

さまざまな機械学習モデルによる室内弾性波試験の S 波到達時刻の予測

秋田大学 学生会員 ○三浦 了 正会員 荻野 俊寛

1. 背景

バンダーエレメント(以下 BE)法は、バンダーエレメントと呼ばれる 2 枚の圧電素子を貼り合わせたバイモルフ型の振動子を用いて、土中を伝播するせん断波(以下 S 波)を測定することで、手軽に任意の時点・応力点における供試体のせん断弾性係数を評価できる非破壊試験である。BE 法の受信波は、周辺のノイズや反射波、屈折波の他、供試体や BE の条件が受信波の形状に大きく影響し、波の到達点の決定が困難になる場合がある。Ogino¹⁾は送・受信 BE および供試体をそれぞれひとつの線形系とみなした線型モデルによって任意の送信波に対する受信波を数値計算する手法を開発し、実際の実験結果とよく一致することを示した。この手法では供試体を伝播する S 波速度を任意に設定するため、真の到達時間が既知の状態を受信波形が得られる。横山ら²⁾はこのことを利用し、数値計算から得られた 8960 通りの受信波形から学習したサポートベクター回帰モデルを実際の実験データに対する予測に用い、モデルの予測値が熟練者の判定値と近い値になることを示した。本報告では、BE 法の S 波到達時間評価の高精度化を目的とし、サポートベクター回帰、ガウス過程回帰、ニューラルネットワークの 3 種類の機械学習アルゴリズムを用いて S 波到達時間を予測するモデルを作成し、モデルの予測精度を確認した。

2. データ

(1) 訓練データ・検証データ

本研究では教師あり学習を使用するため、学習データでは真の S 波到達時刻が既知である必要がある。Ogino¹⁾によって提案された BE 試験の線形モデルは任意の送信波に対する受信波は周波数領域において式(1)で表すことができる。

$$Y = H_{be,r} \cdot H_{soil} \cdot H_{be,s} \cdot X \quad (1)$$

ここに、 X 、 $H_{be,s}$ 、 H_{soil} 、 $H_{be,r}$ 、 Y はそれぞれ送信波、送信 BE、供試体、受信 BE、受信波の伝達関数であり、これらのパラメータを表-1 に示す範囲で数値を様々に変化させ、7296 通りの受信波を生成した。数値計算によって生成した送受信波形の代表例を図-1 に示す。この手法では、受信波形のパラメータとして供試体の高さや S 波速度が含まれるため、真の S 波到達時刻は常に既知となる。機械学習モデルのハイパーパラメータは全学習データの 80% を訓練データとして、残りの 20% を検証データとしてモデルの汎化性能を評価する 5 分割交差検証によって決定した。

表-1 パラメータ範囲

送信波の周波数 [kHz]	S 波速度 [m/s]	BE 間距離 [mm]	BE 長さ [mm]	湿潤密度 [kg/m ³]
1~80	20~200	10~120	3~12	1000~2200




図-1 数値計算によって生成した受信波形

(2) テストデータ

テストデータでは本研究室で過去に実施された実験の一部の波形を使用した。実験に使用された試料は月面模擬土、豊浦砂、泥炭の 3 種類であり、データ数の内訳はそれぞれ 83 個、75 個、132 個である。実際の実験での受信波形の代表例を図-2 に示す。実際の実験データでは、実験条件によってトレンドやノイズが含まれていることから、適切に予測が行えるようにこれらの除去を行なった。トレンド除去では受信波形から最良近似直線を除去し、ノイズ除去では各ウィンドウ長さを 80 に固定し、ガウス加重移動平均によって平滑化していくことで実施した。また、受信波形の形状において最初のピークが最大ピークになっていないため、S 波到達点の見極めが困難であることが推測される。この現象は、泥炭などの軟弱な試料に比べ、比較的硬質な砂質土試料で生じやすい。




図-2 実際の実験データの代表例

3. 機械学習モデルの作成

(1) 特徴量の抽出

学習に使用した特徴量は、BE 長さ、送信波の周波数、BE 間距離、土の湿潤密度、受信波の形状から得られるピーク点及びゼロクロス点に対応する時刻の計 11 次元である。受信波形の特徴量抽出箇所を図-1, 2 に示す。ピーク点は受信波の正の最大ピークの中から基準ピークを決定し、その前後の負のピークを 2 つ、1 つ後ろの正のピーク点の時刻情報のみを抽出した。基準ピークの決定方法は、受信波の正の最大ピーク値を検出し、その前方で最大ピーク値の 1/2 以上の値を示すピーク点がある場合、その中で時刻が最小の正のピーク点を基準ピークとし、ない場合は正の最大ピークを基準とした。ゼロクロス点は抽出された正負ピーク点間にあり、受信波の振幅の値が負から正に変わる際に値が 0 となる時刻を抽出した。このようにして、受信波の形状から合計 6 次元の特徴量を抽出し、モデルの学習に使用した。

(2) 機械学習モデルの学習

機械学習のアルゴリズムにはサポートベクター回帰(SVR)、ガウス過程回帰(GPR)、ニューラルネットワーク(NN)の 3 種類を用いた。SVR では、 s 、 C 、 ϵ を 10 分割グリッドサーチによって最適化した結果、カーネルスケール: 5.9948、ボックス制約: 0.2154、 ϵ 不感帯: 7.6909×10^{-7} であった。

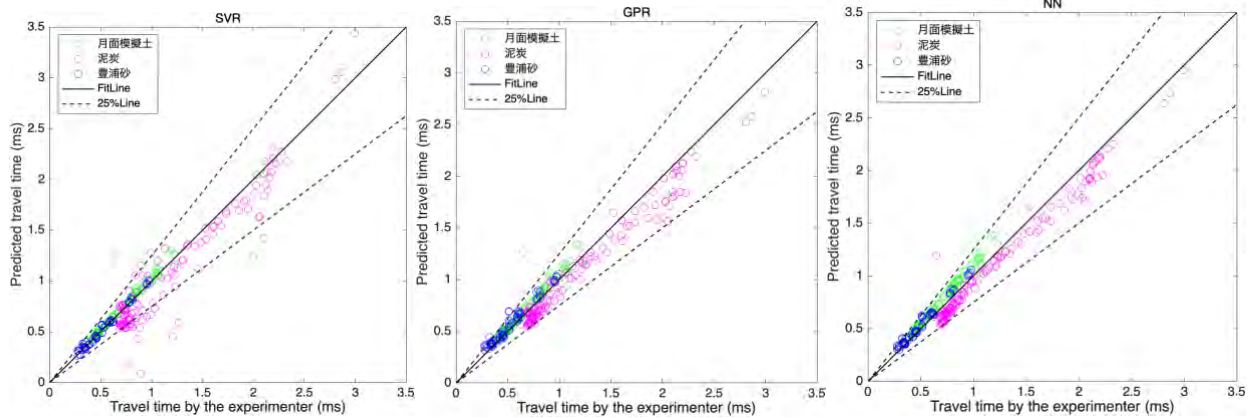


図-3 熟練者による判定値と予測値の比較

GPR では、基底関数、カーネル関数、ノイズ標準偏差、および標準化の有無をベイズ最適化によって調整した結果、基底関数：pure Quadratic、カーネル関数：有理 2 次カーネル、ノイズ標準偏差：0.0158、標準化有りであった。また、推定されたカーネル関数のパラメータは、 σ_f ： 8.083×10^{-7} 、 σ_l ：168.7、 α ：1.037 であった。

NN では、正規化強度 λ 、活性化関数、中間層の層数及びノード数を 10 分割グリッドサーチによって調整した結果、 λ ： 7.691×10^{-7} 、NN モデルの中間層：1 層、ノード数：28、活性化関数は恒等関数が最適であると評価された。

4. 機械学習モデルの予測精度

テストデータに対する予測では、真の S 波到達時刻が未知であるため熟練者による S 波到達点の判定値と比較した(図-3)。砂質土である月面模擬土、豊浦砂に関しては、各モデルで大きな外れ値は無く、傾き 1 の直線付近にプロットが集中しており、3 つのモデルの予測値は概ね熟練者と近い値を示すことがわかる。一方、泥炭では GPR, NN の予測は熟練者の判定値からの誤差±25%の範囲を示す破線に概ね収まっているが、SVR による予測は熟練者による予測値よりも早い値を示しているプロットが多く見られる。

各試料及びモデルごとに算出した平均二乗誤差(RMSE)を表-2 に示す。全てのモデルに共通して泥炭の RMSE の値が最も高く、砂質土との土質特性の違いが予測精度に影響していることがわかる。また、SVR では月面模擬土、豊浦砂に対する RMSE が最も低い値を示しており、砂質土試料に対する予測精度の高さが見られる一方、泥炭に対する RMSE は表-2 内で最も高い値を示している。

各モデルで予測誤差の最大となった波形を図-4 に示す。波形では最大ピークが基準ピークとなっているが、0.5~1ms 付近に特徴的な正のピークが確認でき、熟練者はこのピーク付近を S 波到達点と判定している。このピークは最大ピーク値の 1/2 に満たないことから、本研究での特徴量抽出法では検出できない。こういった特徴抽出の不具合は、最初のピークが最大振幅にならない場合に見られる現象であり、比較的硬質な試料である月面模擬土、豊浦砂で発生しやすい(図-2)。このように、特徴抽出が適切に行われていない場合、全てのモデルで予測を行うことは困難であり、特徴量の中で受信波形から得られるピーク点時刻及びゼロクロス点の重要度が高いことが示された。

次に、3 つのモデルの予測値の標準偏差が最大となった波形を図-5 に示す。GPR, NN は妥当な予測値を示している一方、SVR では大きく後方を S 波到達点と予測している。このように SVR のみ予測誤差が大きくなる波形は複数存在し、それらの波形に共通している条件として、泥炭試料であること、波形の立ち上がりが非常になだらかであること、特徴量抽出において最初の負のピーク点が基準ピークに対し大きく前方に存在することの 3 つの要因が挙げられる。これらの波形では GPR, NN の予測値が熟練者の判定値と近い値を示しており、機械学習アルゴリズムの違いに起因する予測のばらつきであると考えられる。

5. 結論

BE 法の S 波到達時間評価の誤差低減を目的とし、SVR, GPR, NN の 3 種類の機械学習アルゴリズムを用い、実際の実験データに対する予測精度を確認した。S 波到達時間が既知である人工的に生成した受信波を学習データとして、11 次元の特徴量を抽出し、異なる機械学習モデルを作成した。予測結果の比較から、いずれのモデルも砂質土試料では予測結果に大差はないが、泥炭の一部では GPR, NN が妥当な予測を示す一方、SVR での予測誤差が大きくなり、機械学習アルゴリズムに起因する予測のばらつきが確認できた。

【参考文献】 1) T. Ogino: Travel time observation using numerical simulation of bender element testing in time and frequency domain, Soils and Foundations, Vol.59, No.3, pp. 657--670, 2019. 2) 椋山・荻野：機械学習を用いたベンダーエレメント試験の受信波形における S 波到達点の予測, AI・データサイエンス論文集, Vol. 3, No. J2, pp. 76-84, 2022. https://doi.org/10.11532/jsceiii.3.J2_76

表-2 平均二乗誤差(RMSE)

	SVR	GPR	NN
月面模擬土	0.35×10^{-5}	0.55×10^{-5}	0.81×10^{-5}
泥炭	2.29×10^{-5}	1.60×10^{-5}	1.30×10^{-5}
豊浦砂	0.24×10^{-5}	0.56×10^{-5}	0.45×10^{-5}
ALL	1.56×10^{-5}	1.16×10^{-5}	1.01×10^{-5}




図-4 共通して予測誤差の大きい波形




図-5 予測値のばらつきが大きい波形