

プローブデータの車両挙動を活用した 冬期の路面すべり摩擦係数の推定

奥村 航太¹・齊田 光²・大廣 智則³・伊東 靖彦⁴

¹正会員 (国研)土木研究所寒地土木研究所 (〒062-8602 札幌市豊平区平岸 1 条 3 丁目 1-34)
E-mail: okumura-k@ceri.go.jp (Corresponding Author)

²正会員 (国研)土木研究所寒地土木研究所 (〒062-8602 札幌市豊平区平岸 1 条 3 丁目 1-34)
E-mail: saida-a@ceri.go.jp

³正会員 (国研)土木研究所寒地土木研究所 (〒062-8602 札幌市豊平区平岸 1 条 3 丁目 1-34)
E-mail: oohiro-t@ceri.go.jp

⁴正会員 (国研)土木研究所寒地土木研究所 (〒062-8602 札幌市豊平区平岸 1 条 3 丁目 1-34)
E-mail: yasu-ito@ceri.go.jp

冬期における道路維持管理の出動計画には路面状態の把握が必要であるが、路面状態を網羅的に捉えることは容易ではない。一般車両のプローブデータから路面状態の推定が可能となれば、冬期の道路維持管理に有益な情報となる。そこで本研究では走行調査から得た車両の加速度、車輪速度等に関するプローブデータを用いて、すべり摩擦係数を基準に路面状態を推定するモデルを構築した。さらに路面状態の推定に用いた各説明変数における寄与度を定量的に示した。結果として路面温度だけではなく車両挙動を示すプローブデータから得られた数値の分散等が路面のすべり摩擦係数を推定するために有効である可能性がわかった。

Key Words: Road management in winter, Probe data, Vehicle behavior, Machine learning

1. はじめに

(1) 背景

冬期の道路維持管理作業には凍結路面の発生を抑制する凍結防止剤の散布がある。この作業を適切なタイミングで行うためには路面状態を把握することが重要である。しかし刻一刻と変化する冬期の路面状況を網羅的に把握することは容易ではない。一方、近年の車両には位置や速度などの情報が収集できるシステムが搭載されるようになっており、これら一般交通のプローブデータを冬期の道路維持管理に活用することが可能であれば、その課題解決の一策となり得ると考えられる。さらに近年、発展の著しい機械学習手法は大量のデータから高い推定結果を算出することが可能になっている。これにより機械学習手法を用いることで効率的に路面状況を把握することができると考えられる。

(2) 既往研究

プローブデータから路面状態を推定する既往研究を以下にまとめる。

瀬尾ら¹⁾は ETC2.0 プローブデータを活用して凍結路面を客観的に管理できる可能性を示唆した。これにより雪氷路面の把握は維持管理をより効率的にすることが期待されている。しかし ETC2.0 プローブデータはリアルタイムに取得できない等の課題がある。

大廣ら²⁾はタイヤ内部に加速度センサを取り付け、100 m 毎に路面判別を行う技術開発を行った。そこで路面判別結果に応じて凍結防止剤を自動散布することで凍結防止剤の削減効果が見られた。しかしタイヤ内部に設置する装置は高価なものであることから高速道路会社の管理車両への普及に留まっている。

佐々木ら³⁾は積雪寒冷地においてスリップ時のプローブデータを基にスリップ発生地点の検知を行うため、GPS 速度、各車輪速度の差分、ハンドル操舵角からスリップ地点を検出できることを明らかにした。

齊田ら⁴⁾は路面のすべり抵抗値を計測し、それと車載カメラの映像の突き合わせを行い、画像認識技術を用いた路面のすべり抵抗値の推定モデルを構築した。しかし新雪に覆われた路面表層部の推定精度が低下する等の課題がある。

これらの研究のように、プローブデータから冬期における路面状態の推定やスリップ箇所の検出を行った既往研究が存在する。しかしデータの取得時期や費用、特定条件での精度あるいは大量のデータ処理に有利な機械学習が取り入れられていないなどの課題がある。

(3) 目的

本研究では一般道において走行調査を行い、プローブデータと路面状態別の車両挙動の関係性を示す。またプローブデータを説明変数、すべり摩擦係数を基準とした路面状態データを目的変数とした機械学習モデルを構築した。この機械学習モデルにより、プローブデータから路面状態を推定する手法を提案する。

2. 調査方法

(1) 調査日程と路線及び車両

走行調査は 2022/2/7 から 2022/2/24 の間において 12 回行った。走行した路線は図-1 に示す主に 2 つの調査経路である。調査路線 A は札幌市内の環状通から二十四軒手稲通に至る走行経路であり、調査路線 B は路線 A から途中で分岐し国道 5 号線から小樽市内に至る走行経路である。

本研究では路面のすべり摩擦係数を計測する車両（以下、計測車両、図-2）とプローブデータを取得する車両（以下、調査車両）を用いた。また調査車両は一般的な SUV であり、その諸元を表-1 に示す。

(2) 路面のすべり摩擦係数の取得方法

計測車両を用いて取得したデータの一例を表-2 に示す。計測車両は連続路面すべり抵抗測定装置を牽引しており、この装置で路面のすべり摩擦抵抗力を取得した。連続路面すべり抵抗測定装置は図-2 のように車輪が進行方向に対して「ハ」の字状になっている。この進行方向に対する傾きを表すトー角は約 1~2° である。連続路面すべり抵抗測定装置は計測車輪のグリップ力によって変化する横力を計測できるものである。その横力が小さい場合の多くは凍結や圧雪等の雪氷路面に分類される。計測車輪軸にかかる横力の単位は HFN (Halliday Friction Number) として定義される。HFN は計測機器独自の指標であるため路面のすべり摩擦係数 μ に変換を行う必要がある。そこで路面すべり摩擦係数計測車(図-3)に計測車両(図-2)が追走し、 μ と HFN の関係式(図-4)を取得した。その結果から HFN を路面のすべり摩擦係数 μ に換算した。

また計測車両にはヴァイサラ社の Surface Patrol[®] を取り付けた。この舗装温度センサーから、外気温と路面温度を取得した。路面のすべり摩擦係数と温度に関するデータはサンプリング周波数 10Hz の記録した。

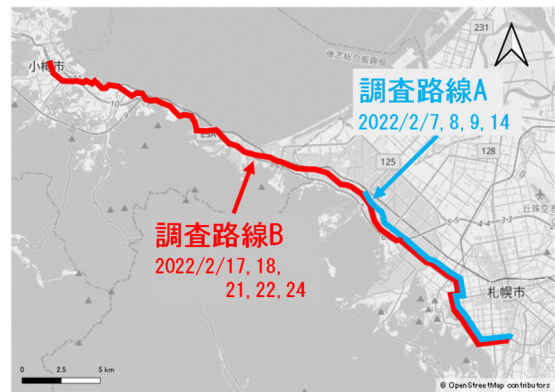


図-1 調査経路




図-2 計測車両と連続路面すべり抵抗値測定の概要

表-1 調査車両の諸元

全長×全幅	駆動方式
4610×1795 mm	フルタイム AWD
最低地上高	横滑り防止装置
220 mm	あり
タイヤ幅	トランスミッション
225 mm	CVT
ホイールベース	デフロック
2640 mm	なし
トレッド[前後]	ホイールサイズ
1545/1555 mm	17インチ

表-2 計測車両の取得データ

取得データ	単位	サンプリング周波数
すべり摩擦抵抗力	HFN	10Hz
車速パルス	km/h	
路面温度	℃	
気温	℃	
GNSS 緯度経度	—	
時刻	—	



図-3 路面すべり摩擦係数計測装置

(3) 車両挙動に関するプローブデータの取得方法

図5に示すようにプローブデータを取得する調査車両は計測車両を先頭にして追走した。調査車両のプローブデータは車両用故障診断機を用いて取得した。車両用故障診断機とは自動車に搭載されているコンピューターにアクセスし、各種センサの状態を調べることが可能な装置である。取得可能なデータは診断機や自動車の種類によって異なり、今回取得したデータは表3に示す通りである。今回のデータサンプリング周波数は約 2.3 Hz である。

さらに調査車両にスマートフォンを搭載して、そのGNSS 受信機能を利用し車両用故障診断機のデータとスマートフォンの GNSS データを時刻で結合した。またGNSS のサンプリング周波数は 1 Hz のため、1 秒毎のデータ間を按分するように線形補完にて 10 Hz の位置情報データを作成した上で、約 2.3 Hz の走行挙動データに時刻が近い位置情報を付与した。

(4) 計測車両と調査車両によるプローブデータの結合

次に2(2)で示した計測車両で取得したデータと2(3)で示した調査車両で取得したプローブデータの結合を行った。双方のデータにおける位置座標間の直線距離（以下「直線距離」とする。）が最も小さくなるデータ同士を結合した。ただし結合の条件は双方のデータの観測時刻の差が 25 秒以内であり、直線距離が 15 m 以内である場合とした。これは GNSS の計測誤差を加味し計測車両と調査車両の間において時空間的に乖離がある場合をデータ分析の対象外とするためである。

3. データの取得とデータセットの構築

(1) 走行調査毎のすべり摩擦係数の集計

調査によるデータの取得状況について、調査日と路面温度、路面のすべり摩擦係数のサンプル数を表4に示す。すべり摩擦係数のデータは $\mu < 0.3$, $0.3 \leq \mu < 0.7$, $0.7 \leq \mu$ の3つにクラス分けを行った。一般的に圧雪や凍結路面はすべり摩擦係数が $\mu < 0.3$ 程度となることが知られている⁹⁾。また本研究におけるデータセット内のすべり摩擦係数と乾燥路面を比較した結果、湿潤や乾燥路面の約8割が $\mu \leq 0.7$ に該当した。また全ての走行調査においてABS(アンチロック・ブレーキ・システム, Antilock Braking System)やTCS(トラクションコントロールシステム, Traction Control System)の作動は見られなかった。

(2) プローブデータによる新たな特徴量の算出

プローブデータから得られた指標を基に、新たな指標として、 V_{1diff} : 前方車輪速度差[km/h], V_{1per} : 前方車




図4 HFN とすべり摩擦係数の関係

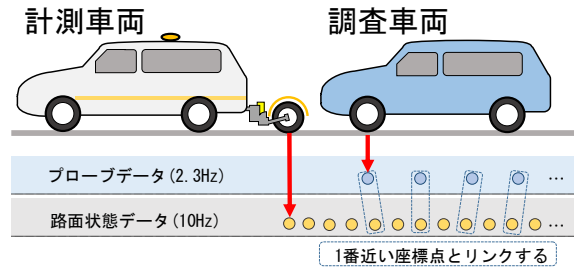


図5 データの照合

表3 調査車両のプローブデータ

取得装置	取得データ	単位	サンプリング周波数
車両診断ツール	右前車輪速度	km/h	2.3 Hz
	右後車輪速度	km/h	
	左前車輪速度	km/h	
	左後車輪速度	km/h	
	前後加速度	m/s ²	
	左右加速度	m/s ²	
	ヨーレート	degree/s	
	時刻	—	
スマートフォン	GNSS 位置座標	—	1 Hz
	GNSS 速度	km/h	
	方位角	degree	
	時刻	—	

表4 走行調査のデータ取得状況

計測番号	路線	日付	路面温度	すべり摩擦係数[μ]		
				-0.3	0.3-0.7	0.7-
1	A	2/7	0.2	2,005	1,272	858
2			-3.6	2,111	2,516	923
3		2/8	1.0	379	1,246	3,858
4			-2.3	641	3,039	1,586
5	2/9	-0.3	-0.3	1,457	2,046	2,481
6			-1.6	312	1,585	3,586
7			2/14	-1.2	304	1,219
8	B	2/17	-1.1	3,960	3,651	3,516
9		2/18	2.6	1,173	1,202	6,621
10		2/21	-1.2	12,627	908	61
11		2/22	-2.1	10,822	922	65
12		2/24	-1.7	1,049	2,206	3,584

※路面温度は平均値である。

輪速度割合[-], V_{2diff} : 前後車輪速度差[km/h], V_{2per} : 前後車輪速度割合[-], S : スリップ率[-]を算出した. それらの算出式を下記に示す. ただし, スリップ率の算出式に関しては制動時の車輪のロックと駆動時の車輪の空転を考慮するため鈴木らの研究⁷⁾を参考にした.

$$V_{1diff} = V_{fr} - V_{fl} \quad (1)$$

$$V_{1per} = \begin{cases} \frac{V_{fr} - V_{fl}}{V_{fr} + V_{fl}}, & V_{fl} \neq V_{fr} \neq 0 \\ 0, & V_{fl} = V_{fr} = 0 \end{cases} \quad (2)$$

$$V_{2diff} = \frac{(V_{fr} + V_{fl}) - (V_{rr} + V_{rl})}{2} \quad (3)$$

$$V_{2per} = \begin{cases} \frac{(V_{fr} + V_{fl}) - (V_{rr} + V_{rl})}{V_{ave}}, & V_{ave} \neq 0 \\ 0, & V_{ave} = 0 \end{cases} \quad (4)$$

$$S = \begin{cases} \frac{V_{ave} - V_g}{V_{ave}}, & V_{ave} > V_g \\ \frac{V_g - V_{ave}}{V_g}, & V_g > V_{ave} \\ 0, & V_g = V_{ave} \end{cases} \quad (5)$$

ただし,

- V_{fr} : 前方右車輪速度[km/h]
- V_{fl} : 前方左車輪速度[km/h]
- V_{rr} : 後方右車輪速度[km/h]
- V_{rl} : 後方左車輪速度[km/h]
- V_{ave} : 四輪平均車輪速度[km/h]
- V_g : GNSS 車速[km/h] とする.

(3) データセットの構築

a) 各変数における前処理

表-5は本研究におけるデータセットを示す. 目的変数は調査車両で観測したすべり摩擦係数をそれぞれの閾値で分類した質的変数とした. 一方, 説明変数は2つに分類できる. 1つ目は計測車両より取得した観測地点における気温と路面温度である. 2つ目は各観測時刻 t から6秒前までに観測された各車両挙動の平均や分散などの統計的な指標である. 説明変数として6秒間に設定した理由は60km/hで走行する車両が100m分の走行挙動を取得することが可能であることを参考にした. 車両挙動のサンプリング周波数である約2.3Hzに6秒を乗算し14地点分の車両挙動の統計的な指標で数値化した. これは直近の大まかな車両挙動を表すために算出した.

b) データセットの分割

データセットは89,133行になった. 一般的に教師ありの機械学習モデルの構築は学習データと検証データに分割する. 学習データとはモデルの構築のみに活用するデータ群であり, 検証データはそのモデルの精度を確認す

表-5 データセット変数構成

目的変数	
すべり摩擦係数	$\mu < 0.3, 0.3 \leq \mu < 0.7, \mu \leq 0.7$
説明変数	
路面温度	
気温	
前方車輪速度差: V_{1diff}	直近6秒間における ・平均値(Ave) ・分散(Std) ・最小値(Min) ・最大値(Max) ・総和(Sum) ・絶対和(Abs)
前方車輪速度割合: V_{1per}	
前後軸車輪速度差: V_{2diff}	
前後軸車輪速度差割合: V_{2per}	
スリップ率: S	
左右加速度	
前後加速度	
ヨーレート	

るために活用する. 本研究では以下に示す2つの方法でデータセットを学習データと検証データに分割し推定モデルの精度検証を行った.

1つ目は調査回数の全12回のうち調査番号1から8, 11, 12を学習データ, 調査番号9, 10を検証データとして機械学習モデルの学習と精度検証を行った. この分割は観測されたすべり摩擦係数について, 学習データ内の分布を均すように設定した. これを推定モデルA(日別分割による学習モデル)とする.

2つ目の方法では全データから学習データ数と検証データ数の比が7:3となるように無作為で分割しモデルの学習を行った. これを推定モデルB(無作為分割による学習モデル)とする. 推定モデルBでは一般的な機械学習手法による推定モデルの妥当性を確認することができる.

(4) 推定モデルの構築と評価方法

本研究では推定結果を出力する時間が短く, 単純な構造にも関わらず良好結果が得られることが知られているランダムフォレストを採用した⁸⁾. ランダムフォレストは決定木を複数活用した機械学習法であり, 各決定木による予測値と目的変数との差を減少させるように学習し決定木を追加していくものである. ランダムフォレストを用いるとランダムに説明変数を抽出し複数の決定木から出力結果を多数決や平均化することで, 分類や回帰を行うことができる. 分類の予測結果は各決定木の多数決によって予測値が定まる. またランダムフォレストは説明変数の寄与度を確認できる利点がある. 一般的に推定モデルを構築する際には説明変数が多くなるにつれ, 推定精度が過学習等によって低下する可能性がある. そのため本研究では初めに, 全50種類の説明変数について, それぞれの寄与度を確認するためにモデルを構築した. 次に全説明変数において寄与度が上位1/3に占めた15種

類の変数であるものを抽出し、最終的な推定モデルを構築した。次章以下の結果は、この説明変数を 1/3 に絞ったモデルを用いた結果である。

また本研究では推定モデルの評価指標として再現率、適合率、F 値、正解率を用いる。再現率は各路面状態のデータ数に対して推定によって正しく分類できた割合を示す。適合率は各路面状態の推定に対して実際に正しい分類である割合を示す。F 値は再現率と適合率の調和平均を示す。正解率は検証データの総数に対して正しく分類されたデータ数を割った値である。ランダムフォレストのハイパーパラメータチューニングについて最良な設定方法は明らかにされていない。モデルの構築において決定木の木数を変えて試行した結果、本研究では決定木の作成する木数を 500, 1000, 2000, 4000 本の 4 パターンとし、分割に使用する説明変数の数 N とした場合 \sqrt{N} , $\log_2 N$ の 2 パターンを総当たりで構築したモデルの推定結果から F 値が一番高いチューニング構成を採用した。その構成における推定結果と説明変数の寄与度を次章に示す。

4. 分析結果

(1) 寄与度を基準とした説明変数選択

表-6 は説明変数を選択して再構築した推定モデル B の寄与度を示す。上位 1/3 に見られた変数に着目すると、路面温度と気温は特に寄与度が高い値であった。また車両挙動による変数は前方の車輪速度による差やその割合が寄与していることがわかった。統計的な指標について、全説明変数を扱った推定モデルの構築では平均値や総和を算出した変数が含まれていた。しかし上位 1/3 の説明変数に着目すると統計的な指標では分散が多くみられた。このことから、すべり摩擦係数の推定には路面状態の物性に影響の大きい温度に関するデータに加えて、直近の車両挙動の変化について分散等で特徴を捉えることが有益である可能性が明らかとなった。

(2) プローブデータによる路面状態の推定結果

推定モデル A と B における結果を表-7 にまとめた。推定モデル A の F 値は 55.7% であり、推定モデル B は 85.2% であった。

推定モデル A は学習データと検証データの区分において、表-4 に示す調査日程を基準とした計測番号で指定した。モデル A の推定結果について、乾燥・湿潤路面が多く占める $\mu \geq 0.7$ の再現率は 95% 程度、圧雪・凍結路面が多く占める $\mu < 0.3$ の適合率は 90% 程度となった。しかし、すべり摩擦係数 $0.3 \leq \mu < 0.7$ における分類の推定結果は他の分類結果と比較して大きく低下した。さらに実測値が $\mu < 0.3$ であるデータに対して、 $\mu \geq 0.7$ と推定

表-6 推定モデル B における寄与度

変数名	寄与度
路面温度	0.147
外気温	0.095
前方車輪速度差 V_{1diff} (Std)	0.076
前方車輪速度割合 V_{1per} (Std)	0.067
前方車輪速度割合 V_{1per} (Max)	0.061
前後車輪速割合 V_{2per} (Max)	0.059
前後車輪速割合 V_{2per} (Std)	0.056
スリップ率 S (Abs)	0.056
左右加速度(Std)	0.056
ヨーレート(Std)	0.056
スリップ率 S (Max)	0.056
前方車輪速度割合 V_{1per} (Min)	0.055
スリップ率 S (Std)	0.055
前後加速度(Std)	0.053
ヨーレート(Abs)	0.053

表-7 すべり摩擦係数の分類における推定結果
推定モデル A (日別分割による学習モデル)

推定値 実測値	-0.3	0.3-0.7	0.7-	合計	再現率
-0.3	9,749	1,765	2,286	13,800	0.706
0.3-0.7	772	215	1,123	2,110	0.102
0.7-	230	69	6,383	6,682	0.955
合計	10,751	2,049	9,792	22,592	0.588
適合率	0.907	0.105	0.652	0.555	
正解率	0.707	F 値	0.557		

推定モデル B (無作為分割による学習モデル)

推定値 実測値	-0.3	0.3-0.7	0.7-	合計	再現率
-0.3	10,374	426	214	11,014	0.942
0.3-0.7	1,179	4,456	898	6,533	0.682
0.7-	311	475	8,407	9,193	0.915
合計	11,864	5,357	9,519	26,740	0.846
適合率	0.874	0.832	0.883	0.863	
正解率	0.869	F 値	0.852		

されたデータ数の影響により、 $\mu < 0.3$ における再現率が低下することがわかった。これは路面温度や気温が低くすべり摩擦係数高いデータを増加させることで結果が改善される可能性がある。

一方、推定モデル B の推定結果として精度が高くなった理由は学習データと検証データの区分において無作為に抽出したため、観測時刻が近いデータが双方に含まれていたことが考えられる。具体的に推定結果を確認すると、すべり摩擦係数 $0.3 \leq \mu < 0.7$ の分類は再現率が低いことがわかった。よって、この範囲において、さらなるプローブデータの蓄積や車両挙動における特徴を抽出できる新たな説明変数の算出が望まれる。

以上の結果より、日別分割の推定モデル A によって異なる日時のプローブデータからすべり摩擦係数の推定を

行った場合、推定モデルBに比べて推定精度が大きく低下することが明らかになった。つまり、モデルの頑健性に改善の余地があると考えられる。

5. おわりに

本研究ではプローブデータから得られた車両挙動と気温・路面温度を説明変数にして、すべり摩擦係数を基準に分類を行った。また機械学習のランダムフォレストを用いて、プローブデータから路面状態を推定する手法を提案し、どの変数がすべり摩擦係数の分類に有益であるのかを定量的に検証した。以下に得られた結果を以下に示す。

- すべり摩擦係数の推定のため必要な説明変数を寄与度を基準に精査した。そこで路面温度の寄与度が一番大きく、その影響を相対的に示した。また車両挙動は前方の車輪速度の差やその割合について寄与度が大きい傾向にあることがわかった。さらに直近6秒間の車両挙動計測値の分散が寄与度が上位になる傾向が分かった。
- 学習データと検証データを無作為に分けて推定モデルを構築した場合、推定精度のF値は85.2%程度となった。一方で、学習データと検証データをそれぞれ異なる日時の気象、車両挙動等データから作成した推定モデルの場合は路面のすべり摩擦係数の推定精度が低下することがわかった。よって推定モデルの頑健性に改善の余地があることが明らかとなった。
- すべり摩擦係数が $0.3 \leq \mu < 0.7$ の範囲にある場合の推定精度は低くなることがわかった。よって、この範囲について、走行するプローブデータの蓄積や評価できる新たな説明変数の算出を行う必要がある。

本研究にて構築したモデルは限られた条件下で取得したプローブデータを元にした観測地点毎の学習である。

つまり車輪速度差割合等の分散が大きい値で継続している等のデータの連続性を考慮した学習ではない。したがって今後はプローブデータの連続性を考慮した分析手法で推定モデルを構築し、車輪の速度や加速度に関するデータのサンプリング周波数を高めたデータの分析を進める予定である。最終的には一般車両が走るることによって路面状態を把握できるシステムの開発を目指し、道路の維持管理に有益なデータの発信に繋げたい。

REFERENCES

- 1) 瀬尾亜希子, 船岡直樹, 金木大輔 (2021), ETC2.0 プローブデータを活用したスリップ検出手法の構築, 交通工学研究発表会論文集, 41, 199-206
- 2) 大廣智則, 萩原亨, 花塚泰史, 高倉清, 中村広美(2022), 道路管理者と協調した凍結防止剤散布の低減に資するスマート凍結防止剤散布システムの開発, 日本雪氷学会誌「雪氷」, 第82巻, 6号, pp.299-316.
- 3) 佐々木正大, 鈴木理, 浜岡秀勝 (2008), プローブデータを用いた車両スリップの検知に基づくスリップ路面情報提供システムの構築, 土木計画学研究・論文集, 25, 909-917
- 4) 齊田光, 大廣智則, 畠山乃 (2022), 深層学習を用いた冬期路面すべり摩擦係数推定技術に関する基礎的検討, 寒地土木研究所月報 第826号
- 5) ヴァイスラ Surface Patrol ディスプレイ付き舗装温度センサ DSP100, <https://www.vaisala.com/sites/default/files/documents/WCO-RDS-DSP100-Surface-Patrol-Datasheet-B210979JA.pdf> (閲覧: 2023年3月10日)
- 6) 北海道開発局: 冬期路面管理マニュアル(案), 1995年11月
- 7) 鈴木理, 濱口慎平, 浜岡秀勝 (2007), 高精度車両挙動データを用いた路面状態の推定方法, 土木計画学研究・論文集, 24, 803-811.
- 8) 波部斉 (2012), ランダムフォレスト, 研究報告コンピュータビジョンとイメージメディア(CVIM), 31号, pp. 1-8

(Received Mar 10, 2023)

(Accepted ?)

ESTIMATING THE COEFFICIENT OF FRICTION ON WINTER ROADS USING VEHICLE BEHAVIOR IN PROBE DATA

Kota OKUMURA, Akira SAIDA, Tomonori OHIRO and Yasu ITO