

車両運動データに基づいた冬期路面状態推定のための統計的モデル*

A Statistical Model for Estimating Road Surface Conditions in Winter*

水野秀樹**・中辻隆***・白川龍生****・川村彰*****

By Hideki MIZUNO**・Takashi NAKATSUJI***・Tatsuo SHIRAKAWA****・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¹⁾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²⁾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³⁾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、車両運動データを用いて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。

*キーワード：交通管理、交通安全、交通情報、ITS

**学生員、工修、北海道大学大学院工学研究科

(北海道札幌市北区13条西8丁目、
TEL011-706-6217、FAX011-706-6217)

***正員、工博、北海道大学大学院工学研究科

(北海道札幌市北区13条西8丁目、
TEL011-706-6215、FAX011-706-6215)

****正員、工博、北見工業大学土木開発工学科

(北見市公園町165番地
TEL 0157-26-9510、FAX 0157-26-9510)

*****正員、工博、北見工業大学土木開発工学科

(北見市公園町165番地
TEL 0157-26-9510、FAX 0157-26-9510)

2. 冬期路面走行試験

(1) あいの里冬期路面走行試験

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 センサー)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	
	ピッチ角度	
	ヨー角度	
角速度	ロール角速度	
	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	

(2) 札幌市内、及び周辺地域冬期路面走行試験

2006年2月から3月にかけての数日間において、SRセンサーとは異なる車両運動センサー(SSM; Subaru Select Monitor)を搭載した車両を札幌市内、及び周辺地域で走行させCANデータの収集を行った。収集したCANデータの例を表 - 3 に示す。走行時において、天候、路面状況、滑りやすさ、散布剤の有無などの目視によるデータも定期的に記録を行った。

表 - 3 SSMによる測定項目と測定間隔

測定項目	測定間隔
緯度、経度	0.1秒
エンジン回転数、ハンドル角、	
ヨーレート、ブレーキ圧力、	
横加速度、前後加速度、	
VDC / ABSフラグ、	
前軸平均車速、左前軸車速、	
右前軸車速、左後軸車速、	
右後軸車速、外気温 etc.	

3. すべり摩擦係数の推定方法

(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緒元、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。モデルパラメータに関する感度分析により推定摩擦係数がパラメータ依存性を有していないことが確認されているが、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。車両運動データの中から閾値を超えたデータを用いて先の 20 変数を対象とした主成分分析を行って情報の集約化を行った上で 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。

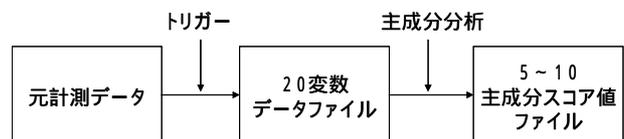


図 - 3 統計的モデルにおけるデータの集約化

(2) 多層型ニューラルネットワークモデル

ある入力信号に対して、適切な出力信号を出すためには、シナプス荷重の値を調整する必要がある。これを学習という。階層型のニューラルネットワークモデルの学習にはバックプロパゲーション法が有効であることが過去の研究により知られている。

図 - 4 に示す階層型モデルでのバックプロパゲーションのアルゴリズムを説明する。この図では、A 層が入力層、B、C、D 層が中間層、及び E 層が出力層である。学習に関係するのは B、C、D、E 層の 4 層で、A 層は入力された信号を正規化した後、B 層に伝える役目だけを担うと仮定する。

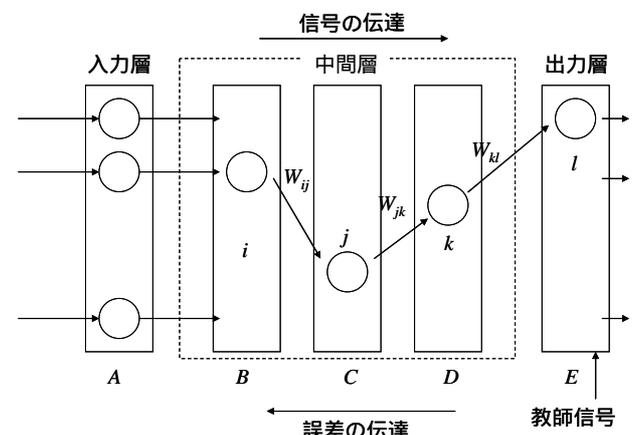


図 - 4 逆伝播法によるニューラルネットワークモデル

バックプロパゲーションにおいては、順方向の信号の流れとその逆方向の誤差補正の流れとがある。信号の流れは、入力層にある信号が入力されると、ニューラルネットワークのダイナミクスに従って中間層から出力層へと信号が順次伝達されていく。このネットワークの中で理論的に求めることのできないパラメータとして、“中間層の数”、“各層のニューロンの数”などがあるが、これらは経験的に定められる。たとえば、シナプスの数は、学習データのパターン数分は必要であるという経験則が得られている。

一方、誤差補正の流れについては、出力層からの信号が既知の教師信号と比較され、2乗誤差の程度に応じて各層間のシナプス荷重の大きさを入力層に向けて順次補正していく。

今、出力層における l 番目のニューロンの出力信号を O_l 、それに対応する教師信号を t_l とすると、この教師信号と実際に与えられた出力信号との2乗誤差をとれば誤差関数 E は、

$$E = \sum (t_l - O_l)^2 / 2 \quad \dots ()$$

と表される。バックプロパゲーションの学習とは、この E を極小化するようにネットワークのシナプス荷重を変化させることにほかならない。

出力層の出力 O_l は、中間層からの出力とシナプス加重によって次のように表せる。

$$O_l = f(\sum W_{kl} \cdot I_k) \quad \dots ()$$

各ユニットで用いた応答関数 f のシグモイド関数は、微分形がもとの関数形で表現できるという特徴を持っている。

$$f(x) = 1 / \{1 + \exp(-2x / \mu_0)\} \quad \dots ()$$

$$f'(x) = 2 \cdot f(x) \cdot \{1 - f(x)\} / \mu_0 \quad \dots ()$$

よって、シナプス加重の微小変化量に対する出力への影響は、次の式で表せる。

$$\begin{aligned} \delta O_l / \delta W_{kl} &= \delta O_l / \delta S \cdot \delta S / \delta W_{kl} \\ &= f'(S) \cdot I \\ &= \eta \cdot O_l \cdot (1 - O_l) \cdot I \\ &\dots () \end{aligned}$$

よって、式 () の O_l で微分したものと式 () より、シナプス加重の二乗誤差 E への影響は、次式で示すことができる。

$$\begin{aligned} \delta E / \delta W_{kl} &= \delta E / \delta O_l \cdot \delta O_l / \delta W_{kl} \\ &= -\eta \cdot (t_l - O_l) \cdot O_l \cdot (1 - O_l) \cdot I \\ &\dots () \end{aligned}$$

最急降下法により、シナプス荷重の変化量を dW と表すものとする。出力層 (l 層) とその直前の中間層 (k 層) の間のシナプス荷重の変化量 dW_{kl} は、

$$\begin{aligned} dW_{kl} &= -\alpha (\delta E / \delta W_{kl}) \\ &= \alpha \cdot \eta \cdot (t_l - O_l) \cdot O_l \cdot (1 - O_l) \cdot I \quad \dots () \\ &= \eta_2 \cdot \delta_l \cdot I \quad \dots () \end{aligned}$$

一つ前の層におけるシナプス荷重の変化量 dW_{jk} を以下のように定義することにより、

$$\delta_k = y_k \cdot (1 - y_k) \cdot (\sum \delta_l W_{kl}) \quad \dots ()$$

$$dW_{jk} = \eta \cdot \delta_k \cdot y_j \quad \dots ()$$

と求まる。このように、後ろのシナプス荷重から順に前のシナプス荷重の修正量が求まっていく。

本研究における適用に際して、遺伝的アルゴリズムによるニューラルネットワークモデル適用後に再度逆伝播法を適用し、精度の向上を図る。

4. 統計的モデルによるすべり摩擦係数の推定

(1) 閾値(トリガー)によるデータの集約化

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いうため、表 - 4 に示すように閾値(トリガー)を設定し、三段階(a, b, c)にデータの集約化を行った。抽出後のデータ数を表 - 5 に示す。

収集した20変数の車両運動データのうち、すべり摩擦係数と相関の高い前後方向加速度、横方向加速度、上下方向加速度、回転角速度、前後輪スリップ比の6変数を入力値とし、多層型ニューラルネットワークモデルによりすべり摩擦係数の推定を行った。トリガーなしの場合とトリガーを設定した場合の決定係数を表 - 6 に示す。cの場合においても十分な決定係数は得られなかったが、閾値を設定することによりモデルの精度が上がる事が確認された。

表 - 4 前後方向加速度の最大値によるデータの抽出

	a	b	c
加速時	0.03g以上	0.05g以上	0.10g以上
減速時	0.05g以上	0.10g以上	0.20g以上

表 - 5 データ抽出後のデータ数

	a		b		c	
	加速時	減速時	加速時	減速時	加速時	減速時
往路	281	261	210	225	117	121
復路	223	277	183	234	105	124
合計	504	538	393	459	222	245

表 - 6 トリガーの有無による決定係数の比較

	加速時		減速時	
	往路	復路	往路	復路
none	0.13	0.11	0.25	0.17
a	0.12	0.13	0.38	0.09
b	0.26	0.29	0.36	0.08
c	0.35	0.31	0.45	0.28

(2) 主成分分析による情報の集約化

(1)で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。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、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 - 7、図 - 5, 6 に示す通りモデルの精度は大幅に改善され、c のケースにおいては高い決定係数が得られた。

表 - 7 主成分分析による情報集約化後の決定係数

	加速時		減速時	
	往路	復路	往路	復路
none	0.43	0.42	0.58	0.41
a	0.48	0.46	0.57	0.48
b	0.63	0.45	0.65	0.47
c	0.69	0.76	0.72	0.74

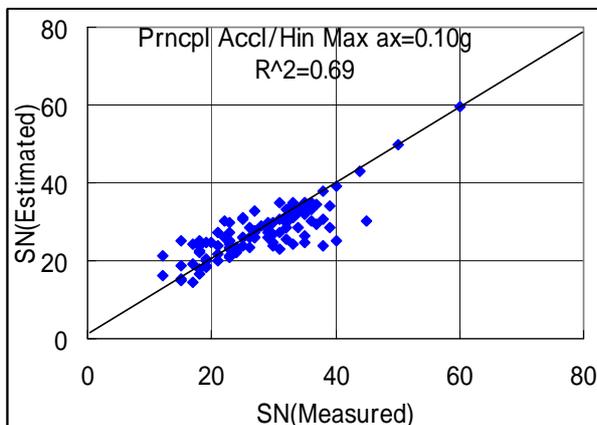


図 - 5 加速時におけるすべり摩擦係数の推定

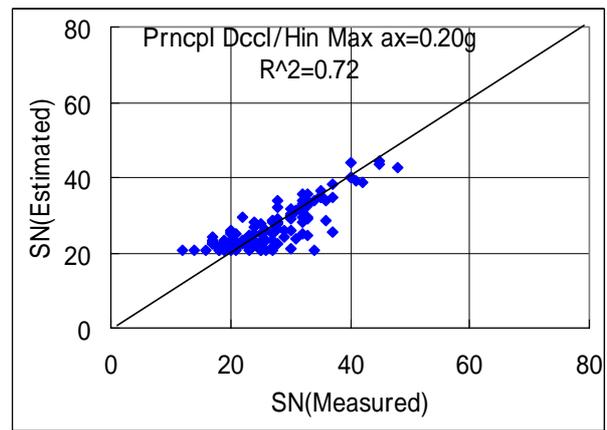


図 - 6 減速時におけるすべり摩擦係数の推定

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時、減速時のデータを抽出し、トリガーを設定し計測データの集約化を行った。また、主成分分析により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することで、既存の解析的モデルと同程度の精度が出るという結果が得られた。このことにより、実務へ適用する上で好ましい単純構造を有した統計的モデルがすべり摩擦係数推定モデルとして有用であるということが明らかとなった。さらに、CANデータをモデルに組み込むことで精度が向上すると考えられるため、推定モデルの改善を模索していく必要がある。

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 RESEAECH 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党規路面管理に関する研究, 平成17年度調査研究報告書, 2006