

統計的手法に基づいた冬期路面状態の推定、及び予測に関する研究

A Statistical Model for Estimating Road Surface Conditions in Winter

北海道大学大学院工学研究科 ○学生員 水野秀樹 (Hideki Mizuno)
北海道大学大学院工学研究科 正 員 中辻隆 (Takashi Nakatsuji)
北見工業大学土木開発工学科 正 員 白川龍生 (Tatsuo Shirakawa)
北見工業大学土木開発工学科 正 員 川村彰 (Akira Kawamura)

1. はじめに

積雪寒冷地において冬期における滑りやすい路面は交通の安全性、円滑性の大きな弊害となっており、質の高い路面管理が求められている。その一方で、除雪や凍結防止剤散布などの膨大な路面管理費の削減も同時に不可欠な問題であり、効率的かつ効果的な路面管理が社会的に要請されている。

路面管理の進んでいるフィンランドなどの北欧諸国では、路面管理の指標としてすべり摩擦係数が用いられている。すべり抵抗測定車による直接計測はコスト面で問題があるため、簡易な加速度計を車両に取り付けすべり摩擦係数の計測を行っている。しかし、計測時における急制動や、車両の走行特性の違いがすべり摩擦係数に大きく反映されるなどの問題から、リアルタイムで広範囲の路面状況を把握することは困難とされている。

近年、我が国においてすべり摩擦係数の推定・予測に関する研究がなされており、車両運動の解析的な挙動に基づくすべり摩擦係数推定モデルが考案されている。しかし、実務においての適用を考えると単純構造を有したモデルが好ましい。本研究では、摩擦係数と相関性を有する変量による統計的モデルを用いてすべり摩擦係数の推定を行い、その妥当性の検証を行う。また、推定したすべり摩擦係数の値と気象データ等を用いて、既存研究で課題となっていた数時間先のすべり摩擦係数の予測を行う。

2. 冬期路面走行試験

(1) あいの里冬期路面走行試験(2004)

a) 走行試験概要

2004年12月19～23日に図-1に示す札幌市北区あいの里の道道にて、一般車両の流れに乗りながら走行試験を行った。センサーを取り付けた試験車両が走行し、そのすぐ後ろをすべり抵抗測定車が試験車両に追従する形で車両運動データの計測と走行地点のすべり摩擦係数の測定を行った。主に交差点付近で試験車両が発進・制動をした地点のすべり摩擦係数を計測した。気象データに関しては、走行試験区間内の交差点に測定ポイントを定めて機器を設置し、30分毎に計測を行った。



図-1 市街地走行試験区間

b) 試験車両

冬期路面走行中の挙動を計測する車両として、図-2 (a) に示す車両(いすゞ Big Horn) に GPS と車両運動センサーを取り付けて走行試験を行った。走行時の路面の状況を把握するため、図-2 (b) に示すバスタイプのすべり抵抗測定車で走行地点のすべり摩擦係数を測定した。



(a) 試験車両



(b) すべり抵抗測定車

図-2 使用車両

c) 測定項目

試験車両に取り付けた車両運動センサー(SR; Safety Recorder)と GPS から測定した項目と、その測定間隔を表-1 に示す。これらのデータを実際に分析で使用する際には、計算時間を短縮させるため0.5秒毎の平均値に直して使用した。また、表-2 は、路面状態の変動と関係があると考えられる気象データや交通量などの測定項目と測定間隔を示したものである。

表-1 車両運動データ項目と測定間隔

	測定項目	測定間隔
加速度	前後加速度	0.1秒
	横加速度	
	上下加速度	
角度	ロール角度	0.1秒
	ピッチ角度	
	ヨー角度	
角速度	ロール角速度	0.1秒
	ピッチ角速度	
	ヨー角速度	
車速パルス	前輪パルス	0.1秒
	後輪パルス	
GPS	時刻	1秒
	緯度、経度	
	GPS速度	

表-2 気象データ項目と測定間隔

測定項目	測定間隔
気温	30分
路温	
全天日射量	30分累積値
放射収支量	
アルベド(反射率)	
交通量	

3. 分析方法

(1) 統計的モデル

既存研究において試験車両の寸法や重量などの車両諸元、タイヤの弾性定数や路面との接触形状など多くのパラメータを含む構造的に複雑な解析的モデルが考案されている。しかし、実務においては単純なモデル構造が望ましいことから、本研究においては、統計的モデルの導入を検討する。

相関性の高い統計的モデルを構築するために、図-3に示すように前後方向加速度に閾値(トリガー)を設定した。閾値を超えた20変数からなる車両運動データファイルを対象に主成分分析を行って情報の集約化を行った上で5～10主成分のスコア値から形成されるデータを新たな「計測データ」として遺伝的アルゴリズム(GA; Genetic Algorithm)と逆伝播法からなる多層型ニューラルネットワークモデルによる分析を行った。




図-3 統計的モデルにおけるデータの集約化

(2) 多層型ニューラルネットワークモデル

本研究では、滑り摩擦係数の推定にランダム探索型の最適化手法である遺伝的アルゴリズム(GA; Genetic Algorithm)を用いる。逆伝播法によるニューラルネットワークと組み合わせることで効率的な学習が行うことができる。本研究では、入出力層が各一層、中間層が二層からなる多層型ニューラルネットワークモデルを適用した。




図-4 多層型ニューラルネットワークモデル

4. 統計的モデルによるすべり摩擦係数の推定

車両から収集した計測データをそのまま利用すると精度が低くなってしまうため、表-3に示すように閾値(トリガー)を設定し、二段階(a, b)にデータの集約化を行った。抽出後のデータ数を表-4に示す。

トリガーを設けることにより得られた三段階のデータファイルにおいて主成分分析を行い、情報の集約化を行った。データ数の関係上、トリガーなしの場合は第10主成分まで、a の場合は第8主成分まで、b の場合は第6主成分までを入力値として設定した。これらを新たな「計測データ」と

とし、多層型ニューラルネットワークモデルによるすべり摩擦係数の推定を行った。

表-5に示す通りモデルの精度は大幅に改善され、b のケースにおいても十分な精度は得られなかった。

表-3 前後方向加速度の最大値によるデータの抽出

	a	b
加速時	0.05g以上	0.10g以上
減速時	0.10g以上	0.20g以上

表-4 データ抽出後のデータ数

データ数	none		a		b	
	加速時	減速時	加速時	減速時	加速時	減速時
往路	314	330	210	225	117	121
復路	251	341	183	234	105	124
合計	565	671	393	459	222	245

表-5 主成分分析による情報集約化後の決定係数

決定係数	加速時		減速時	
	往路	復路	往路	復路
none	0.43	0.42	0.58	0.41
a	0.44	0.45	0.60	0.47
b	0.41	0.27	0.46	0.59

5. おわりに

本研究では、既存の解析的モデルに代わり、すべり摩擦係数と相関の強い車両運動データを用いて統計的モデルを用いてすべり摩擦係数の推定・検証を行った。すべり摩擦係数に大きく反映される加速、減速時のデータを抽出し、トリガーを設定することにより計測データの集約化を行った。また、主成分分析により5～10主成分のスコア値から形成されるデータを多層型ニューラルネットワークモデルにより解析を行った。その結果、Safety Recorderで得られる車両運動データのみでは十分な精度が得られないことが明らかとなった。今後、CANデータを用いた滑り摩擦係数の推定の分析を行う必要がある。また、車両運動データだけでなく、路温・アルベドなどの気象データや交通量なども滑り摩擦係数との相関性が高いと考えられるため、モデルへの入力値として考慮していきたい。

冬期路面管理において、リアルタイムですべり摩擦係数を把握するだけでなく、数時間先のすべり摩擦係数を予測し質の高いサービスを提供していくことが望まれる。今後、推定したすべり摩擦係数と気温、交通量などの気象データを用いて数時間先のすべり摩擦係数を予測するモデルの構築を行う必要がある。

参考文献

- 1) Malmivou M.: Use of Road Surface Friction Measurements and Measurement Devices in Finland, TECHNICAL RESEAECHE CENTRE OF FINLAND, Finland, 2001
- 2) 林郁子: 車両運動データに基づいたすべり摩擦係数のオンライン予測に関する研究, 北海道大学大学院修士論文, 2006
- 3) 中辻隆: 摩擦係数に基づいた冬期路面管理に関する研究, 平成17年度調査研究報告書, 2006