

単年度の舗装路面データによる ニューロパフォーマンスモデルの構築

齋藤 雅道¹・福田 正²

¹学生員 東北大学大学院情報科学研究科博士課程前期 (〒980-77 仙台市青葉区荒巻字青葉)

²フェロー員 工博 東北大学大学院情報科学研究科教授 (〒980-77 仙台市青葉区荒巻字青葉)

アスファルト舗装のパフォーマンスモデルとして、著者らは舗装設計式を利用したニューラルネットワークによるパフォーマンスモデルの構築方法について既に報告した²⁾。この場合には、再学習のデータとして1地点における多年度の経年的なデータを必要とした。本研究においては、幾つかの地域における単年度の舗装路面データを対象とすることによって、パフォーマンスモデルを構築する方法を検討した。

Key Words : performance, neural network, AASHTO equation

1. はじめに

ニューラルネットワークによりアスファルト舗装のパフォーマンスモデルを構築する場合、学習のために多様な属性を持つ比較的大量の供用履歴データを使用する必要がある¹⁾。そこで、著者らは、舗装設計式に基づいたニューラルネットワークによる舗装のパフォーマンスモデル(以下、本論文においてはニューロモデル)を構築する方法について既に報告した²⁾。この方法においては、再学習のためのデータは1地点でよいが、多年度の経年的なデータを用いるために、データの入手に長期間を要する。そこで、本研究においては、学習データとして幾つかの地点における単年度の舗装路面データを用いることで、パフォーマンスモデルを構築する方法を検討した。

2. ニューロパフォーマンスモデル

(1) AASHTO 設計式

米国のAASHTO指針³⁾の舗装設計式を、ニューロパフォーマンスモデルの基本学習データとして用いた。この舗装設計式の諸量を、わが国において使用されている諸量に変換を行うと式(1)のようになる。

$$0.98 \cdot \log(W) = 9.36 \log(T_A / 7.26 + 1) - 1.34 + 2.32 \log(CBR) + \frac{\log((\Delta MCI - 7.2) / 1.12 + 6.43)}{0.4 + 1094 / (TA / 7.26 + 1)^{5.19}} \quad (1)$$

ここで、

W : 累積大型車交通量 (台)

CBR : 路床土の設計 CBR (%)




図-1 ニューロパフォーマンスモデル

T_A : アスファルト舗装の等値換算厚 (cm)

ΔMCI : 初期供用性指数 MCI_0 と終局供用性指数 MCI_t との差

(2) ニューロモデル

本研究においては、舗装のパフォーマンスモデルの予測手法として Perceptron (階層) 型のニューラルネットワークを適用し、学習アルゴリズムとして BP (Back Propagation) 法による学習を行う。

本研究においては、入力層3ユニット、中間層4ユニット、出力層1ユニット構造のニューラルネットワークを用いる(図-1)。また、次に示す計算手順に基づいて学習を行う²⁾。

STEP1 : 式(1)を用いて、基本学習データのための出力を行う。

STEP2 : **STEP1** で出力された数値データを基にニューラルネットワークの学習を行い、基本ニューロモデルを構築する。

STEP3 : **STEP2** で作成された基本ニューロモデルを、実測データを用いて再学習を行い、修正ニューロモデルを構築する。

表-1 供用履歴に関する実測データ⁴⁾

NO	調査箇所	CBR	T _A	上段										MCI									
				下段										累積大型車交通量 (万台)									
実測年度 (昭和)				47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63			
0	弘前市 (7)	10.0	24.2									7.2	6.8	5.2	4.7	4.2	5.0						
												131	176	229	278	328	371						
1	陸ヶ関 (7)	10.0	19.8	7.7	7.4	4.2	5.1																
				119	144	171	191																
2	種市町 (45)	4.0	21.0	8.1	8.2	8.1	7.8	7.0	6.6	5.6	5.5	5.6	5.4	5.2	5.0	4.7	4.5	4.1					
				19	27	36	41	52	60	71	89	107	122	140	160	181	195	215					
3	紫波町 (4)	4.0	32.0										7.8	7.3	6.6	6.0	5.6						
													109	192	265	349	419						
4	三戸町 (4)	5.0	29.5									7.5	7.0	6.6	6.1	5.3							
												132	193	266	348	430							
5	盛岡市 (46)	10.0	26.4									8.3	7.9	7.3	7.0	6.4	6.3						
												30	53	83	120	173	198						
6	能代市 (7)	19.0	24.0										7.9	7.0	6.3	5.8	5.3						
													111	166	211	274	327						
7	十文字 町(13)	10.0	24.0									8.1	7.9	7.4	6.3	5.8	5.0	3.3					
												75	114	157	201	232	276	326					
8	柴田町 (4)	9.2	27.3	7.6	7.6	7.5	6.8	6.2	5.9	5.7	5.0	4.8	4.2	3.8									
				118	227	363	417	548	663	788	923	1052	1167	1305									
9	亶理町 (6)	5.0	31.6	7.8	7.7	7.5																	
				78	146	209																	
10	白石市 (4)	3.0	33.1									8.2	7.7	7.3	6.9	6.5	6.1	5.7	5.3				
												62	138	221	306	392	451	539	633				
11	いわき 市(6)	8.0	33.1									7.0	6.5	6.0	5.4								
												115	175	242	349								
12	山形市 (13)	10.0	28.2	8.0	7.6	7.3	7.0	6.0	3.4	3.3													
				237	294	358	405	519	563	654													
13	立川町 (47)	10.0	23.0	7.9	7.4	6.9	5.9	5.4	5.3	5.2													
				102	135	179	206	256	299	342													
14	鶴岡市 (112)	6.0	28.0									8.6	8.2	8.0	7.8	7.6	7.5	7.2	7.1				
												20	34	50	69	91	112	136	138				

注：表中のゴシック体の数字は昭和 61 年度の実測データを示す。

3. 東北地方の事例

東北地方におけるアスファルト舗装の供用履歴に関する実測データ (表-1)⁴⁾において、累積大型車交通量、CBR、T_Aなどが適度の範囲に分布している昭和 61 年度の 4 箇所の実測データを利用する場合について、次の 2 つの方法でニューロモデルを構築し、両者を比較した。

(1) 実測データのみによる場合 (ケース 1)

4 個の実測データによって 30000 回の学習を行い、ニューロモデルを構築した。構築されたニューロモデルの適合性の検証には、表-1 の 14 箇所、96 個の

実測データを用いた。このように、4 個の実測データのみでニューロモデルを構築した場合、出力 MCI と実測 MCI の関係は図-2 に示すとおりで、両者の相関係数は 0.55 である。

(2) 舗装設計式で補完する場合 (ケース 2)

2. (2) に述べた方法によりニューロモデルを構築する。この場合、まず式(1)による 5615 個の数値データを 30000 回学習させ、基本ニューロモデルを構築した。次に、この基本ニューロモデルを 4 個の実測データによって 10000 回の再学習を行い、修正ニューロモデルを構築した。この場合の出力 MCI と実測 MCI の関係は図-3 に示すとおりで、相関係数は




図-2 実測値と出力値の比較 (ケース1)




図-3 実測値と出力値の比較 (ケース2)




図-4 NO.2 (種市町) の場合

0.78 である。路面の状態が悪い $MCI < 5$ の領域では両者のばらつきは大きい。通常の道路管理において対象となる $MCI > 5$ の領域では両者は比較的よく合致している。

(3) パフォーマンス曲線の出力例

ケース (1) の方法では東北地方のアスファルト舗




図-5 NO.7 (十文字町) の場合




図-6 NO.3 (紫波町) の場合




図-7 NO.10 (白石市) の場合

装のパフォーマンス予測を行うことは難しい。ケース (2) の方法で作成されたニューロモデルは、実測データのばらつきを考慮すれば、アスファルト舗装のパフォーマンスを良好に表現していると言える。構築したニューロモデルに累積大型車交通量、 T_A 、設計 CBR を入力することにより、 MCI を出力することができる。図-4~図-7は、累積大型車交通量と MCI との関係、すなわちパフォーマンス曲線を、舗

装条件 (T_d , 設計 CBR) のもとで出力し, これを実測データと比較した例である.

地方建設局の貴重な資料を使用させていただいた. ここに深く感謝の意を表します.

5. むすび

ニューロパフォーマンスモデルを構築するためには, 実測データの入手に長い期間を必要とする. そこで, 本研究においては, 舗装設計式 (AASHTO 式) による基本モデルを作成し, 幾つかの地点において単年度に測定された少数の実測データを用いて再学習し, ニューロパフォーマンスモデルを構築する方法を示した.

構築されたニューロモデルは, さらに経年的に測定された新しいデータによって再学習し, その信頼性を高めることができる. また, このようにデータを継続的に測定することによって, その調査箇所の一連のデータのニューロモデルからの乖離状態を検討することも可能である.

本研究の事例に, 建設省土木研究所ならびに東北

参考文献

- 1) 堀木 賢一, 福田 正: ニューラルネットワークによる舗装のパフォーマンスモデル, 土木学会論文集, No.496/V-24, pp.99-102, 1994, 8.
- 2) 斎藤 雅道, 福田 正: 舗装設計式に基づいたニューロパフォーマンスモデル, 土木学会論文集, No.550/V-33, pp.213-217, 1996, 11.
- 3) AASHTO GUIDE FOR DESIGN OF PAVEMENT STRUCTURES, American Association of State Highway and Transportation Officials, 1986.
- 4) 建設省: アスファルト舗装の構造設計に関する検討報告書, 土研資料第 3041 号, 1991.

(1997.1.27 受付)

NEURO-PERFORMANCE MODELING APPLYING ANNUAL PAVEMENT DATA

Masamichi SAITOH and Tadashi FUKUDA

We reported a method of the neural network performance modeling using a pavement design equation. In that case, pavement data, which were measured for several consecutive years at a pavement section, were applied to modeling. In this study, we examined a method of the neural network performance modeling applying annual pavement data measured at a few pavement sections.