi - mode ambient noise tomography with dense OBS network at the Japan Trench. *Journal of Geophysical Research: Solid Earth*, e2021JB021789.