

Rayleigh 波分散曲線から S 波速度構造への逆解析に対する AI 技術の適用に関する基礎的研究

吉野 将生

1. はじめに

地震大国である我が国では、地震防災において強震動の予測は重要な要素の一つである。強震動を予測するためには、予測地点における地下構造の影響を考慮する必要がある。地盤の S 波速度は地面の揺れやすさを知るための重要な情報であり、S 波速度を明らかにすることで地下構造の影響を知ることができる。

一般的な地下構造を求める手法の一つに、地面の微小な揺れである常時微動から地下の S 波速度構造を推定する微動アレイ探査法があげられる。微動アレイ探査法では、微動アレイ観測を行い、得られた記録を解析し、Rayleigh 波分散曲線を抽出する。そこで抽出された Rayleigh 波分散曲線から逆解析的に S 波速度構造を推定することで地下構造を知ることができる。この逆解析には、山中・石田 (1995) ¹⁾ の遺伝的アルゴリズム (以下、GA) などが用いられている。山中・石田 (1995) ¹⁾ や山中 (2007) ²⁾ は、GA による逆解析は、それ以前に用いられていた勾配法による非線形最小 2 乗法の逆解析よりも、最適な S 波速度構造モデルの探索に有効であり、正解値とほぼ同様に収束させることができること、初期モデルの制約が少ない、微分計算がいらなといった点で、従来の勾配法よりも有用であることを指摘している。しかし、GA はこのような利点がある一方で、結果を評価するうえで重要な指標である推定誤差を評価することができないことや解の集団の中に同じモデルが多数存在することにより多様性が低くなり、モデル探索が効率的に行われない「未成熟の収束の問題」といった問題点があることも指摘されている ²⁾。

そこで本研究では、これらの問題点を解決するために、近年注目されているディープラーニング (以下、DL) を用いて、Rayleigh 波の位相速度と S 波速度の関

係を学習させることにより、Rayleigh 波分散曲線から S 波速度構造の逆解析への適用を目指している。本研究では、表層と工学的基盤の 2 層からなる地盤を仮定し、多数の擬似的な 2 層地盤モデルに対する Rayleigh 波分散曲線の理論値を算出し、深さごとの地盤情報、位相速度およびそれに対応する周波数情報を学習させることで、Rayleigh 波分散曲線から S 波速度構造への逆解析に AI 技術を適用するための基礎的検討を行う。

2. 2 層地盤モデルの作成

2.1 2 層地盤モデル

本研究では、中国地方の防災科学技術研究所 KiK-net 観測点における浅部地盤構造を対象とした微動アレイ観測で得られた地盤モデルの範囲を考慮して、表層と工学的基盤からなる 2 層地盤モデルの作成を行った。図 1 は、中国地方の全 58 地点における KiK-net 観測点の地盤モデルである。これにより得られた表層および工学的基盤の S 波速度、層厚の範囲を表 1 に示す。2




図 1 中国地方の全 58 地点における KiK-net 観測点の地盤モデル

表 1 擬似 2 層地盤モデルの S 波速度と層厚の範囲

	S波速度 (m/s)	層厚 (m)
1層目	60-380	1.5-32
2層目	400, 500, 600	-

層地盤モデルの2層目を工学的基盤とし、S波速度は400 m/s、500 m/s、600 m/sの3種類とした。この3種類の工学的基盤に対して、表層である1層目はS波速度を60~380 m/sの範囲で5 m/sずつ増やした64種類、同じように層厚を1.5~32 mの範囲で0.75 mずつ増やした41種類を設定し、これらのすべての組み合わせである合計7872種類の擬似的なS波速度構造のモデルを作成した。

2.2 Rayleigh 波分散曲線の算出

擬似的な7872種類の2層地盤モデルに対して、Rayleigh 波分散曲線の理論計算を行った。Rayleigh 波分散曲線の算出には、久田³⁾による反射・透過マトリックス法のプログラムを用いた。周波数は0~40 Hzとし、位相速度の理論計算の際に用いた密度 ρ (g/cm³)とP波速度 V_p (m/s)は(1)式の太田ほか⁴⁾と(2)式の狐崎ほか⁵⁾のS波速度 V_s (m/s)からの換算式を用いて算出した。

$$\rho = 1.4 + 0.67\sqrt{V_s} \quad (1)$$

$$V_p = 1290 + 1.1V_s \quad (2)$$

以上のように求められた分散曲線のうち、40 Hzを超えても形状が平坦にならない分散曲線を除いた5110本の分散曲線を本研究での対象とした。図2は理論計算により得られたRayleigh 波分散曲線(b)とS波速度構造(a)の一部である。

3. ディープラーニングによるS波速度構造予測の概要

3.1 ディープラーニング (DL)

DL(深層学習)とは、多層の人工ニューラルネットワークを用いる機械学習の方法の1つである。図3にDLの概念図を示す。それまでのニューラルネットワークに比べて多くの中間層を持つことができ、より複雑な問題を解くことができる。

3.2 学習モデルの予測精度の評価手法

本研究では、DLを用いて予測させたS波速度の精度を評価するために、各学習モデルにおいての平均絶対パーセント誤差(MAPE: Mean Absolute Percentage Error)を式(3)に基づいて算出して比較を行った。

$$MAPE = 100 \times \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (3)$$

(\hat{y}_i : 予測値、 y_i : 理論値、 n : データの総数)

3.3 作成した学習データセットの概要

Rayleigh 波の位相速度情報と地下構造の深さおよびS波速度情報をもとに、データセットを作成した。作成した5110個のデータのうち、7割にあたる3600個を学習させるための学習データ、残りの1510個をモ




図1 理論計算により得られたRayleigh 波(b)と擬似的なS波速度構造(a) (図は一部抜粋)

デルの精度検証用のテストデータとした。今回、理論計算で得られた位相速度の情報は膨大な量であるため、リサンプリングして、解析に用いた。この際、浅部地盤を対象とした微動アレイ探査で求まる現実的な位相速度の周波数範囲を考慮して、0.3~30 Hzの範囲の位相速度を対象とし、周波数を対数軸で等間隔になるようにリサンプリングを行った。

4. S波速度構造予測の結果と考察

4.1 使用したネットワーク構造の比較

本研究では、DLを用いた学習および予測を行うためにSONYによって提供されているAI開発ツールであるNeural Network Console⁶⁾(以下、NNC)を用いた。

学習に用いたネットワークの初期学習モデル(model①)の構造はPanほか⁸⁾を参考に設定した(図4)。ここで、Affineレイヤは入力されたデータの重みを調整するレイヤである。また入力された合計値を出力値に変換する際の非線形関数である活性化関数にはSELUを用いた。AffineレイヤとSELUレイヤで構成されるHidden layerの最適なレイヤ数を検討するためにこれらのレイヤをmodel①では4層であるのに対し、3層(model②)、5層(model③)と変えて予測結果の比較を行った。ここで、model①における分散曲線を表すデータは40点にリサンプリングしており、学習のサイクルであるepoch数は100、バッチサイズは64とした。また、過学習の抑制のためのDropoutレイ




図3 DLの概念図

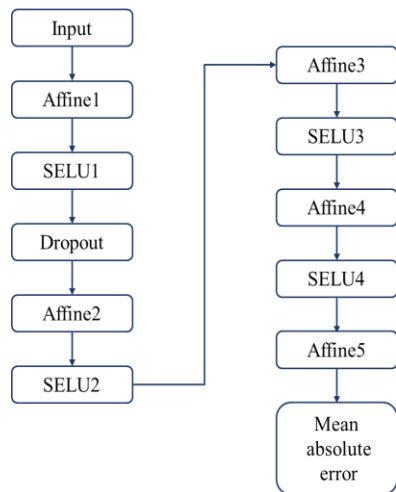


図 4 本研究のディープニューラルネットワークの初期学習モデル構造

ヤを 1 層目の SELU レイヤの後に配置する構造とし、損失関数には式 (4) で表される平均絶対値誤差 (MAE: Mean Absolute Error) を使用した。ここで、損失関数は、予測値と目標値とのズレを評価する関数である。ここで、 y_i は理論値であり、 \hat{y}_i は予測値、 n はデータの総数を表す。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

以上のように設定した学習モデルで Hidden layer のレイヤ数を変化させて予測を行ったところ、3 層の場合は MAPE が 49.7%、4 層では 45.6%、5 層では 49.8% という結果となり、最も MAPE が小さかった 4 層構造が最適であると判断した。

4.2 各学習モデルにおける S 波速度構造予測の比較

4.2.1 データセットの内容を変えたモデルと結果

最適な学習モデルを検討するために、データセットの内容を変えた学習モデルを 4 パターン、epoch 数、DL のネットワーク構造を変えた学習モデルを 2 パターン準備した。model①では、前述のとおり、入力データとして 40 点にリサンプリングした位相速度情報のみを用いた。これに対して、リサンプリングを 20 点としたパターン (model④)、80 点としたパターン (model⑤) と入力する情報量を変化させて予測を行った。また、model①、④、⑤においては、位相速度の情報のみを入力データに取り込んでいたが、それに加えてリサンプリングした位相速度に対応する周波数情報も含めたパターン (model⑥) で予測を行った。

図 5 は、学習過程における学習データとテストデータに対する損失関数 MAE の推移を示している。model ①、④～⑥は最終的なトレーニング誤差、テスト誤差ともに 100 m/s を超えており、収束せず安定していな

い。それに加え、右肩上がりの推移を見せ、過学習の傾向も見られる。過学習とは、学習データにのみ高い適用性能を示してしまい、他データに対する汎用性が失われてしまう状態を指す。

図 6 に、各学習モデルにおける全 S 波速度構造の予測値 (図中の灰色線) と最も誤差割合の小さかった S 波速度構造 (図中の黒実線) を示す。表 2 は各学習モデルにおける MAPE の値である。表 2 の model①、④、⑤を見ると、リサンプリング数を増やすと誤差割合が高くなるということがわかる。これは、入力情報が増大し、特徴量が増えすぎたことで生じるノイズの影響により、学習の質が下がったことが考えられる。

4.2.2 ネットワーク構造を変えた学習モデルと結果

次に、model①では、epoch 数を 100 としたが、それに対して、epoch 数を 1000 としたパターン (model⑦)、さらに、図 4 で示した初期モデルに対して、それぞれの Affine レイヤの後に Batch Normalization レイヤを追加して予測を行った (model⑧)。Batch Normalization レイヤとは、入力されたデータの平均を 0 に、分散を 1 にする正規化を行うレイヤである⁹⁾。図 5 を見ると model⑧のトレーニング誤差、テスト誤差ともに 35 m/s 付近に収束し安定している。また、過学習の傾向も見られない。Batch Normalization レイヤを追加することで、データの広がりや抑えられ、最終的に安定し収束につながったと考えられる。表 2 より、model⑦の MAPE は 42.80% であり、model①の 45.64% と比べて 2.84 ポイント減少している。しかし、図 6 をみると model⑦は工学的基盤の S 波速度が 400、500、600 m/s と 3 種類があるにも関わらず、最大でも 400 m/s となっている。一方、model⑧の MAPE は 15.21% であり、model①に比べて 29.88 ポイントの減少が見られた。工学的基盤の S 波速度についてもよく再現されており、擬似 S 波速度構造とよく対応している。これは、Batch Normalization レイヤを追加することで正規化が行わ




図 5 クロスバリデーションで得られた (a) トレーニングデータと (b) テストデータの MAE (epoch 数の異なる model⑦は除いた)




図 6 擬似的な S 波速度構造と各学習モデルにおける S 波速度構造予測の全体図
 — 予測値
 — 最も精度の良い S 波速度構造

れ、学習が適切に進んだ結果であると考えられる。

4.2.3 精度の上がった学習モデルの組み合わせ

最後に、以上までの検討を踏まえて、リサンプリングする位相速度を 20 点、データセットに周波数情報も含め、epoch 数を 1000 にし、ネットワーク構造に Batch Normalization レイヤを追加させて予測を行った (model 9)。model 9 における MAPE は model 1 よりも 30.43 ポイント減少し、図 6 においても 1 層目と 2 層目の境界をはっきりしており、目に見えて精度が向上していることがわかる。

表 2 各モデルの MAPE (平均絶対パーセント誤差)

	MAPE
model 1	45.64
model 4	41.75
model 5	54.70
model 6	39.78
model 7	42.80
model 8	15.76
model 9	15.21

5. まとめ

本研究では、Rayleigh 波分散曲線から S 波速度構造への逆解析において DL を用いた予測を行った。試行錯誤的に、Hidden layer の数、入力するデータセットの形式、ネットワークの構造を変え、それぞれの予測精度の比較を行った。得られた知見を以下にまとめる。

- Batch Normalization レイヤを追加すると予測精度が大幅に上がる。
- DL を用いた逆解析においてリサンプリング数 20

点、epoch 数 1000、Batch Normalization レイヤ、周波数情報を含めた平均誤差割合が 15.21% の学習モデルを作成することができた。

今後は、誤差割合をさらに小さくするとともに、2 層地盤のみではなく、多層地盤にも適用できるように検討を行う。また、既存の逆解析手法である GA との結果と比較し、適用性の検討を行う。実地盤への適用についての検討を行う。

参考文献

- 1) 山中浩明、石田寛：遺伝的アルゴリズムによる位相速度の逆解析、日本建築学会構造系論文集、第 468 号、pp.9-17、1995
- 2) 山中浩明：ハイブリッドヒューリスティック探索による位相速度の逆解析、物理探査 第 3 号、p.265-275、2007
- 3) 久田嘉章、成層地盤における正規モード解及びグリーン関数の効率的な計算法、日本建築学会構造系論文集 第 501 号、pp.49-56、1997
- 4) 太田外氣晴、江守勝彦、河西良幸：耐震・振動・制御、共立出版、339 p. 2001
- 5) 狐崎長琅、後藤典俊、小林芳正、井川猛、堀家正則、斎藤徳美、黒田徹、山根一修、奥田宏一：地震動予測のための真相地盤 P,S 波速度の推定、自然災害科学、Vol.9、No.3、2001
- 6) SONY (2021). Neural Network Console, available at <https://dl.sony.com/> (last accessed February 2021)
- 7) Klambauer, G., T. Unterthiner, A. Mayr, and S.
- 8) Hochreiter Self-normalizing neural networks, Adv. Neural Inf. Process. Syst.972-981.2017
- 9) Da Pan, Hiroyuki Miura, Tatsuo Kanno, Michiko Shigefuji, and Tetsuo Abiru : Deep-Neural-Network-Based Estimation of Site Amplification Factor from Microtremor H/V Spectral Ratio、Bulletin of the Seismological Society of America、vol.112、No.3、pp.1630-1646、2022
- 10) 斎藤康毅「ゼロから作る Deep Learning -Python で学ぶディープラーニングの理論と実装」オライリージャパン出版、9 月、2016 年
- 11) 足立悠、「ソニー開発の Neural Network Console 入門[増補改訂・クラウド対応版]—数式な、コーディングなしのディープラーニング」、リックテレコム出版、11 月、2018 年