

IV-29

ニューロ・カルマンを用いた路面管理指標の予測手法について

北海道大学大学院 学生員 山川 顕吾
 北海道大学工学部 学生員 吉原 豊
 北海道大学工学部 正員 中辻 隆

1. はじめに

路面状態、あるいは路面のすべり易さの変動は極めて複雑であり、気象条件や道路・交通条件の変化によって大きく変動する。このような変動過程を数学的にモデル化することは大変困難である。しかしながら、冬期路面に対して経験豊富な運転者であれば気象データなどの説明要因の条件が与えられるならばある程度正確に短時間先の路面状況を予測することはそれほど困難ではない。本研究では、気象条件と路面状況に関する調査を行うとともに、このような経験豊かな運転者の予測過程を模擬するためにニューラルネットワークモデルの導入による路温と路面のすべり易さの短期予測を試みる。すなわち、ニューラルネットワークモデルによって予測された路温も説明変量としてリアルタイムに路面のすべり易さを予測するために、カルマンフィルタと組み合わせたニューロ・カルマンフィルタモデルの作成を行う。

2. 気象条件と路面状況に関する調査

2.1 調査目的

まず、定点における気象条件と路面状況に関する調査を行い、主観的に判断されたすべり指標が物理的に測定されたすべり摩擦係数(スキッドナンバ)と気象条件に応じてどのような特性を示すかを調査した。ここでは、運転者の主観によるすべり感覚指標とすべり摩擦係数(スキッドナンバ)の測定を行うとともに、日射量や放射量、気温、あるいは路温などの気象データの計測を行った。

2.2 調査方法

札幌市内のあいの里の茨戸福移通において1994年12月19日から23日まで、バス型すべり抵抗試験車によって路面の摩擦係数の測定を行うと同時に、日射量や放射量などの気象データの測定を行った。観測項目を表-1に示す。調査時間は午前7時から午後8時ま

である。路温の測定においては、道路車線上の表面温度の測定を行った。

表-1 観測地点における調査項目

調査項目	調査方法	測定頻度
雲量	目視	1時間おき
全日射量	全日射計	30分積算値
放射収支量	放射収支計	"
気温	温度プローブ	打点記録
湿度	湿度プローブ	"
路面表面温度	放射温度計	"
雪中アスファルト表面	"	"
雪温	"	"
路面状態 ¹⁾		
すべりやすさ ²⁾	目視	"
スキッドナンバ	すべり試験車	1時間おき

2.3 調査結果

図-1は、路面状況の変動が大きかった21日から23日の観測データに対して、目視による主観的なすべり感覚評価とスキッドナンバ(SN)を比較したものである。なお、ここでは、摩擦係数とスケールを合わせるために、すべり易さを1から4の値を持つすべりづらさとして表現している。また、路面が湿潤状態である時にはすべり試験機を保護するためにSN値の測定は行わずに、過去の経験に基づき70を仮定している。また、図-2は、各調査日における日射量、路温、および気温の変動状況を表しているが、21日は時々晴れ間ののぞく曇り空で風が強く気温もマイナス3℃からマイナス5℃と低い状態にあった。路面分類としては、ほぼ圧雪状態で日中に部分的にややすべりやすい状況にあった。22日は、安定した曇り空であったが風がないため気温が高く日中にはプラス3℃まで上昇がみられていた。早朝に凍結していた路面は日中には湿潤状態

Prediction of Road Slipperiness in Winter Using a Neural Kalman Filter

by Kengo Yamakawa, Yutaka Yoshihara, Takashi Nakatsuji




図-1 主観的なすべりやすさとスキッドナンバ

となり、夕方には再凍結していた。23日は晴天であり、早朝の気温はマイナス6℃であったが日中にはプラスとなった。路面も前日同様凍結状態から始まり日中で湿潤、夕方に再凍結状態となった。こうした天気や路面の変動状況を念頭に置いて、図-1の結果を見ると、

- ・主観的なすべり感覚指標が物理的なSN値に総合的に良く合致している
- ・路面状態が急激に変化している時、例えば22日午前などでは運転者の判断が実際の状況と乖離している

ことなどが分かる。他の調査日においても運転者によるすべり感覚指標はSN値と比較的良好な対応を示しており、路面管理のための指標として信頼性があると言える。




図-2 日射、路温、気温の時刻変動 (交差点3上り)

また、図-2において気温や路温の変動特性を見ると、特に23日の記録において顕著であるように、気温よりも路温が日射量の変化に良く追随していることが分かる。図-3は、全観測日を対象として目視による路面のすべりやすさと路温や気温との相関関係を表したものである。路温や気温ともに、マイナス6℃から0℃ですべりやすい路面の出現頻度が高くなっていること、

あるいは気温や路温が低い時にはすべりづらい路面ととっていることが分かる。この傾向は個々の観測日においても見られているが、23日の気温-すべりづらさの関係においては、マイナス4℃から0℃の範囲でもすべりづらさが大きくなっている。これは上に述べたように日射量と気温との間の変動の時間遅れに起因していると考えられ、気温による路面監視が不適切となる場合の例を示している。

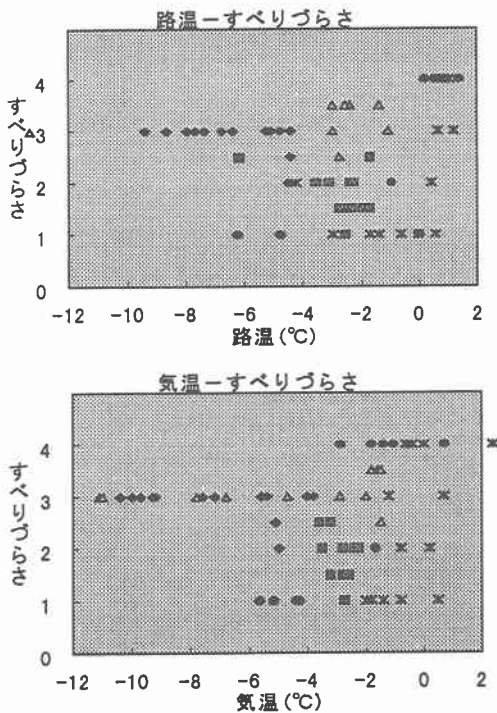


図-3 気温・路温とすべり (交差点3:上り)

3. 路温予測システム

路温の変化が路面のすべりや路面状態の変化に大きな影響を与えることは、路温が気温よりも日照条件の変化に対して敏感であることから肯首される。ここでは、後の予測システムにおいて重要な説明変量となる路温を予測するモデルをニューラルネットワークモデルを用いて作成した。

3.1 予測モデル

本研究では、理論式ではなく、得られたデータから、経験的に路面温度を予測しようと考え、入力値だけで

自己組織化によってモデルを構築できるニューラルネットワークの適用を試みた。

図-4は、モデル構造を表している。ここでの目的変量は計測可能な路温であるのでカルマンフィルタを導入する必要はなく、ニューラルネットワークモデルのみでモデルを作成している。図に示すように、時刻kでの観測値と時刻kでの路温や他の気象データを入力値とし、1つ先の時刻k+1における路温を出力とする多入力1出力構造である。すなわち、入力層のニューロン数は気象データ数、出力層のニューロン数は1である。中間層の数は基本的には2とした。用いる気象データ(入力層のニューロン数)、および中間層のニューロン数は解析対象例によって異なる。時間刻みは、使用した入力データに応じて、30分あるいは1時間とした。なお、日射量もしくは放射収量は、時刻kから時刻k+1の間の積算量を入力することにした。従って、路面温度を予測する際には、積算日射量の予測情報が必要となるが、これは別途気象予測の一環として得られていると仮定している。

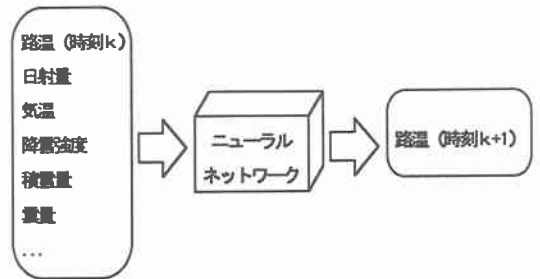


図-4 路温予測モデル

3.2 学習過程

2組の観測データを用いてモデルの作成を行った。表-2にデータの概要を示す。データセット1は、2.に述べた定点観測によって得られたものである。降雪強度と積雪深については、最寄りのSNETマルチセンサデータ(MSID16:あいの里拓北)を用いている。計測は午前7時から20時まで30分ごとに行われ、5日間で合計107組(欠落を除く)のデータが得られている。ここでは、12月20日の24組のデータを予測検証用のデータとし、それらを除いた85組のデータを学習パターンとした。ニューラルネットワークモデルとしては、[8]-[8]-[5]-[1]の4層構造とし、13000回の学習を繰

り返した結果、全学習パターンでの平均誤差が0.47%、最大誤差が2.2%まで収束した。

表-2 観測データの概要

データ	観測時期	観測場所	観測主体	入力変量
1	1994	北区あいの里	北海道	路温、放射収支量、 気温、日射量、 湿度、曇量、 降雪強度*、積雪深*
	12.19- 12.23	茨戸福井通	北海道大学	
2	1994	中央区	札幌市	路温、気温、 日射量**、 降雪強度*、積雪深*
	1.1-1.31	南9条西9	北海学園大学	

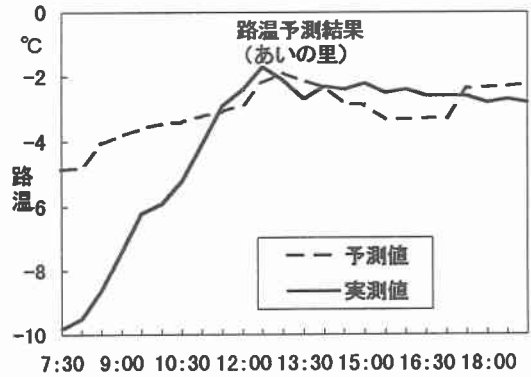
*:SNETデータ、 **:アメダスデータ

データセット2は、札幌市と北海学園大学が共同で札幌市中央区において常時観測を行っているデータを両者の協力によって用いた。路温は独自に開発した路温センサ（アスファルトに埋設した熱伝対方式）で計測したものである。日射量についてはアメダスデータを、降雪強度と積雪深については、最寄りのSNETマルチセンサデータ（MSID 1：中央区土木事業所）を用いている。データは94年1月のデータから1時間ごとに693組のデータを得、その中から1月15日の23組のデータを予測検証用として除いた670組のデータを学習パターンとした。[5]-[4]-[4]-[1]の4層構造で学習を行った。2700回繰り返して学習した結果、全パターンの平均誤差が1.4%であった。


3.3 路温の予測結果

学習したモデルを用いて路温の予測を行い、予測精度の検証を行った。予測は、データセット1（あいの里）に対しては中日の12月20日を対象としている。学習データはこの日を除いた前後4日間のデータを用いているが、予測対象日以後のデータも学習データとしているのは非現実的であるが、データの不足を補うための方便として、過去に同様なデータが得られていることを想定している。同様にデータセット2（南9西9）においても、中日の1月15日を予測対象日としている。予測値と実測値の比較結果を図5に示す。データセット1においては、未だ学習データが不足しているために朝方における予測精度が劣っている。RMS誤差は、2.1℃と大きい。一方、データセット2においては、学習データが十分にありかなり変動パターンを表

現しているが若干予測値が高めに出ている。この時のRMS誤差は、1.1℃であった。



(1) データセット1（あいの里：1994.12）



(2) データセット2（南9西9：1994.1）

図-5 路温の予測結果

4. 路面のすべり予測システム

冬期の路面管理にとって直接的な目的は路面のすべり易さを低減することであることを考慮して路面のすべりやすさ（づらさ）自体を予測することを考える。ここでは、経験豊富な運転者による予測過程を模擬するために、状態方程式と観測方程式をニューラルネットワークモデルを用いて表現したカルマンフィルタの適用を試みる。

4.1 予測モデル

図-6に示すように、滑り予測モデルは状態方程式と観測方程式からなっている。路面のすべり易さ（づらさ）を状態変数 $x(k)$ とする。一般的に路面のすべり $x(k)$ を直接計測することは困難であるので、路面状況

を間接的に計測を行う。ここでは、路面状態分類を観測変量 $y(k)$ としている。ここでは、1地点のみを対象とするので $x(k)$ と $y(k)$ はともにスカラー量となる。

4.1.1 状態方程式

$x(k)$ は、自己の過去からの影響や気象条件の影響を受けて時間的に変化する。この変動過程を表現するのが状態方程式であるが、その過程は複雑であるので物理現象学的に解析的なモデルを用いて表現することは困難である。ここでは過去の経験をもとにニューラルネットワークモデルを用いて表現する。実際には定点観測における気象データとすべり易さデータを学習データとしてモデルの作成を行う。

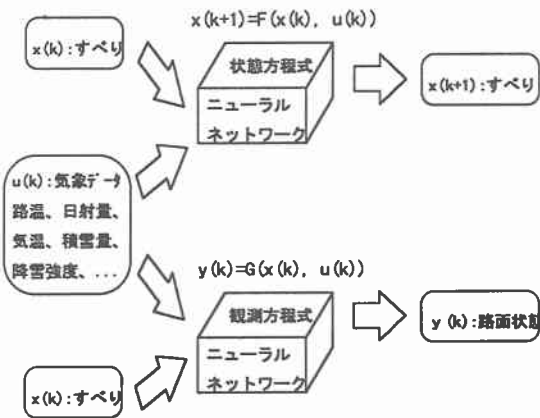


図-6 路面のすべり予測モデル

4.1.2 観測方程式

一般的に路面管理のための路面状況データは路面状態の分類として得られることが多く、路面のすべりやすさそれ自体は計測されない。本手法の主眼は路面状態の分類データが得られた時に路面のすべり易さを推定することである。そのためには路面のすべりやすさと路面状態分類の間に関数関係を確立する必要がある。これを観測方程式という。この滑りやすさと目視による路面状態との関係も複雑であり明確な解析式は存在しない。ここでは、定点観測から得られているデータからニューラルネットワークモデルを用いて経験的にモデル化することを試みる。しかしながら、モデル構造としては、路面状態分類や気象データを与えて滑りやすさを出力する逆問題構造とはしないで、本現象の因果律を踏まえて、路面のすべりやすさや気象条件が

路面状態を規定するという形を採用している。こうしたモデル構造の採用によってカルマンフィルタのアルゴリズムに従って、時刻 k の気象データ $u(k)$ と路面状態 $y(k)$ が得られた時に、その時の路面のすべりやすさ $x(k)$ を推定したり、あるいは1ステップ先の $x(k+1)$ を予測することが可能となる。

4.2 学習過程

2. で得られた観測データを用いて状態方程式の関数 F と観測方程式の関数 G の同定を行った。表3にそれぞれの入力信号と出力信号をまとめた。路面のすべりについては、主観的に判別された分類コードを表現するために4つのニューロンを割り当てている。路面状態についても8つの分類を表現するために8つのニューロンを準備している。他の気象データについては、量的データであるので適当な絶対数で無次元化している。すなわち、関数 F のモデルでは、入力層のニューロン数が10、出力層のニューロン数が4、一方、関数 G のモデルでは、入力層のニューロン数が10、出力層のニューロン数が8となっている。関数 F を同定するための学習パターンは59組、関数 G を同定するためには63組得られているが、これらは未知のシナプス荷重の値を調整するには必ずしも十分ではなく、学習後の推定精度は関数 F で9%、 G で30%であった。

表-3 ニューロ・カルマンフィルタの入力信号と出力信号

	状態方程式	観測方程式
入力信号	$x(k)$:路面のすべり $u(k)$:路温、日射量、 気温、降雪強度、 湿度、積雪深	$x(k)$:路面のすべり $u(k)$:路温、日射量、気温 湿度、降雪強度、 積雪深
出力信号	$x(k+1)$:路面のすべり	$y(k)$:路面状態

4.3 路面のすべりやすさの予測結果

ニューロ・カルマンフィルタによる路面の滑りやすさの予測値を実測値と比較した結果を図-7に示す。ここで、 $x_b(k)$ は観測値 $y(k)$ が得られる前の状態量 $x(k)$ の推定値 $\tilde{x}(k)$ であり、 $x_s(k)$ は $y(k)$ が得られた後の状態量 $x(k)$ の推定値 $\hat{x}(k)$ を表している (実際には $x(k)$ はスカラー量である)。換言するならば、 $x_b(k)$ は時刻 $k-1$ における時刻 k に対する予測値である。観測は日中しか実施されていないので、予測も日中のみ

を対象としているがスペースの節約のために、観測日
を連続して表示している。また、前節の路温の予測は、
学習用データとは別途設備された検証用データを対
象として行われたが、ここでの予測は、十分な観測デ
ータが得られなかったために、学習用データに対して
行われたものである。そのため、全体的にはよく追従
しているように見えるが、これは学習用データに対す
る予測結果であるので当然の結果といえる。さらに、
 $x_b(k)$ と $x_h(k)$ を比較すると、 $x_b(k)$ において精度の
改善がみられていない。すなわち、新たな観測量 $y(k)$
が状態量の推定精度の改善にあまり寄与していないこ
とを表している。路面のすべりと路面状態が極めて複
雑な非線形な関数状態にあるため、そしてさらに、観
測方程式の学習パターン数が不足していたため十分な
学習が行われなかったためと考えられる。いずれにし
ても、観測データが十分でなかったために、モデルの
有効性を検証する結果が得られていない。

成を試みた。すなわち、路面のすべりやすさを基本状
態量、観測によって得られる路面状態分類を観測量、
気象データを外的変量としたカルマンフィルタモデル
を基本構造として、それらの状態方程式と観測方程式
をニューラルネットワークモデルによって同定するモデ
ルの提案を行った。同時に、外的な気象データの中で
重要な働きをする路温についても、ニューラルネット
ワークモデルを用いた予測モデルを作成しその適用性
の検討を行った。

- ① 目視による主観的なすべり感覚指標は、実際に計測
された路面のすべり摩擦係数に比較的良く合致す
る。
- ② 路面雪表面上の路温の方がアスファルト表面上の
路温よりも気象の変化に対応している。
- ③ 路面温度の変化に対して、前の時刻での路面温度、
気温、の影響が大きく、降雪強度の影響は相対的に
小さい。
- ④ 学習データ数が十分あった南9西9では1℃ほど
の、データ数が不足なあいでは、2℃ほどの平均推定誤差が見られた。
- ⑤ 特に前者の予測結果では、このような予測問題に発
生する1ステップ遅れの現象も見られず比較的良好な
波形形状を示していた。
- ⑥ 路面のすべりやすさに対しては、状態方程式と観測
方程式ともに、前ステップでのすべりやすさ、路温、
気温、日射量などの影響が大きく、湿度や降雪強度
の影響が小さい。
- ⑦ 学習データが少ないにも拘わらず、学習データ自体
に対しては比較的良好な路面のすべりの予測結果
を与えているが、モデルの妥当性の評価は、別途観
測データの取得を待たなければならない。

滑りやすさ すべり予測結果 (あいの里 12月)




図-7 ニューロ・カルマンフィルタによる路面のすべり予測

5. まとめ

冬期路面管理において重要な指標は路面のすべりやす
さそのものであり、運転者の主観的なすべりやすさ
の評価が信頼に足りることを明らかにした。さらに、
路面のすべりを直接計測することは困難であるのに対
して、路面状態分類を判断することは比較的容易であ
ることを考慮して、観測された路面状態情報をもとに
短時間先の路面のすべりやすさを予測するモデルの作
成を行った。ここでは、冬期路面に対して経験豊かな
運転者の思考過程を模擬し、ニューラルネットワーク
モデルとカルマンフィルタを組み合わせたモデルの作

参考文献

1. L. Axelson. Proposal for New Winter Road
Maintenance Strategy-MINSALT Project. *Proc. Int.
Workshop on Winter Road Management*, 1993,
pp. 29-32
2. L. D. Minsk. SHARP Research on Snow and Ice
Control. *Proc. Int. Workshop on Winter Road
Management*, 1993, pp. 43-47