

少数データによる舗装のパフォーマンスモデルの構築

斎藤 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)

舗装の路面状態を予測するパフォーマンスモデルとして、既に著者らは、舗装設計式 (AASHTO 式) を基にして、比較的少ないデータでニューロパフォーマンスモデルを構築する手法を報告した²⁾。この場合に使用したデータは東北地方のアスファルト舗装の供用履歴データであったため、スパイクタイヤによる磨耗の影響を受けていた。そこで本研究においては、温暖地である九州地方のデータを適用することによって、本手法の汎用性を確認し、またより一般的なニューロパフォーマンスモデルを構築することを試みた。

Key Words : performance, neural network, AASHTO equation

1. はじめに

アスファルト舗装の路面状態を予測するパフォーマンスモデルとして、著者らは、舗装設計式 (AASHTO 式) を基にして、比較的少量の供用履歴データで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⁾。しかし、この場合に用いたデータは、東北地方の供用履歴データであったために、スパイクタイヤによる磨耗の影響を受けていた。そこで本研究においては、温暖地である九州地方のデータを対象に本モデルに適用することによって、本手法の汎用性を確認し、さらにより一般的なニューロパフォーマンスモデルを構築することを試みた。

ニューロモデルは、学習するデータによって容易に修正できる特徴がある。そこで、本研究においては、アスファルト舗装に関する AASHTO 設計式⁴⁾を学習させた基本ニューロモデルを構築し、これに九州地方の供用履歴データを学習させて修正ニューロモデルを構築した。

さらに本研究においては、既に得られている東北地方のパフォーマンスモデルと本研究で得られた九州地方のモデルとの比較検討を行った。

2. AASHTO 設計式と舗装要綱設計式

(1) パフォーマンス式の比較

わが国の舗装の構造設計式は、竹下が AASHTO 道路試験の結果及びわが国の舗装の実測データから提

案した式(1)を用いて導くことができる⁵⁾。

$$SN = 2.2 \cdot P^{0.64} / CBR^{0.3} \quad (1)$$

これは P を 100 万回載荷した場合に $PSI=2.5$ になるような舗装の SN と P の関係を示している。

一方、4 乗則により P と N には次の関係がある。

$$P = 5 \cdot (N/10^6)^{1/4} \quad (2)$$

SN と T_A については次の関係式を用いる。

$$SN = T_A \cdot 0.44 / 2.54 = T_A / 5.68 \quad (3)$$

以上の式(1)～式(3)より、わが国の舗装要綱の設計式(4)を導くことができる⁶⁾。

$$T_A = \frac{3.84 \cdot N^{0.16}}{CBR^{0.3}} \quad (4)$$

ここで、

N : 累積 5t 輪換算数

CBR : 路床土の設計 CBR (%)

T_A : アスファルト舗装の等価換算厚 (cm)

本研究においては、AASHTO 指針の構造設計式をニューロモデルの基本データとして用いるためには、わが国の舗装設計式(4)との整合性が必要とされる。

$$\begin{aligned} \log(W_{18}/0.452) &= Z_R \cdot S_0 \cdot 9.36 \cdot \log(SN+1) - 0.2 - 8.07 \\ &+ 2.32 \log(M_R) + \frac{\log(\Delta PSI / (4.2 - 1.5))}{0.4 + 1094 / (SN+1)^{5.19}} \end{aligned} \quad (5)$$

ここで、

W_{18} : 18kip (=8.2tf) の等価単軸荷重の予測数

Z_R : 信頼性確率に関する係数で、信頼性確率 50% の場合 $Z_R = 0$ となる。

S_0 : 交通量とパフォーマンスの予測の標準偏差

ΔPSI : 初期供用性指数 PSI_0 と終局供用性指数 PSI_t との差

M_R : 路床土のレジリエント係数(psi)

SN : 構造厚指数

式(5)を日本の諸量に対応させ信頼性確率を50%とした場合、式(6)のように変換することができる⁵⁾。

$$\log(W_5/0.452) = 9.36 \log(T_A/7.26 + 1) - 0.96 + 2.32 \log(CBR) + \frac{\log(\Delta PSI/(4.2 - 1.5))}{0.4 + 1094/(T_A/7.26 + 1)^{5.19}} \quad (6)$$

ここで、

W_5 : 累積 5t 換算輪数

CBR : 路床土の設計 CBR (%)

T_A : アスファルト舗装の等値換算厚 (cm)

ΔPSI : 初期供用性指数 PSI_0 と終局供用性指数 PSI との差

ここで、式(4)と式(6)との整合性について検討する。式(4)を終局供用性指数を $PSI=2.5$ とした場合のパフォーマンス式と見なして、式(6)と比較すると図-1 のようになり、両者はほぼ一致する。(相関係数 = 0.99) このことより、両者は基本的に同一の設計概念による式であることが分かる。

このように舗装要綱の設計式は、AASHTO 設計式の終局供用性指数を $PSI=2.5$ に固定した式と見なすことができる。つまり、AASHTO 設計式は舗装要綱の設計式を包括した柔軟性の高い設計式であることが分かる。そこで、本研究においては AASHTO 設計式をニューロパフォーマンスの基本の学習データとして用いる。

(2) わが国の諸量への変換

現在、わが国において実施されている路面性状調査において収集されるデータは、路面の供用性指標として MCI が用いられる場合が多く、また交通条件に関しては大型車交通量が用いられる。そのため、日常での道路管理における利便性を考慮した場合には、容易に入手可能なこれらのデータを使用したモデル式への変換が必要とされる。そのため、式(1)を基本学習のデータとして用いるために、対応する諸量の変換を行う。

PSI と MCI の変換については、次の式(7)を用いる。⁶⁾

$$MCI = 1.6 \cdot PSI + 0.8 \quad (7)$$

5 t 換算輪数と大型車交通量の変換については、建設省の研究⁷⁾による式(8)を用いる。

$$\log w_5 = 0.981 \cdot \log(W) - 0.03 \quad (8)$$

ここで、

w_5 : 5 t 換算輪数 (輪)

W : 大型車交通量 (台)

これらを式(1)に代入して変換すると、次式が得られる。

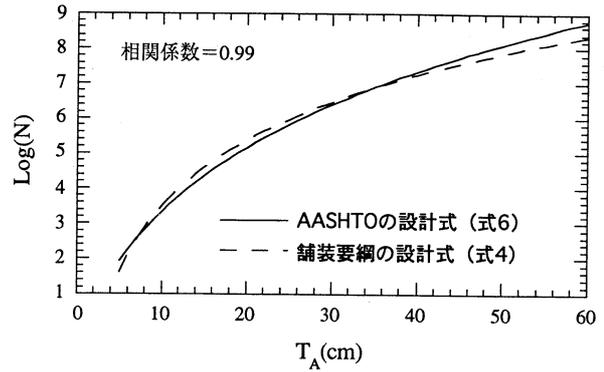


図-1 式(4)と式(6)との比較

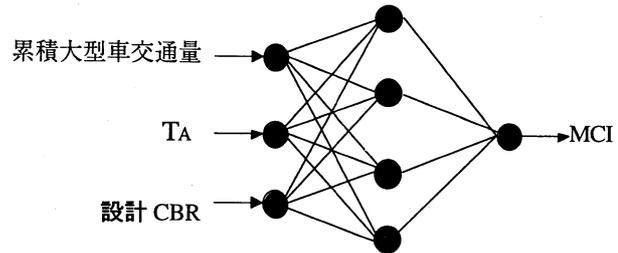


図-2 ニューロパフォーマンスモデル

$$0.98 \cdot \log(W) = 9.36 \log(T_A/7.26 + 1) - 1.34 + 2.32 \log(CBR) + \frac{\log((\Delta MCI - 7.2)/1.12 + 6.43)}{0.4 + 1094/(T_A/7.26 + 1)^{5.19}} \quad (9)$$

3. ニューロパフォーマンスモデル

(1) ニューラルネットワークモデル

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 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 Back Propagation 法による学習を行う。

このアルゴリズムは以下のとおりである^{8), 9)}。図-2 に示すような n 層からなるネットワークを考える。入力された各ユニットの情報は、ウェイトを付けられて次の層に伝わる。最終層で出力された情報は期待される出力 (教師信号と呼ぶ) と比較され、両者の差が小さくなるように結合ウェイトは修正される。

すなわち、パターン p を掲示したときの第 k 層 ($k = 2, 3, 4, \dots, n$) の各入出力関数を次のように表す。

$$o_{pj}^k = f_j^k(i_{pj}^k) \quad (10)$$

$$i_{pj}^k = \sum_{i=1}^{N_{k-1}} w_{i,j}^{k-1,k} o_{pi}^{k-1} + \theta_j^k \quad (11)$$

ここで、

o_{pj}^k : パターン p における第 k 層の j 番目のユニ

表-1 再学習の対象とした実測データ（九州地方）¹⁰⁾

NO	調査箇所	設計 CBR	T _A	MCI/累積大型車交通量（万台）
1	3号 宗像町	10	26.8	6.2/545, 5.2/647, 6.0/743, 5.6/831, 5.4/933, 5.0/1039, 4.8/1147, 3.9/1199, 5.0/1247, 4.8/1291

表-2 検証に使用した実測データ（九州地方）¹⁰⁾

NO	調査箇所	設計 CBR	T _A	MCI/累積大型車交通量（万台）
1	3号 久留米市	6.0	41.1	7.8/158, 8.0/236, 7.6/309, 7.5/337, 6.8/395, 6.5/451, 5.9/528
2	10号 行橋市	0.5	22.3	5.0/424, 2.6/488, 3.1/586
3	3号 福岡市	10.0	31.8	8.8/222, 7.7/276, 7.5/339, 7.2/388, 6.8/432, 6.8/507, 6.7/577, 7.0/653, 6.7/741
4	2号 飯塚市	1.8	47.5	8.1/139, 7.3/188, 7.2/228, 6.6/267, 6.7/298, 6.4/327, 6.4/364, 6.4/408, 6.3/460
5	10号 大分市	10.0	24.0	4.8/868, 5.5/1023, 5.6/1101, 5.6/1172
6	10号 日之出町	20.0	31.0	7.9/111, 7/166, 6.3/211, 5.8/274, 5.3/327
7	34号 武雄市	2.5	47.5	8.6/102, 7.3/167, 7.2/272, 7.2/349, 7.5/401, 6.5/504, 6.4/557, 6.5/632, 6.7/710, 6.4/772
8	57号 相野町	10.0	24.3	7.5/78, 7.1/99, 7.1/123, 7.1/136, 6.8/158, 6.6/189, 6.5/216, 6.6/246
9	3号 熊本市	3.0	46.0	8.9/37, 8.6/66, 8.6/105, 7.3/143, 7.7/182, 7.7/214, 7.3/248, 7.2/297, 7.0/333
10	57号 大津町	4.0	31.5	7.7/412, 6.6/447, 6.6/495, 6.4/537, 6.6/591, 6.8/637, 6.3/697, 5.7/747, 5.6/796, 5.4/867
11	10号 日向市	6.0	24.5	6.0/329, 6.2/366, 4.8/442, 4.7/460, 4.6/507, 3.6/568, 3.3/660
12	10号 都農町	6.0	17.3	5.5/329, 6.7/366, 6.0/441, 6.4/459, 5.6/505, 5.3/561, 5.3/645, 4.8/694
13	10号 宮崎市	2.0	25.3	3.7/853, 5.0/928, 3.8/989, 3.7/1007
14	10号 住吉町	10.0	15.0	5.6/244, 4.7/276, 3.8/310, 3.7/345, 3.9/379, 3.3/418, 3.2/458, 3.2/480, 2.7/503
15	10号 鹿児島市	10.0	25.3	7.1/196, 9.0/213, 8.8/257, 6.1/331, 5.7/416, 5.0/497

ットの入力値

t_{pj}^k : パターン p における第 k 層の j 番目のユニット

の入力値

$w_{ij}^{k-1,k}$: 第 $k-1$ 層の i 番目のユニットと第 k 層の第 j 番目のユニットとの結合ウェイト

f_j^k : 第 k 層の j 番目のユニットの入出力関数

θ_j^k : 第 k 層の j 番目のユニットのしきい値

N_k : 第 k 層のユニットの数

評価関数として、教師信号と出力値の 2 乗誤差 E_p 及び E を考える。

$$E_p = \frac{1}{2} \sum_{i=1}^{N_n} (t_{pj}^n - o_{pj}^n)^2 \quad (12)$$

$$E = \sum_p E_p \quad (13)$$

ここで、

t_{pj}^n : パターン p における最終層 n 層のユニット j の教師信号

この評価関数 E_p が最小になるように、教師信号と出力値との差を出力側から入力側へ逆方向に伝搬を繰り返すことで学習を行う。

(2) データの学習

本研究においては、図-2 のような入力層 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、次に示す計算手順に基づいて学習を行う²⁾。

STEP1: PSI から MCI 、5 t 換算輪数から大型車交通量への変換後の式(9)を用いて、基本学習データのための出力を行う。

STEP2: **STEP1** で出力されたデータを基に基本の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ラルネットワークを、対象地域の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作成する。

4. 解析事例

(1) 九州地方の事例

AASHTO 設計式を 30000 回学習させ、基本ニューロモデルを作成した。次にこの基本ニューロモデル

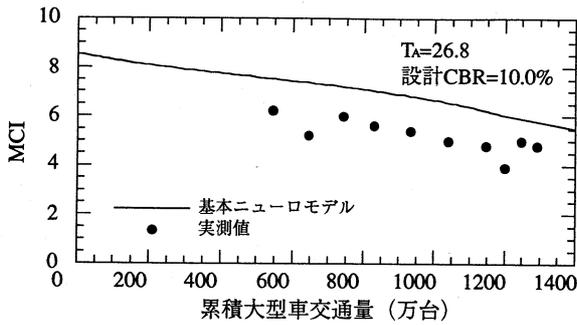


図-3 基本ニューロモデルと実測値

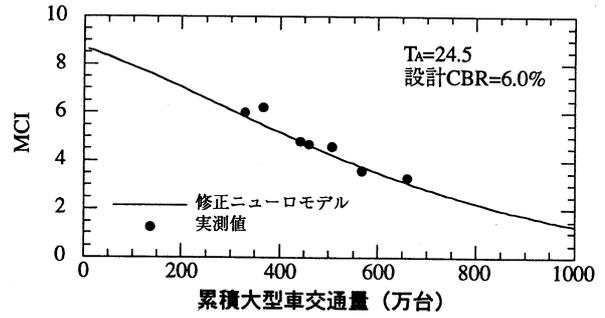


図-6 NO.11の場合(九州地方)

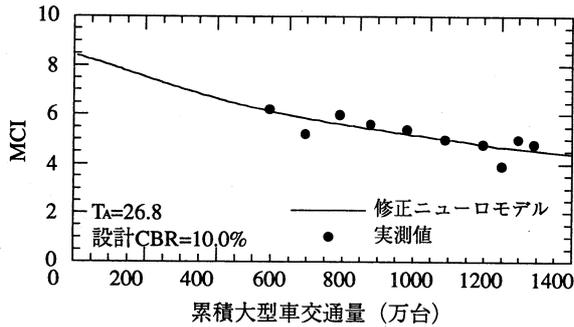


図-4 修正ニューロモデルと実測値

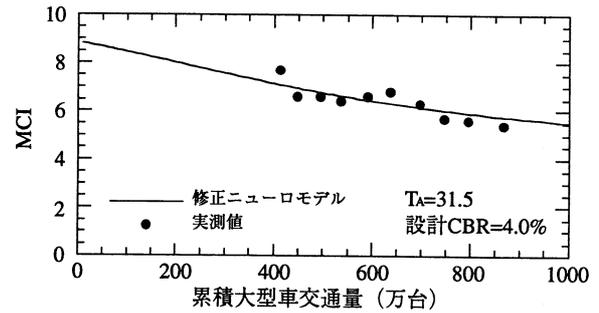


図-7 NO.10の場合(九州地方)

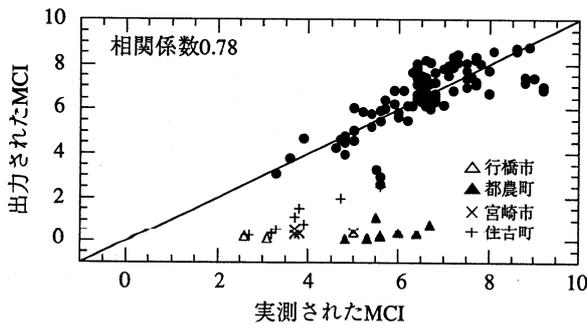


図-5 実測値と出力値との比較(九州地方)

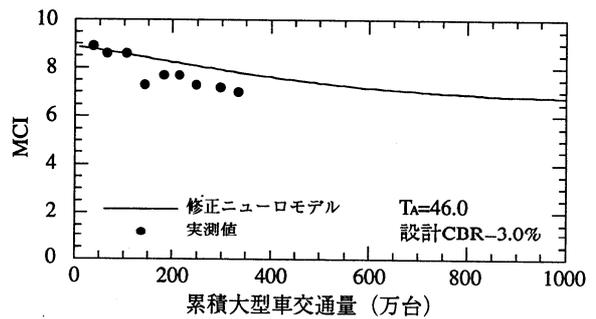


図-8 NO.9の場合(九州地方)

を九州地方の国道における実測データによって再学習を行った。再学習に用いた実測データは、表-1に示す宗像郡宗像町のデータ¹⁰⁾である。

このように作成されるパフォーマンスモデルの適合性の検証には、九州地方の国道における16箇所、122個のデータ¹⁰⁾を用いた。(表-2)

まず、基本ニューロモデルを出力し、これを宗像町の実測データを比較すると、図-3のようになる。このように、AASHTO設計式から得られた基本ニューロモデルは地域特性が加味されていないために、実測データと合致しない。そこで、実測データをこの基本ニューロモデルを用いて、1000回の再学習を行った。図-4はその結果である。

図-5は修正ニューロモデルを用いて、実測データを出力値と比較したものである。出力値と実測データの相関係数は0.78であった。図-5に示す実測

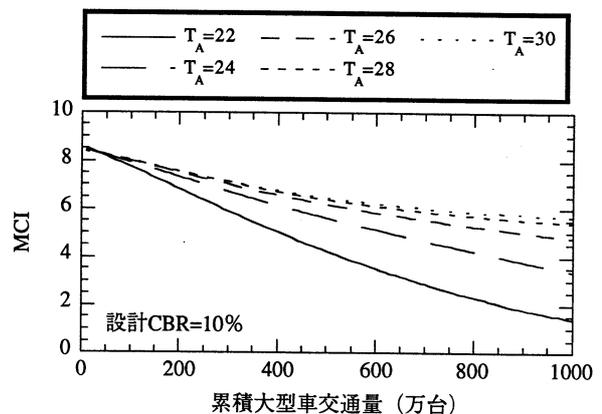


図-9 設計曲線の例(九州地方)

MCIと予測MCIとの相関データを見ると、両者がほぼ一致するデータグループと、一致しないグループに分かれる。前者は本研究で作成したニューロパフ

パフォーマンスモデルで規範されるデータであり、後者はそれ以外のデータといえる。すなわち、後者に属する4箇所のデータは、 T_A または設計CBRのいずれかが比較的小さく、他の地点の劣化挙動とは異なるため、これらに対しては別個のモデルで対応する必要があるように思われる。このような乖離が大きい4箇所のデータグループを除いた相関係数は0.81となる。

図-6~図-8は、累積大型車交通量とMCIとの関係を、修正ニューロモデルによる出力値と実測データによって示したものである。また、図-9は、修正ニューロモデルによって、設計CBRが10%の場合を事例にパフォーマンス曲線を示したものである。

(2) 東北地方の事例

(1)と同様に、基本ニューロモデルを弘前市の7個のデータ¹⁰⁾を用いて1000再学習を行い、東北地方におけるパフォーマンスモデルを作成した²⁾。適合性の検証には、14箇所、96個のデータ¹⁰⁾を用いた(図-10)。

(3) 両地域のパフォーマンス式の比較

各地方におけるパフォーマンスとAASHTO設計式のパフォーマンスの比較を行ったものが図-11である。

東北地方におけるパフォーマンスは他のパフォーマンスと比べると路面の劣化の進行が早い。これはスパイクタイヤ禁止以前のデータが含まれているためであると考えられる。また、AASHTO設計式と九州地方のパフォーマンスを比べた場合、九州地方の方が劣化の進行が早い。このように本モデルを用いることによって、各地域の供用履歴データに含まれる交通条件や気象条件等のような地域特性を反映したパフォーマンスモデルを容易に作成することができる。

3. むすび

既往のニューロモデル^{1), 3)}によって舗装のパフォーマンスモデルを作成するためには、比較的大量のアスファルト舗装の供用履歴データを学習する必要があった。しかし、このような大量のデータを収集することは、一般にはきわめて困難である。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、これを少量の実測データを用いて再学習することによってパフォーマンスモデルを構築する手法を検討した。

本研究では本手法を九州地方に適用し、一般的なモデルを構築しその汎用性と適合性の検証を試みた。さらに本研究においては、既に得られている東北地

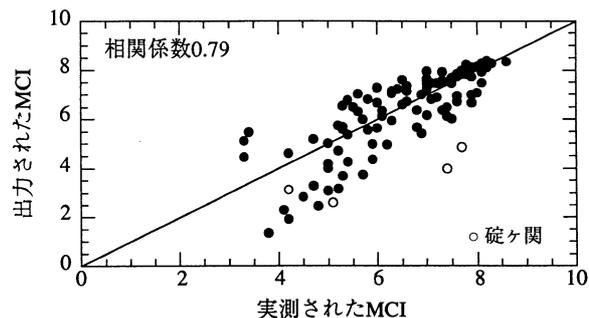


図-10 実測値と出力値との比較(東北地方)

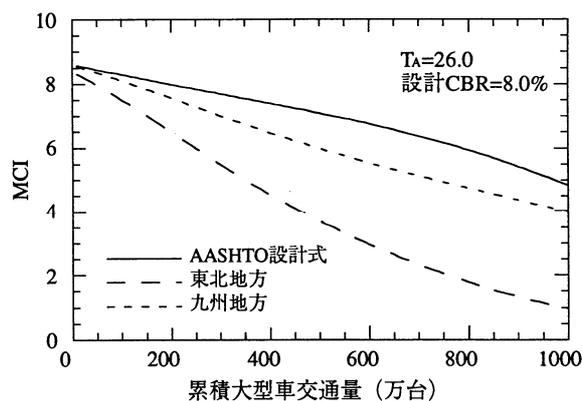


図-11 パフォーマンスの比較

方パフォーマンスモデルと本研究で得られた九州地方のモデルとの比較検討を行った。

本研究の事例研究に、建設省土木研究所ならびに各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。

参考文献

- 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, pp99-102, 1994.
- 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(投稿中)
- 堀木 賢一, 福田 正:ニューロパフォーマンスモデルを用いたプロジェクト型舗装管理システム, 土木学会論文集, NO.520/V-28, pp195-201, 1995.
- AASHTO GUIDE FOR DESIGN OF PAVEMENT STRUCTURES, American Association of State Highway and Transportation Officials, 1986.
- 竹下 春見:アスファルト舗装の構造設計に関する考え方, 舗装, vol. 1, NO.2, 1966.
- 孔 永健, 福田 正:動的計画法に基づくアスファルト舗装の最適設計, 土木学会論文集, NO.502/V-25, pp167-170, 1994.
- 建設省:車両重量調査結果の解析, 土研資料第 1722号, 1981.

- 8) 安居院 猛, 長崎 宏, 高橋 裕樹:ニューラルプログラム, 昭晃堂, 1993.
- 9) 麻生 英樹:ニューラルネットワーク情報処理, 産業図書, 1988.
- 10) 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.

NEURO PERFORMANCE MODELING USING FEW PAVEMENT DATA

Masamichi SAITOH and Tadashi FUKUDA

We reported a method of the neural network performance modeling using a pavement design equation and few pavement data obtained in Tohoku. However, the pavement data had the influence of abrasion by studded tires. In this study, we used the pavement data obtained in Kyushu, and confirmed the general use of the neuro performance modeling using few pavement data.