

I-2 ニューラルネットワークモデルとカルマンフィルターを組み合わせた冬期路面状態推定手法

A Neural-Kalman Filtering Method for Estimating Road conditions in Winter

Nasser Pourmoallem 藤原 隆* 中辻 隆 萩原 亨

Nasser Pourmoallem Takashi Fujiwara Takashi Nakatsuji Toru Hagiwara

[抄録] 冬期の路面状態は、気象条件、沿道条件、あるいは交通条件の影響を受けて複雑に変化する。ニューラルネットワークモデルを用いてカルマンフィルタの状態方程式と観測方程式を表現することによって短時間先の路面状態を予測、あるいは推定するモデルの開発を行った。本モデルの導入によって、極めて非線形が強い路面変化の経時変化の定式化が可能となった。また、ニューロモデルによる表現によって拡張カルマンフィルターにおける微係数行列の導出が容易になった。2カ年の冬期間の観測データを用いて有効性の検証を行い、ニューロモデルが学習能力に優れていること、影響要因分析が容易であることを明らかにした。

[Abstract] A new estimation method that integrated a neural network model into the Kalman filter was developed. Both the state and the observation equations in the Kalman filter were described by a multilayer neural network model. This method made it possible to represent nonlinear and unsteady problems mathematically, which were so far almost impossible to formulate analytically. The method was applied to the prediction of slipperiness of road surface in winter. In this paper, it was discussed how both the equations of the Kalman filter were expressed by a neural network model and how effective the new method was in predicting the skid number of road surface in winter.

[キーワード] カルマンフィルター、ニューラルネットワークモデル、冬期路面、すべり摩擦係数、冬期路面管理、短期予測

[Keywords] Kalman filter, Neural network model, skid number, winter maintenance, snow and ice control

1. まえがき

動的な状態量をリアルタイムに推定する手法としてカルマンフィルター¹⁾⁻³⁾がある。対象とする状態量の時間的変化を記述する状態方程式が定義されているがその状態量を直接計測出来ない時に、計測出来る他の観測量から間接的にそれを推定する手法である。この状態量と観測量の関係を観測方程式という。カルマンフィルターは、その理論構成が明快であること、あるいは計算機演算のためのコード化が容易であることから、多くの分野において平滑、推定、および予測問題に適用されている⁴⁾⁵⁾⁶⁾。しかしながら、カルマンフィルターにおいては、状態方程式と観測方程式が予め定義されていることを基本としている。すなわち、状態量の時間的変化や観測量との関係が前もって解析的に記述されていなければならない。実際の問題において、このような方程式を解析的に記述することが困難であることことも多い。例えば、冬期の雪氷路面における路面状態の短

期予測もそのような例である。冬期において、現下の路面状態が、日照などの気象条件、道路周辺の土地利用などの沿道条件、あるいはその道路を通過する交通量などの交通条件の影響を受けて、2～3時間先には凍結路面にも乾燥路面にも成りうる。この路面状態の時間的変化を微分方程式で表現したり、日射量や交通量などの観測データとの関係を解析的に表したりすることは極めて困難である。現状では道路管理者や交通管理者の経験に基づいた予測が行われており必ずしも精度の高い信頼性ある結果を得ていない。適切なタイミングで薬剤散布を行って効率的な冬期路面管理を実現したり、あるいは道路利用者に最新の情報提供を行って冬道走行への備えをしてもらうために、精度の高い路面状態予測モデルの確立が求められている。

多層階層型のニューラルネットワークモデル^{7),8)}には、入力信号と出力信号があれば、それらの間の関係を容易に表現することが出来るという優れた性

質がある。すなわち、カルマンフィルタにおける状態方程式と観測方程式に関する事前の予備知識なしにそれらの方程式を容易に再現することができる。さらに、ニューラルモデルには、量的なデータだけでなく質的なデータも取り扱うことが出来る、解析的な回帰モデルと異なりサンプル数の影響を受けることが少なくその多少に関わらず安定したモデルの同定を行うことが出来る、あるいは出力信号に対する入力信号の微係数の導出が容易であり拡張カルマンフィルタにおける係数行列を簡単に求めることが出来るなどといった特徴があり、非線形現象の表現に適している。

本論文では、カルマンフィルタの状態方程式と観測方程式を多層階層型のニューラルモデルで表現した“ニューラルカルマンフィルタ”の開発を行った。冬期の路面状態の短期予測を例として、ニューラルネットワークモデルによる両方程式の定式化、再現能力、および未知データに対する予測精度などについて述べる。次節においては、カルマンフィルタと多層階層型のニューラルネットワークモデルの基本的概念を紹介するとともにそれらを統合したニューラルカルマンフィルタの定式化を行う。次に、冬期路面のすべり摩擦係数の予測に関する適用例を通して、本手法の有用性を明らかにする。

2. ニューラル・カルマンフィルタ

2.1 カルマンフィルタ¹⁾

x_k を対象とするベクトル状態量であり、その時間的変動が

$$x_{k+1} = A_k \cdot x_k + v_k \quad (1)$$

によって記述できるものとする。ここで A_k は既知の係数行列であり、 v_k は雑音である。一方、状態量 x_k は、雑音 w_k を含んだベクトル観測量 y_k を通して観測される。

$$y_k = C_k \cdot x_k + w_k \quad (2)$$

ここで、 C_k も既知の係数行列である。時刻 k において、新しい観測値 y_k が得られていない段階での x_k の推定値(予測値)を \tilde{x}_k 、 y_k が得られた段階での x_k の推定値を \hat{x}_k とする時、 \hat{x}_k はカルマンフィルタの理論から

$$\hat{x}_k = \tilde{x}_k + K_k(y_k - \tilde{y}_k) \quad (3)$$

と与えられる。ここで、

$$\tilde{x}_k = A_{k-1} \hat{x}_{k-1} \quad (4)$$

$$\tilde{y}_k = C_k \tilde{x}_k \quad (5)$$

$$K_k = M_k C_k' (C_k M_k C_k' + W_k)^{-1} \quad (6)$$

$$M_k = A_{k-1} P_{k-1} A_{k-1}' + V_k \quad (7)$$

$$P_k = M_k - K_k C_k M_k \quad (8)$$

ここで、 V_k と W_k は雑音 v_k と w_k の共分散行列、 M_k は観測量 y_k が得られていない段階での x_k の推定誤差行列、 P_k は y_k が得られた後での推定誤差行列である。 K_k はカルマンゲインと呼ばれている。すなわち、式(3)~(8)は、初期状態 \hat{x}_0 と P_0 が与えられると、新しい観測量 y_k が得られるごとに x_k の予測値 \tilde{x}_k と推定値 \hat{x}_k が順次求まることを表している。

2.2 拡張カルマンフィルタ¹⁾

状態方程式と観測方程式が、非線形関数

$$x_{k+1} = f(x_k, u_k) + v_k \quad (9)$$

$$y_k = g(x_k, u_k) + w_k \quad (10)$$

として記述されている場合にも、 \hat{x}_k を均衡点としてテラー展開を行って線形化

$$\Delta x_{k+1} = A_k \Delta x_k + v_k \quad (11)$$

$$\Delta y_k = C_k \Delta x_k + w_k \quad (12)$$

を行うことによって式(3)から(8)のアルゴリズムを踏襲することが出来る。これを拡張カルマンフィルタという。なお、ここで、 u_k は外的作用を表している。行列 A_k と C_k は次式で定義される。

$$\begin{aligned} A_k &= \frac{\partial f}{\partial x} \\ C_k &= \frac{\partial g}{\partial x} \end{aligned} \quad (13)$$

2.3 ニューラルネットワークモデル⁹⁾

ニューラルネットワークモデルは、脳の情報処理機構を数学的に模擬したモデルである。その中でも、多層階層モデルは、

- 入出力データのみからそれらの間の関数関係を構築することが出来る

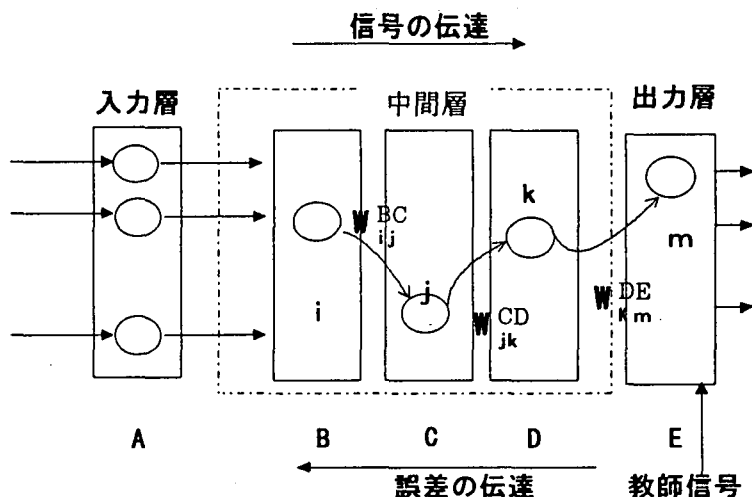


図-1 多層階層型のニューラルネットワークモデル

- 学習データの多少に拘わらず比較的安定したモデル同定を行うことができる
- 入力信号と出力信号を初等関数を結合した形で表現出来るのでその間の微係数の導出が容易である
- 質的データも取り扱うことが出来る

などの優れた特性を有している。

本研究においては、図-1に示す多層階層型のモデルを用いた。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。同一層のニューロンは、お互いに結合されてはならず、各層間のニューロンのみシナプス結合されているものと仮定する。また、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ものとしている。入力層に信号が入力されると、ニューラルネットのダイナミクスに従って中間層を経て出力層へと信号が順次伝達されて最終層において

$$y_m^E = h \left(\sum_k w_{km}^{DE} h \left(\sum_j w_{jk}^{CD} h \left(\sum_i w_{ij}^{BC} h(x_i^A) \right) \right) \right) \quad (14)$$

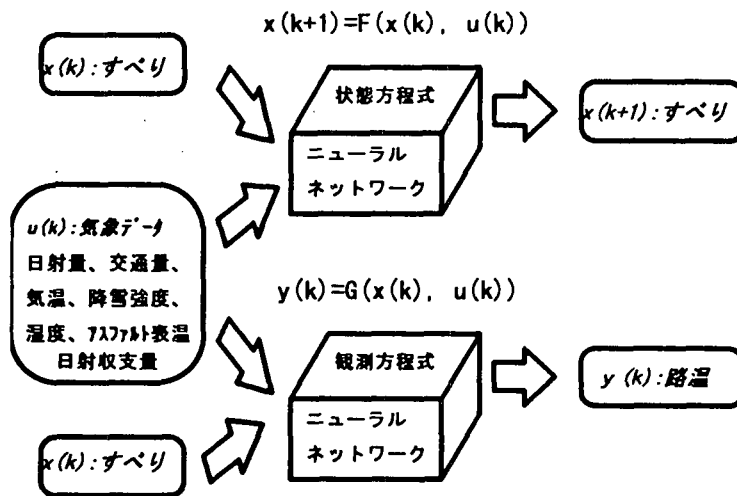
の出力信号を得る。ここで、hは各ニューロンにおける応答関数である。

出力信号が予め別途用意された教師信号に近づくようシナプス荷重の値を調整することを学習という。幾多の入力信号に対して、その出力信号と対応する教師信号との誤差が充分小さくなるまでシナプス荷重の調整を繰り返す。学習データが現下の問題を代表するのに充分である時には、学習終了後のモデルは未学習の入力信号パターンに対しても充分な精度の推定結果を与えることができる。実際には、層数と各層のニューロン数、および所要の学習データ数は、経験的な試行錯誤を経て決定される。一般的には、未学習の入力信

号に対する推定精度を目安として学習の達成度が判断される。なお、ここでは、モーメント法に基づく逆伝搬法によってシナプス荷重の調整を行った。

2.4 ニューラル・カルマンフィルタ

路面のすべりの予測問題を例として、カルマンフィルタにおける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定式化することを考える。路面の滑りやすさを状態変数 x_k とする。一般的に x_k は気象条件や交通条件などの外的な影響 u_k を受けて時間的に変動する。これを表現するのが状態方程式(9)である。また、路面のすべり x_k を計測するにはすべり抵抗測定車などの特別の試験装置を必要とするのでそれを随時計測することは困難である。そのため路面状態を路温等の計測しやすい観測変数 y_k を計測することによって、間接的に路面のすべり x_k を推定することになる。観測変数 y_k と状態変数 x_k の関係を規定するのが観測方程式(10)である。すなわち、状態方程式と観測方程式が事前に規定されていると、観測変数 y_k の計測値が得られるごとに状態変数の推定値 x_k 、あるいは予測値 x_{k+1} がリアルタイムに得られることになる。これがカルマンフィルタの原理である。しかしながら、冬期路面の問題において、状態方程式と観測方程式をそれらの物理法則に従って解析的に表現することは極めて困難である。ここでは、多層階層型ニューラルネットワークモデルを用いて両方程式を表現することを試みる。このモデルをニューラル・カルマン・フィルタと名付けた。図-2に路面のすべりを予測するためのニューラル・カルマンフィルタの基本基本構造を示す。



図一 2 ニューラル・カルマンフィルターによる路面のすべり予測の概念図

(1) 状態方程式

冬期の路面状態を表す指標⁹⁾には路面分類やスキッドナンバ (SN: 摩擦係数を100倍した値) などがあるが、ここでは冬期の路面管理に最も適したSN値を状態変量として用いた。また、外的な影響要因としては、気温、日射量、降雪強度などの気象条件、交通量などの交通条件を考慮した。すなわち、現在の時刻の路面状態と外的要因を入力信号として、1時刻先の路面状態を出力信号として与えてニューラルネットワークモデルFを作成した。

(2) 観測方程式

路面のすべりと密接な関係がある路温のデータが得られた時に路面の滑りやすさの推定を行うことを考える。そのためには路面のすべりやすさと路温の間に関数関係を確立する必要がある。このすべりやすさと路温との関係も複雑であり、両変量の他に気象条件や交通条件も影響を及ぼしていると予想されるので、外的要因も観測方程式に含まれるものとした。すなわち、すなわち、路面状態と外的要因を入力信号として、そして路温を出力信号としてニューラルネットワークモデルGを作成した。

(3) 影響係数

路面のすべり予測などの複雑なシステムに対してニューラルネットワークモデルを導入することによる最大の利点は、拡張カルマンフィルターにおける A_k 行列と C_k 行列を容易に誘導できることである。すなわち、式(14)から入力信号 x_i^B と出力信号 y_m^E の間の偏微分係数は

$$\frac{\partial y_m^E}{\partial x_i^B} = y_m^E (1 - y_m^E) \sum_k W_{km}^{DE} y_i^D (1 - y_i^D) \sum_j W_{jk}^{CD} y_j^C (1 - y_j^C) W_{ij}^{BC} \quad (15)$$

と表すことが出来る。すなわち、状態方程式あるいは観測方程式ともに偏微分係数(15)が A_k 行列と C_k 行列の(m, i)要素に対応することになるので、拡張カルマンフィルターへの展開が可能となる。また、式(15)は出力信号 y_m^E に対する入力信号 x_i^B の影響係数と理解することができるので、要因の感度分析にも有用である。ここでは、ニューラルネットワークモデルを4層構造として微係数を導出したが、任意の数の層を有する構造に対しても式(15)と同様な式を容易に求めることが出来る。

3. 冬期の路面状態の予測

3.1 既存の予測手法

冬季の路面状態の予測に関しては、和田¹⁰⁾は、三峠における観測データをもとに重回帰モデルによる降雪予測に基づく凍結予測を試みている。あるいは、武市¹¹⁾は変動の周期性に注目しフーリエ級数に基づいた凍結予測モデルを提案している。また、鈴木¹²⁾は重回帰モデルによって、特定の1地点あるいは路線全体を対象とした路面温度の予測を行っている。しかし、これらのモデルは静的なモデルであり路面状態の時間的な変化を表現していない。中辻ら¹³⁾が、峠部の摩擦係数の動的予測を主眼として、GMDH (Group Method of Data Handling) モデル、あるいは複合型のニューラルモデルの導入を試みているが、それらは摩擦係数を直接的に予測するものである。すなわち、路温等を通して間接的に予測するというカルマンフィルターの概念は含まれていない。

3.2 路面状況調査

冬期路面状態の変動特性とそれに影響を及ぼす要因に関する知見を得るために、1994年と1995年の12月に札幌市郊外の幹線道路（札幌市内一般道道札幌広島環状線）において路面状況調査を実施した。調査にあたっては、路側の1地点に気象観測機器の設置を行って、気温、湿度、日射量、放射収支量などの気象データの計測を行うとともに、バス型すべり抵抗測定車による路面のスキッドナンバの測定、目視によるすべりやすさ指標の判断、路温計によるホイールパス上の路面表面温度の測定、および堆雪下のアスファルト表面温度を行って路面状況の把握を行った。また、同時に車種別の通過交通量の計数も行った。表-1に冬期路面状況調査の概要を示す。観測は路面状態の変化が大きい日中において実施した。1995年度には、前年度のデータの不足を補うため夕刻の調査も集中的に行っている。気象データ、路面データ、および交通データの計測は、30分単位に行った。日射量、放射収支量においては30分ごとの累積値を計測値とした。

3.3 ニューラルネットワークモデルの構造

観測データを用いて状態方程式と観測方程式のニューラルネットワークモデルFとGの同定を行った。表-2にニューラルネットワークFとGの入出力信号の構成を示す。路面状況の予測に必要な気象データのレベルを把握するために、気象データのうち、気温や湿度など比較的容易に計測出来るものを便宜的に通常データ、日射量や放射収支量などのようにその計測に特別な機器を必要とするものを特殊データとした上で、通常データの他に特殊データも用いた場合を case 1、通常データのみを用いた場合を case 2として2つのケースに対してモデルの作成を行った（表-3）。交通量は早朝からの累積交通量を用いた。また、地中温度の影響を考慮するために堆雪下のアスファルト表面温度も入力信号として用いた。以上の結果、入力信号の数は、case 1のモデルで8、case 2では6となった。出力信号はスキッドナンバであり、ニューロン数は1である。中間層におけるニューロン数は、これまでの経験的を基に、第1中間層で入力層と同数、第2中間層でその半数とした。

表-1 冬期路面状況調査

調査日時	1994年12月	19日(月)~23日(金)	7:00~20:00
	1995年12月	14(木)、18日(月)、20日(水)、25日(月) 15(金)、19日(火)、21日(木)、26日(火)	15:00~20:00 7:00~20:00
調査項目	気象データ	気温、湿度、日射量、放射収支量 降雪強度、積雪深	30分毎
	路面データ	路面状態分類、スキッドナンバ(SN) アスファルト表面温度、路温	30分毎
	交通データ	通過交通量、大型車混入率	30分毎

表-2 ニューロ・カルマンフィルターの入力信号と出力信号

	状態方程式	観測方程式
入力信号	路面のすべり(時刻k) 気象データ 累積交通量 アスファルト表面温度	路面のすべり(時刻k) 気象データ 累積交通量 アスファルト表面温度
出力信号	路面のすべり(時刻k+1)	路温(時刻k)

表-3 気象データの設定


CASE	通常データ	特殊データ
1	気温、湿度、積雪深	全天日射量、放射収支量
2	同上	なし

3.4 学習結果

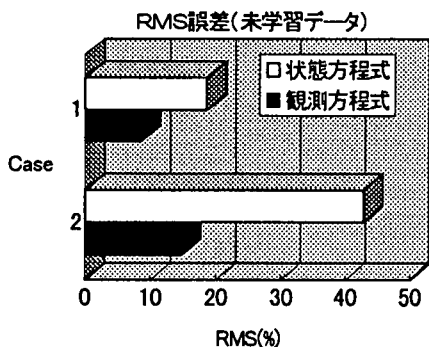
観測データの中から、日中の気象変化が大きかった1995年12月26日のデータを学習後の推定精度を検証するためのチェックデータとし、それ以外の観測日のデータから学習データを作成し、状態および観測方程式の両ニューラルネットワークモデルの同定を行った。学習はモーメント法に基づく逆伝搬法によって行った。図-3に(1)学習後の推定誤差(RMS誤差)、(2)検証用としての未学習データを入力した場合の推定誤差を示している。学習データに対しては、両方程式とも5%以下、特に特殊気象データも考慮したCase 1では、おおよそ1%となっており優れた再現能力を示している。しかしながら、未学習データに対しては、Case 1の観測方程式が10%以下の良い結果を与えているが、Case 1の状態方程式や、特殊気象データを使用していないCase 2では両方程式とも推定誤差がやや大きくなっている。特に状態方程式では40%もの誤差となっている。すなわち、ここでの結果は、日射量や放射収支量などの日照の状況を表す気象データが重要な働きをしていること、あるいは延べ1週間程度の観測

データでは、複雑な冬期の路面状況の変動を表現するにはデータ不足であることなどを示唆している。逆に換言するならば、通常の解析的な回帰モデルと異なり、ニューラルネットワークモデルは、観測データ数が増加してもその再現能力はあまり低下しないという特徴があるので、より広範な路面状態も含めて再度学習を行うことによって、未学習データに対しても数%程度の推定誤差を実現することも可能であると思われる。ここではこの後、ある程度小さな誤差を確保できたCase 1のモデルのみを対象として解析を行った。

モデルは、応答関数とシナプス荷重によって入力と出力の関係を一意に表現することができるので、出力値に対してどの入力値が影響を与えているかを定量的に評価できる。すなわち、出力変量を入力変量で偏微分した式(15)がその影響度を表している。状態方程式と観測方程式について、学習データの出力値に対する入力値の影響係数の絶対値の平均を求めた結果を図-4に示す。横軸のスキッドナンバーは前の時刻のスキ



(1) 学習データ



(2) 未学習データ

図-3 状態方程式と観測方程式を表現するニューラルネットワークモデルの推定精度







図-4 平均影響係数 (Case 1 : 通常気象データ+特殊気象データ)

ッドナンバ値を意味している。縦軸はニューラルネットワークの出力信号に対応した無次元化量である。影響係数 $|dy/dx|$ が大きいほど出力値に対する影響が大きい判断される。全体的に前の時刻のすべりと気温と交通量及び放射収支量の影響が大きいことが分かる。これは、路面状態が30分や1時間程度では大きくは変化しないこと、観測の時間帯が主に日中を対象としているために交通量の変動が路面のすべりと見掛け上の相関を有していたこと、あるいは日照条件に関する放射収支量による影響が大きいことを表している。

図-4では影響係数は絶対値の平均値として表現したが、式(15)に見るように影響係数は入力信号の値によって変化し、入力信号自体も時間とともに変動するので、影響係数も経時的に変化する。すなわち、式(15)の係数は、入力信号が出力信号に与える影響を経時的に分析するのにも有用である。図-5は、1995年12月15日のデータを例として、放射収支量が両方程式の出力変量である(1)スキッドナンバと(2)路温に対してどのように影響を与えているかを見ても



(1) 状態方程式




(2) 観測方程式


図-5 放射収支量の影響度の経時変化

のである。スキッドナンバにおいては、午前9～10時、あるいは午後15～17時頃に、また、路温においても午前8～9時に影響係数が大きくなっているが、それらの時間帯ではスキッドナンバや路温の変化が相対的が大きくなっていることが分かる。

ニューロ・カルマンフィルターを用いて実際の路面のすべりの予測を行った結果を図-6に示す。(1)が学習データ、(2)が未学習データに対する予測値である。図中の■印は実測の値を示している。(1)の結果は学習用データに対して行われたものであるため必然的な結果である。他の観測日に対してもほぼ同様な結果となっており、ニューラルネットワークモデルの再現能力の高さを表している。しかしながら、学習データに対する精度の高さは必要条件であるが、予測モデルとしての要件としては充分ではない。すなわ



(1) 学習データ(12/15, 1995)



(2) 未学習データ(12/26, 1996)

図-6 路面のスキッドナンバの予測結果の実測値との比較

ち、本モデルの最終目的は、未知の気象・交通状態に対してスキッドナンバの予測を行うことであるから、未学習データに対しても精度の良い予測が望まれる。

(2) は、未学習データ (12月26日) に対して行った予測結果を表している。スキッドナンバの過渡変動時 (午前9時から12時) における応答に遅れがあり、スキッドナンバ値を過小に評価しているがその前後においては、ほぼ妥当な予測を行っている。図-3 に示したように、特に状態方程式のニューラルネットワークモデルの精度不足が影響を及ぼしていると予想される。ニューラルネットワークモデルは、多変量解析モデルと異なり、サンプルデータ数が増加しても柔軟にそのシナプス荷重を調整出来ることを特徴の1つとしているので、より多くのデータを用いて学習を行うことによって精度の改善を図ることが出来るものと期待される。なお、図-6の結果は、表-3のCase 1に対するものであるが、日照に関するデータを考慮していないCase 2においては、図-3の結果からも推定されるように、既学習データに関しては、比較的良好な予測結果を与えたが、未学習データに対しては全く精度の悪い結果を与えていた。このことは、冬期の路面状態の推定予測においては、日照の活動状況に関するデータが重要な役割を果たしていることを表している。

4. まとめ

従来解析的な定式化が困難であった冬期の路面状態の短期予測に関して、カルマンフィルターの状態方程式と観測方程式を多層階層型のニューラルネットワークモデルで表現した予測モデルの開発を行った。すなわち、路面のすべり摩擦係数(スキッドナンバ)を状態量、雪氷路面の表面温度を観測量とするカルマンフィルターを用いた定式化において、状態方程式では、気象条件や交通条件を入力信号、そして次時刻のスキッドナンバを出力信号とするニューラルネットワークモデルを、他方、観測方程式では、スキッドナンバの他に気象条件や交通条件を入力信号、そして路面の表面温度を出力信号としたニューラルモデルの作成をおこなった。ここでの成果は以下のように要約される。

- 1) カルマンフィルターによる表現によって、直接的な計測が難しいすべり摩擦係数を路温の計測によって間接的に推定することが可能となった。
- 2) ニューラルモデルの導入によって、極めて非線形が強い冬期路面状態の変動過程と観測過程の定式

化が可能となった。同時に、拡張カルマンフィルターにおける微係数行列の導出が容易になった。

- 3) 2カ年の観測データを用いて有効性の検証を行い、ニューロモデルが学習能力に優れていること、影響要因分析が容易であることを明らかにした。
- 4) 未学習データに対しては、未だ十分な予測精度が得られなかったが、学習データ数の増加によってより精度の高い予測が期待できる。
- 5) 全天日射量、あるいは放射収支量などの日照の活動状況を表すデータが路面状態の推定・予測に重要な役割を果たしている。

今後は、観測データの充実や入力データの精選による予測精度の向上、あるいは予測のリードタイムの延長を通して予測システムの実用化を図る必要がある。本研究は、(財)佐川交通社会財団の研究助成によって実施された。記して謝意を表したい。また、観測調査およびデータ解析に多大な尽力をした大学院生松尾元君と山川賢吾君にも深く感謝したい。

参考文献

- 1) 有本: カルマンフィルター, 産業図書, 1979
- 2) 片山: 応用カルマンフィルター, 朝倉書店, 1980
- 3) 星谷・斉藤: 建設技術者のためのデータ解析と応用 鹿島出版, 1991
- 4) 日野・森・吉川: カルマンフィルターによる大気汚染の予測, 土木学会論文報告集, 第224号, pp. 79-90, 1974
- 5) 奥谷: カルマンフィルター理論を用いた道路交通状態の推定と予測, 土木学会論文報告集, 第289号, pp. 131-144, 1978
- 6) Cremer: Der Verkehrsfluß auf Schnellstraßen, Springer-Verlag, New York, 1979.
- 7) Nielsen R. H.: Neurocomputing. New York, Addison-Wesley, 1990
- 8) Wasserman P.: Neural Computing, New York, Van Nostrand Reinhold, 1989
- 9) NAKATSUJI, et. al: SNOW and ICE CONTROL SYSTEM BASED on SLIPPERINESS DATA TRANSMITTED by DRIVERS, Transp. Res. Rec., TRB (in press)
- 10) 和田・増田・奥住: 冬期の道路管理水準に関する一考察, 交通工学, Vol. 21, No. 1, pp. 25-35, 1986
- 11) 武市: 路面凍結の予測に関する研究, 土木学会論文集, No. 470, IV-20, pp. 175-184, 1993
- 12) 鈴木・天野・平間: 路面凍結予測手法に関する研究, ゆき, Vol. 11, pp. 69-77, 1993
- 13) 中辻・藤原・萩原・加来: 峠部における冬季の路面摩擦状態の予測手法について, 雪氷, Vol. 56, No. 4, pp. 353-361, 1994