

IV-24

冬期道路の路面状態予測モデルに関する研究

北海道大学工学部 学生員 松 尾 元
正 員 萩 原 亨
正 員 加 来 照 俊

1. はじめに

わが国では「脱スパイク」が進む一方、環境問題や経済性あるいは気象条件の厳しさの面から凍結防止剤の大量使用は困難である。このため、いつどこでどのような路面が現れているかを迅速かつ正確に知ることが冬期道路の路面管理において重要な課題になっている。

本研究では路面状態の予測を行うためにニューラルネットワークモデルを適用する。ニューラルネットワークモデルは論理的モデルの作成が困難な場合に適応でき、過去の研究においてもその有効性が実証されている。予測には、時系列的に変化する気象データを主に用いた。

2. ニューラルネットワークモデル

神経回路網（ニューラルネット）は神経細胞（ニューロン）が多数結合して何らかの信号を出す一つのシステムである。ニューロンは図1に示すように他のニューロンから入力を受け取るとともに関数作用を受けた出力を他のニューロンへ伝える機能をもっている。また、各ニューロン間の結合の重みはシナプス荷重といわれる。

今、シナプス結合の強度を W_{ij} とすると i 番目のニューロンが受け取る入力 U_i は

$$U_i = \sum_{j=1}^N W_{ij} V_j + I_i \quad (1)$$

であたえられる。 I_i は外部からの i 番目のニューロンへの入力である。入力 U_i を受け取ったニューロンは、以下の関数に従って出力 V_i を出す。

$$V_i = f(U_i / \mu) \quad (2)$$

ここで関数 f は、 μ の値によって傾きが変わるシグモイド型の単調増加関数である。

図2に示す5層モデルを例として説明する。図2でA層は入力層、B、C、D層は中間層、及びE層は出力層と言われる。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




図1 神経細胞の工学的モデル




図2 多層階層型ニューラルネットワークモデル

路面状態予測モデルの入力に用いたデータの構成は、年月日・時刻・路面・気温・日照・積雪・降雪・除雪・降雪の有無・交通量の10種類である。これらのデータは、前述した気象データ、交通量データと路面状態のデータを組み合わせたものである。

図3は、平成4年1月と2月の路面状態の構成率をインター別に並べたものである。図4から図6は、路面状態と気温・降雪量・日照時間のデータをまとめたものである。気温が0℃以上ではほとんど雪氷路面がないのに対して、0℃以下では50%以上が雪氷路面になる。また日照時間が長くなれば、雪氷路面の構成率は直線的に減少することが分かる。

4. 路面状態予測へのニューラルネットワークモデルの適用とその結果

4. 1ニューラルネットワークモデルの適用

本研究では、2節で述べた逆伝搬法を路面状態の予測に用いた。入力信号は、予測する数時間前の気象データと路面状態及び予測する時刻の気象データとした。出力信号は、予測する時刻の路面状態である。

路面状態の予測に用いたネットワークの構造を図7に示す。入力するデータは、予測する時刻の気温・日照時間・積雪量・降雪量・除雪の有無・降雪の有無・交通量の7個のデータと、数時間前の同様なデータ及び路面状態である。

入力値は、すべて0から1の数値になおしてそれぞれ1個のニューロンに入力する。路面状態は、乾燥、湿潤、凍結、積雪の4種類を4個のニューロンを用いてパターンで入力する。従って、入力層のニューロン数は予測する時刻の観測データで7個、数時間前の観測データで7個、及び路面状態の4個を加えて計18個となる。中間層のニューロン数は、過去の経験から出力層と同数の4個とした。教師信号と予測結果のRMS誤差が2.5以下になるまで学習を繰り返した。

路面状態予測モデルとして望ましいのは、路面の変化に追従できることである。しかし、観測されたデータでは、路面状態が変化しないケ




図5 降雪量別路面出現率




図6 日照時間別路面出現率




図7 予測に用いたニューラルネットワークモデル




図8 観測した路面状態と予測の時間的変動

ースが圧倒的に多い。例えば、降雪後においては凍結路面が数日間に渡って連続したり、あるいは路面が一度乾燥すれば数日間連続する。そこで、学習に用いるデータでは路面状態が変化するケースと変化しないケースをほぼ同数にした。また、地理的影響を考慮して地域別に学習した。全学習データ数は3,095ケース用意し、そのデータの路面構成は、乾燥が最も多く50%であり、次に凍結(25%)、湿潤(21%)、積雪(4%)であった。

4. 2予測の結果

地域別に学習したシナプスデータを用いて各地域別に各々3インターの路面状態を予測した。学習する計算時間は、計算速度が20MIPS程度の計算機で10時間程度必要であった。

図8に路面の観測データと予測データの時間的変動を比較した結果を示す。縦軸には便宜的に乾燥から積雪の順に並べた。前の時間での路面状態の影響が大きくひとつ遅れでの追従が目立った。

表1にすべてのデータの路面の変化別の的中状況を示す。乾燥路面と湿潤路面では、的中率が6割を越えた。路面状態が変化しないケースは積雪路面を除いて的中率が高かった。特に湿潤路面では93.9%であった。路面状態の変化のあるものでは、積雪から乾燥、凍結から湿潤、積雪から凍結と気温の高くなる方向が良い結果となった。また、積雪を予測できたものはなかった。その理由として学習データに占める積雪路面の構成率が4%と低いことが挙げられる。

5. まとめ

本研究は、路面状態を予測する手法としてニューラルネットワークモデルを適用したものである。その結果は、現時点では満足できるレベルには達していない。改良すべき課題としては、学習データの構成が挙げられよう。

最後になりましたが、本研究の基礎データを提供していただいた日本道路公団札幌建設局の関係各位に感謝の意を表する次第です。

参考文献：加来、他：冬期道路交通情報システムに関する研究、北海道土木技術会道路研究委員会平成2年度調査研究報告書、平成3年3月

表 1 路面予測の的中率

路面の変化	予測した路面	的中した個数	データ数	的中率 (%)
1→1	1	7256	10582	68.57
2→1	1	70	879	7.964
3→1	1	38	458	8.297
4→1	1	24	37	64.86
	1	7388	11956	61.79
1→2	2	244	789	30.93
2→2	2	2094	2229	93.94
3→2	2	182	453	40.18
4→2	2	11	47	23.40
	2	2531	3518	71.94
1→3	3	32	485	6.598
2→3	3	24	352	6.818
3→3	3	1934	3902	49.56
4→3	3	146	328	44.51
	3	2136	5067	42.16
1→4	4	0	100	0.0
2→4	4	0	58	0.0
3→4	4	0	254	0.0
4→4	4	0	109	0.0
	4	0	521	0.0
		12055	21062	57.24

表中の路面 [1:乾燥 2:湿潤 3:凍結 4:積雪]