

ニューラルネットワークを用いた 冬季道路の舗装路面温度予測モデル

堀井雅史¹・加藤清也²・福田正³

¹正会員 工博 日本大学助教授 工学部土木工学科 (〒963-8642 福島県郡山市田村町徳定字中河原1)

²正会員 国際航業(株) 東北事業本部 (〒980-0852 宮城県仙台市宮城野区榴岡5-1-23)

³フェローメンバー 工博 宮城大学教授 事業構想学部デザイン情報学科 (〒980-3298 宮城県黒川郡大和町学苑1)

本研究は、凍結防止剤散布の効率化を支援するための、冬季道路の舗装路面温度予測モデルの構築を試みたものである。本研究では、ニューラルネットワークを用いることによって、3時間後の路面温度予測モデルを構築した。すなわち、舗装路面温度の時系列的変動を学習させることにより、3時間後の路面温度をかなりの精度で予測可能であることを示した。この予測モデルを用いることによって、路面凍結の予測が可能となり、効率的な凍結防止剤の事前散布が可能となる。

Key Words: pavement temperature forecast system, neural network, anti-icing

1. はじめに

道路交通体系の整備促進などにより雪国を取り巻く生活環境は大きく変化し、無雪地域と積雪地域の日常的交流がこれまで以上に広まっている。このような生活様式の変化に伴い、冬季間の道路交通に対する社会的ニーズもより高度なものとなってきている。

我が国においては環境問題への対応策の一環として、平成2年に「スパイクタイヤ粉塵の発生の防止に関する法律」が施行された。これにより冬用タイヤがスパイクタイヤからスタッドレスタイヤへと移行したが、スタッドレスタイヤは氷上での制動能力が劣るためスリップ事故が増加している。したがって、道路管理者は、冬季において道路交通を確保するために、凍結防止剤散布等を実施している。

しかし、凍結防止剤の散布は土壤や植生への環境問題、構造物の損傷を引き起こしている。また、一方で冬期間の交通に対する需要の高まりに伴い散布量は年々増加し、財政負担を高めている。

凍結防止剤散布の方法は、凍結の発生防止を目的とする事前散布と、雪氷の融解を目的とする事後散布に分けられる^{1,2)}。路面凍結前に凍結防止剤を散布し、ある濃度の水溶液になると、水より低い結氷点になる。また、路面温度が結氷点まで低下しても、氷の固相と塩水の液相が混在することで路面の水分

が完全に凍ることはない。このため凍結防止剤の事前散布は凍結防止効果が高く、凍結防止剤の使用量は事後散布の場合と比較して著しく減少できると言われている²⁾。

限られた財政の中、周辺地域への環境悪化を最低限に押さえながら冬季交通を確保するためには、事前に道路の路面温度が予測でき、路面凍結前に凍結防止剤散布を可能にするシステムの構築が要請されている^{3,4)}。また、現場での路面管理では、より簡便な手法が要求される。しかしながら、現状ではそのような実用的予測システムは構築されていない。

2. 既往の研究

凍結防止剤散布について長い経験を持つ欧米諸国では、散布量削減に向けて路面凍結予測の研究が進められている。イギリス^{4,5)}では気象観測機器を各地に設置し、そのデータより路面凍結予測システムの構築を行っている。またデンマーク⁶⁾では気象モデルと路面から地下への熱伝導モデルからなる路面凍結予測モデルを開発している。これらのモデルはいずれも熱収支および熱伝導によるモデルである。

一方、我が国においてもスパイクタイヤ禁止以来、路面凍結予測に関する研究が始まられている。まず、武市⁷⁾は、路面温度の変動パターンをフーリエ級数展開によって近似し、路面温度を予測するモデルと

熱収支解析モデルを提案している。さらに、予測曲線の上下1°Cの範囲の上限・下限予測曲線が0°Cを挟む時間帯で凍結が発生するとし、高い的中率が得られると報告している。井上、高田⁹⁾は熱収支および熱伝導解析による路面温度予測、路面温度のパターン解析による路面温度予測、さらに熱伝導方程式を基にした重回帰分析による路面温度予測モデルなどを提案し、予測モデルの検証を行っている。鈴木、天野、平間¹⁰⁾は気象観測所と気象台のデータより重回帰分析を用いた路面温度予測モデルを構築し、高い予測結果が得られていると報告している。

以上のように、既往の研究では様々な路面凍結予測モデルを構築しているが、予測精度を高めるためには、膨大な気象データを必要とし、さらに熱収支解析には各項目の熱量計算など複雑な過程が要求されている。また定量化の難しい要因の存在など課題も残されている。したがって、これらのモデルは様々な気象観測機器の設置された限られた地点にのみ適用可能であり、舗装の路面凍結が問題となる地点に直接に適用するというわけにはいかない。

これに対し、Fröhling¹⁰⁾は、路面温度の短時間予測のためにニューラルネットワークを用いている。このモデルは路面温度、気温、地下4cmの温度、風速、日照をそれぞれ並列に入力データとして、3時間後の路面温度を予測している。1993年の1月1日から3月31日までの学習結果からは、精度±1°C内の的中率61.5%，±1.5°C内で76.2%の結果が得られたと報告している。

本研究においても同様にニューラルネットワークを用いて路面温度の短期予測モデルを構築する。ただし、入力データは、汎用性を考慮してなるべく収集しやすいものとする。また、そのデータの時系列的変動特性をニューラルネットワークに学習させたモデル構築を試みる。このモデルの予測結果と実際の路面温度を比較することによって、本モデルの有効性を確認する。

3. ニューラルネットワークによるモデル構築

本研究で用いるニューラルネットワークは、階層型ネットワークで、学習には誤差逆伝播法(BP法)が用いられる。しかしながらBP法は、学習に長時間を要する、あるいは所定の回数で誤差が収束しない場合があるなどの欠点を有している。本研究では現場での適用を念頭に置いていため、少ない学習回数で収束が可能な拡張カルマンフィ

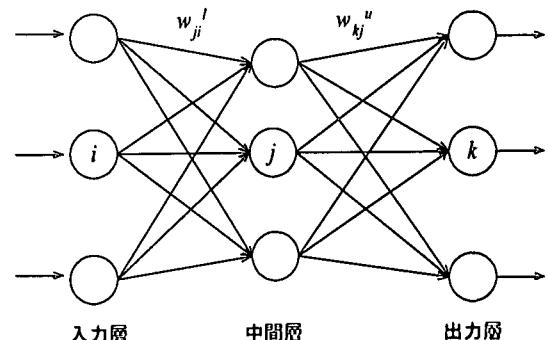


図-1 ニューラルネットワークモデル

ルタによるニューラルネットワーク¹¹⁾を用いて、路面温度予測モデルを構築する。

いま、図-1に示すような3層からなる階層型ニューラルネットワークを考える。入力層、中間層、出力層のユニット数をそれぞれ I, J, K とする。中間層、出力層に入出力関数を用いることにすれば、中間層第 j ユニット ($j=1, 2, \dots, J$)、出力層第 k ユニット ($k=1, 2, \dots, K$) の出力 o_j, y_k はそれぞれ次式のようになる。

$$o_j = f(u_j) \quad (1)$$

$$y_k = f(z_k) \quad (2)$$

ここで、 u_j, z_k はそれぞれ中間層第 j ユニット、出力層第 k ユニットへの入力値であり、次式で算出される。

$$u_j = \sum_{i=1}^I w_{ji}^l x_i, \quad z_k = \sum_{j=1}^J w_{kj}^u o_j \quad (3)$$

ここで、

w_{ji}^l ：入力層 i ユニットと中間層 j ユニット間のリンク結合加重

w_{kj}^u ：中間層 j ユニットと出力層 k ユニット間のリンク結合加重

x_i ：入力層 i ユニットへの入力データ

なお、しきい値 θ 、 α は、定数入力に対する重みと見なせるので、省略しても数式的には一般性を失わない。

入出力関数には次式のシグモイド関数を用いる。

$$f(x) = \frac{1}{1+e^{-x}} \quad (4)$$

学習は、教師信号ベクトルを y_{dk} とすると次式の出力層における誤差の2乗和の1/2が最小化されるように行う。

$$E = \frac{1}{2} \sum_{k=1}^K (y_k - y_{dk})^2 \quad (5)$$

通常は BP 法を用いて式(5)の評価関数を w_{ji}' , w_{kj}'' で偏微分し、これに刻み幅を乗じてそれぞれの修正量を決定する。しかしながら、前述のとおり、長時間の学習を要するなどの欠点があるため、ここでは、拡張カルマンフィルタ¹²⁾を用いて、ニューラルネットワークの学習を次のような非線形システムの状態推定問題として取り扱う。

$$w_{t+1} = F_t(w_t) + G_t v_t \quad (6)$$

$$y_t = h_t(w_t) + n_t \quad (7)$$

ここで、 w_t は n 次元状態ベクトル、 y_t は p 次元観測ベクトル、 F_t は $n \times n$ 状態遷移行列、 G_t は $n \times m$ 駆動行列で、それぞれ時間 t のみに依存する行列である。 v_t 、 n_t はそれぞれ m 次元プラント雑音、 p 次元観測雑音で、平均値 0、共分散行列が

$$E\left\{\begin{pmatrix} v_t \\ n_t \end{pmatrix} \begin{pmatrix} v_t^T & n_t^T \end{pmatrix}\right\} = \begin{pmatrix} Q_t & 0 \\ 0 & R_t \end{pmatrix} \delta_{tt} \quad (8)$$

なるベクトルとする。また w_t は v_t 、 n_t とは独立と仮定する。初期状態 w_0 は平均値 \bar{w}_0 、共分散行列 $E\left\{\left[w_0 - \bar{w}_0\right] \left[w_0 - \bar{w}_0\right]^T\right\} = \Sigma_0$ のガウス確率ベクトルとする。ただし、ここではシナプス結合加重が状態ベクトルであり、時間に依存しない定数であると考えられる。このような定常的なシステムに誤差の混入はないと仮定できることから、プラント雑音は削除する。また、式(6)の状態方程式には時間軸について一定であるという条件をつける目的で状態遷移行列に単位行列 I を選ぶ。したがって、状態方程式(6)は次式となる。

$$w_{t+1} = I w_t \quad (9)$$

実際の計算では、時間軸を反復計算軸と考えることになる。

式(7)の $h_t(w_t)$ は p 次元非線形ベクトル関数で、 w_t について微分可能と仮定する。

いま、非線形関数 h_t が滑らかであるという仮定の下に、式(7)を推定値 \hat{w}_{t+1-1} の近傍で近似的に線形化する。なお、 \hat{w}_{t+1-1} は現在(t)より 1 ステップ前($t-1$)のデータに基づく現在の状態量の推定値である。

$$h_t(w_t) = h_t(\hat{w}_{t+1-1}) + H_t(w_t - \hat{w}_{t+1-1}) + \dots \quad (10)$$

ここで、 H_t は

$$H_t = \left(\frac{\partial h_t}{\partial w_t} \right)_{w=\hat{w}_{t+1-1}} \quad (11)$$

で定義される $p \times n$ 行列である。式(10)の高次の項を無視すれば、

$$y_t = H_t w_t + n_t + h_t(\hat{w}_{t+1-1}) - H_t \hat{w}_{t+1-1} \quad (12)$$

となる。ここで、

$$\eta_t = y_t - h_t(\hat{w}_{t+1-1}) + H_t \hat{w}_{t+1-1} \quad (13)$$

とおくと、式(12)は

$$\eta_t = H_t w_t + n_t \quad (14)$$

となる。すなわち、ここで用いる拡張カルマンフィルタのアルゴリズムは以下のようになる。

$$\hat{w}_{t+1} = \hat{w}_{t+1-1} + K_t [y_t - h_t(\hat{w}_{t+1-1})] \quad (15)$$

$$K_t = P_{t+1-1} H_t^T (H_t P_{t+1-1} H_t^T + R_t)^{-1} \quad (16)$$

$$P_{t+1} = P_{t+1-1} - K_t H_t P_{t+1-1} \quad (17)$$

ここで、 \hat{w}_{t+1} は現在(t)より 1 ステップ前に計算されたシナプス結合加重の推定値 \hat{w}_{t+1-1} にある修正量を加えて得られる現在の推定値を示す。 K_t は、現在 t において計算されるカルマンゲインを、 P_{t+1} は現在より 1 ステップ前のデータに基づく推定誤差共分散行列を示す。

以上のアルゴリズムにおいて、ベクトル y_t を教師データ、 $h_t(\hat{w}_{t+1-1})$ を計算出力とすれば、パラメータの推定が可能である。

4. ケーススタディ

(1) 使用したデータ

路面温度予測のケーススタディに用いたデータは、日本道路公団郡山管理所管内の東北自動車道観測地点のデータ¹³⁾である。分析対象地点は盛土区間 1 地点(以下 A 地点と呼ぶ)と切土区間 1 地点(B 地点と呼ぶ)の計 2 地点とした。これは盛土区間と切り土区間では舗装の路面温度変動が異なると考えたからである。収集した期間は平成 8 年 1 ~ 2 月、平成 9 年 1 ~ 2 月であり、その内容は各時間ごとの路面温度、気温、地中温度(5cm), 地中温度(10cm), 風速、風向、時間雨雪量などである。

(2) 温度予測モデル

温度予測モデルとして適用したニューラルネットワークモデルは入力層、中間層 1 層、出力層の 3 層構造とする(図-2)。入力値に上述の変数の時

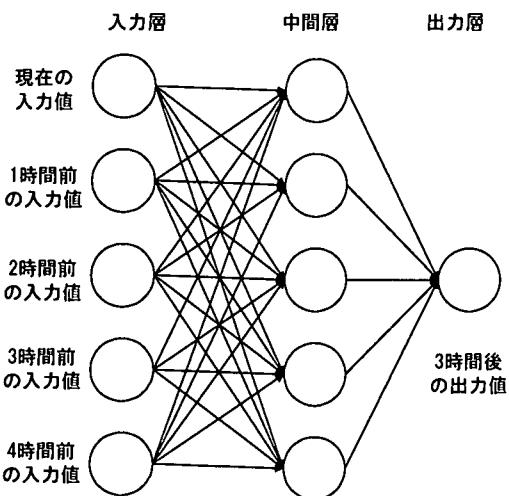


図-2 温度予測モデル

表-1 入力変数の違いによる相関係数
(A 地点・盛土区間)

入力 変数	入力 ユニット数	中間 ユニット数	相関係数	
			再現時	予測時
気温	5	9	0.929	0.749
路面温度	5	10	0.969	0.875
地中温度 (5cm)	5	10	0.956	0.771
地中温度 (10cm)	5	8	0.948	0.686

系列的変動値を用い、出力値としては、3時間後の路面温度とした。この3時間後という数字は、路面凍結する前に凍結防止剤散布車が出動し、散布が完了する時間に相当する^{1,6)}。この入出力値に対し、中間層のユニット数を変化させて、モデル構造を決定した。

モデルの評価はモデルの再現性能と予測性能について検討を行った。ここで、再現性能とは学習済みのニューラルネットワークモデルに学習データを入力した場合の再現性の高さを示す。また、予測性能とは学習済みニューラルネットワーク(以下学習モデルと呼ぶ)に新しい学習データを入力した際の予測精度の高さを意味する。

(3) モデル構造の決定

モデル構造の決定に当たっては、再現性能のみならず、予測性能についても検討を行う必要がある。これは、再現性能はモデル構造を複雑にし、あるいは学習回数を増やすことによって、学習結

表-2 入力変数の違いによる相関係数
(B 地点・切り土区間)

入力 変数	入力 ユニット数	中間 ユニット数	相関係数	
			再現時	予測時
気温	5	5	0.900	0.825
路面温度	5	7	0.905	0.862
地中温度 (5cm)	5	6	0.912	0.750
地中温度 (10cm)	5	7	0.882	0.830

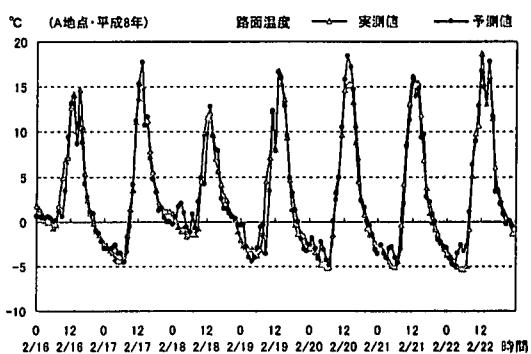


図-3 路面温度に関する再現結果

果は実測値に近づくが、この学習モデルに新たな学習データを入力して予測を試みた場合、必ずしも良好な予測性能が得られない場合がある。したがって、モデル構造の決定の際には、再現性能をある程度確保しつつ、予測性能も有するモデルを構築する必要がある。

表-1にA地点における各入力変数に対して、入力ユニット数および中間ユニット数を変化させた場合の最良な分析結果を示す。同様に表-2にはB地点の同様な結果を示す。なお、学習期間は平成8年2月16日0時から2月22日23時までとし、入力ユニット数は3～8時間、中間ユニット数は4～11とした。なお、中間ユニット数11においてはほとんど学習が不能であった。学習回数については、入力変数が路面温度の場合について、50回、100回、150回、200回で学習させた結果、学習回数を増加させても精度の向上があまり見られなかつたため、実用性を考慮してすべて100回としている。この学習モデルに対し、統く平成8年2月23日0時から2月29日23時までの路面温度を予測させたときの相関係数を合わせて示した。表-1、表-2とも入力ユニット数は5としたが、これは以下の理由による。

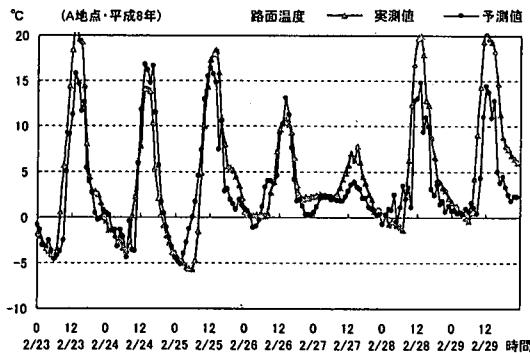


図-4 学習モデルによる予測結果

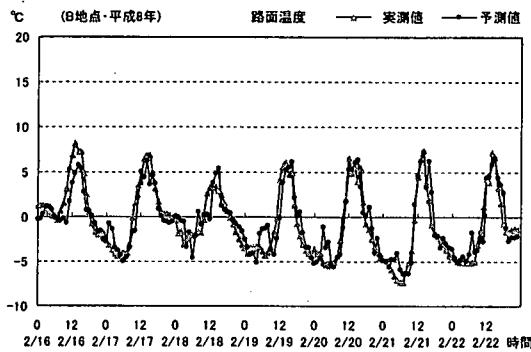


図-5 路面温度に関する再現結果

入力ユニット数をさらに増加させると、学習時の相関係数は向上するが、続く1週間を予測した場合、相関係数は必ずしも向上せず、予測波形が振動するなどの問題が生じる。すなわち、過度の多入力を行った場合、その時系列的変動パターンに類似した場合は良いが、異なる変動パターンの場合には予測性能が低下した。

表-1、表-2によれば入力変数を路面温度とした場合、最も良好な結果が得られた。図-3にA地点の再現結果を、図-4に予測結果を示す。また図-5、図-6にはB地点の同様の結果を示す。なお、当時の気象状況、路面状態についてであるが、本研究で対象とした道路区間は、路面凍結前に凍結防止剤を散布する管理体制がとられているため、通常の場合、路面凍結状態はあまり出現しない。また、各地点とも直接天候、路面状態を計測しておらず、各地点に最も近い観測地点の結果(毎日9時、15時のみ計測)から推測すれば、次のようにあった。

まず、A地点に関しては、再現性能の検討に用いた期間中、2月18日9時の天候は雪で時間雨雪量が3cm、路面状態は湿潤であり、2月22日9時

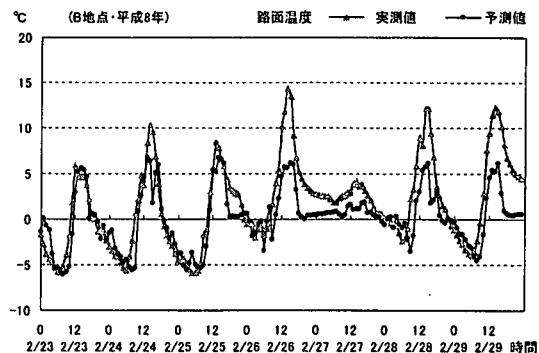


図-6 学習モデルによる予測結果

に粉雪が降った。予測性能の検討に用いた期間では、2月26日9時に降雪が5cmあり、路面状態は湿潤であった。それ以外は晴れか曇りであり、路面状態は乾燥である。B地点においては、再現期間中2月18日9時に6cmの降雪があり、路面状態は湿潤であった。予測期間では、2月26日9時に7cmの降雪があり、路面状態は湿潤、2月27日9時の路面状態は湿潤である。それ以外はA地点と同様に晴れか曇りで路面状態は乾燥であった。このように一部の期間で気象状況、路面状態に変化が見られたが、いずれの結果においても路面温度の変動をかなり正確に再現、予測しているといえる。

その他の入力変数については、予測に関して波形の振動がより大きいと判明した。また、入力変数の組み合わせについて検討した結果、たとえば路面温度3ユニット、風速3ユニットとした6入力ユニットに対して、再現時の相関係数0.971、予測時の相関係数が0.841であり、路面温度とその他の入力変数との組み合わせによって、必ずしもモデルの精度は向上しなかった。また、路面温度2ユニット、風速2ユニット、時間雨雪量2ユニットを入力とした場合、再現時の相関係数が0.922、予測時の相関係数が0.716と入力変数を増加させると、逆に精度が低下した。すなわち、路面温度の短期予測に関しては、その入力ユニットに他の気象要因またはその組み合わせによるものよりも、時系列路面温度データを直接的に使用することがよいと判明した。したがって、路面温度の予測に関しては、路面温度の時系列データを入力データとするモデルを構築することにした。路面温度はデータ収集が比較的容易にできるため、以後路面温度の時系列的変動を基に3時間後の路面温度予測性能について検討を行った。

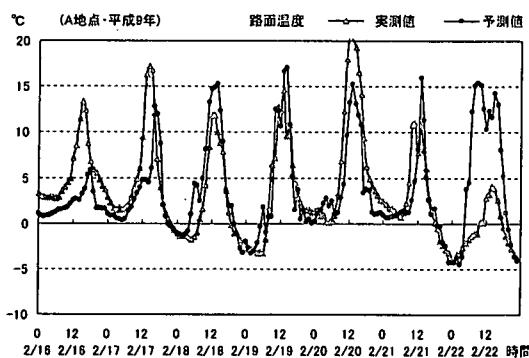


図-7 学習モデルの予測性能の検討

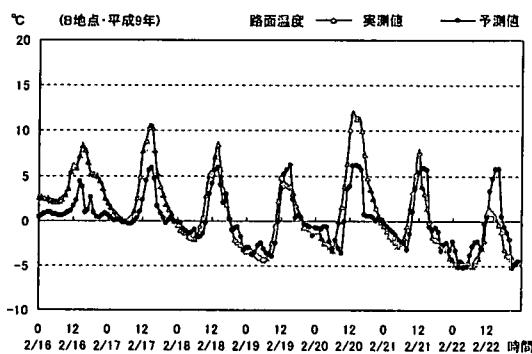


図-8 学習モデルの予測性能の検討

表-3 本モデルによる適合数(A 地点)

予測値	$\leq 0^{\circ}\text{C}$	$> 0^{\circ}\text{C}$
実測値		
$\leq 0^{\circ}\text{C}$	28	11
$> 0^{\circ}\text{C}$	2	60
的中率	(28+60)/101=0.871	

表-4 重回帰モデルによる適合数(A 地点)

予測値	$\leq 0^{\circ}\text{C}$	$> 0^{\circ}\text{C}$
実測値		
$\leq 0^{\circ}\text{C}$	34	5
$> 0^{\circ}\text{C}$	26	36
的中率	(34+36)/101=0.693	

5. 予測性能の評価

ここでは、学習モデルの予測性能についての検討を行った。具体的には、上記の路面温度を入力変数として構築された学習モデル(表-1、表-2の入力変数が路面温度の場合)を用いて、1年後の平成9年2月16日～22日の1週間のデータに対して予測を行った。その結果と重回帰モデルを用いた

表-5 本モデルによる適合数(B 地点)

予測値	$\leq 0^{\circ}\text{C}$	$> 0^{\circ}\text{C}$
実測値		
$\leq 0^{\circ}\text{C}$	64	1
$> 0^{\circ}\text{C}$	10	26
的中率	(64+26)/101=0.891	

表-6 重回帰モデルによる適合数(B 地点)

予測値	$\leq 0^{\circ}\text{C}$	$> 0^{\circ}\text{C}$
実測値		
$\leq 0^{\circ}\text{C}$	63	2
$> 0^{\circ}\text{C}$	6	30
的中率	(63+30)/101=0.921	

路面温度予測手法による結果(以下重回帰モデルと呼ぶ)^{9),10)}と比較することによって、本モデルの予測性能の評価を試みた。なお、平成9年のデータを用いた理由は、重回帰モデルによる予測システムが平成9年から当該区間において運用開始されたためである。

予測性能の評価は、次のような予測値と実測値の適合数によって行った。

①対象とするデータとして19時～翌日9時までの夜間データを用いる。

②3時間後の路面温度予測値と実測値を、 0°C 境界として、的中1(実測値が 0°C 以下で予測値も 0°C 以下)、的中2(実測値が 0°C を越え予測値も 0°C を越える)、危険側誤判別(実測値が 0°C 以下に対し、予測値が 0°C を越える)、安全側誤判別(実測値 0°C を越えるのに対し、予測値が 0°C 以下)の4群に分類する。

③的中率を算出する。

図-7にA地点に関する予測結果を示す。4.(3)で述べた気象データによれば、2月21日9時から降雪があり、2月22日9時での路面状態が圧雪であることから実測値の波形が変化しており、路面温度のプラス側の予測は必ずしも適合していない場合があるものの、路面温度が 0°C 付近の変動についてはかなり正確に予測していることが分かる。

図-8は同様にB地点に関するものである。この場合も2月22日の路面状態が圧雪であり、予測波形の若干の乱れがあるものの 0°C 付近の路面温度の変動を的確に表している。

表-3にA地点における本モデルによる予測値と実測値の適合数を示す。表-4には重回帰モデルによる適合数を示した。これらによると、A地点に関しては、本モデルの的中率が0.871、重回帰モデルによる的中率が0.693と重回帰モデルによる予測結果を若干上回る結果が得られた。

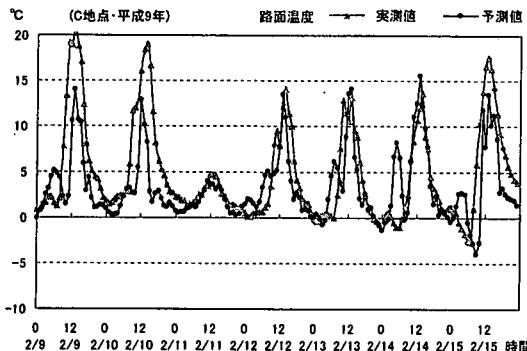


図-9 学習モデルの予測性能の検討

表-7 A 地点の予測モデルによる適合数
(C 地点・1週間予測)

実測値 \ 予測値	$\leq 0^\circ\text{C}$	$> 0^\circ\text{C}$
$\leq 0^\circ\text{C}$	5	11
$> 0^\circ\text{C}$	11	78
的中率	$(5+78)/105=0.790$	

表-8 A 地点の予測モデルによる適合数
(C 地点・1か月予測)

実測値 \ 予測値	$\leq 0^\circ\text{C}$	$> 0^\circ\text{C}$
$\leq 0^\circ\text{C}$	65	73
$> 0^\circ\text{C}$	29	250
的中率	$(65+250)/417=0.755$	

表-5、表-6は同様に B 地点に関する分析結果である。この場合は、本モデルの的中率が 0.891、重回帰モデルの場合が 0.921 となった。

なお、路面状態が変化した場合の的中率については、前述のとおり路面状態が推測であることから断言はできないが、図-7、図-8の波形から判断すると、A 地点では的中率が若干低下する可能性があるが、B 地点に関してはほとんど変化しないと考えられる。

以上のように、本モデルによる路面温度の予測は、重回帰モデルによる予測システムと同等の予測性能を有していると判断される。

最後に、構築された予測モデルの実用性について評価を試みた。すなわち、本モデルが予測地点、予測期間が異なった場合に路面温度の予測性能を有しているかについて検討を行った。このために、盛土区間である A 地点で構築した学習モデルを用いて、そこより 16km 離れた盛土区間(C 地点とする)の路面温度の予測を試みた。予測期間は平成 9 年 2 月 9 日 0 時～2 月 15 日 23 時の 1 週間お

よびこれを含む平成 9 年 2 月 1 日～2 月 28 日の 1 か月間とした。

図-9に C 地点の 1 週間にに関する予測結果を示す。これによると、0 °C 付近の変動はかなりの精度で予測できており、異なる条件下でも予測が可能であることを示している。また表-7、表-8にそれぞれ 1 週間、1 か月間の適合数を示した。1 週間予測に関しては、本モデルによる的中率が 0.790 に対して、重回帰モデルによる的中率が 0.771 であった。1 か月間予測については本モデルの的中率が 0.755、重回帰モデルのそれが 0.832 であり、長期間の路面温度予測にも適用可能であると考えられる。

6. まとめ

本研究は、ニューラルネットワークを用いて、実用的な舗装路面温度の短期的予測システムの構築を目指したものである。本研究で得られた主な成果は、次のとおりである。

路面温度予測モデルとして、ニューラルネットワークの適用が可能であることを示した。この場合、入力変数は路面温度とし、5 ユニットのデータを時系列的に学習させた場合が最も良好であった。

予測性能について、重回帰モデルによる場合と比較し、これと同程度の成果が得られることが分かった。本モデルで必要とするデータは路面温度のみであり、現場で適用できる実用性を有していることを確認した。

今後の課題としては、路面凍結は舗装の路面温度が氷点下になり、さらに路面上に水分が存在する場合に発生することから、路面の水分検知システムと総合した、路面凍結予測システムの構築を目指す予定である。その際、凍結防止剤散布前後の路面温度変動についても十分検討する必要がある。これについても今後の課題である。

謝辞：資料収集に当たり、日本道路公団東北支社保全企画課長阿部公一氏、郡山管理事務所維持助役渋谷優氏のご協力をいただいたことに謝意を表します。

なお本研究は、(社)東北建設協会より助成を受けて行った研究成果の一部である。

参考文献

- 日本建設機械化協会編：道路除雪ハンドブック，pp. 156-164, 1993.
- Curtailing usage of de-icing agents in winter maintenance, OECD, Road Transport Research, pp. 1-125, 1989.

- 3) Manual of practice for an effective anti-icing program, A guide for highway winter maintenance personnel, Federal Highway Administration; Electronic Version of Publication No. FHWA-RD-95-202, 1996.
- 4) Rayer, P.J.: The meteorological office forecast road surface temperature model, *Meteorological Magazine*, Vol.116, pp.180-191, 1987.
- 5) Shao, J., Thornes, J.E. and Lister, P.J.: Description and verification of a road ice prediction model, *Transportation Research Record*, Vol.1387, pp.216-222, 1993.
- 6) Voldborg, Henrik: On the prediction of road conditions by a combined road layer- atmospheric model in winter, *Transportation Research Record*, Vol.1387, pp.231-235, 1993.
- 7) 武市靖：路面凍結の予測に関する研究，土木学会論文集，No.470/W-20, pp.175-184, 1993.
- 8) 井上元哉, 高田吉治:路面凍結の予測システム, 雪氷, 33巻, 4号, pp. 239-257, 1971.
- 9) 鈴木立見, 天野和祐, 平間照一: 路面凍結予測手法に関する研究, 日本道路公団試験研究所報告, Vol.30, pp.179-190, 1993.
- 10) Fröhling, P. W.: Ein neuronales netz zur kurzzeit-temperaturprognose auf straßen, IX PIARC International Winter Road Congress Technical Report, pp.601-608, 1994.
- 11) 村瀬治比古, 小山修平, 石田良平: パソコンによるカルマン・ニューロコンピューティング, 森北出版, 1994.
- 12) 片山徹: 応用カルマンフィルタ, 朝倉書店, 1983.
- 13) 日本道路公団郡山管理所: 気象観測データ一覧(平成8年・9年).

(1998.8.19 受付)

PAVEMENT TEMPERATURE FORECAST MODEL USING NEURAL NETWORK FOR MAINTAINING WINTER ROADS

Masafumi HORII, Kiyonari KATO and Tadashi FUKUDA

An examination was made of a method of forecasting pavement surface temperatures by the neural network computing system. The neuro-model can be used to forecast the pavement surface temperature after 3 hours and warn when it will drop below freezing. By using this neuro-model, it is possible to adopt an effective anti-icing practice for maintaining winter roads.