

地震動 H/V スペクトル比に基づく横浜市の地盤情報の推定に向けた機械学習の利用

久保田 将史¹・劉 ウェン²・丸山 喜久³

¹学生会員 千葉大学大学院融合理工学府 博士前期課程 (〒263-8522 千葉県千葉市稲毛区弥生町 1-33)

E-mail: m.kubota@chiba-u.jp

²正会員 千葉大学助教 大学院工学研究院 (〒263-8522 千葉県千葉市稲毛区弥生町 1-33)

E-mail: wen.liu@tu.chiba-u.ac.jp

³正会員 千葉大学教授 大学院工学研究院 (〒263-8522 千葉県千葉市稲毛区弥生町 1-33)

E-mail: ymaruyam@tu.chiba-u.ac.jp

地震発生時の地震動強さは、震源や地震波の特性の他に表層地盤の性質によって決まることから、地震に対する防災対策を考案する上で表層地盤に関する情報を把握することは重要である。本研究では、横浜市を対象とし、地震動 H/V スペクトル比の機械学習に基づき AVS30 (地表から深さ 30m までの平均 S 波速度) や地盤の S 波伝達関数を推定することを目的とした。AVS30 の推定では XGBoost を用いたモデルが良好な精度を示した。また、S 波伝達関数の推定では、説明変数に AVS30 を加えることで精度向上を図ったところ、Random Forest を用いたモデルが最も良好な精度を示し、一定の再現性を有することを確認できた。

Key Words: AVS30, H/V spectral ratio of ground motion, machine learning, S-wave transfer function

1. はじめに

我が国では、過去に多数の地震による被害が生じており、今後発生が見込まれている地震に対して防災対策を考える必要がある。一般に、地震動強さは、震源の特性、地震波の伝播の特性の他に表層地盤の性質によって決まると言われている¹⁾。同一の地震に対しても表層地盤特性の違いによって揺れやすさは異なるため、地震に対する防災対策を考案する上で地点ごとに表層地盤に関する情報を把握することは重要である。

一般に、表層地盤の揺れやすさを評価するのに、AVS30 (地表から深さ 30m までの平均 S 波速度) や地盤の S 波伝達関数がよく用いられる。AVS30 は、1979 年に Borchardt らによって地盤の増幅特性を簡易に評価するために提案された²⁾。これにより、地盤の揺れやすさなどの地盤の特性を広域的に評価することが可能になった。藤本、翠川は AVS30 と地盤増幅度 (AF_{pgv}) の関係式として、(1) 式を提案している³⁾。

$$\log AF_{pgv} = 2.367 - 0.852 \log(AVS30) \pm 0.166 \quad (1)$$

AVS30 を精密に評価することは地盤の特性を精緻に把握することにつながるが、AVS30 の情報を得るには PS 検層などの詳細な地盤調査が必要となるため、広域にわたって高密度に詳細調査を実施することは費用等の面からも難しい。

地盤の S 波伝達関数は、表層地盤の地盤増幅度を周期 (または振動数) で表した関数で、AVS30 に比べてより直接的に、詳細に地盤の揺れやすさを評価できる。地盤の伝達関数を算出するには、層ごとの S 波速度や土の密度などといった情報が必要となるが、AVS30 と同様にこれらの情報を得るためには詳細な地盤調査を行う必要がある。

このような背景を踏まえて、本研究では地震計が高密度に設置されている神奈川県横浜市を対象に、地震動や常時微動の記録から算出される H/V スペクトル比 (水平成分と鉛直成分の振幅スペクトルの比) を用いて、AVS30 や S 波伝達関数の推定することを目指す。地震記録などから高精度に表層地盤の揺れやすさに関する指標を予測できるようになれば、詳細な地盤調査の必要が無

くなり、費用等の削減につながる。また、本研究の予測モデルによって得られた推定結果をもとに揺れやすさマップを作成することによって、今後の地震防災対策に貢献できるものと考えられる。

2. 使用する地震記録と地震動H/Vスペクトル比の算出

(1) 横浜市内における観測地点と使用する地震記録

本研究では横浜市が設置した横浜市強震計と、東京ガスが横浜市内に設置したリアル防災システム SUPREME の地震計 (SI センサー) による地震データを用いる。本研究で使用した地震記録がある観測地点数は、横浜市強震計が 150 地点、東京ガスの地震計が 596 地点である。図-1 に、本研究で用いた地震観測地点の位置および微地形区分⁴⁾を示す。

本研究では、まず横浜市強震計によって 1997 年～1998 年に発生した 10 地震から得られた 1439 記録を使用し、予測モデルの構築・検証を行う。10 地震の発生日月日、震央地およびマグニチュードを表-1 に示す。次に、構築したモデルを東京ガスの地震計による地震記録に適用し、観測地点における AVS30 の予測を行う。ここで使用する地震記録は 1998 年～2013 年に発生した 148 地震で計 4792 記録である。

(2) 地震動 H/V スペクトル比

横浜市強震計の加速度記録全 1439 記録について、地震動 H/V スペクトル比を算出した (図-2)。スペクトルの平滑化はバンド幅 0.4Hz の Parzen のラグ・ウィンドウによって行い、3 成分の加速度フーリエスペクトルの算出を行った。それらの値を用いて(2)式より H/V スペクトル比の計算を行った。

$$|R_{surface}(f)| = \sqrt{|F_{EW}(f)|^2 + |F_{NS}(f)|^2} / |F_{UD}(f)| \quad (2)$$

ここで、 $R_{surface}$ は地震動 H/V スペクトル比、 F は地震動の各成分の加速度フーリエスペクトルである。

機械学習モデルの説明変数として地震動 H/V スペクトル比を用いる場合、それぞれの周期ごとに算出した地震動 H/V スペクトル比の値は、高速フーリエ変換の影響で短周期成分の計算数が多いためばらつきが大きく、訓練データとして最適ではない。そこで、本研究では複数の周期区間を設定し、地震動 H/V スペクトル比の平均値を算出し、それを説明変数として用いることにした⁶⁾。この際、最適な周期区間数を確認するため、周期区間の数

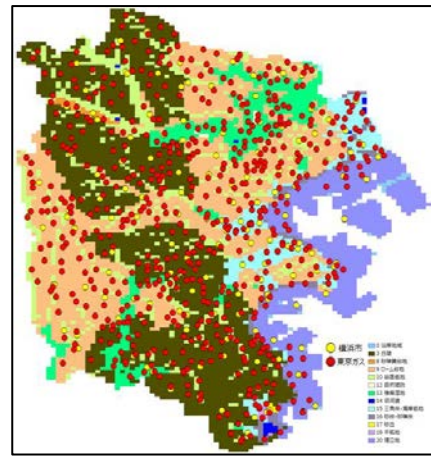


図-1 本研究で用いた地震観測地点と微地形区分

表-1 本研究で用いた地震のリスト

地震番号	発生日月日	震央地名	M
1	1997/7/9	千葉県北西部	4.8
2	1997/8/9	埼玉県南部	4.7
3	1997/9/8	東京湾	5.1
4	1998/1/14	千葉県北西部	4.9
5	1998/1/16	千葉県南部	4.6
6	1998/5/3	伊豆半島東方沖	5.7
7	1998/5/16	千葉県南部	4.8
8	1998/6/14	千葉県東方沖	5.6
9	1998/7/19	千葉県北東部	4.4
10	1998/8/29	東京湾	5.1




図-2 地震動 H/V スペクトル比の例 (観測地点名: kh01, AVS30: 249.89m/s)




図-3 地震動 H/V スペクトル比の比較

を 10 個, 20 個, 30 個, 40 個の 4 パターンを用意し, パターンごとに精度の比較を行った. また, 既往研究⁶⁾を参考に, 機械学習に用いる地震動 H/V スペクトル比の周期は 0.045s~3.0s とした.

また, AVS30 と地震動 H/V スペクトル比には関係性があることが知られており, AVS30 が小さな地点では地震動 H/V スペクトル比のピーク周期が長くなる. 逆に, AVS30 が大きな地点になるにつれてピーク周期が短くなる傾向がある. 実際に AVS30 が大きな地点 (418.15m/s), 中程度の地点 (249.89m/s), 小さな地点 (104.94m/s) の地震動 H/V スペクトル比を比較すると, その傾向を確認することができた (図-3).

3. AVS30 の推定

(1) AVS30 の算出とデータセットの作成

横浜市強震記録観測地点 150 地点の PS 検層データから, AVS30 を算出した. 藤本・翠川にならい³⁾, H_i を i 層目の層厚, V_{si} を i 層目の S 波速度とし(3)式を用いて計算を行った.

$$AVS30 = \sum_{i=1}^n \left(\frac{H_i}{V_{si}} \right) \quad (3)$$

次に, 機械学習に用いるデータセットの作成を行った. データセット作成に当たり, 横浜市強震観測地点 150 地点を 8:2 の割合で分割し, 対応する地震記録をそれぞれ訓練データとテストデータとした. その結果, 訓練データは 1148 記録, テストデータは 291 記録となった. ここで, 分割の際に訓練データとテストデータにおいてそれぞれの微地形区分の割合が等しくなるようにし, 地形の違いによって結果が左右されないようにした. また, 予測モデルの説明変数には地震動 H/V スペクトル比の他に微地形区分⁴⁾をダミー変数化して用いている.

(2) 本研究で使用した手法

R 言語を用いて, 地震動 H/V スペクトル比と微地形区分から AVS30 の値を推定する数理モデルを機械学習によって構築する. 数理モデルの構築に際し, 本研究では Random Forest と XGBoost の 2 つの回帰手法を採用した. 以下に, 各手法の概要を述べる.

a) Random Forest (RF)

アンサンブル学習による機械学習アルゴリズムの一つで, 複数の決定木によって構成される⁷⁾. アンサンブル学習とは, 複数の弱学習器を個別に学習させ, それらの予測結果を平均や多数決などに基づいて統合することで個々の学習器よりも高精度なモデルを構築する方法であ

る. 2001 年に提案された手法で, 回帰・分類の両方に用いることが可能である⁸⁾.

現在 Random Forest はコンピュータ関連の分野において広く用いられている. その主な理由として, 学習の速度が速いことや, 説明変数の重要度などモデル構築の過程を可視化できること, ビッグデータに対しても利用可能であることなどが挙げられる.

b) XGBoost

XGBoost は決定木の勾配ブースティングを用いた機械学習手法である⁹⁾. ブースティングとは, 複数の学習器を合わせて一つのモデルとするアンサンブル学習の一つで, 誤差を改善するように弱い学習器を追加していく手法である. ここで, 弱学習器には決定木 (gbtree) が採用されることが多いため, 本研究でもこれを用いる. また, 勾配ブースティングとは, ブースティングにおいて勾配情報を用いて損失を減少させる方向を決める方法のことであり, XGBoost ではモデルの学習時に勾配情報を用いてパラメータの値を更新する. RF と同じく, こちらも分類・回帰の両方に利用できる.

XGBoost を用いるメリットとしては, 並列分散処理が可能であるためモデルの探索が高速であることや, 非線形な予測モデルである決定木を弱学習器にしているため, 非線形な予測モデルの構築が可能であることなどが挙げられる.

(3) ハイパーパラメータチューニングの方法

各回帰手法において行ったハイパーパラメータチューニングの方法について述べる. RF では, R 言語の `caret` パッケージ内にある `train` 関数を用いてパラメータのチューニングを行った. この際, `trControl` (予測の評価方法) には交差検証, `tuneLength` (パラメータチューニングの範囲) は 8 に設定し, `method` には `rf` を用いた. `method` で用いる `rf` では, `mtry` (決定木の枝分かれ層) のみをハイパーパラメータとしてチューニングし, 得られた `mtry` の値を用いて AVS30 の推定を行った.

XGBoost では, 自前のプログラムを用いてチューニングを行った. XGBoost において設定したハイパーパラメータは 5 つで, `eta` (学習率), `max_depth` (最大の木の深さ), `min_child_weight` (決定木の葉の重みの下限), `colsample_bytree` (各決定木においてランダムに抽出される列の割合), `subsample` (各決定木においてランダムに抽出される標本の割合) である. パラメータチューニングはグリッドサーチで行い, 精度を検証するにあたり訓練データとテストデータとして 8:2 に分割した. 本研究では, 初めに `max_depth` と `min_child_weight` のチューニングを行った. この際, 他のパラメータの値は 1.0 で固定した. 次に, 一番精度の良かった `max_depth` と `min_child_weight` の組み合わせを固定したまま,

表-2 RF と XGBoost における推定精度

		平均値の精度		AVS30 の範囲別の精度 (RMSE)			
		RMSE	R_f^2	100-200(m/s)	200-300(m/s)	300-400(m/s)	400-(m/s)
手法	RF	76.30	0.47	78.68	32.71	23.18	152.62
	XGBoost	70.07	0.56	68.39	29.79	25.02	144.77

colsample_bytree と subsample のチューニングを行った。最後に、これまでチューニングを行った4つのハイパーパラメータを固定したまま eta のチューニングをし、定まった5つのパラメータを用いて nrounds (ブースティングの繰り返し回数) を xgb.cv 関数によって定めた。そして、ここまでで得られたハイパーパラメータと nrounds の値を用いてモデルを構築し、AVS30 の推定を行った。

(4) 推定結果

RF と XGBoost による推定結果を表-2, 図-4 に示す。ここでは、精度評価指標には RMSE (二乗平均平方根誤差) と R_f^2 (自由度調整済み決定係数) を用い、各地点の推定値の平均値に対して精度を算出している。また、ハイパーパラメータチューニングの結果、RF では mtry = 23, XGBoost では表-3 に示す組み合わせとなった。さらに、説明変数の地震動 H/V スペクトル比の周期区間数は、両手法ともに最も精度の高かった 30 とした (表-4)。

表-2 では、各地点の平均値に対する RMSE と R_f^2 と、観測地点の AVS30 の範囲別に見た RMSE の精度を示している。まず、各モデルの平均値の精度を比較すると、両指標ともに XGBoost の方が推定精度が良好で、RMSE は 70.07, R_f^2 は 0.56 となった。次に、AVS30 の範囲別に見た精度を比較する。AVS30 が 100-200m/s, 200-300m/s のときの推定精度は、XGBoost を用いたモデルの方が優れていることがわかった。AVS30 が 300-400m/s のときはほぼ同程度、400m/s 以上のときは XGBoost の方が推定精度が高かった。以上より、本研究では XGBoost のモデルを AVS30 の予測に用いることにした。

(5) 東京ガス地震記録への適用

最も良好な精度を示した XGBoost で構築した数理モデルに、東京ガスの地震計によって観測された地震動 H/V スペクトル比を入力し、AVS30 を推定した。まず、横浜市強震計によって観測された全 1439 記録の地震動 H/V スペクトル比を訓練データとし、数理モデルを構築し直した。このモデルを東京ガス地震計の 4792 記録から算出した地震動 H/V スペクトル比に適用し、東京ガス地震観測地点 596 地点分の AVS30 を推定した。

次に、推定した AVS30 の妥当性の確認を行うために、横浜市神奈川区における AVS30 と、地震動強さの指標である最大速度 (PGV) との関係性を調べた。ここでは、

表-3 XGBoost モデルのハイパーパラメータ

max_depth	min_child_weight	colsample_bytree	subsample	eta	nrounds
14	4	0.5	0.8	0.01	4789

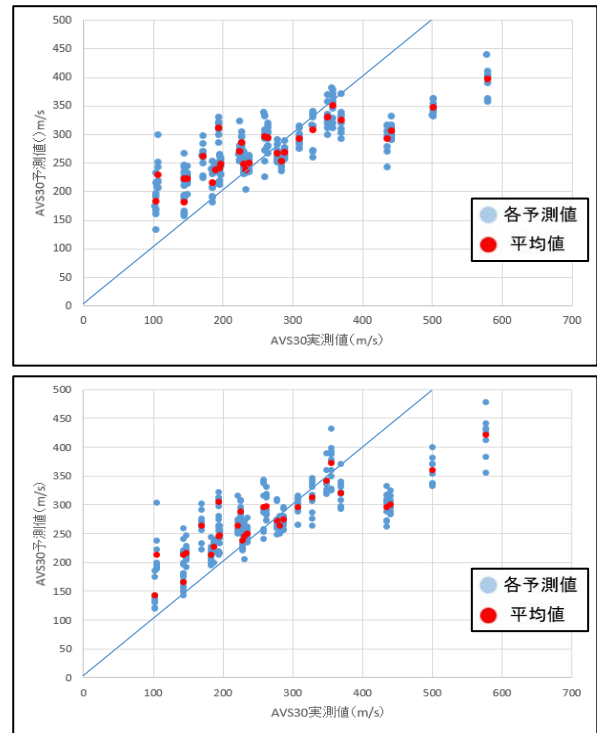


図-4 AVS30 の推定値と実測値の関係 (上図: RF 下図: XGBoost)

表-4 AVS30 の推定における説明変数の周期区間

変数	周期区間(s)	変数	周期区間(s)
X1	0.045≤t<0.475	X16	0.25≤t<0.3
X2	0.0475≤t<0.05	X17	0.3≤t<0.35
X3	0.05≤t<0.0525	X18	0.35≤t<0.4
X4	0.0525≤t<0.055	X19	0.4≤t<0.45
X5	0.055≤t<0.06	X20	0.45≤t<0.5
X6	0.06≤t<0.065	X21	0.5≤t<0.55
X7	0.065≤t<0.07	X22	0.55≤t<0.6
X8	0.07≤t<0.075	X23	0.6≤t<0.7
X9	0.075≤t<0.08	X24	0.7≤t<0.8
X10	0.08≤t<0.09	X25	0.8≤t<0.9
X11	0.095≤t<0.1	X26	0.9≤t<1.0
X12	0.1≤t<0.125	X27	1.0≤t<1.25
X13	0.125≤t<0.15	X28	1.25≤t<1.5
X14	0.15≤t<0.2	X29	1.5≤t<2.0
X15	0.2≤t<0.25	X30	2.0≤t<3.0

2011年東北地方太平洋沖地震の本震のPGVを用いた。一般に、地震動の強さは震源の規模・震源からの距離・表層地盤の性質の影響の3つの要素が影響する。東北地方太平洋沖地震本震の震源は遠く、横浜市神奈川区内の観測地点と震源との距離の違いは無視できる。したがって、PGVの大きさの違いは、観測地点における表層地盤の影響が最も大きいものと仮定した。つまり、AVS30は揺れにくい地点（PGVが小さい）では大きな値を示し、揺れやすい地点（PGVが大きい）では小さな値を示す。この単純化した関係性に基づき、本研究で推定したAVS30の妥当性の確認を行う。さらに、本研究の推定値の尤もらしさを、東京ガスによって推定されているAVS30の値（近傍のボーリングデータのN値からS波速度を換算し、推定したもの）と比較した。横軸に神奈川区の観測地点におけるPGVを降順に並び、縦軸に本研究によるAVS30の推定値、東京ガスのAVS30の推定値をそれぞれとったグラフを図-5に示す。

図-5より、本研究の推定値のグラフは明確に右肩上がりの関係を示している。AVS30の推定値が大きくなるにつれてPGVの値も小さくなる、つまり地盤が揺れにくくなる傾向を示している。一方、東京ガスのAVS30の推定値について見ると、本研究の予測値と比較してPGVとの相関が弱い。このことから、本研究のAVS30の予測値は、AVS30と地盤の揺れやすさの単純化した関係性に合致しており、N値から推定した東京ガスのAVS30と比較しても尤もらしいことがわかった。

次に、予測結果に基づき、横浜市におけるAVS30の分布を確認し、地盤の揺れやすさの評価を行う。本研究の予測値（597地点分）と、横浜市強震観測点のPS検層データより算出されたAVS30（150地点分）を合わせ、AVS30の値による色分けを微地形区分上で行ったものを図-6に示す。まず、本研究の予測値と横浜市強震観測点のPS検層データから算出されたAVS30を比較すると、予測値は横浜市強震観測点のAVS30と調和的な値を示していることから、この点に関しても本研究の予測値は妥当であることが言える。次に、AVS30の分布を確認すると、微地形の種類によって揺れやすさがはっきり分かれていることが確認できる。具体的には、北東部や東部の後背湿地や三角州・海岸低地、埋立地においてAVS30の値が100~200m/sの地点が集中しており特に揺れやすく、北西部と南部の丘陵ではAVS30の値が250m/s~450m/s以上の地点が多く揺れにくいということが読み取れる。また、中部や北西部に位置するローム台地や谷底低地にもAVS30が200~250m/sの地点が複数存在し、比較的揺れやすい地点であることがわかった。

(6) 推定モデルの精度向上に向けた地形指標TPIの活用
XGBoostを用いた数理モデルについて、さらなる精度

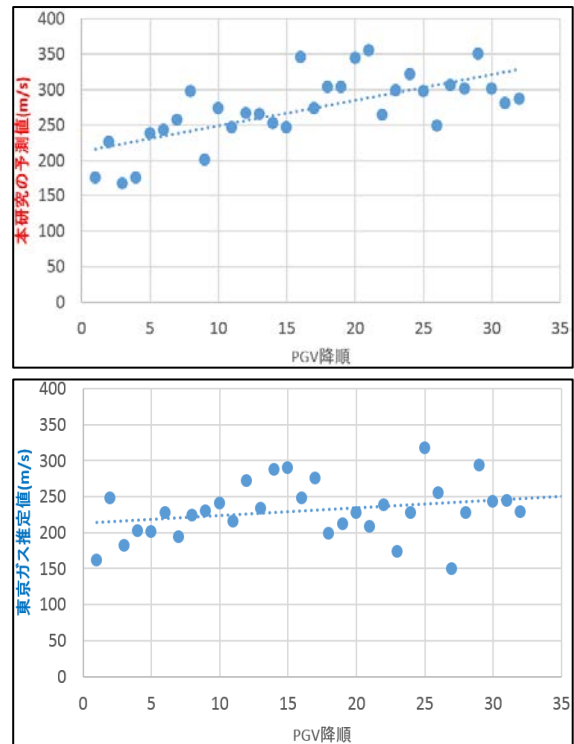


図-5 横浜市神奈川区におけるPGVとAVS30の関係性
(上図：本研究の推定値 下図：東京ガスの推定値)

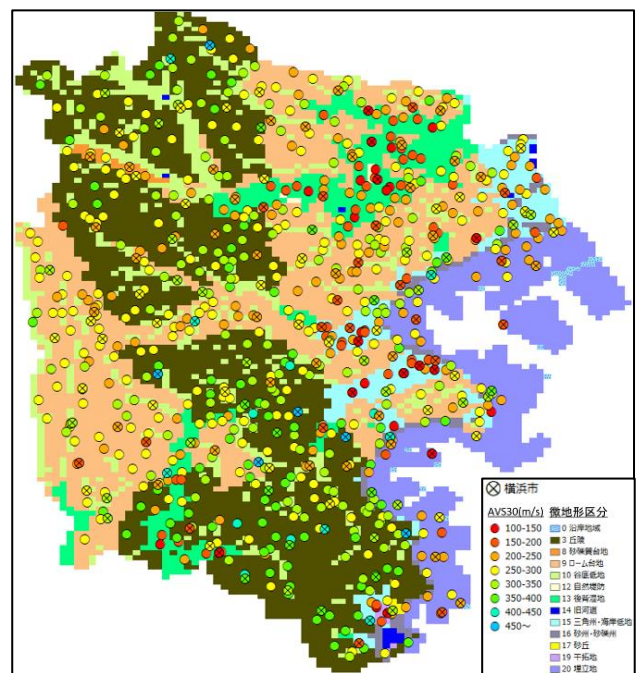


図-6 横浜市におけるAVS30の分布

の向上を目指して、説明変数に用いている地震動H/Vスペクトル比と微地形区分に加えて、地形指標TPI (Topographic Position Index) の活用を検討した。TPIはDEM (数値標高モデル) の各セルの標高と、その周辺セルの標高平均値との差で定義され、式(4)によって算出される。

表-5 微地形区分を加えたモデルと新たに TPI を加えたモデルの予測精度の比較

		平均値の精度		AVS30 の範囲別の精度 (RMSE)			
		RMSE	R_f^2	100-200(m/s)	200-300(m/s)	300-400(m/s)	400-(m/s)
説明変数の 組み合わせ	微地形	70.07	0.56	68.39	29.79	25.02	144.77
	TPI300+微地形	70.98	0.54	67.94	28.23	25.47	149.27
	TPI500+微地形	70.40	0.55	69.01	33.45	19.37	144.26

$$TPI = A - B \quad (4)$$

ここで、A は DEM の当該セルの標高、B は周辺セルの標高平均値である。B は当該セルを中心とした円内で、半径 R は任意に設定することができる。TPI を活用する狙いとして、横浜市における谷底低地の抽出が挙げられる。一般に、谷底低地では地震の際に揺れやすいことが知られている¹⁰⁾が、TPI を活用することで微地形区分に比べてさらに詳細に谷底低地の数値化・抽出が可能となると考え、数理モデルの精度向上を図った。

本研究では、ArcGIS の Topography Tool によって得られた TPI の画像に位置情報を付与し、横浜市強震観測点の TPI を取得した。この際、半径 R の値は 100m、300m、500m の 3 パターンとした。ここで、半径 R を 500m に設定した際の横浜市の TPI マップを図-7 に示す。黒が濃くなっている部分は TPI の値が小さくなっていることから谷筋であることを示し、反対に白くなっている部分は尾根である。

説明変数の地震動 H/V スペクトル比に TPI のみを加えた場合 (3 パターン) と、TPI と微地形区分の両方を加えた場合 (3 パターン) で XGBoost による機械学習を実行し、6 パターンの推定精度を比較した。その結果、TPI (R=300m) と微地形区分を加えたモデル、TPI (R=500m) と微地形区分を加えたモデルの 2 つのモデルの精度が比較的高かった。表-5 に、これらの 2 モデルと、先述した地震動 H/V スペクトル比に微地形区分のみを加えた XGBoost モデルの推定精度を示す。6 パターンのモデルの中で全体の精度が最も良好だったのは TPI (R=500m) と微地形区分を加えたモデルで、RMSE は 70.40、 R_f^2 は 0.55 であった。しかし、微地形区分のみを加えたモデルと比較すると、全体の精度は若干劣った。さらに、AVS30 が小さな地点における推定精度も良好でないことがわかる。また、TPI (R=300m) と微地形区分を加えたモデルと微地形区分のみを加えたモデルを比較すると、AVS30 が小さな地点についてはわずかに精度が高まったが、全体的には精度は低下した。これらの結果から、説明変数に TPI を加えても予測モデルの精度はほとんど変わらない、もしくはやや劣る結果となり、明確な精度向上にはつながらなかった。




図-7 横浜市の TPI マップ (半径 R=500)

4. 地盤の S 波伝達関数の推定

(1) S 波伝達関数の算出

地震動 H/V スペクトル比から地盤の S 波伝達関数を推定することを試みる。まず、等価線形解析プログラム microSHAKE¹¹⁾を用いて、横浜市強震観測地点 150 地点分の PS 検層データに基づき、最下層を露頭基盤とした場合の地表面の S 波伝達関数を算出した。この際、各層の減衰定数は 2% とし (最下層は 0%)、土の密度には PS 検層データの各層における N 値より換算した値¹²⁾¹³⁾を用いた。microSHAKE によって算出された伝達関数のグラフの一例を図-8 に示す。

(2) データセットの作成

S 波伝達関数を推定するための説明変数には、地震動 H/V スペクトル比を用いる。さらに、AVS30 も説明変数とした。AVS30 が無い地点においては、本研究の 3 章の数理モデルで AVS30 を推定し、その後 S 波伝達関数を推定することになる。また、S 波伝達関数は、周期 0.1s~1.024 の間から 20 個の値を抽出し、これらの値を推定することを目指した (図-9)。また、推定する伝達関数の周期範囲に合わせて説明変数の地震動 H/V スペクトル比の周期も 0.1s~1.024s とした。そして AVS30 予測の際

と同様に周期区間を設定し、その区間に含まれる値を平均化したものを説明変数に用いた。今回設定した周期区間の数は20個と30個の2パターンであり、各パターンの推定精度を比較した。さらに、訓練データとテストデータの分割方法については、AVS30の推定と全く同じ方法を用いた。

(3) 推定モデルの構築

S波伝達関数の推定は、目的変数の数が1地点につき20個存在するため、一度に複数の値を推定することになる。ここで、回帰分析において複数の推定値を出力できるアルゴリズムとして、Random Forest (RF) や Neural Network (NN) が挙げられる。また、プログラミング言語の一つであるPythonではMulti Output Regressor (MOR) が実装されており、この機能を用いれば複数出力に対応していない回帰手法でも複数の値を予測できるようになる。本研究では、RFとNNの2手法、そしてMORを使ったXGBoostとLight GBMの2手法の合計4手法の精度を比較検討した。訓練データに全データを用いて精度を調べた結果、RF、XGBoost (MOR) の2手法が高精度であった。そこで、この2手法を用いてS波伝達関数の推定を行った。ハイパーパラメータは、pythonの機械学習ライブラリscikit-learnのGridSearchCVを用いたグリッドサーチで探索を行った。RFのハイパーパラメータは4つあり、n_estimators (生成する木の数)、max_depth (木の深さ)、max_features (分岐に用いる説明変数の数)、min_sample_split (分割する際の最小のサンプル数の設定) である。XGBoostは、AVS30を推定する際に用いたパラメータと同一のものを用いる (learning_rate は eta と同義である。また、nrounds は使用しない)。

(4) 推定結果

RFとXGBoost (MOR) について、地震動H/Vスペクトル比の周期区間数の違いによる精度の比較を行った。その結果、両手法ともに周期区間数30 (表-6) のときの予測モデルの精度が良好であった。また、両手法とも説明変数に微地形区分を加えたモデルの方が精度が良好であったため、周期区間数30の地震動H/Vスペクトル比、AVS30、微地形区分を説明変数に用いたRFとXGBoost (MOR) の推定精度をそれぞれ表-7、表-8に示す。また、両モデルにおけるハイパーパラメータを表-9、表-10に示す。

両手法を比較すると、周期0.4s~0.65sの区間においては同程度の精度を示したものの、それ以外のほぼ全ての周期においてRFの方が良い精度を示した。特に、周期0.7s~1.0sにおいてその傾向が顕著に表れている。

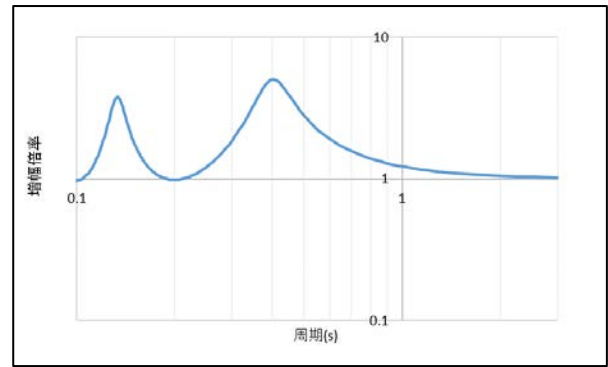


図-8 kg01における伝達関数のグラフ




図-9 tr01における伝達関数と推定する20周期における値

表-6 S波伝達関数の推定における説明変数の周期区間

変数	周期区間(s)	変数	周期区間(s)
X1	0.1≤t<0.105	X16	0.275≤t<0.3
X2	0.105≤t<0.11	X17	0.3≤t<0.325
X3	0.11≤t<0.115	X18	0.325≤t<0.35
X4	0.115≤t<0.12	X19	0.35≤t<0.4
X5	0.12≤t<0.125	X20	0.4≤t<0.45
X6	0.125≤t<0.13	X21	0.45≤t<0.5
X7	0.135≤t<0.14	X22	0.5≤t<0.55
X8	0.14≤t<0.15	X23	0.55≤t<0.6
X9	0.15≤t<0.16	X24	0.6≤t<0.65
X10	0.16≤t<0.17	X25	0.65≤t<0.7
X11	0.17≤t<0.18	X26	0.7≤t<0.75
X12	0.18≤t<0.2	X27	0.75≤t<0.8
X13	0.2≤t<0.225	X28	0.8≤t<0.85
X14	0.225≤t<0.25	X29	0.85≤t<0.9
X15	0.25≤t<0.275	X30	0.9≤t<1.024

(5) 伝達関数の推定精度の評価

RFモデルについて、各周期における推定値と実測値との関係を図-10に示す。周期0.1s~0.2sまでは精度が悪いが、周期0.25s以上は自由度調整済み決定係数の値が大きくなり、精度が良好である。周期0.35s~0.4sにおいては、増幅倍率の大きな地点における推定値が外れ値となっており、その影響でRMSEの値も大きくな

表-7 RF を用いた際の伝達関数の各周期における予測精度 (RMSE, R_f^2)

		周期										
		0.1s	0.13s	0.16s	0.2s	0.25s	0.3s	0.35s	0.4s	0.45s	0.5s	
精度 評価 指標	RMSE	0.83	0.73	0.77	0.72	0.76	0.65	1.14	0.88	0.84	0.64	
	R_f^2	-0.37	-0.44	-0.14	-1.07	0.18	0.33	0.30	0.41	0.32	0.51	
			周期									
			0.55s	0.6s	0.65s	0.7s	0.75s	0.8s	0.85s	0.9s	0.95s	1.0s
	RMSE	0.52	0.39	0.37	0.59	0.63	0.72	0.69	0.61	0.54	0.48	
R_f^2	0.64	0.70	0.77	0.58	0.41	0.15	0.11	0.14	0.21	0.54		

表-8 XGBoost (MOR) を用いた際の伝達関数の各周期における予測精度 (RMSE, R_f^2)

		周期										
		0.1s	0.13s	0.16s	0.2s	0.25s	0.3s	0.35s	0.4s	0.45s	0.5s	
精度 評価 指標	RMSE	0.86	0.83	0.82	0.70	0.73	0.82	1.35	0.83	0.86	0.60	
	R_f^2	-0.38	-0.80	-0.23	-0.88	0.27	-0.044	0.068	0.51	0.32	0.59	
			周期									
			0.55s	0.6s	0.65s	0.7s	0.75s	0.8s	0.85s	0.9s	0.95s	1.0s
	RMSE	0.49	0.43	0.49	0.98	0.83	0.81	0.77	0.61	0.56	0.64	
R_f^2	0.69	0.65	0.60	-0.11	0.024	-0.025	0.063	0.18	0.18	0.19		

ってしまっていることがわかる。周期 0.5s-0.7s については、外れ値も少なく非常に良く推定できていることが確認できる。この周期帯においては、増幅倍率の大きな地点についても実測値に近い値を推定することができている。一方で周期 0.8s-0.95s においては自由度調整済み決定係数が小さい。増幅倍率 2 倍付近の過大予測と、増幅倍率 3 倍以上の過小予測が目立っている。ここで、特に長周期側の増幅倍率が大きな地点における過小予測は、地震被害への観点から重大な問題であると考えているため、この誤差を小さくして過小予測の度合いを減らすことが今後の大きな課題であると考えている。

実際の S 波伝達関数のグラフの上に RF モデルによる各周期の推定値をプロットし、S 波伝達関数の再現度を確認した。この際、各地点の推定値にはそれぞれ 8~10 個の推定値を平均化した値を用いて、各地点 20 個ある周期における推定値と実際の値について誤差 RMSE の算出を行っている。地点ごとに RMSE を算出した結果、最も RMSE の値が小さい地点は kz09 (AVS30=500(m/s), 丘陵) で 0.0094, 反対に最も大きい地点は sk01 (AVS30=143.41(m/s), 後背湿地) で 1.58 となった。

RMSE の大きさごとに S 波伝達関数の再現度の違いを評価した。RMSE が 0-0.4, 0.4-0.8, 0.8 以上の 3 パターンに分けてそれぞれ図示した (図-11~図-13)。RMSE が 0-0.4 の該当地点は 30 地点中 10 地点であった。図中では、そのうちの 3 地点を掲載しているが、S 波伝達関数を良く再現できている。RMSE が 0.4-0.8 の該当地点は 13 地点あった。誤差が生じている周期が多くはなっているが、ピーク周期やピーク倍率などは実際の値に近い値を推定できている。

RMSE が 0.8 以上の該当地点は 7 地点であり、これま

表-9 RF モデルのハイパーパラメータ

n_estimators	max_depth	max_features	min_sample_split
500	15	39	3

表-10 XGBoost モデルのハイパーパラメータ

max_depth	min_child_weight	colsample_bytree	subsample	learning_rate
8	5	1.0	1.0	0.1

での 2 つのパターンと比較すると S 波伝達関数に対する当てはまりが非常に悪くなっていることが読み取れる。これらの地点においてはピーク周期、ピーク倍率ともに実際の値をはかけ離れた値を推定してしまっており、特にピーク倍率の過大評価や過小評価が目立っている。このような傾向を示した地点は、すべて AVS30 が 100-250m/s といった地点であった。この結果から、AVS30 の推定においても S 波伝達関数の推定においても、AVS30 が小さく揺れやすい地点における推定精度を改善が本研究における大きな課題の一つであるといえる。

5. 結論

本研究では、地震記録から地盤情報を推定できる数理モデルの構築を目的に、地震動 H/V スペクトル比から AVS30 や地盤の S 波伝達関数を機械学習による回帰手法を用いて予測を行い、モデルの精度を評価した。AVS30 の予測では、説明変数に微地形区分を加えた XGBoost モデルが最も良い精度を示し、RMSE = 70.07, R_f^2 = 0.56 であった。このモデルを東京ガスのデータに適用

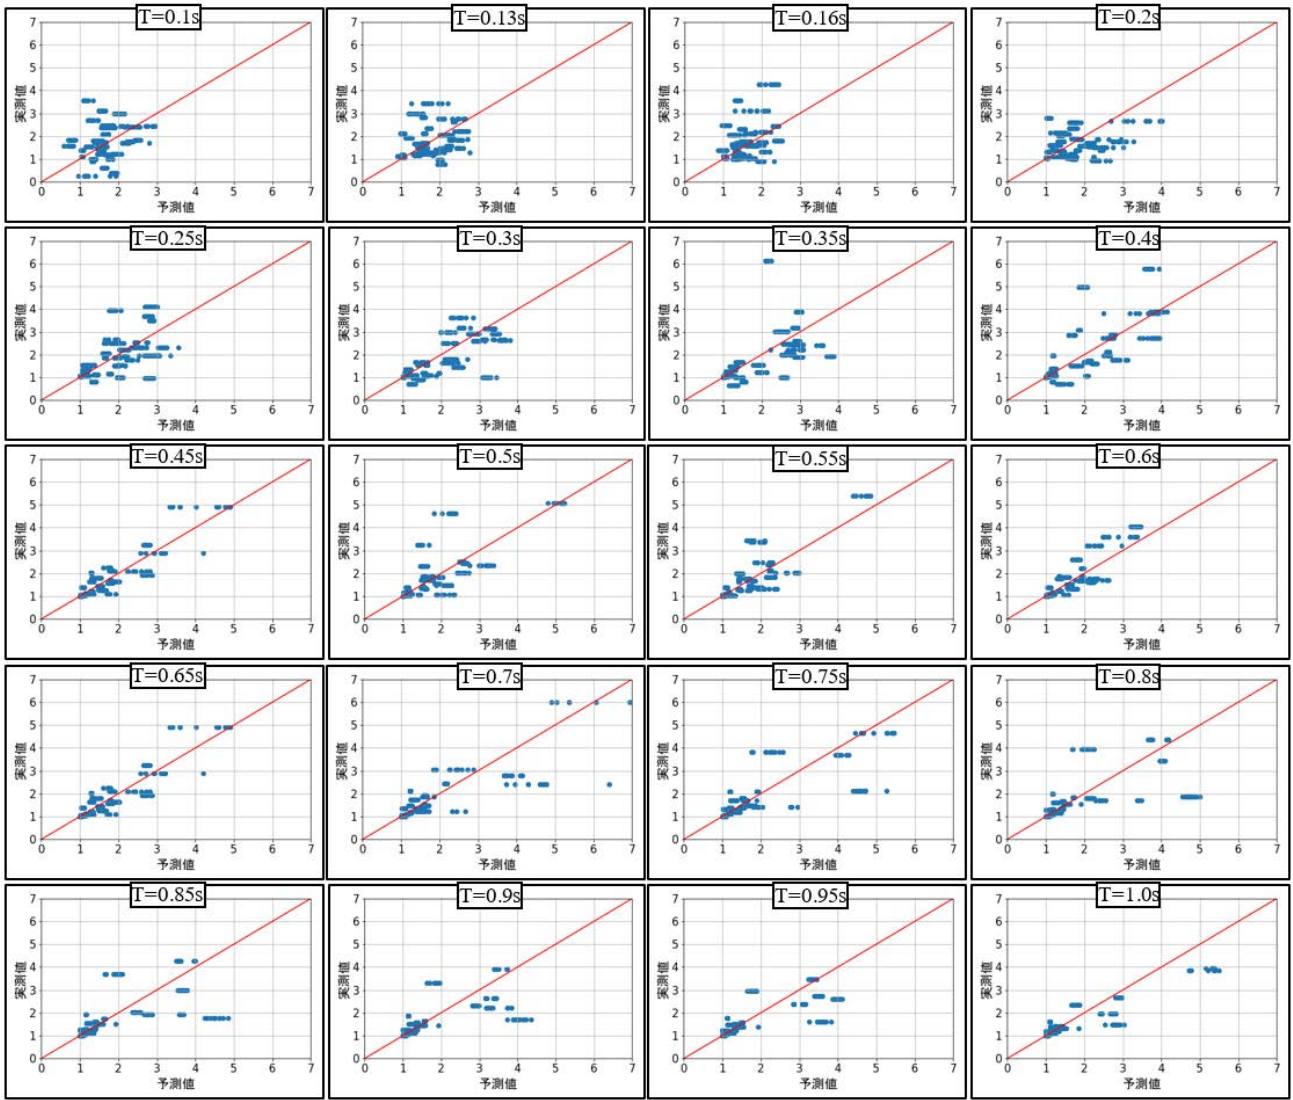


図-10 RFモデルによる、各周期における推定値と実測値の関係

した結果、推定値は AVS30 と地盤の揺れやすさに合致した傾向を示し、妥当性があることが確認できた。さらに推定値をもとに横浜市の AVS30 の分布を確認した結果、揺れやすさは微地形区分の違いによってはっきりと分かれていることがわかった。

さらに、地震動 H/V スペクトル比から地盤の S 波伝達関数を推定し、実際のグラフを再現することを試みた。この際、AVS30 も説明変数に加え、先に構築した AVS30 の数理モデルによる推定値を活用することも想定して予測を行った。その結果、微地形区分を説明変数に取り入れた RF のモデルが最も良い精度を示し、特に本研究で重視している 0.7-1.0s といった長周期帯の増幅倍率の推定において、他の手法と比較すると高精度であった。また、RF モデルによる S 波伝達関数のグラフに対する再現度の確認を行った結果、RMSE が 0.8 を超える地点では大きく異なる形となった地点が数地点あったものの、RMSE が 0-0.8 のうちのほとんどの地点においては実際のピーク周期やピーク倍率に近い値を推定できているこ

とから、本研究の数理モデルは一定の再現性を持っていることが確認できた。

AVS30 と S 波伝達関数推定について、一定の精度は得られたが、両者とも精度の改善の余地が見られる。特に AVS30 が小さな地点における精度が比較的悪くなっている点は重大な課題である。この原因の一つとして AVS30 の小さな地点における地震記録が不足していることが挙げられる。今後は、このようなデータの偏りを補うために新たな説明変数の追加を検討し、さらなる精度向上を図りたいと考えている。また、地震動だけでなく常時微動による H/V スペクトル比も利用し、より詳細な地盤ゾーニングを目指したいと考えている。

REFERENCES

- 1) 松岡昌志, 翠川三郎: 国土数値情報を利用した地盤の平均 S 波速度の推定, 日本建築学会構造系論文報告集, 第 443 号, pp.65-71, 1993[Matsuoka, M. and




図-11 RMSEが0~0.4の地点における、RFモデルによる予測値の伝達関数の再現度
 左：as04 (RMSE=0.13) 中：hd02 (RMSE=0.25) 右：md06 (RMSE=0.36)




図-12 RMSEが0.4~0.8の地点における、RFモデルによる予測値の伝達関数の再現度
 左：ns04 (RMSE=0.51) 中：kh07 (RMSE=0.64) 右：kh09 (RMSE=0.68)




図-13 RMSEが0.8以上の地点における、RFモデルによる予測値の伝達関数の再現度
 左：iz04 (RMSE=0.99) 中：as05 (RMSE=1.28) 右：sk01 (RMSE=1.58)

Midorikawa, S. : Empirical estimation of average shear-wave velocity of ground using the digital national land information, Journal of Structural and Construction Engineering, Vol.443, pp.65-71, 1993.]

- 2) Borchardt, R. D., Gibbs, J. F. and Fumal, T. E. : Progress on ground motion predictions for the San Francisco Bay region, California, U.S. Geol. Survey Cir. 807, pp.13-25, 1979.
- 3) 藤本一雄, 翠川三郎: 近接観測点ペアの強震記録に基づく地盤増幅度と地盤の平均S波速度の関係, 日本地震工学会論文集, 6巻1号, pp.11-22, 2006. [Fujimoto, K. and Midorikawa, S.: Relationship between Average Shear-Wave Velocity and Site Amplification Inferred from Strong Motion Records at Nearby Station Pairs, Journal of JAEE, Vol. 6, No. 1, pp. 11-22, 2006.]
- 4) 若松加寿江, 松岡昌志: 全国統一基準による地

形・地盤分類250mメッシュマップの構築とその利用, 日本地震工学会誌, 18号, pp.33-38, 2013.

- [Wakamatsu, K. and Matsuoka, M : Construction and use of 250m mesh map of topography and soil classification based on nationally standardized criteria, Bulletin of JAEE, Vol.18, pp.33-38, 2014]
- 5) 大崎順彦: 新・地震動のスペクトル解析入門, 鹿島出版会, 1994. [Ohsaki, Y. : New Introduction to Spectral Analysis of Earthquake Motions, Kajima Institute Publishing, 1994]
 - 6) 草開俊介, 丸山喜久: 地震動 H/V スペクトル比の機械学習による地盤増幅度の評価に向けた AVS30 の推定, 土木学会論文集 A1 (構造・地震工学), 76巻4号, pp. I_249-I_258, 2020. [Kusabiraki, S. and Maruyama, Y.: Estimation of AVS30 based on machine learning of H/V spectral ratio of earthquake ground motion record,

- Transaction of the Japan Society of Civil Engineers AI, vol.76, No.4, pp. I_249-I_258, 2020.*]
- 7) 津村拓海, 齊藤史哲, 石津昌平: ランダムフォレストを用いた特許に関する文書データからの技術駅用領域に関する知識抽出, 日本経営工学会論文誌, 68巻3号, pp. 161-170, 2017. [Tsumura, T. and Saitoh, F. and Ishizu, S. : Knowledge Extraction from Textual Patent Data Using a Random Forest, Journal of Japan Industrial Management Association, Vol.68, No.3, pp.161-170, 2017]
 - 8) 波部斉: ランダムフォレスト, 情報処理学会研究報告, 2012-CVIM-182巻31号, pp.1-8, 2012. [Habe, H.: Random Forests, IPSJ SIG Technical Report, Vol.2012-CVIM-182, No.31, pp.1-8, 2012]
 - 9) 横山侑政, 瀧川一学: 全部分グラフ指示子に基づく決定木の勾配ブースティング, 人工知能学会全国大会論文集, 31巻, 2017.. [Yokoyama, Y. and Takigawa, I. : Gradient Boosting Decision Tree Learning over All Possible Subgraph Indicators, Proceedings of the Annual Conference of JSAI, No.31, 2017]
 - 10) 安田進: 東京における地震時の地盤工学上の課題, 第四紀研究, 56巻5号, pp.217-225, 2017. [Yasuda, S. : Geotechnical problems to be studied to predict damage that may occur in Tokyo due to future earthquakes, The Quaternary research, Vol.56, No.5, pp.217-225, 2017]
 - 11) 株式会社地震工学研究所: microSHAKE/3D, http://flush.co.jp/soft/doc/outline_ms3d_v20.pdf, 2014. [JISHIN KOGAKU KENKYUSHO, INC. : microSHAKE/3D, http://flush.co.jp/soft/doc/outline_ms3d_v20.pdf, 2014.]
 - 12) 防災科学研究所: 強震観測網 (K-NET, KiK-net) 観測点一覧: <https://www.kyoshin.bosai.go.jp/cgi-bin/kyoshin/db/sitedat.cgi?0+AOM008+knet>. [National Research Institute for Earth Science and Disaster Resilience.: Strong motion network (K-NET, Kik-NET) Observation point list]
 - 13) 神奈川県地震被害想定調査委員会: 神奈川県地震被害想定調査報告書 (手法編), pp.9, 2015. [Kanagawa Prefecture Earthquake Damage Estimation Investigation Committee.: Kanagawa Prefecture Earthquake Damage Assumption Survey Report (Methodology), pp.9, 2015.]

USING MACHINE LEARNING TO ESTIMATE GEOTECHNICAL INFORMATION OF YOKOHAMA CITY BASED ON GROUND MOTION RECORDS

Masafumi KUBOTA, Wen LIU and Yoshihisa MARUYAMA

The ground shaking during an earthquake depends not only on the seismic source and seismic wave characteristics, but also on the properties of the surface soil. In this study, we developed a prediction model using a machine learning method for Yokohama City, Kanagawa Prefecture, where seismographs are densely installed, with the aim of accurately predicting ground information such as AVS30 (average S-wave velocity from the ground surface to a depth of 30 m) and S-wave transfer function from earthquake records. The model using XGBoost showed good accuracy in predicting AVS30 with RMSE=0.71 and $R^2=0.56$, and was able to predict highly valid values even for unknown data. In the prediction of the S-wave transfer function, AVS30 was added as an explanatory variable to improve the accuracy, and the model using the Random Forest showed the best accuracy and a certain degree of repeatability for the original transfer function.