

IV-59

冬期路面状態の短期予測手法に関する比較研究

北海道大学 学生員 花岡 真也

北海道大学 正 員 小野寺雄輝

北海道大学 正 員 中辻 隆

1. まえがき

路面状態、あるいは路面のすべりやす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化する。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なものではない。ここで、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面のすべりやす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を説明変量としてリアルタイムに路面のすべりやすさを予測するために、カルマンフィルタ^{1)~3)}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い、適用性の検証を行った。

2. ニューラル・カルマンフィルタ

2.1 カルマンフィルタ

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、

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

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

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

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

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

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。

また、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、線形化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。

2.2 ニューラルネットワークモデル

ニューラルネットワークモデル⁴⁾⁵⁾は脳の情報処理機構を数学的に模擬したモデルである。

本研究においては、入力層1層、中間層2層、出力層が1層の計4層の多層階層型のモデルを用いた。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。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

$$y_k^D = h \left(\sum_j W_{jk}^{CD} h \left(\sum_i W_{ij}^{BC} h(x_i^B) \right) \right) \quad (11)$$

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。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。

2.3 ニューラル・カルマンフィルター

路面のすべりの予測について、カルマンフィルター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。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な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ーの原理である。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・カルマンフィルターと名付けた。図-1に路面のすべりを予測するためのニューラル・カルマンフィルターの基本構造を示す。

(1) 状態方程式

冬期の路面状態を表す指標⁶⁾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値を状態変数として用いた。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、両変数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、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。

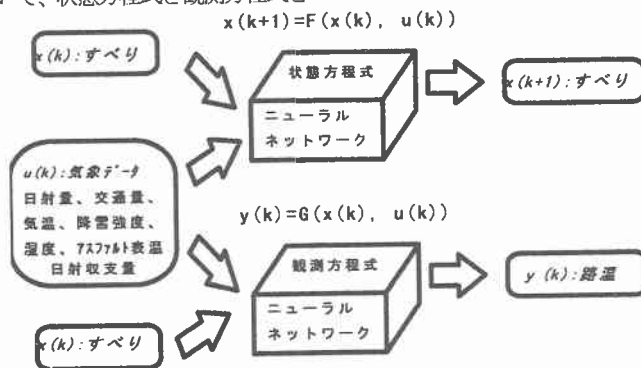


図-1 ニューラル・カルマンフィルターによる路面のすべり予測の概念図

3. 冬期の路面状態の予測

3.1 路面状況調査

1994年と1995年の12月に札幌市郊外の幹線道路(札幌市北区一般道札幌広島環状線)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の路温の測定を行った。また、同時に車種別の通過交通量の計数も行った。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に夕刻の調査も集中的に行っている。


3.2 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。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。


3.3 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-2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。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。また、今回は既存のモデルとして重回帰モデルとの比較を行った。



(1) 学習データ



(2) 未学習データ

図-2 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

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-3に、また、重回帰を用いて行った予測結果を図-4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。ニューロ・カルマンに関し、図-3(1)の結果は学習用データに対して行われたものであるで必然的な結果である。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。図-3(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)における応答が遅れがあり、スキッドナンバ値を過小に評価している。図-2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が、学習データの増加によって精度の改善を図ることが出来るものと思われる。一方、重回帰に関し、図-4では学習データ、未学習データともニューロ・カルマンよりも再現性が低いものとなっている。


4. まとめ

従来定式化が困難であった冬期の路面状態の短期予測を例として、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。ニューラルモデルの導入によって、極めて非線形が強い挙動の定式化が可能になった。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、あるいは未学習データにも今後の学習データの増加によってより精度の高い予測が期待できることなどの知見を得た。今後は、観測データの充実を通して予測精度の向上に努めたい。


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・斎藤:建設技術者のためのデータ解析と応用鹿島出版, 1991
- 4) Nielsen R.H.:Neurocomputing,New York,Addison-Wesley, 1990
- 5) Wasserman P.: Neural Computing, New York, Van Nostrand Reinhold, 1989
- 6) NAKATSUJI, et. al: SNOW and ICE CONTROL SYSTEM BASED on SLIPPERINESS DATA TRANSMITTED by DRIVERS, Transp. Res.

Rec., TRB (in press)




(1) 学習データ(12/15, 1995)




(2) 未学習データ(12/26, 1995)

図-3 路面のスキッドナンバの予測結果の実測値との比較 (ニューロ・カルマ)



(1) 学習データ(12/15, 1995)



(2) 未学習データ(12/26, 1995)

図-4 路面のスキッドナンバの予測結果の実測値との比較 (重回帰)