

投稿論文 (和文ノート)

TECHNICAL

NOTE

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

堀木賢一*・福田 正**

舗装管理システムにおいては、舗装の路面状態を予測するためのパフォーマンスモデルが必要である。一般にこのようなパフォーマンスモデルは、舗装の路面状態の遷移に関するデータの非線形重回帰分析によって求められている。本研究においては、舗装のパフォーマンスモデルの構築にニューラルネットワークを適用することを試みた。

Key Words : neural network, performance, pavement management system, serviceability

1. はじめに

舗装の路面状態は、路面のわだち、ひびわれ、縦断凹凸等の破損量を基に、MCI (Maintenance Contol Index)¹⁾などの供用性指標値によって評価されている。舗装の交通履歴に伴うこの供用性指標値の時系列的な推移を、舗装のパフォーマンス (performance) と呼んでいる。

舗装のパフォーマンスの予測は舗装の管理システムにおいて重要であり、従来は路面の破損データに非線形重回帰分析によってパフォーマンス式が求められている〔例えば、文献2)〕。しかし、このような統計解析手法では関数モデルを仮定しなければならないなど一般に複雑であり、日常の舗装管理においてはさらに簡便な手法が望まれる。

本研究においては、このような舗装のパフォーマンスの予測手法に、ニューラルネットワークを適用することを試みたものである。ニューラルネットワークは人間の神経回路を模擬したコンピュータプログラムシステムであり、曖昧さをもつパターン認識などの情報処理に適しているといわれる。前述のように舗装のパフォーマンスは路面状態の時系列パターンであり、またいくつかの不確定要因を含んでいることから、ニューラルネットワークの適用性は高いように思われる。

2. ニューラルネットワークモデル

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、これのバックプロパゲーション法 (逆誤差伝搬法) は次のとおりである^{3),4)}。まず、図-1に示すような n 層からなるネットワークを考える。入力層に




図-1 ネットワーク

入力された各ユニットの情報、結合ウェイトと呼ばれる重みをつけられて次の層に伝わる。最終層で出力された情報は望ましい出力 (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 を提示したときの第 k 層 ($k=2, 3, \dots, n$) の各ユニットの入出力関数を次のように表わす。

$$o_{kj}^k = f_j^k(i_{kj}^k) \dots \dots \dots (1)$$

$$i_{kj}^k = \sum_{i=1}^{N_{k-1}} w_{ij}^{k-1,k} o_{ki}^{k-1} + \theta_j^k \dots \dots \dots (2)$$

o_{kj}^k : パターン p における第 k 層の j 番目のユニットの出力値

i_{kj}^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乗差 E_p および E を考える。

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

** 正会員 工博 東北大学大学院情報科学研究科教授

$$E_p = \frac{1}{2} \sum_{i=1}^{N_n} (t_{pi}^n - o_{pi}^n)^2 \dots\dots\dots (3)$$

$$E = \sum_p E_p \dots\dots\dots (4)$$

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

結合ウェイト $w_{i,j}^{k-1,k}$ を、評価値 E_p が最小になるように変化させるための結合ウェイトの変化量 $\Delta w_{i,j}^{k-1,k}$ は、次の関係が必要である。

$$\Delta w_{i,j}^{k-1,k} = -\eta \frac{\partial E_p}{\partial w_{i,j}^{k-1,k}} \dots\dots\dots (5)$$

η : 比例定数 ($\eta > 0$)

式 (5) の右辺は、次のように分解することができる。

$$\frac{\partial E_p}{\partial w_{i,j}^{k-1,k}} = \frac{\partial E_p}{\partial i_j^k} \cdot \frac{\partial i_j^k}{\partial w_{i,j}^{k-1,k}} \dots\dots\dots (6)$$

ここで、

$$\frac{\partial i_j^k}{\partial w_{i,j}^{k-1,k}} = \frac{\partial}{\partial w_{i,j}^{k-1,k}} \sum_{s=1}^{N_{k-1}} (w_{s,j}^{k-1,k} o_{ps}^{k-1} + \theta_j^k) = o_{pi}^{k-1} \dots\dots\dots (7)$$

式 (6) の右辺の第 1 因数を $\delta_{pj}^k = -\frac{\partial E_p}{\partial i_j^k}$ と表すと式 (5) は次のように表される。

$$\Delta w_{i,j}^{k-1,k} = \eta \delta_{pj}^k o_{pi}^{k-1} \dots\dots\dots (8)$$

ここで、 δ_{pj}^k は次のように分解することができる。

$$\begin{aligned} \delta_{pj}^k &= -\frac{\partial E_p}{\partial i_j^k} = -\frac{\partial E_p}{\partial o_{pj}^k} \cdot \frac{\partial o_{pj}^k}{\partial i_j^k} \\ &= -\frac{\partial E_p}{\partial o_{pj}^k} \cdot \frac{\partial}{\partial i_j^k} f_j^k(i_j^k) \dots\dots\dots (9) \end{aligned}$$

式 (9) の第 1 因数は、(a) 出力層のユニットの場合、(b) 出力層以外のユニットの場合について検討する必要がある。

(a) の場合は次のようになる。

$$\frac{\partial E_p}{\partial o_{pj}^k} = -(t_{pj}^k - o_{pj}^k) \dots\dots\dots (10)$$

(b) の場合は次のようになる。

$$\begin{aligned} \frac{\partial E_p}{\partial o_{pj}^k} &= \sum_{s=1}^{N_{k+1}} \left(\frac{\partial E_p}{\partial i_s^{k+1}} \cdot \frac{\partial i_s^{k+1}}{\partial o_{pj}^k} \right) \\ &= \sum_{s=1}^{N_{k+1}} \left(\frac{\partial E_p}{\partial i_s^{k+1}} \cdot \frac{\partial}{\partial o_{pj}^k} \sum_{t=1}^{N_{k+1}} (w_{ts}^{k,k+1} o_{pj}^k) \right) \\ &= -\sum_{s=1}^{N_{k+1}} (\delta_{ps}^{k+1} w_{ts}^{k,k+1}) \dots\dots\dots (11) \end{aligned}$$

入出力関数としては、次のシグモイド関数を用いる。

$$f(x) = \frac{1}{1 + \exp(-x)} \dots\dots\dots (12)$$

この導関数は

$$\frac{d}{dx} f(x) = f(x) (1 - f(x)) \dots\dots\dots (13)$$

であるから式 (10), (11) はそれぞれ次のように表される。

$$\delta_{pj}^k = (t_{pj}^k - o_{pj}^k) f_j^k(i_j^k) (1 - f_j^k(i_j^k))$$




図-2 本研究で用いるネットワーク

$$= (t_{pj}^n - o_{pj}^n) o_{pj}^n (1 - o_{pj}^n) \dots\dots\dots (14)$$

$$\begin{aligned} \delta_{pj}^k &= f_j^k(i_j^k) (1 - f_j^k(i_j^k)) \sum_{s=1}^{N_{k+1}} (\delta_{ps}^{k+1} w_{ts}^{k,k+1}) \\ &= o_{pj}^k (1 - o_{pj}^k) \sum_{s=1}^{N_{k+1}} (\delta_{ps}^{k+1} w_{ts}^{k,k+1}) \dots\dots\dots (15) \end{aligned}$$

ただし、 $k=2, 3, \dots, n-1$

このように、教師信号値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によって結合ウェイトの学習を行うことができる。

3. 事例研究

(1) 使用したデータ

ニューラルネットワークによって、東北地方におけるアスファルト舗装のパフォーマンスモデルの構築を試みる。データは土木研究所資料「アスファルト舗装の構造設計に関する検討報告書」²⁾ (以下、土研資料という) から引用して適用した。この調査は全国 273 箇所の建設省直轄国道において実施されたものである。本研究ではこの中から東北地方におけるデータを用いた。

この土研資料には、調査箇所の舗装構造、 T_A 、路床の CBR 値、交通量および車両重量の履歴、舗装のひびわれ率、わだち掘れ量、平坦性などについて、昭和 44 年～昭和 63 年までの測定値が記録されている。さらに舗装のひびわれ率、わだち掘れ量、平坦性のデータから、舗装の供用性指標 MCI が求められ、これと累積大型車交通量との関係、すなわちパフォーマンスモデルが非線形重回帰分析によって求められている。

(2) ニューラルネットワークモデル

入力層 3 ユニット、中間層 3 ユニット、出力層 1 ユニットのニューラルネットワークを用いる(図-2)。出力データは MCI とし、入力データには次の 2 事例により、影響要因に関する検討例を示す。

事例-1: T_A 、累積大型車交通量、路床 CBR

事例-2: T_A 、累積大型車交通量、表層材料の種類

学習の対象とした調査区間は、東北地方の 2 車線道路とした。これらの調査箇所は土研資料によれば全体で 22 箇所であるが、その中で最終的に整合性のあるデータとしてニューラルネットワークモデルの対象としたのは、表-1 に示す 18 箇所の調査箇所のデータである。

ニューラルネットワークの場合、表層材料のような質的データは、それぞれの種類ごとに仮の数値を与えるこ

表一 使用したデータ (文献2) より作成)

NO	調査箇所	CBR	T _A	表層材料	MCI / 累積大型車交通量 (万台)
1	7号 礎ヶ関村	10.0	19.8	細粒As(13)	7.7/119, 7.4/144, 4.2/171, 5.1/191
2	7号 弘前市	10.0	24.2	粗粒As	7.2/131, 6.8/176, 5.2/229, 4.7/278, 4.2/328, 5.0/371
3	45号 種市町	4.0	21.0	修正トベカ	8.1/19, 8.2/27, 8.1/36, 7.8/41, 7.0/52, 6.6/60 5.6/71, 5.5/89, 5.6/107, 5.4/122, 5.2/140, 5.0/160 4.7/181, 4.5/195, 4.1/215
4	4号 紫波町	4.0	32.0	細粒GAs	7.8/109, 7.3/192, 6.6/265, 6.0/349, 5.6/419
5	4号 三戸町	5.0	29.5	細粒GAs	7.5/132, 7.0/193, 6.6/266, 6.1/348, 5.3/430
6	46号 盛岡市	10.0	26.4	細粒GAs	8.3/30, 7.9/53, 7.3/83, 7.0/120, 6.4/173, 6.3/198
7	7号 能代市	19.0	24.0	細粒As(13F)	7.9/111, 7.0/166, 6.3/211, 5.8/274, 5.3/327
8	13号 十文字町	10.0	24.0	細粒As(13F)	8.1/75, 7.9/114, 7.4/157, 6.3/201, 5.8/232, 5.0/276 3.3/326
9	4号 柴田町	9.2	27.3	密粒GAs	7.6/118, 7.6/227, 7.5/363, 6.8/417, 6.2/548, 5.9/663 5.7/788, 5.0/923, 4.8/1052, 4.2/1167, 3.8/1305
10	6号 亘理町	5.0	31.6	細粒As(13)	7.8/78, 7.7/146, 7.5/209
11	48号 宮城町	不明	23.5	細粒As(13)	7.7/126, 7.1/163, 7.0/197, 5.6/224, 5.0/294
12	4号 白石市	3.0	33.1	密粒As	8.2/62, 7.7/138, 7.3/221, 6.9/306, 6.5/392, 6.1/451 5.7/539, 5.3/633
13	45号 鳴瀬町	不明	26.0	密粒As	7.3/207, 6.9/294, 6.1/373, 5.8/460, 5.3/521, 3.0/589
14	49号 郡山市	不明	23.5	粗粒As	7.0/393, 5.6/415, 4.9/472
15	6号 磐城市	8.0	33.1	密粒As	7.0/115, 6.5/175, 6.0/242, 5.4/349
16	13号 山形市	10.0	28.2	細粒As(13)	8.0/237, 7.6/294, 7.3/358, 7.0/405, 6.0/519, 3.4/563 3.3/654
17	47号 立川町	10.0	23.0	細粒As(13)	7.9/102, 7.4/135, 6.9/179, 5.9/206, 5.4/256, 5.3/299 5.2/342
18	112号 鶴岡市	6.0	28.0	細粒GAs	8.6/20, 8.2/34, 8.0/50, 7.8/69, 7.6/91, 7.5/112 7.2/136, 7.1/138, 7.1/212




図-3 実測値と予測値の比較




図-5 No. 8の場合




図-6 No. 2の場合




図-4 No. 11の場合




図-7 No. 13の場合




図-8 No. 9 の場合




図-10 No. 4 の場合




図-9 No. 5 の場合




図-11 T_A によるパフォーマンス曲線

とによって入力することができる。表層材料の種類は、細粒アスファルト混合物 (13F)、細粒ギャップアスファルト混合物、細粒アスファルト混合物 (13)、修正トベカ、密粒アスファルト混合物、粗粒アスファルト混合物、密粒ギャップアスファルト混合物の 7 種類である。

(3) 出力結果

表一に示す MCI と累積大型車交通量に関する 116 組のデータを、事例一、事例二についてそれぞれ 10 000 回繰り返して入力学習させた。その結果、式 (4) による評価値 E は事例一の場合は 0.301、事例二の場合は 0.218 であった。そこで、ここでは事例二の入力設定によるニューラルネットワークモデルを用いて、出力値と実測値の全数を比較すると図-3 のようになる。また、図-4~図-10 は T_A と表層材料を固定した場合の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の出力と結果の例で、比較のために実測値を示した。また図-11 に本ニューラルネットワークによって得られる、表層材料が細粒アスファルト混合物 (13) の場合のパフォーマンス曲線の例を示した。

4. まとめ

舗装の路面状態と交通量の推移に関するデータを用い

て、舗装のパフォーマンスモデルを構築する際には、一般に、重回帰分析などの複雑な統計処理を行う必要がある。本研究によれば、このような場合、ニューラルネットワークを適用することによって、容易にパフォーマンスモデルを構築することができることが分かった。また、ニューラルネットワークを適用することにより、舗装路面に関するデータが固有する規則性を検討することが可能であることが分かった。

本研究の事例研究に、土木研究所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

- 1) 建設省道路局国道一課、土木研究所：舗装の維持修繕の計画に関する調査研究、第 33 回建設省技術研究会報告書、1979。
- 2) 建設省土木研究所道路部舗装研究室：土木研究所資料、アスファルト舗装構造の設計に関する検討報告書、1991。
- 3) 安居院猛、長橋宏、高橋裕樹：ニューラルプログラム、昭晃堂、1993。
- 4) 麻生英樹：ニューラルネットワーク情報処理、産業図書、1988。

(1994. 1. 20 受付)

PAVEMENT PERFORMANCE FORECASTING MODEL USING NEURAL NETWORK

Ken-ichi HORIKI and Tadashi FUKUDA

Performance forecasting model is indispensable to any pavement management system. Generally, pavement performance model is obtained by multivariate nonlinear regression. In this study, neural network approach is evaluated for developing pavement performance model.