

舗装設計式に基づいたニューロパフォーマンスモデル

東北大学 大学院 情報科学研究科 学生員 斎藤 雅道
 東北大学 大学院 情報科学研究科 学生員 柴崎 由記
 東北大学 大学院 情報科学研究科 フェロ一員 福田 正

1.はじめに

現在、路面状態は、路面のわだち、ひび割れ、縦断凹凸等の破損量を基に、供用性指標値によって評価され、この供用性指標値の時系列的な推移を表現するパフォーマンスマネジメントにより予測されている。

このようなパフォーマンスマネジメントとして、著者らは、ニューラルネットワークによる舗装のパフォーマンスマネジメント（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。¹⁾ この場合には、学習のために、比較的大量の供用履歴データを使用する必要があった。しかしながら、このようなデータを大量に収集することは、一般には困難なことである。そこで、本研究においては、舗装設計式（AASHTO式）²⁾を学習させた基本ニューロモデルを構築し、これに利用可能なその地域の舗装の供用履歴データを学習させる方法を検討した。

2. AASHTO 設計式について

AASHTO 指針の舗装設計式をわが国の舗装要綱の諸量に対応させると、次式のように変換することができる。⁴⁾ この式とわが国のアスファルト舗装の設計式の関係は、同一の設計概念であると見なせることを既に著者らは述べている。⁴⁾ そこで、本研究においては、基本ニューロモデルを構築するための学習データとして、わが国の舗装設計式における諸量に変換した式²⁾を用いることにする。

$$\begin{aligned} \log(W_s / 0.452) &= 9.36 \log(TA / 7.26 + I) - 0.96 \\ &+ 2.32 \log(CBR) + \frac{\log(\Delta PSI / (4.2 - 1.5))}{0.4 + 1094 / (TA / 7.26 + I)^{5.19}} \end{aligned} \quad (1)$$

ここで、

W_s ：累積5t換算輪数

CBR ：路床土の設計 CBR (%)

TA ：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_f の差

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、次の近似式を用いる²⁾。

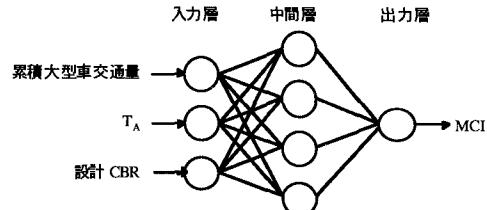


図-1 本研究で用いるニューラルネットワーク

$$MCI = 1.6 \cdot PSI + 0.8 \quad (2)$$

累積5t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³⁾による次式を用いる（相関係数0.66）。

$$\log W_s = 0.981 \cdot \log(W) - 0.03 \quad (3)$$

ここで、

W_s ：5t換算輪数（輪）

W ：大型車交通量（台／日・1方向）

これらを式(1)に代入して変換すると、次式が得られる。

$$\begin{aligned} 0.98 \cdot \log(W) &= 9.36 \log(TA / 7.26 + I) - 1.34 \\ &+ 2.32 \log(CBR) + \frac{\log((\Delta MCI - 7.2) / 1.12 + 6.43)}{0.4 + 1094 / (TA / 7.26 + I)^{5.19}} \end{aligned} \quad (4)$$

3. ニューロパフォーマンスマネジメント

(1) 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マネジメントの予測手法として 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。⁴⁾

本研究においては、図-1に示すような入力層3ユニット、中間層3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。また、次に示す計算手順に基づいて学習を行う。

STEP1 : PSI から MCI 、5t換算輪数から大型車交通量への変換後の式(4)を用いて、基本学習データのための出力をを行う。

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. 東北地方の事例

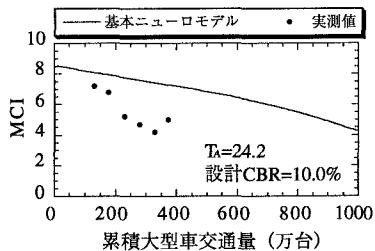


図-2 基本ニューロモデルと実測値

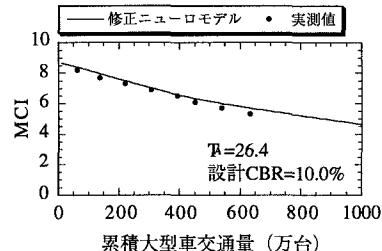


図-5 白石市の場合

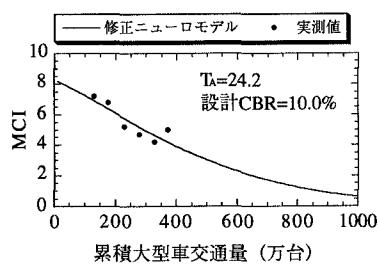


図-3 修正ニューロモデルと実測値

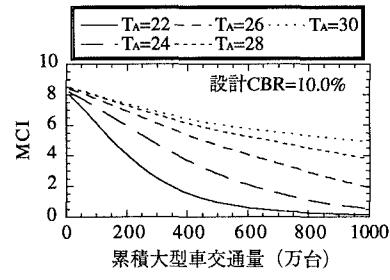


図-6 設計曲線の例 (設計 CBR=10%)

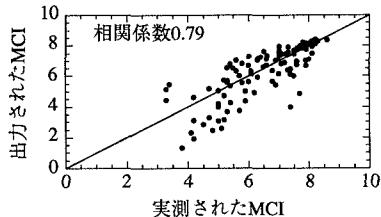


図-5 実測値と出力値の比較

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を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、弘前市の 7 個のデータ^④である。

このように作成されるパフォーマンスマネジメントの東北地方における適合性の検証には、既往の研究^⑤で用いた 18箇所のデータから設計 CBR が不明な 3 地点と学習データを除いた 14 箇所、96 個のデータ^⑥を用いた。

まず、基本ニューロモデルを出し、これを弘前市の実測データを比較すると、図-2 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-3 はその結果である。

次に、弘前市の実測データによる修正ニューロモデルと東北地方における他の地域の実測データとの適合性

を検討した。出力値と実測データの相関係数は 0.79 (図-4) であり、実測データの全数の学習によって作成した場合の相関係数 (0.86)^⑦より、若干低い値になった。

図-5 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-6 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マネジメント曲線を示したものである。

5. むすび

既往のニューラルパフォーマンスマネジメント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。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汎用性の高いパフォーマンスマネジメントモデルを構築する方法を提案した。

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マネジメント、土木学会論文集、NO.496/V-24, pp99-102, 1994.
- 2) 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, 11.
- 3) 建設省：車両重量調査結果の解析、土研資料第 1722 号, 1981.
- 4) 安居院 猛：ニューラルプログラム、昭晃堂, 1993.
- 5) 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.
- 6) 斎藤 雅道、福田 正：舗装設計式に基づいたニューラルパフォーマンスマネジメントモデル、土木学会論文集 (投稿中)