

舗装路面凍結予測システムの構築

堀井雅史¹・福田正²

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フェロー会員 工博 宮城大学副学長・教授 事業構想学部 (〒980-3298 宮城県黒川郡大和町学苑1)

本研究は、凍結防止剤の事前散布を支援する冬季道路の路面凍結予測システムの構築を目指したものである。このために、ニューラルネットワークと判別分析を用い、路面温度の時系列的変動と路面上の水分の有無を検知するモデルを構築し、これらを統合することにより、3時間後の路面凍結予測システムを確立した。本予測システムを適用した結果、3時間後の路面凍結を実用的に高い精度で予測可能であることが明らかとなった。

Key Words : pavement ice prediction, anti-icing, neural network, discriminant analysis

1. はじめに

我が国において、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、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。しかしながら、スタッドレスタイヤは氷上での制動能力が劣るため、冬季における路面管理は積雪寒冷地において重要な課題となっている。このために道路管理者は、冬季において凍結防止剤散布等を実施しているが、凍結防止剤の散布は土壌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、水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³⁾。

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、事前に道路の路面凍結が予測でき、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^{2),3)}。この場合、現場での路面管理では、より簡便な予測手法が要求される。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。著者ら⁴⁾は、ニューラルネットワークを用いて実用性を考慮した路面温度予測モデルを提案した。本研究では、さらにこれを路面凍結予測システムに発展させることを試みた。

2. 既往の研究

路面温度予測あるいは路面凍結予測については、欧米諸国において数多くの研究がなされている。たとえば、イギリス^{5),6)}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⁷⁾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、我が国においては、井上、高田⁸⁾が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⁹⁾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。武市¹⁰⁾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℃の範囲の上限・下限予測曲線が0℃を挟む時間帯で凍結が発生するとし、高い中率が得られると報告している。

以上のように、既往の研究では様々な路面温度あるいは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。また急激に変動する風や雲の影響や路面状態に左右されるパラメータ(たとえばアルベド、湿潤度)を、路面状態予測時にどのように入力すべきかといっ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一般的に適用するというわけにはいかない。これに対して著者ら⁹⁾はニューラルネットワークを用いて、路面温度の時系列的変動を学習させることにより、より簡便な方法で3時間後の路面温度を実用的に高い精度で予測可能であることを示した。ただし、この研究では路面凍結予測までは至っていない。

3. 路面凍結予測システム

(1) ニューラルネットワーク

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、学習には少ない学習回数で収束が可能な拡張カルマンフィルタによるニューラルネットワーク^{9),10),11)}を用いる。

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、出力層に出入力関数を用いることにすれば、中間層第 j ユニットの ($j=1,2,\dots,J$)、出力層第 k ユニットの ($k=1,2,\dots,K$)での出力 o_j, y_k はそれぞれ次式のようになる。

$$o_j = f(u_j) = f\left(\sum_{i=1}^I w_{ji}^l x_i\right) \quad (1)$$

$$y_k = f(z_k) = f\left(\sum_{j=1}^J w_{kj}^u o_j\right) \quad (2)$$




図-1 ニューラルネットワークモデル

ここで、

u_j : 中間層第 j ユニットへの入力値

z_k : 出力層第 k ユニットへの入力値

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

である。なお、しきい値 θ_j, α_k 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。

$$f(x) = \frac{1}{1+e^{-x}} \quad (3)$$

学習は、教師信号ベクトルを y_{ak} 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。

$$E = \frac{1}{2} \sum_{k=1}^K (y_k - y_{ak})^2 \quad (4)$$

通常はBP法を用いるが、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を用いて、ニューラルネットワークの学習を非線形システムの状態推定問題として取り扱う。最終的に得られ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。

$$\hat{w}_{t/t} = \hat{w}_{t/t-1} + K_t [y_t - h_t(\hat{w}_{t/t-1})] \quad (5)$$

$$K_t = P_{t/t-1} H_t^T (H_t P_{t/t-1} H_t^T + R_t)^{-1} \quad (6)$$

$$P_{t/t} = P_{t/t-1} - K_t H_t P_{t/t-1} \quad (7)$$

ここで、 $\hat{w}_{i,t}$ は現在 (t/t) より 1 ステップ前に計算された n 次元シナプス結合加重の推定値 $\hat{w}_{i,t-1}$ にある修正量を加えて得られる現在の推定値を示す。 $h_i(w_i)$ は p 次元非線形ベクトル関数で、各層への入力値にシグモイド関数を施した出力層での関数形である。 H_i は

$$H_i = \left(\frac{\partial h_i}{\partial w_i} \right)_{w=\hat{w}_{i,t-1}} \quad (8)$$

で定義される $p \times n$ 行列である。 K_t は、現在 t において計算されるカルマンゲインを、 $P_{i,t}$ 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。

したがって、計算手順は 1 ステップ前に計算されたシナプス加重の推定値を用いて式 (8) の H_i を計算し、式 (6) のカルマンゲインの計算を行うと、式 (5) においてベクトル y_t が教師データ、 $h_i(\hat{w}_{i,t-1})$ が計算出力であるので、現在のシナプス加重の推定値が得られる。なお、初期値には乱数を入力しているが、このアルゴリズムの場合、共分散行列の推定を工夫する事により、収束速度を高めていることが示されている¹³⁾。

(2) 判別分析

判別分析は、いくつかの群がすでに与えられており、新しい個体がどの群に属するかを多変量の観測値を基に分類する手法である¹³⁾。

いま、母集団分布の平均ベクトルが

$$\mu^{(1)}, \mu^{(2)}, \dots, \mu^{(G)}$$

で与えられ、分散共分散行列が各群共通で $\Sigma = (\sigma_{rr})$ であるような G 個の群からそれぞれ大きさ m_1, m_2, \dots, m_G の個体が得られているとする。ここでどの群に属するか不明の R 変量の観測値 $x = (x_1, x_2, \dots, x_R)$ が得られたとし、これを G 群のどれかに判別することを考える。

観測値 x と各群の重心 $\mu^{(g)}$ ($g=1, 2, \dots, G$) との距離を次式で定義する。

$$\Delta_{(g)}^2 = (x - \mu^{(g)})' \Sigma^{-1} (x - \mu^{(g)}) \quad (9)$$

ここで式中の「 $'$ 」は転置を意味する。この距離が最小になる群に x を判別すればよい。

そこで、未知の平均ベクトルおよび分散共分散行列に対する推定値として、それぞれ

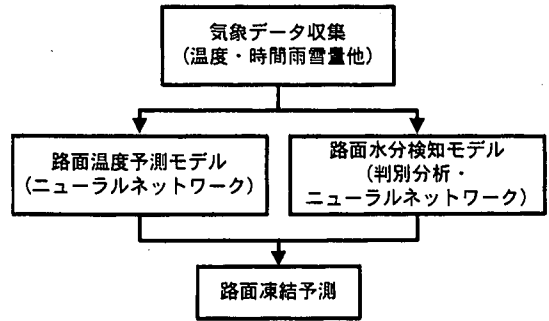


図-2 路面凍結予測システムの構成

$$\bar{x}^{(g)} = \frac{1}{m_g} \sum_{l=1}^{m_g} x_l^{(g)} \quad (10)$$

$$S = \frac{1}{m-G} \sum_{g=1}^G \sum_{l=1}^{m_g} (x_l^{(g)} - \bar{x}^{(g)}) (x_l^{(g)} - \bar{x}^{(g)})' \quad (11)$$

を用いて

$$D_{(g)}^2 = (x - \bar{x}^{(g)})' S^{-1} (x - \bar{x}^{(g)}) \quad (12)$$

を最小にする群 g に判別する。ここで $x_l^{(g)}$ は g 群の l 番目の観測ベクトル、 m は総個体数を示す。式 (12) の x の 2 次項は g によらず一定であるので、式 (12) を最小にする g を求めることは次式の線形関数 $q_g(x)$ を最小にすることと同じである。

$$q_g(x) = x' S^{-1} \bar{x}^{(g)} - \frac{1}{2} \bar{x}^{(g)'} S^{-1} \bar{x}^{(g)} \quad (13)$$

したがって、新しい個体の分類は各群ごとに設定される式 (13) の線形判別関数を算出し、その最大値を与える群に分類すれば良い。

(3) 予測システムの構成

路面凍結は、路面温度が 0°C 以下になり、水分が存在する場合に発生する現象であることから、路面温度予測モデルと路面水分検知モデルを構築し、これらを総合することにより、路面凍結予測システムを作成する。以上の手順を図-2に示す。すなわち、すでに構築されている路面温度予測モデル¹⁴⁾と今回構築する路面水分検知モデルを組み合わせることで路面凍結予測システムを構築する。




図-3 路面温度予測モデル

4. 予測システムの検証

(1) 使用したデータ

使用したデータは、日本道路公団郡山管理所内の東北自動車道および磐越自動車道各1地点の観測結果である¹⁴⁾。東北自動車道の観測地点は切り土区間(A地点とする)であり、磐越自動車道の観測地点は盛土区間(B地点とする)である。収集した期間は、平成8年1～2月、平成9年1～2月とし、その内容は、各時間ごとの路面温度、気温、車道部における地中温度(5cm)、地中温度(10cm)、風速、時間雨雪量である。また、2地点とも直接路面状態を観測していないので、A地点に関しては9.0km南方の各時間帯別路面状態観測データを、B地点では5.0km西方の同路面状態観測データを収集した。さらにアメダスデータ(日照時間)を追加した^{15)、16)}。

(2) 路面温度予測モデル

まず、路面温度予測モデルをニューラルネットワークによって構築する。路面温度予測に用いるニューラルネットワークは入力層、中間層1層、出力層の3層の階層型ニューラルネットワークとする(図-3)。前回の研究⁹⁾で、路面温度予測には路面温度の時系列データを入力するのが最も良いという結果が得られているので、入力層には路面温度の時系列データを入力し、出力層には3時間後の路面温度を出力するモデルを構築した。この3時間は、路面凍結する前に凍結防止剤散布車が出勤し、散布が完了する時間に相当する¹⁾。この入出力値に対し、中間層のユニット数を変化させ、モデル構造を決定した。

表-1 入力時間による相関係数の変化

入力時間数	相関係数	
	再現時	予測時
3	0.933	0.875
4	0.945	0.848
5	0.951	0.855
6	0.955	0.838
7	0.962	0.827
8	0.963	0.822

注1)分析地点は既往の著者論文⁹⁾におけるA地点(本研究のA地点とは異なる)。

注2)学習期間は平成8年2/16～2/22、予測期間は平成8年2/23～2/29である。

注3)中間ユニット数は5である。

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(以下学習モデルと呼ぶ)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、予測性能とは学習モデルに新しい未学習データを入力した際の予測精度の高さを意味する。

なお、路面温度予測モデルを構築するにあたり、入力時間数を5時間とし、学習回数を100回としているが、これは以下の理由による。すなわち、入力時間数を増加させると、再現性能は向上するが、必ずしも予測性能が向上しないこと(表-1)、また学習回数を増加させても精度の向上が見られないことが既往の研究成果より得られているためである。学習期間は平成9年1月1日0時から1月31日23時までとし、続く2月1日0時から2月28日23時までを予測用データとした。

表-2にA地点における中間ユニット数を変化させた場合の再現時と予測時の相関係数を示す。同様に表-3にB地点の結果を示す。なお、表中で数値が記入されていないところは学習不能であったケースである。これらによると、1か月間の学習および予測について、ある程度の精度を有していることがわかる。図-4、図-5にはA地点での中間ユニット数7の場合の再現時、予測時の結果を示す。図-6、図-7にはB地点の中間ユニット数8の場合の同様の結果を示す。これらによると、プラス側の高い路面温度で実測値と予測値の乖離が見られる。ニューラルネットワークの場合、学習データの範囲内のデータに対しては妥当な出力結果を示すが、その範囲を超えるデータを入力した場合には、乖離した出力結果を示す場合がある。このことが上記の結果に対する原因として考えられ

表-2 中間ユニット数の違いによる相関係数
(A地点・切り土区間)

中間 ユニット数	相関係数	
	再現時	予測時
5	0.855	0.837
6	0.844	0.821
7	0.856	0.840
8	0.863	0.814
9	-	-
10	-	-

表-3 中間ユニット数の違いによる相関係数
(B地点・盛土区間)

中間 ユニット数	相関係数	
	再現時	予測時
5	0.789	0.700
6	0.789	0.694
7	0.794	0.717
8	0.795	0.718
9	0.789	0.711
10	-	-

る。これに対して、0℃付近の変動は、実測値を正確に追従しており、路面凍結予測には十分な精度を有していると判断できる。

表-4、表-5は上記の結果に対して、路面温度を0℃で分類した場合の適合数を示したものであり、高い的中率が得られた。

(3) 路面水分検知モデル

ここでは、路面の水分検知モデルを変数選択式の判別分析とニューラルネットワークの2種類の方法によって構築を試みた。出力は両者とも3時間後に路面上の水分が存在するか否かの0, 1変数となる。ここで路面上の水分なしとは、路面状態が乾燥の場合であり、その他は水分ありとした。

入力変数は、判別分析における変数選択の検討結果とし、最終的にA地点は各時間帯の日照時間、時間雨雪量、天候ダミー変数(0:晴れ・曇り, 1:雨・雪)、B地点は日照時間、天候ダミー変数とした。ニューラルネットワークの場合も各地点ごとに同じ変数とし、それぞれ2時間分を入力変数とした。このネットワークに対し、中間層のユニット数を変化させてモデル構築を行った。なお、前述のとおり、路面状態が各観測箇所直接観測されていないので、2地点とも離れた地点の路面状態を用いた。

表-6、表-7に判別分析を用いた場合のA, B地点における適合数を示す。表-8には各地点ごとの判別分析結果を示す。ここで、各データは表中の判別係




図-4 学習モデルによる路面温度の再現結果(A地点)




図-5 学習モデルによる路面温度の予測結果(A地点)

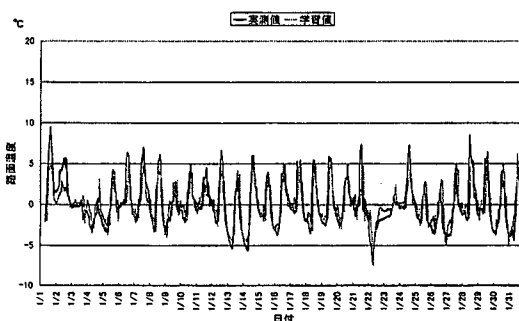


図-6 学習モデルによる路面温度の再現結果(B地点)




図-7 学習モデルによる路面温度の再現結果(B地点)

表-4 路面温度予測モデルによる適合数(A地点)

a) 再現時 平成9年1月

	予測値	≤ 0℃	> 0℃
実測値			
≤ 0℃		361	70
> 0℃		37	269
的中率		(361+269)/737=0.855	

b) 予測時 平成9年2月

	予測値	≤ 0℃	> 0℃
実測値			
≤ 0℃		279	32
> 0℃		47	314
的中率		(279+314)/672=0.882	

表-5 路面温度予測モデルによる適合数(B地点)

a) 再現時 平成9年1月

	予測値	≤ 0℃	> 0℃
実測値			
≤ 0℃		329	100
> 0℃		58	250
的中率		(329+250)/737=0.786	

b) 予測時 平成9年2月

	予測値	≤ 0℃	> 0℃
実測値			
≤ 0℃		308	49
> 0℃		50	265
的中率		(308+265)/672=0.853	

数を用いた判別関数による得点が高いグループに判別されることになる。なお、B地点において時間雨雪量が5%の有意水準で選択されなかった。これは、B地点では時間雨雪量に高い値が観測されておらず(1群の平均値:0.000mm/h, 2群の平均値:0.075mm/h)、判別に寄与していないことが原因と考えられる。表-9、表-10にはニューラルネットワークによる路面水分検知モデルの適合数を示す。これらによると、全体的な中率は高い。これに対して、水分あり的中率は52~59%であり、あまり高い値とはいえない。これに関しては、水分ありに該当する路面状態は湿潤、水べた雪、圧雪、凍結を含むものであり、これらすべての路面状態を、本研究で用いている入手しやすいデータで予測することは困難であることを示している。これらについては今後の課題としたいが、このような条件下で路面凍結がどの程度予測可能かについて検討するため、以下のような路面凍結予測を試みた。

(4) 路面凍結予測

ここでは、路面温度の予測結果と路面の水分検

表-6 判別分析を用いた路面水分検知モデルによる適合数(A地点)

a) 再現時 平成9年1月

	予測値	水分あり	水分なし
実測値			
水分あり		114	90
水分なし		6	527
的中率		(114+527)/737=0.870	

b) 予測時 平成9年2月

	予測値	水分あり	水分なし
実測値			
水分あり		65	55
水分なし		10	542
的中率		(65+542)/672=0.903	

表-7 判別分析を用いた路面水分検知モデルによる適合数(B地点)

a) 再現時 平成9年1月

	予測値	水分あり	水分なし
実測値			
水分あり		192	180
水分なし		24	341
的中率		(192+341)/737=0.723	

b) 予測時 平成9年2月

	予測値	水分あり	水分なし
実測値			
水分あり		168	144
水分なし		24	336
的中率		(168+336)/672=0.750	

表-8 判別分析結果

	A地点			B地点		
	判別係数		偏F値	判別係数		偏F値
	1群	2群		1群	2群	
日照時間	2.084	1.008	14.18**	2.469	1.061	23.39**
時間雨雪量	0.120	2.451	58.64**			
天候ダミ	0.293	6.978	445.8**	0.554	3.348	211.1**
定数	-0.319	-2.040		-0.273	-0.900	
F値	193.5**			134.4**		

注 1) 判別関数は $q = \alpha * (\text{日照時間}) + \beta * (\text{時間雨雪量}) + \gamma * (\text{天候}) + \delta$ となる。 $\alpha, \beta, \gamma, \delta$:判別係数。

注 2) 1群:水分なしグループ、2群:水分ありグループ。

注 3) F値、偏F値の**は有意水準1%で有意であることを示す。

知の予測結果を総合して、3時間後の路面凍結予測

表-9 ニューラルネットワークを用いた路面水分検知モデルによる適合数(A地点, 中間ユニット数5)

a) 再現時 平成9年1月

予測値 \ 実測値	水分あり	水分なし
水分あり	121	83
水分なし	6	527
的中率	$(121+527)/737=0.879$	

b) 予測時 平成9年2月

予測値 \ 実測値	水分あり	水分なし
水分あり	67	53
水分なし	15	537
的中率	$(67+537)/672=0.899$	

表-10 ニューラルネットワークを用いた路面水分検知モデルによる適合数(B地点, 中間ユニット数6)

a) 再現時 平成9年1月

予測値 \ 実測値	水分あり	水分なし
水分あり	204	168
水分なし	25	340
的中率	$(204+340)/737=0.738$	

b) 予測時 平成9年2月

予測値 \ 実測値	水分あり	水分なし
水分あり	178	134
水分なし	26	334
的中率	$(178+334)/672=0.762$	

システムの構築を試みた。具体的には、路面温度が0℃以下となり、路面に水分が検知された場合に凍結が発生するとして路面凍結を予測するものである。ここで、ニューラルネットワークによる路面温度予測モデルと判別分析による路面水分検知モデルを組み合わせたものを路面凍結予測システムⅠとし、両者ともニューラルネットワークで作成したものを路面凍結予測システムⅡと呼ぶことにする。なお、凍結防止剤散布によって、0℃以下でも凍結しない状態が発生するが、これを把握するためには凍結防止剤散布実績あるいは路面上の残留塩分濃度のデータが必要となる。今回これらのデータを手に入らなかったため、ここでは0℃を基準として予測モデル構築を行った。

表-11、表-12に2地点における路面凍結予測システムⅠによる適合数を示す。同様に表-13、表-14に2地点における路面凍結予測システムⅡによる適合数を示した。これらによると、両地点とも再現時および予測時において比較的高い中率が得

表-11 路面凍結予測システムⅠによる適合数(A地点)

a) 再現時 平成9年1月

予測値 \ 実測値	凍結する	凍結しない
凍結する	12	0
凍結しない	70	655
的中率	$(12+655)/737=0.905$	

b) 予測時 平成9年2月

予測値 \ 実測値	凍結する	凍結しない
凍結する	20	4
凍結しない	22	626
的中率	$(20+626)/672=0.961$	

表-12 路面凍結予測システムⅠによる適合数(B地点)

a) 再現時 平成9年1月

予測値 \ 実測値	凍結する	凍結しない
凍結する	43	17
凍結しない	74	603
的中率	$(43+603)/737=0.877$	

b) 予測時 平成9年2月

予測値 \ 実測値	凍結する	凍結しない
凍結する	43	5
凍結しない	78	546
的中率	$(43+546)/672=0.876$	

られた。また2つのシステムとも同程度の精度を有しており、本論文で示した路面凍結予測システムは、実用上耐える再現性能と予測性能を有していると考えられる。なお、路面水分検知モデルにおいて、水分ありの適合数が少ないのに対して、路面凍結の適合数が高かったのは、以下の理由による。水分ありの状態は、前述のとおり路面湿潤、水べた雪、圧雪、凍結をすべて含むものであり、誤判別されたものは湿潤、水べた雪、圧雪状態が多く含まれると考えられる。これに対して、凍結状態に関しては、正しく判別されたものの中に多く分類されており、その結果、これらすべての路面状態を予測することは難しいが、凍結状態については正確に予測されていると考えられる。

また、誤判別については以下のようなものである。まず冬季路面管理上問題となる危険側誤判別(実測値:凍結, 予測値:凍結せず)についてはその割合が0~28%に分布しているが、特に予測時において10%程度であり、さほど問題にはならないであろう。これに対して、安全側誤判別(実測値:凍結せず, 予測値

表-13 路面凍結予測システムⅡによる適合数(A地点)

a) 再現時 平成9年1月

予測値 \ 実測値	凍結する	凍結しない
凍結する	12	0
凍結しない	72	653
的中率	$(12+653)/737=0.902$	

b) 予測時 平成9年2月

予測値 \ 実測値	凍結する	凍結しない
凍結する	20	4
凍結しない	24	624
的中率	$(20+624)/672=0.958$	

表-14 路面凍結予測システムⅡによる適合数(B地点)

a) 再現時 平成9年1月

予測値 \ 実測値	凍結する	凍結しない
凍結する	44	16
凍結しない	80	597
的中率	$(44+597)/737=0.870$	

b) 予測時 平成9年2月

予測値 \ 実測値	凍結する	凍結しない
凍結する	43	5
凍結しない	82	542
的中率	$(43+542)/672=0.871$	

:凍結)に対しては 14 ~ 48%となっている。この原因として考えられることは、前述したように、凍結防止剤散布により、氷点降下あるいは水と氷の混合により0℃では完全に凍結しないことが考えられる。これについては、高速道路が高度に管理された道路であることを考えると、今後凍結防止剤散布実績に関する資料を収集する事によって、路面温度の基準値を適正に設定できれば、モデルの改良が可能であると考えられる。

5. まとめ

本研究は、実用的な舗装路面凍結の短期的予測をめざし、路面温度予測モデルと路面水分検知モデルから成るシステムの構築を試みたものである。本研究で得られた主な成果は、次のとおりである。

路面温度の予測モデルとして、ニューラルネットワークの適用が可能であることを確認した。

路面の水分検知モデルを判別分析とニューラルネットワークによって構築を試みたところ、同程度

の判別能力を有していることを確認した。

両者の結果を総合して、舗装路面の凍結予測システムの構築を行い、実用的な再現性能と予測性能を有していることを明らかにした。本システムは入手しやすい変数を用いてシステム構築を行っており、路面凍結が問題となっている地点に容易に適用可能である。

今回のケーススタディにおいて、予測精度に若干の課題が認められたが、予測作業の難易さと予測に伴う費用を考慮すれば、本研究による予測手法は簡便であり、実用性が高いと考えられる。

今後の課題は、上記の問題点を踏まえてさらに適用実績を増やし、路面凍結予測システムの精度を向上させ、汎用性の確認することと、線的予測可能性の検討などが考えられる。これについては継続研究としたい。

謝辞：本研究を遂行するに当たり、日本道路公団東北支社に観測データの提供を頂いた。さらにデータ処理について大学院学生田原隆之氏(現新潟県勤務)に多大なるご協力を頂いた。深く感謝いたします。

なお、本研究は、平成12年度日本大学工学部研究費の助成を受けて行った研究成果の一部である。

参考文献

- 1) 日本建設機械化協会編：道路除雪ハンドブック，pp. 156-164, 1993.
- 2) Curtailling 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) 堀井雅史, 加藤清也, 福田正：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, 土木学会論文集, No. 620/V-43, pp. 271-278, 1999.
- 5) Rayer, P.J.: The meteorological office forecast road surface temperature model, *Meteorological Magazine*, Vol.116, pp.180-191, 1987.
- 6) 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.
- 7) 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.
- 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) 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/IV-20, pp.175-184, 1993.

- 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) 田中豊, 垂水共之: 統計解析ハンドブック, 共立出版, 1995.
- 14) 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).
- 15) (財)気象業務支援センター:平成9年アメダス観測年報, 1997.
- 16) (財)気象業務支援センター:平成10年アメダス観測年報, 1998.

(2000.5.16 受付)

PAVEMENT ICE PREDICTION SYSTEM IN WINTER MAINTENANCE

Masafumi HORII and Tadashi FUKUDA

A prediction model using a neural network and discriminant analysis to predict pavement freezing after three hours is proposed to increase the efficiency of anti-icing programs. The results of the present study revealed that the pavement freezing in three hours can be predicted with considerable precision by combining the pavement surface temperature prediction model and the detection model of pavement wetness.