

冬期路面管理指標の評価に関する研究

An Analysis on index evaluation of road surface control in winter

北海道大学大学院工学研究科 ○学生員 浜田 直樹 (Naoki Hamada)
 北海道大学大学院工学研究科 正会員 中辻 隆 (Takashi Nakatsuji)
 北海道自動車短期大学 茄子川 捷久 (Katsuhisa Nasukawa)

1. まえがき

北海道の冬期において、スパイクタイヤの使用規制後、交通渋滞に加え、交通事故の多発によって死亡者数、交通事故件数は増加している傾向があり、交通事故対策として凍結路面対策が大きな課題の一つとなっている。わが国では、路面状態分類によって路面管理を行っており、観測が容易である一方、その分類が路面状態を必ずしも反映しないという問題がある。海外の路面管理活動においては、極めて正確な路面状態を表現することのできる、滑り摩擦係数を指標として用いており、道路管理者が提供するサービス水準を細かいレベルに分け、摩擦係数の測定を行い、その値が規定のサービスレベルを満たしていない場合、早急に薬剤散布による摩擦係数の回復に努めている。しかし、すべり摩擦係数は、空間的・時間的に変動が激しく、測定法が確立できていないのが現状である。そこで、本研究は冬期路面管理指標としてのスキッドナンバー（以下SN：滑り摩擦係数を100倍したもの）を、他の気象データ・交通関連データなどの説明変量によって代替的に表現する事を目的とする。

2. 本研究のフロー

以下に本研究のフローを示す。




図-1 本研究のフロー

説明変量として、気温、路温、全天日射量、放射収支量、湿度、交通量を用い、分類パターンとして、午前・午後それぞれにおける、SNの増加・減少傾向別にCM△散布の有無を考慮した8パターンである。複雑な変動を示す路面状況、気象状況等のデータ群について、これまで3年間の観測により観測データを増やしてきたが、類似したデータの出現により収束しにくいものとなつて

きた。そこで、本研究ではデータの集約化の過程において、Kohonen Feature Map（以下K.F.M）というニューラルネットワークの一種のモデルを用いてデータの集約化を行った。集約されたデータ群について主成分分析を行い、SNと各主成分の主成分得点との相関を見る。更に、重回帰分析を適用する事によりそのSN代替重回帰式の確立を行い、新しい観測データによるSNの予測を試みる。午前・午後それぞれにおいてSNの増加・減少傾向を示す部分が存在するが、午前におけるSNの減少傾向、午後におけるSNの減少傾向ではSNの変化に影響する説明変量は同様ではないことは、明白である。

3. Kohonen Feature Map

K.F.Mは2層からなるネットワークを形成する。第1層は入力層、第2層は競合層と呼ばれ、一般的には2次元グリッド状に形成される。2つの層のニューロンは、全て第1層から第2層へと結合している。図-2にその基本構造を示す。




図-2 K.F.Mの基本構造図

入力パターンが与えられると、各結合間には結合ウェイトが与えられ、その値はネットワークの学習中に更新される。コホーネンネットの第1段階は、競合層の各ニューロンのマッチング値を計算することである。この値は、入力パターンの値に応じて各ニューロンのウェイトがマッチングするかどうかを測るものである。ニューロン*i*のマッチング値は、ベクトルEとU_iとの距離に相当するので、 $\sqrt{\sum (e_i - u_{ij})^2}$ と表す事が出来る。このマッチング値の最も低い値のニューロンが競合に勝つ。ここでベストマッチのニューロンをニューロン*c*とすると、*c*は、 $\|E - U_c\| = \min\{\|E - U_i\|\}$ と表すことができる。

勝利ニューロン決定後、次にそのNeighborhood（以下NGH）を決定する。NGHは、図-3に示すように、勝利ニューロン*c*を中心とした、四角形内のニューロンからなる。ウェイトは、勝利ニューロンのNGH内の全

てのニューロンについて学習過程に更新する。

KFMの入力パターンは $E=[e_1, e_2, e_3, \dots, e_n]$ 、ウェイトは $U_i=[u_{i1}, u_{i2}, u_{i3}, \dots, u_{in}]$ と表すことができる。この調整の結果、勝利ニューロンとそのNGHのウェイトは修正され、入力パターンに近づくようになる。競合に勝つような勝利ニューロンは、その後入力パターンと同じか似たような値として表せられる。




図-3 NGH概念図

3. SNの予測モデルの構築

本研究では、全天日射量の存在しない、日没後のSNの増加・減少傾向、散布の有無の4パターンについてKFMを適用した。データ数は、増加傾向散布有り44個、散布無し26個、減少傾向散布有り98個、散布無し78個であり、一律20個に集約させている。

3.1 KFMの適用

この過程においては、前述したようにKFMを用いて、収束しにくいデータの集約化を行う。図-4に減少傾向散布有りの路温を例にとって、KFMによる集約後の変化を示す。




図-4 原データと集約後データのプロット図

図-4は、98個から20個に集約したものであるが、類型化したにも関わらず、元のデータは各路温帯において幅広くSNが変化しているのが分かる。又、KFM適用後の集約データは、ほとんどの路温帯をカバーできていることがわかる。他の変量についても同様の結果を得ることができた。

3.2 主成分分析結果

3.1において集約された、4つのパターンのデータに主成分分析を適用した。その結果を表-1に示す。主成分分析を用いることによって、各説明変量間同士の相関を考慮する必要がなくなり、気温や路温など相関が高

いが、説明変量として除くことのできない変量も取り入れることができる。このことにより、各主成分をSNの代替説明変量として重回帰分析に適用することができる。しかし、破棄すべき相関値の最低ラインを見定めることはできない。この検討については次節で行う事とする。

表-1 SNと各主成分得点との相関

増加傾向	第1主成分	第2主成分
散布有り	0.019	0.797
散布無し	0.808	0.287
減少傾向	第1主成分	第2主成分
散布有り	0.536	0.833
散布無し	0.680	0.250

3.2 重回帰分析結果

この過程では、各パターンの主成分を説明変量に用いて重回帰式を求める。その結果を表-2に示す。

表-2 重回帰式

		偏回帰係数	t値	決定係数	f値
増加散布有り	第1主成分	0.066	0.128	0.6351	14.796
	第2主成分	2.830	5.438		
増加散布無し	第1主成分	5.583	6.461	0.7343	23.496
	第2主成分	1.980	2.292		
減少散布有り	第1主成分	3.511	15.902	0.9807	432.044
	第2主成分	5.459	24.723		
減少散布無し	第1主成分	5.501	6.045	0.7099	20.805
	第2主成分	2.048	2.251		

表-1の増加傾向散布有りの第1主成分は、SNとの相関0.019、重回帰分析によるt値0.128、更に、決定係数を減少させる傾向があるので、第1主成分はSNを代替する説明変量としては有用ではないことを示している。

他の説明変量については、全てt値=2.11、f値=3.5915を超えており、又、SNとの相関が0.3近辺の主成分を説明変量に加えることによって、決定係数が向上する傾向があるため、この相関値を目安として、説明変量としての有用性を検証することができるのではないかとと思われる。この点については継続して検討を行う必要がある。以上のことより、全てのパターンの回帰精度は、SN代替指標として期待できる数値であると思われる。

4. おわりに

今後の課題として、全天日射量存在下のパターンについて同様の作業を行い、そのパターン特有の回帰式を確立した後に、観測データによるSNの予測を行い、その予測値の検証も重ねて行う。更に、新しい観測データから、SNの変動パターンを判別する判別分析の適用を試みる。これにより、新しい観測データからSNの変動パターンの判別を行う事ができると考えられる。

参考文献

1) 北海道大学交通工学講座：冬期路面管理に関する調査報告書、1994～1997。
2) J.dayhoff-原著 桂井 浩一訳：ニューラルネットワークアーキテクチャ入門、森北出版株式会社。