スマートフォンで計測した自動車の 上下加速度を用いた舗装路面凹凸の評価

河井大地¹・丸山喜久²・永田茂³

¹学生会員 千葉大学大学院工学研究科 建築・都市科学専攻 (〒263-8522 千葉県千葉市稲毛区弥生町1-33)

E-mail : acya2137@chiba-u.jp

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

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

³正会員 鹿島建設株式会社技術研究所 都市防災・風環境グループ (〒182-0036 東京都調布市飛田給2-19-1)

E-mail : nagata-shigeru@kajima.com

本研究では、スマートフォンで計測した自動車の上下加速度を用いて路面凹凸を評価する数理モデルを構築した。ロジスティック回帰分析とサポートベクトルマシンの2種類の機械学習手法に基づき、国際ラフネス指数 (IRI) が12 mm/m以上の区間を抽出する数理モデルを構築することを目的とした。数理モデルの構築に使用していないデータを用いて、2種類の手法による数理モデルの判定精度を評価したところ、ロジスティック回帰分析の方が良好な結果を示した。さらに、路面不良区間が誤判定される原因として、スマートフォンで加速度を取得するときの車速が影響していることが分かった。

Key Words : vertical acceleration, smartphone, International Roughness Index (IRI), logistic regression analysis, support vector machine

1. はじめに

我が国では社会基盤施設が高度経済成長期に主に整備された。このため、近年道路ストックの老朽化が懸念されており、集中的な道路ストックの修繕が今後必要になると言われている。また、2012年には笹子トンネル天井板落下事故が発生し、戦略的な維持管理や更新の必要性が高まっている。このような背景から、2013年に国土交通省は総点検実施要領(案)¹⁾をとりまとめ、橋梁やトンネル、舗装等の道路ストックごとに、安全で円滑な交通の確保のための維持管理の効率化を目指した点検要領を示している。

舗装路面の点検は、道路管理者の予算制約や技術者不足が原因となって、思うように進まないこともある²⁾。幹線道路では、路面性状測定車^{3) 4)}による高精度な点検が行われ、合理的な維持管理が図られている⁵⁾。しかし、路面性状測定車は、初期費用や運用費が高額であるため、簡易な路面のモニタリングシステムの検討も行われている^{6) 7)}。また、住民に最も身近な生活道路では、目視点検^{8) 9)}が実施されているものの、客観的データに基づく路面性状評価は困難である。

そこで本研究では、生活道路でも客観的データに基づ

く路面性状評価が行えるようになることを目指し、スマートフォンで計測した自動車の上下加速度を用いた舗装路面の凹凸評価に関する検討を行う。鹿島道路(株)の多機能路面測定車¹²⁾とスマートフォンを車載した自動車を併走させ、高精度な路面性状データと自動車の上下加速度を同時に計測した。計測結果を用いて、機械学習手法であるロジスティック回帰分析¹³⁾とサポートベクトルマシン¹⁴⁾に基づき、路面凹凸が不良である区間を抽出する数理モデルを構築した。

2. 本研究で使ったデータ

(1) 計測した路面性状データ

本研究では、2015年9月29日、10月9日にそれぞれ神奈川県横浜市と東京都調布市において実走調査を行った。鹿島道路(株)の多機能路面測定車¹²⁾によって、国際ラフネス指数 (IRI) を10 mおよび100 m間隔でそれぞれ計測した。

IRI は、車両下部に取り付けたレーザー変位計によって測定した路面の縦断プロファイルを用いて算出した。鹿島道路(株)の多機能路面測定車¹²⁾は、一般財団法人

図-1 クォーターカーモデル

(a) 神奈川県横浜市

(b) 東京都調布市

図-2 計測した国際ラフネス指数 (IRI) の例

土木研究センターの実施する性能確認試験¹⁵⁾を受けている。性能確認試験では、路面性状の3要素（わだち、ひび割れ、平たん性）の測定性能の評価に加えて、IRIの測定性能評価も補助的に行われており、水準測量で得られたIRIと比較されている。本研究で用いた鹿島道路（株）の多機能路面測定車¹²⁾は、IRIの誤差が ± 0.5 mm/mであることが確認されている。さらに、鹿島道路（株）の多機能路面測定車¹²⁾は、IRIの共通試験¹⁶⁾に参加し測定値の反復性、再現性を評価している。非接触型のプロファイル測定装置を用いて算出されるIRIは、IRIが大きくなるほどバラツキが大きくなる傾向があるが、ほぼすべての測定値は真値の+30%以内に収まっている¹⁶⁾。また、調査時の車両速度を20~40 km/h または 40~60 km/h とした場合、IRIの測定結果に車両速度が大きな影響を与えることはなかった。

縦断プロファイルからIRIを算出するには、図-1に示すようなクォーターカーモデルを仮定し、一定の速度で

図-3 計測したIRIの損傷レベルごとのデータ数

路面上を走行させたときの車が受ける上下方向の変位の累積値 (mm) と走行距離 (m) との比を算出する (式 (1))¹⁷⁾。なお、クォーターカーモデルの m_s は車体の質量 (ばね上質量)、 m_u は車輪質量 (ばね下質量) である。 k_s と c_s はサスペンションのばね係数およびダンピングを表し、 k_t はタイヤのばね係数である。

$$IRI = \left\{ \int_0^{L/V} |\dot{z}_s - \dot{z}_u| dt \right\} / L \quad (1)$$

ここで、 z_s はばね上質量の高さ (mm)、 z_u はばね下質量の高さ (mm)、 L は区間長 (m)、 V は走行速度 (80 km/h)、 t は時間 (s) を表す。IRIを算出するには、縦断プロファイル (路面凹凸量) z_{in} に対する車両のばね上、ばね下質量の応答 z_s 、 z_u を推定する必要がある、このときのパラメータは $c_s/m_s = 6.0$ 、 $k_t/m_s = 653$ 、

$k_s/m_s = 63.3$ 、 $m_u/m_s = 0.15$ と定められている¹⁸⁾。

IRIは値が大きいほど路面状況が悪いことを示す指標で、総点検実施要領(案)の参考資料¹⁹⁾では、IRIが8 mm/m程度以上で損傷レベル大、特にIRIが11~12 mm/mでは、古い舗装の場合で劣化が進行し明確な損傷が連続的に発生している状態としている。IRIは、全く維持されていない未舗装路面から滑走路のラフネスまで同一尺度で表現できる¹⁹⁾特徴を持っており、道路の平たん性の季節変動の評価²⁰⁾、農道における土砂系舗装の平たん性評価²¹⁾、ドライビングシミュレータを用いた乗り心地の評価²²⁾など幅広く用いられている。図-2(a)に神奈川県横浜市、図-2(b)に東京都調布市で計測したIRI (10 m間隔)、図-3に損傷レベル¹⁹⁾ごとのIRIのデータ数を示す。なお、本研究で使用したデータの道路延長は35.81 km (県道14.98 km, 市道20.83 km) である。また、IRI計測時の多機能路面測定車の速度は平均27.8 km/h、標準偏差9.0 km/hである。

図-4 調査車両内でのスマートフォンの設置状況

図-5 スマートフォンで記録された上下方向加速度の例

図-6 振動台の加速度とスマートフォンで記録された加速度の比較

図-7 振動台とスマートフォンの加速度記録のフーリエスペクトルの比較

(2) スマートフォンで計測した上下加速度データ

鹿島道路(株)の多機能路面測定車を、別の自動車(マツダ・デミオ)で併走し、その車中でスマートフォン(アップル・iPhone 5)に内蔵されている加速度セン

サを用いて上下加速度を計測した。スマートフォンは、図-4のように運転席側と助手席側の2カ所に設置した。運転席側のスマートフォンはホルダーで固定し、助手席側はアームレスト上にテープ等で固定した。スマートフォンの加速度は、CoreMotionのCMDeviceMotionクラスのインスタンスプロパティであるuserAcceleration²⁹⁾から取得し、フィルタリング等の処理は行っていない。

サンプリング周波数を100 Hzとし、スマートフォンで水平2成分、上下1成分の加速度を計測した。さらに、スマートフォン内蔵のGPSを用いて、車両の位置を同時に記録した。路面凹凸と相関が最も高いのは上下方向の加速度と想像される。例えば、八木²⁴⁾は自動車のダッシュボード上に固定したスマートフォンで計測した上下加速度を用いてばね下の上下変位量を推定し、その結果を路面プロファイラの計測結果(延長280 m)と比較し、精度を検証している。本研究では、多数の計測値に基づく堅牢な数理モデルを構築することを目指し、道路延長35.81 kmに渡って10 m間隔でIRIを計測した。さらに、IRIを教師データとした機械学習手法の適用を意図して、ロジスティック回帰分析とサポートベクトルマシンに基づき、上下方向の加速度に着目した分析を行うこととした。図-5にスマートフォンで記録された上下方向加速度の例を示す。

スマートフォンによる加速度の計測精度を検討することを目的とし、1方向加震できる振動台(IMV(株)製、衝撃波形振動制御システムF3/SHOCK)を用いた加震実験を行った。本実験では、東北地方太平洋沖地震時の幕張メッセにおける120 s間の地震動を振動台の入力地震動として用いた。実走調査で使用したスマートフォンを振動台上に設置して加速度を計測し、振動台による再現加速度と比較した。図-6に振動台の加速度とスマートフォンで記録された加速度を比較する。また、図-7にそれらの加速度のフーリエスペクトルを示す。振動台の加速度とスマートフォンで記録された加速度波形は、ある程度一致している。0~0.5 Hzの周波数領域において、スマートフォンは振動台の加速度を正確に計測できていないが、0.5 Hz以上の周波数領域の加速度の計測精度は高い。例えば、自動車が50 km/hで走行する場合、IRIが敏感な波数帯(1.25~30 m/cycle)における周波数領域は0.46~11.11 Hzとなる。これらの結果から、スマートフォンで計測された加速度の信頼性はある程度高いものと考えられる。

3. 路面不良判定モデル

(1) ロジスティック回帰分析による路面不良判定モデルの構築

表-1 路面不良判定モデル検証のための混同行列

		予測	
		Positive 路面不良	Negative 不良でない
計測	True IRI ≥ 12 mm/m	True positive (TP) 路面不良 の的中数	False negative (FN) 路面不良 のはずれ数
	False IRI < 12 mm/m	False positive (FP) 不良でない区間 のはずれ数	True negative (TN) 不良でない区間 の的中数

図-8 学習データ 80%で構築したロジットモデルの ROC 曲線

スマートフォンで計測した自動車のばね上加速度（上下成分）を用いて、路面不良区間を抽出する数理モデルを構築する。スマートフォンのGPSの緯度、経度と加速度時刻歴を関連付け、最も近傍の10 m間隔のIRIと比較した。本研究では10 m間隔のIRIが12 mm/m以上である区間を路面不良と定義した。2章で説明したデータセットからランダムに選んだ学習データをモデルの構築に用い、残りのデータをテストデータとしてモデルの精度評価に用いる。なお、学習データ数の割合は、全データの20～100%まで20%刻みで変化させた。

本研究では、式(2)を仮定したロジスティック回帰分析を行う。

$$p = 1/[1 + \exp\{-(b_0 + b_1x_1 + b_2x_2 + b_3x_3)\}] \quad (2)$$

ここで、 x_1 は10 m区間の平均速度（m/s）、 x_2 は10 m区間の平均加速度振幅（m/s²）、 x_3 は10 m区間の最大加速度振幅（m/s²）を表す説明変数である。なお、平均加速度、最大加速度は、助手席側に設置したスマートフォンの加速度振幅の絶対値を用いて算出し、停車時のデータは除いている。加速度データは、また、 b_0 は定数、 b_1 、 b_2 、 b_3 は偏回帰係数である。最適なロジットモデルを構築するために、AIC（赤池情報量基準）が最小になるように説明変数を選択した¹³⁾。式(2)の p はIRIが12 mm/m以上になる確率を表し、確率変数を Y （IRIが12 mm/m以上：1、12 mm/m未満：0）とすると式(3)、(4)のようになる。

$$p = \Pr(Y = 1|x_1, x_2, x_3) \quad (3)$$

$$1 - p = \Pr(Y = 0|x_1, x_2, x_3) \quad (4)$$

実走調査で測定したIRI（10 m間隔）のうち、12 mm/m以上のデータ数（139）と、12 mm/m未満のデータ数（3442）の比は約1：25と偏りがある。そこで、データの重みを考慮しないロジスティック回帰分析と、IRIが12 mm/m以上のデータに25倍および50倍の重みを加えたロジスティック回帰分析の3通りでモデルを構築した。

(2) ロジスティック回帰分析による路面不良判定モデルの検証

式(2)の関数形を仮定したロジットモデルをROC曲線¹³⁾を用いて検証する。IRIが12 mm/m以上の区間を正しく判別する率を敏感度 TPR （True positive rate）、IRIが12 mm/m未満の区間を正しく判別する率を特異度 TNR （True negative rate）、12 mm/m未満と12 mm/m以上の区間を正しく判別する率を有効度 ER （Efficacy rate）と定義する。敏感度および特異度、有効度は、表-1の混同行列に基づき式(5)、(6)、(7)のようになる。

$$TPR = TP/(TP + FN) \quad (5)$$

$$TNR = TN/(TN + FP) \quad (6)$$

$$ER = (TP + TN)/(TP + FN + FP + TN) \quad (7)$$

式(2)の p の値を適宜変化させ、学習データの TPR および TNR をその都度算出する。そして、横軸を $1-TNR$ 、縦軸を TPR として図化したものがROC曲線である。一般にモデルが有効である場合、ROC曲線は FPR と TPR との比が1:1である直線から左上に離れ、判別能力が高いほど、ROC曲線はグラフの左上隅に近づく²⁵⁾。ROC曲線下の面積はAUC（Area under the curve）と呼ばれ、最大値は1、ランダムな判別では0.5となり、ROC曲線下の面積が大きいほどモデルの精度が良い（優：0.9～1.0、良：0.8～0.9、可：0.7～0.8）²⁶⁾。

図-8に学習データの割合を80%として構築したロジットモデルのROC曲線を示す。これを用いて、IRIが12 mm/m以上の路面不良区間を抽出するための最適なカットオフ値を定める。 TPR と TNR がともに最大となるカットオフ値は、ROC曲線のグラフの左上隅に最も近い点に対応する。ここでは、学習データの割合ごとにカットオフ値を評価した。

表-2、表-3に構築したロジットモデルの回帰定数、カットオフ値、モデルの精度を示す。モデルの精度は、学習データの TPR 、 TNR と ER で評価する。テストデータに対する精度は後述する。重みを考慮せずに構築したロジットモデルは、IRIが12 mm/m以上のデータ数が少ないため、データの重みを考慮したロジットモデルよりも精度が悪くなるものと予想したが、 TPR および TNR の値はほ

表-2 ロジットモデルの回帰定数と判定結果の精度
(重みなし)

学習データの割合	b_0	b_1	b_2	b_3
20%	-1.777	-0.463	—	0.761
40%	-2.681	-0.462	5.406	—
60%	-1.792	-0.550	4.753	—
80%	-1.908	-0.510	3.357	0.310
100%	-2.043	-0.507	3.630	0.278
学習データの割合	AUC	カットオフ値	TPR/TNR	ER
20%	0.81	0.053	0.75/0.84	0.84
40%	0.83	0.034	0.83/0.70	0.70
60%	0.82	0.028	0.83/0.67	0.67
80%	0.82	0.048	0.75/0.76	0.76
100%	0.82	0.045	0.76/0.76	0.76

ば同程度の値を示した。重みを考慮せずに構築したロジットモデルは、IRIが12 mm/m未満のデータ数が多いため、 TNP と ER の値は同じ値を示した。本研究で構築したすべてのロジットモデルでAUCは0.8以上となり、判別能力は良となった²⁹⁾。

(3) サポートベクトルマシン (SVM) の概要

次に、別の機械学習手法であるサポートベクトルマシン (Support Vector Machine : SVM) に関して検討を行う。SVMは1960年代に提案されたパターン分類手法²⁷⁾で、現在、最も優れたパターン分類手法の一つとして注目されている手法である。一般に2クラス分類では、線形分離可能な問題は少なく、線形分離不可能な問題の方がはるかに多い。SVMでは、あるパターン分類問題が線形分離不可能な場合、非線形写像によって特徴空間と呼ばれる高次元空間にマッピングする。これによって線形分離可能な状態となり、最適な分離超平面を求めることができる²⁸⁾。

n 個の訓練集合 $\{(\mathbf{x}_i, y_i)\}_{i \in [n]}$ が d 次元実数ベクトル

$\mathbf{x}_i \in R^d$ と、1か-1の値をとるラベル $y_i \in \{-1, 1\}$ から構成されているとする。本研究では、非線形写像のためのカーネル関数にRBF (radial basis function) カーネルを用いる (式(8))。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (8)$$

表-3 ロジットモデルの回帰定数と判定結果の精度
(重み 25 倍)

学習データの割合	b_0	b_1	b_2	b_3
20%	0.936	-0.482	4.405	—
40%	-0.0385	-0.539	6.900	0.194
60%	1.314	-0.570	5.299	—
80%	1.109	-0.531	4.350	0.236
100%	0.977	-0.533	4.662	0.211
学習データの割合	AUC	カットオフ値	TPR/TNR	ER
20%	0.81	0.57	0.75/0.82	0.79
40%	0.83	0.47	0.80/0.71	0.75
60%	0.82	0.43	0.81/0.69	0.75
80%	0.82	0.55	0.75/0.76	0.76
100%	0.82	0.52	0.76/0.74	0.75

SVMには、訓練事例を完全に分類することを目的としたハードマージンと、ある程度の誤分類を許容するソフトマージンがある。本研究では、ソフトマージンを用いる。分離超平面からどれだけ離れているかを表す指標であるスラック変数 ζ をデータごとに導入する。 ζ はデータが正しく分類されマージン境界上または外側にある場合は0、正しく分類されているがマージン内である場合は0~1、誤分類された場合は1より大きな値をとる²⁹⁾。したがって、解くべき最適化問題は以下ようになる。

$$\begin{aligned} \min_{\mathbf{w}, b, \zeta} & \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i \in [n]} \zeta_i \\ \text{s.t. } & y_i(\mathbf{w}^T \phi(\mathbf{x}_i) + b) \geq 1 - \zeta_i, i \in [n], \zeta_i \geq 0, i \in [n] \end{aligned} \quad (9)$$

ここで、 $\mathbf{w}$ は分離超平面の法線ベクトル、 ϕ は入力ベクトル $\mathbf{x}$ を特徴空間 F へ非線形写像する関数 (式(10))、 b はスカラー変数を表す。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j) \quad (10)$$

式(8)の γ と式(9)の C は、ハイパーパラメータと呼ばれ分類結果に大きく影響する。

(4) SVMによる路面不良判定モデル

ロジスティック回帰分析と同様に学習データの割合を20%ごとに变化させて、SVMによる2クラス分類を行う。入力ベクトルを10 m区間ごとの平均速度 (m/s)、10 m区間の平均加速度振幅 (m/s²)、10 m区間の最大加速度

図-9 10 交差検証法の概要

表-4 SVM のハイパーパラメータと判定結果の精度 (重みなし)

学習データの割合	C	γ	TPR/TNR	ER
20%	2.512	7.943	0.54/1.00	0.99
40%	7.943	1.585	0.22/1.00	0.96
60%	6.310	0.631	0.11/1.00	0.97
80%	3.981	0.158	0.02/1.00	0.96
100%	1.259	5.012	0.12/1.00	0.97

表-5 SVM のハイパーパラメータと判定結果の精度 (重み 25)

学習データの割合	C	γ	TPR/TNR	ER
20%	2.512	7.943	1.00/0.98	0.98
40%	10^4	10^{-7}	0/1.00	0.96
60%	39.811	0.251	0.83/0.78	0.79
80%	1.000	2.512	0.92/0.82	0.83
100%	1.259	3.162	0.94/0.81	0.82

振幅 (m/s^2) とし, IRI が 12 mm/m 以上の区間を路面性状が不良な区間として抽出対象とする. なお, IRI が 12 mm/m 未満と 12 mm/m 以上のデータ数の比は約 25 : 1 であるが, SVM ではこのような不均衡データにクラスごとに重みを付けることができる. 本研究では, 重みなし, IRI が 12 mm/m 以上のクラスに重み 25, 50 を設定した 3通りの 2 クラス分類を行う.

SVM によって最適な路面不良判定モデルを構築するには, 誤判定の許容度を示す正則化係数 C と RBF カーネルの半径に関わる γ を設定する必要がある. 本研究では, 学習データに 10 交差検証法 (図-9) を適用することで C と γ を決定した¹⁴⁾. 10 交差検証法では, 学習データを 10 分割し, 9/10 のデータで学習を行い, 残りの 1/10 のデータで精度評価を行う. さらに, 学習と精度評価を 10 回繰り返す. C と γ は, $10^{-2} \leq C \leq 10^2$, $10^{-5} \leq \gamma \leq 10^5$ の範囲でそれぞれ 10^1 ずつ変化させ, 正答率が最も高い C と γ を

(a) 重みなし

(b) 重み 25

(c) 重み 50

図-10 テストデータに対するロジスティック回帰分析と SVM に基づく路面不良判定モデルの判定精度の比較

最適なパラメータの組とみなした. なお, 重み 25 の SVM で, 学習データの割合が 40% のとき, 最適な C と γ の値が得られなかった. そこで, パラメータの探索範囲を $10^{-4} \leq C \leq 10^4$, $10^{-7} \leq \gamma \leq 10^7$ に広げた. その結果,

探索範囲の下限値が最適な C と γ に選択されたが, 本来の最適値とは限らないことに注意が必要である.

表-4, 表-5 に SVM のハイパーパラメータと判定結果の精度を示す. TPR, TNR と ER は学習データに対するものである. 重み 25 の SVM では, 重みなしの SVM よりも TNR が低い, 学習データの割合が 40% のときを除き TPR は高い.

図-10 にロジスティック回帰分析と SVM により構築した路面不良判定モデルのテストデータに対する判定精度

(a) 西調布駅付近（東京都調布市）

(b) 柴崎駅付近（東京都調布市）

(c) 中山駅付近（神奈川県横浜市）

図-11 計測した IRI と提案モデルの判定結果の例

図-12 提案モデルによる判定結果ごとの平均车速の累積相対度数分布（IRI が 12 mm/m 以上のデータのみ）

を比較する．ロジスティック回帰分析では，IRI が 12 mm/m 以上のデータに重みを付けても判定精度に大きな違いはない．また，全データのうち 40% 以上を学習データとすれば 75% 程度の判定精度を示す．一方，重みなしの SVM は， TPR が非常に低く，未知のデータに対する判定能力がない．IRI が 12 mm/m 以上のデータに重みを設け、

学習データの割合を高めると TPR は向上するが，ロジスティック回帰分析よりも良好な結果は得られなかった．

(5) 提案する路面不良判定モデル

このような検討結果に基づき，本研究ではロジスティック回帰分析に基づく路面不良判定モデルを提案する．

図-10のように，ロジットモデルは未知のデータに対しても概ね学習データと同程度の判定精度を示す．そこで，別の計測データに対しても同程度の判定精度を与えるものとみなし，ここでは全てのデータを用いて構築した（学習データの割合：100%）ロジットモデルを路面不良判定モデルとして提案する（表-2）．

図-11に計測した IRI と提案モデルの判定結果の一部を地図上に示す（判定精度：76%）．IRI が 12 mm/m 以上の区間を，正しく路面不良と判定できなかった原因としては，スマートフォンで上下加速度を計測する際の车速の影響が考えられる．図-12は，IRI が 12 mm/m 以上の区間に関して，ロジットモデルの判定結果ごとに平均车速の累積相対度数分布を示している．路面不良を正しく判定できなかった区間で，加速度計測時の车速が速いことが分かる．このことから，スマートフォンで計測した上下加速度を用いて路面不良区間を高精度に抽出するには，望ましい走行条件があることが示唆される．

4. 結論

本研究では，スマートフォンで計測した自動車の上下加速度を用いて路面凹凸を評価する数理モデルを構築した．ロジスティック回帰分析とサポートベクトルマシンの2種類の機械学習手法を検討し，国際ラフネス指数（IRI）が 12 mm/m 以上の区間を精度良く抽出することを目的とした．

モデル構築に使用していないデータを用いて，ロジスティック回帰分析とサポートベクトルマシンの結果を比較すると，ロジスティック回帰分析の方が良好な判定精度を示した．さらに，学習に用いるデータの割合を変化させ，ロジットモデルの精度の変化を検討したところ，精度に大きな違いを与えなかったため，汎化能力が高いことが期待される．

今後は，他地域でスマートフォンを用いた上下加速度の計測を行い，その適用性を検討する．さらに，調査時の车速が，路面不良区間の誤判定に影響することがわかったため，路面不良評価に望ましい走行方法に関する検討を行う．

謝辞：本研究はJSPS 科研費 15H04023 の助成を受けたものです．

参考文献

- 1) 国土交通省道路局：総点検実施要領（案）【舗装編】（参考資料），2013.
- 2) （公社）日本道路協会：第30回日本道路会議：ワークショップと点検機材等の展示，解説，<https://www.road.or.jp/conference/data/30kaigi/douro.pdf>（2017年5月13日閲覧）
- 3) 遠山貞則，小沼浩，篠崎昌浩，兼平信蔵，大貫薫，幸田信則：路面性状測定車の開発，三菱重工技報，Vol. 34, No. 2, pp. 132-135, 1997.
- 4) （一社）日本道路建設業協会：路面性状調査システム，<http://www.dohkenkyo.net/pavement/kikai/chosa.html>（2017年5月13日閲覧）
- 5) 小田宏一，児玉英二，青木一也，貝戸清之，小林潔司：劣化ハザード率を用いた学習機能を有する舗装マネジメントシステム マネジメントシステム，土木情報利用技術論文集，Vol. 18, pp. 165-174, 2009.
- 6) 朝川皓之，長山智則，藤野陽三，西川貴文，秋本隆，和泉公比古：一般車両の走行時動的応答を利用した舗装路面の簡易状態評価システムの開発，土木学会論文集E1（舗装工学），Vol. 68, No. 1, pp. 20-31, 2012
- 7) 森石一志，中村博康，渡邊一弘：三次元点群データを用いた新たな路面評価手法の検討，土木学会論文集 E1（舗装工学），Vol. 69, No. 3, pp. I-9-I-16, 2013.
- 8) 富山和也，川村彰，大廣智則：モバイルプロフィロメータを利用した高速道路における絶対プロファイルの推定，土木学会論文集E1（舗装工学），Vol. 70, No. 3, pp. I-41-I-48, 2014.
- 9) （株）共和電業：IRI簡易測定装置 STAMPER，<http://www.kyowa-ei.com/jpn/product/special/stamper/index.html>（2017年5月13日閲覧）
- 10) 杉浦聡志，亀山修一，坪井勤，高橋敏彦，市川晴信：美濃加茂市の生活道路の舗装維持管理における目視点検の導入に向けた諸検討，土木学会論文集 E1（舗装工学），Vol. 70, No. 3, pp. I-25-I-31, 2014.
- 11) 亀山修一，金森弘晃，井上昌幸，浅田拓海，川端伸一郎：舗装路面の目視点検の精度に関する研究，土木学会論文集E1（舗装工学），Vol. 71, No. 3, pp. I-25-I-30, 2015.
- 12) 鹿島道路（株）：多機能路面測定車，<http://www.kajimaro.co.jp/technology/detail.php?pcat=1&cat=17&seq=91>（2017年5月13日閲覧）
- 13) 青木繁信：Rによる統計解析，オーム社，2009.
- 14) 竹内一郎，鳥山昌幸：サポートベクトルマシン，講談社，2015.
- 15) 倉持智明，安藤和彦：路面性状自動測定装置の性能確認試験，舗装，Vol. 48, No. 8, pp. 3-6, 2013.
- 16) 富山和也，中村博康，増戸洋幸，坂本政一，渡邊一弘：共通試験結果に基づく路面プロファイラの有効性とその検証方法，土木学会論文集E1（舗装工学），Vol. 71, No. 3, pp. I-9-I-16, 2015.
- 17) 池田拓哉，東嶋奈緒子：国際ラフネス指数の計測方法に関する研究，土木学会舗装工学論文集，第3巻，pp. 9-14, 1998.
- 18) Sayers M. W.: Two quarter-car models for defining road roughness: IRI and HRI, Transportation Research Record, No. 1215, pp. 165-172, 1989.
- 19) 笠原篤：舗装マネジメントシステム，土木学会論文集，No. 478/V-21, pp. 1-12, 1993.
- 20) 亀山修一，川端伸一郎，豊田邦男，川村彰，笠原篤：寒冷地の高速道路における平坦性の季節変動に関する研究，土木学会論文集，No. 742/VI-60, pp. 51-60, 2003.
- 21) 坂本康文，篠塚政則，鎌田修，緒方英彦：ほ場内農道における土砂系舗装の供用性に関する研究，農業農村工学会論文集，No. 278, pp. 121-128, 2012.
- 22) 石田樹，岳本秀人，川村彰，白川龍生：ドライビングシミュレータによる舗装路面の乗心地・安心感評価，舗装工学論文集，土木学会，Vol. 9, pp. 49-56, 2004.
- 23) Apple Inc.: userAcceleration, <https://developer.apple.com/documentation/coremotion/cmdevice/cmdevice/1616149-useracceleration>
- 24) 八木浩一：自動車のばね上観測加速度からの路面縦断プロファイルの推定とその精度検証，土木学会論文集E1（舗装工学），Vol. 69, No. 3, pp. I-1-I-7, 2013.
- 25) Hanley, J.A. and McNeil, B.C.: The meaning and use of the area under a receiver operating characteristic (ROC) curve, Radiology, Vol. 143, No. 1, pp. 29-36, 1982.
- 26) ハスバートル，丸山清輝，野呂智之，中村明：ロジスティック回帰分析を用いた既存地すべり地形の地震時の危険度評価，日本地すべり学会誌，Vol. 49, No. 1, pp. 12-21, 2012.
- 27) Cortes, C. and Vapnik, V.: Support vector networks, Machine Learning, Vol. 20, pp. 273-297, 1995.
- 28) 大石博之，小林央宜，尹禮分，田中浩一，中山弘隆，古川浩平：サポートベクターマシンによる対策工効果を考慮した斜面災害危険度の設定，土木学会論文集F，Vol. 63, No. 1, 107-118, 2007. 3
- 29) 平井有三：はじめてのパターン認識，森北出版，2012.

EVALUATION OF PAVEMENT SURFACE IRREGULARITY USING VERTICAL ACCELERATIONS RECORDED BY A SMARTPHONE

Daichi KAWAI, Yoshihisa MARUYAMA and Shigeru NAGATA

This study developed numerical models to evaluate road surface irregularity using vertical accelerations of a vehicle recorded by a smartphone. The purpose of this study is to detect road sections with an international roughness index (IRI) of 12 mm/m or above. To achieve the objective, the authors considered two kinds of machine learning methods: logistic regression analysis and support vector machine. The discrimination ability of road surface irregularity was evaluated, and the logistic regression model showed a better result.