

# 鋼橋の塗装劣化曲線の同定方法

## IDENTIFICATION OF PAINT DETERIORATION CURVE OF STEEL BRIDGES USING NEURAL NETWORK

有馬博人\* 松井繁之\*\* 田中成典\*\*\*

Hiroto ARIMA, Shigeyuki MATSUI, and Shigenori TANAKA

\*工修 大阪大学大学院博士後期課程 工学部土木工学科 (〒565-0871 大阪府吹田市山田丘2-1)

\*\*工博 大阪大学教授 工学部土木工学科 (〒565-0871 大阪府吹田市山田丘2-1)

\*\*\*工博 関西大学助教授 総合情報学部 (〒569-1095 大阪府高槻市靈仙寺町2-1-1)

The authors had developed a prediction system of deterioration of paint on steel bridges by taking into account the causes. This system is able to predict deterioration rate under the arbitrary combination of deterioration causes, but accuracy for predicting of the future deterioration is not so high. Therefore, the system was divided into two systems of rating system of the influence of deterioration causes and the prediction system for the future. The former system was developed by improvement of the past prediction system, but the latter system for the future was newly invented by using neural network for identification of deterioration curve. The deterioration function can be identified directly from the inspection data instead of activation function. In this paper, the adequacy of the new system is verified.

Keyword: identification of deterioration curve, neural network, paint of steel bridges, prediction

### 1. まえがき

近年、橋梁において多くの損傷発生例が報告されており、維持管理業務の重要性が指摘されている<sup>1)-3)</sup>。維持管理において点検は必要不可欠であり、点検業務を怠ることにより、現状の損傷発生・進展の把握が困難となる。また、現在における点検業務を確実におこなうことによって、将来の損傷の進展状況、または過去の点検結果事例から、損傷の発生を推測することも可能である。今後ますます増大するであろう橋梁の劣化損傷に対して、維持管理は主要な業務となることが予想される<sup>4)-7)</sup>。したがって、維持管理の効率化を図るために、予防処置としての劣化損傷進展の将来予測が必要となる。

著者らは、橋梁の様々な損傷劣化の中でも、鋼橋の塗装劣化に着目し、塗装劣化の原因を考慮した影響の優先順位、および原因の影響の変化による塗装劣化状態の予測を考慮できるようなシステムの開発を試みてきた<sup>8)</sup>。しかし、開発したシステムでは、塗装の経過年数と劣化原因を同時に考慮しようとしたため、煩雑となり、劣化原因の影響度を一意的に求めることは困難であった。

そこで本研究では、開発したシステムを、塗装劣化に対する劣化原因の影響を推定できるシステム(劣化原因影響度推定システム)と、将来の塗装劣化を予測できるよう

なシステム(経年劣化予測システム)の2つに分離することにした。そして、あらためて2つのシステムを統合することにより、単なる劣化状況の将来予測の他に、他部材や他の損傷の補修・補強などにより、劣化原因となる因子の影響が変化した場合の将来予測も可能となる。

前者のシステムは、既存のシステムを簡素化することによって実現できるが、後者のシステムは、既存のシステムでは不十分であるため、新たに開発した。後者のシステムの開発に当たり、基本的な考え方として、ニューラルネットワークを利用して、最小自乗法を数値計算的に解く方法を考案した。これは、関数毎に最小自乗法に基づいて、定式化するのは非常に困難な場合があるからである。そして、経過年数とその時の点検結果より得られた評価値のデータの組を用い、あらかじめ定義された複数の基本的な関数を最小自乗法により同定させ、将来の評価値を求める。

本来、ニューラルネットワークの利点は、非線形関数の同定や内挿的な予測であるので、過去の値から将来の値を推定するような、外挿的な予測に対しては不得意である。したがって、ニューラルネットワークを学習機能としてのみ使用する。そして、ニューラルネットワーク内に任意の関数を表現することによって、その関数をあ

る学習データに対して同定することが可能となる。また、ニューラルネットワーク内に複数の基本的な関数を同時に表現することによって、同時に計算することが可能であり、学習によって求められる劣化曲線の関数は、複数の基本的な関数の和として表現される。

本論文ではまず、劣化原因影響度推定システムと、経年劣化予測システムの全体的な構成について述べる。そして、経年劣化予測システムが実際に最小自乗近似の数値計算法として成立するかどうかを確認するために、塗装の劣化曲線を2種類に設定し、検証をおこなった。また、実際の塗装の調査結果を用いて、経年変化による劣化曲線の形状変化を確認すると同時に、2種類の劣化曲線の妥当性を検証する。次に、実際の調査結果のデータには種々の要因により、バラツキが存在することから、最小自乗近似による劣化曲線の同定の他に、そのデータを内包するような劣化曲線の区間、つまり上限の劣化曲線と下限の劣化曲線を同時に同定できるようなシステムの拡張について述べ、その検証もおこなう。

## 2. 全体的なシステムの概要

図-1に劣化原因影響度推定システムと、経年劣化予測システムの全体的な構成を示す。この図は、両システムの学習過程の流れを示す。

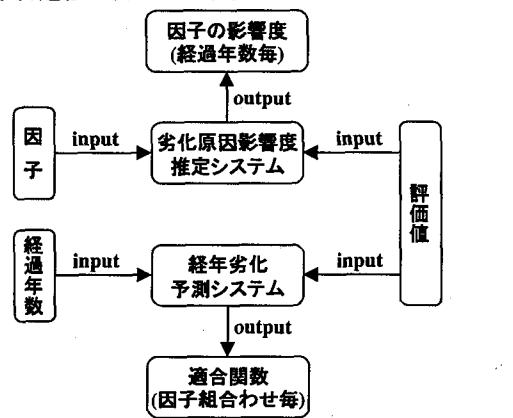
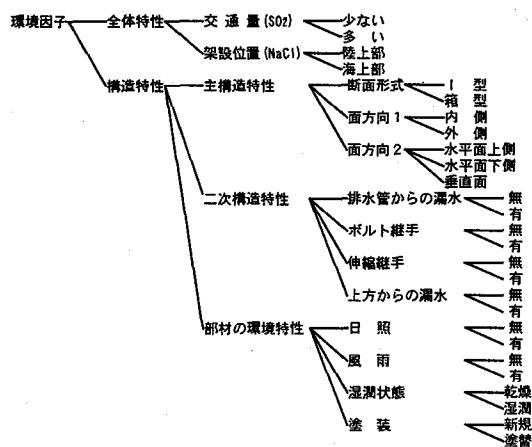


図-1 システムの全体構成



## 図-2 因子一覧

図-1の両システムはデータとして、因子、経過年数および評価値を用いる。因子とは、例えば図-2のような塗装劣化に影響を及ぼすと思われるものを指し、システムには複数の因子の状態を入力する。また経過年数とは、塗装してからの年数をあらわす。そして評価値とは、塗装の劣化状態をあらわす指標であり、因子の組合せの状態と経過年数に対応した評価値をシステムに入力する。具体的には文献<sup>8)</sup>に示しているので、参照されたい。

両システムのうち、劣化原因影響度推定システムは、因子の組合せと評価値を用いて、ファジィ推論により因子の塗装劣化に対する影響を相対的に比較できるシステムである。経年劣化予測システムは、因子の組合せ毎に、データの年数とその評価値に対して、最も適合する関数を選び出すものであり、最小自乗近似を数値計算的に求めるものである。

以上のシステムを連携することによって、環境因子の影響変化があつても、将来の劣化予測が可能であると考える。実際には、2つのシステムの連携は、図-3に示すような、2つの流れになる。

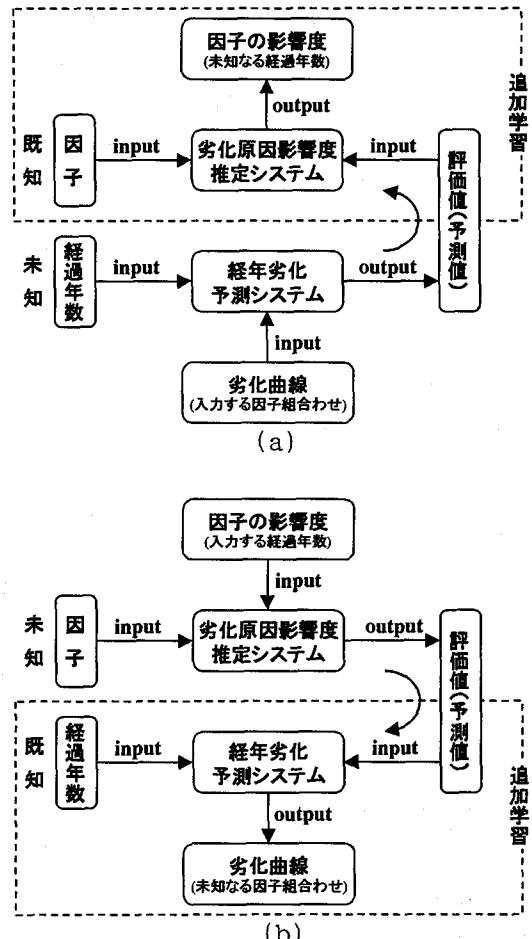


図-3 全体のシステムの流れ

図-3(a)では、経年劣化予測システムで将来の評価値を予測し、その評価値とそれに対応する因子の組合せを用いて劣化原因影響度システムを再学習する。そして、将来の因子の影響度を推定することができる。一方、図-3(b)では、劣化原因影響度推定システムに、未知の因子の組合せを入力し、評価値を推定する、そして、経年劣化予測システムを再学習させ、将来の評価値を得ることができる。例えば、劣化因子に除去が可能な因子(床版からの漏水など)がある場合、図-3(a)により、その因子の将来の影響度を算出し、影響が大きいと判断した場合、図-3(b)により、除去した時の評価値を算出することができ、因子除去の判断材料とすることができる。また、図-3(b)のみでも、入力する未知なる因子の組合せとして、ある因子のみ存在する状態を入力値とすることにより、因子毎の劣化曲線を求めることが可能である。そして、劣化曲線と評価値が完全に一致するのであれば、図-3(a)により求まる因子の影響度と、図-3(b)により求まる因子毎の劣化曲線とは同義となる。しかし実際には、評価値にはバラツキが存在するので、完全に一致することはない。したがって、因子の影響度と因子毎の劣化曲線を比較することによって、劣化曲線の妥当性を検証することができると考える。

### 3. 経年劣化予測システムの開発

経過年数とその評価値との関係に、最も適合する関数を最小自乗法により求め、その関数を用いて将来の評価値を予測することを考えた。しかし、最小自乗法で求めるために、あらゆる関数を定式化することは困難であり、基本となる関数の修正・追加も容易ではない。そこで、定式化して関数の係数を直接求めるのではなく、ニューラルネットワークの学習機能を用いて、近似計算によって関数の係数を求める。したがって、経年劣化予測システムにニューラルネットワークを用いることによって、あらかじめ定義した基本の関数に対して最小自乗法の定式化をおこなう必要はなく、また、複数の関数に対して同時に最小自乗法の近似計算がおこなわれ、ニューラルネットワークの学習によって求められる劣化曲線は、データに最も適合するように、基本の関数の和として、自動的に求めることができる。

経年劣化予測システムの構成を図-4に示す。システムは、3層以上の階層型ニューラルネットワークで構成されている。文献<sup>9), 10)</sup>によれば、3層のニューラルネットワークは、任意の関数を近似することが理論的に証明されているが、今回のシステムでは、入力層と出力層は線形ユニットを使用している。そして、中間層にはそれぞれの基本関数を構成するためのニューラルネットワークが含まれている。

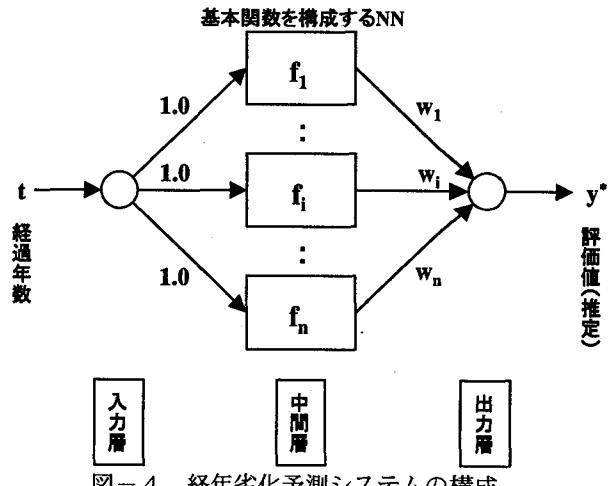


図-4 経年劣化予測システムの構成

通常の階層型ニューラルネットワークでは、応答関数として次式に示すシグモイド関数が用いられている。

$$f(x) = \frac{1}{1 + \exp(-wx + \theta)} \quad (1)$$

ここで、

w : 結合荷重

$\theta$  : しきい値

ニューラルネットワークの学習則として一般に用いられている誤差逆伝播法<sup>11)</sup>は、出力値と実際の値との平均自乗誤差を最少にするようにパラメータを調整する方法である。そこで、シグモイド関数の代わりに劣化予測の基本関数を構成するニューラルネットワークを用いることによって、非線型関数の最小自乗法の近似計算をおこなうことができると考える。

#### 3. 1 ニューラルネットワークの学習の定式化

図-4で示したように、経年劣化予測システムは、入力層、出力層と基本関数を構成する中間層の階層型ニューラルネットワークで構成されている。入出力は1つで、中間層のユニット数は基本劣化曲線の数によって決まる。システムの学習方法としては、通常用いられている誤差逆伝播法を用いる。図-4のシステムでは、通常ニューラルネットワークのように、中間層に存在するユニット間の接続は網目状にはなっていない。そこで、定式化は、図-4にしたがっておこなう。

基本関数を  $f$  とし、第  $k-1$  層の第  $i$  番目のユニットから第  $k$  層の第  $j$  番目の結合荷重を  $w_{ij}^k$ 、第  $k$  層の第  $j$  番目ユニットのしきい値を  $\theta_j^k$ 、第  $k$  層の第  $j$  番目ユニットの出力を  $o_j^k$  とする。便宜上、入力層を第1層、中間層を第2層、出力層を第3層とする。

まず、第1層(入力層)の入出力関係は次式で与えられる。

$$o_1^1 = t \quad (2)$$

ここで、 $t$  は入力値(経過年数)である。

次に、第2層(中間層)の入出力関係は次式で与えられる。

$$q_i^2 = w_{ii}^2 o_i^1 - \theta_i^2 \quad (3)$$

$$o_i^2 = f_i(q_i^2) \quad (4)$$

ここで、基本関数  $f$  自体もニューラルネットワークであるが、学習方法は通常の誤差逆伝播法である。最後に、第3層(出力層)の入出力関係は式(5)、(6)となる。

$$q_i^3 = \sum_i w_{ii}^3 \cdot o_i^2 \quad (5)$$

$$o_i^3 = q_i^3 \quad (6)$$

第  $p$  番目のパターンに対する出力層のユニット出力値  $o_i^3[p]$  と実際の値  $T[p]$  との誤差を次式によって与える。

$$E[p] = \frac{1}{2} \left( \frac{T[p] - o_i^3[p]}{T_{\max}} \right)^2 \quad (7)$$

通常のニューラルネットワークでは、ユニットの応答関数は、0～1の範囲の値を取るような関数が選ばれている。しかし、任意の関数を劣化曲線の候補として導入するためには、劣化指標の取り得る最大値  $T_{\max}$  により正規化する。そして、全パターン数  $P$  に対する平均誤差  $E$  は次式で与えられる。

$$E = \frac{1}{P} \sum_p E[p] \quad (8)$$

次に、通常のニューラルネットワークでは、結合荷重およびしきい値の更新量を次式で与える。

$$\Delta w_{ij}^k(s) = -\varepsilon \frac{\partial E(s)}{\partial w_{ij}^k(s)} + \alpha \Delta w_{ij}^k(s-1) \quad (9)$$

$$\Delta \theta_j^k(s) = -\varepsilon \frac{\partial E(s)}{\partial \theta_j^k(s)} + \alpha \Delta \theta_j^k(s-1) \quad (10)$$

ここで、

$s$  : 学習回数

$\varepsilon$ 、 $\alpha$  : 学習係数

すると、最終的に  $w_{ii}^2$ 、 $w_{ii}^3$  および  $\theta_i^2$  の更新量  $\Delta w_{ii}^2$ 、 $\Delta w_{ii}^3$ 、 $\Delta \theta_i^2$  は式(11)から式(13)となる。

$$\Delta w_{ii}^2(s) = -\varepsilon \frac{\partial E(s)}{\partial w_{ii}^2(s)} + \alpha \Delta w_{ii}^2(s-1) = -\varepsilon(-\delta_i^2 \cdot o_i^1) + \alpha \Delta w_{ii}^2(s-1) \quad (11)$$

$$\Delta w_{ii}^3(s) = -\varepsilon \frac{\partial E(s)}{\partial w_{ii}^3(s)} + \alpha \Delta w_{ii}^3(s-1) = -\varepsilon(-\delta_i^3 \cdot o_i^2) + \alpha \Delta w_{ii}^3(s-1) \quad (12)$$

$$\Delta \theta_i^2(s) = -\varepsilon \frac{\partial E(s)}{\partial \theta_i^2(s)} + \alpha \Delta \theta_i^2(s-1) = -\varepsilon(-\delta_i^2 \cdot (-1)) + \alpha \Delta \theta_i^2(s-1) \quad (13)$$

ここで、

$$\delta_i^2 = f_i'(q_i^2) \cdot \delta_i^3 \cdot w_{ii}^3 \quad (14)$$

$$\delta_i^3 = \frac{1}{P} \sum_p \left( \frac{T[p] - o_i^3[p]}{T_{\max}} \right) \quad (15)$$

### 3. 2 システムで用いる基本劣化曲線

経年劣化予測システムで用いる基本劣化曲線の関数として、劣化の進展が非可逆現象であるため非減少関数であること、評価値は塗装の劣化指標であるので、評価方法にかかわらず、評価値には最大値が存在すること、また文献 12) で示されているように、塗装の劣化曲線としてロジスティック曲線を示していることを考慮して、図-5 の 2 種類の劣化曲線を同定できるように、式(16)に示す関数を基本劣化曲線の関数とした。

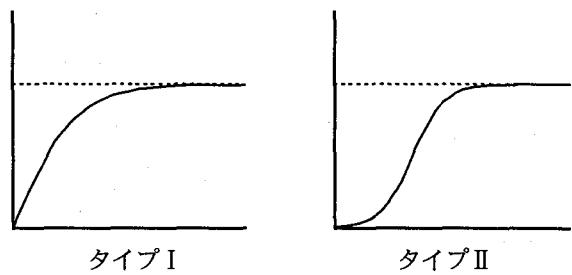


図-5 劣化曲線の形状

$$y(t) = \frac{c}{1 + \exp(at + b)} + d \quad (16)$$

ここで、

$a$ 、 $b$ 、 $c$ 、 $d$  : 劣化曲線の係数

また、評価値  $y$  には最大値  $y_{\max}$  ( $= T_{\max}$ ) が存在すること、経年が 0 年のときは、劣化はまだ発生していないので、評価値は 0 ということから、式(17)、(18) のような制約条件を設定した。

$$y(t) = \frac{c}{1 + \exp(b)} + d = 0 \quad (17)$$

$$\lim_{t \rightarrow \infty} y(t) = c + d = y_{\max} \quad (18)$$

式(17)の制約条件については、学習の初期段階から制約条件に基づいて係数の修正をおこなうと、ニューラルネットワーク自体の学習効果が期待できず、解が平均自乗誤差の極小値に陥ったり、また、平均自乗誤差の収束低下や発散したりする場合がある。したがって、ある程度学習が進み、劣化曲線の形状変化が少なくなつてから、修正をおこなう。劣化曲線の形状変化の指標としては平均自乗誤差を用いる。式(18)の制約条件については、実際の調査結果に仮想のデータとして与えて学習することにより、劣化曲線の漸近する値を  $y_{\max}$  に近づけることが可能となる。ただし、漸近値が  $y_{\max}$  を越える場合には、式(19)、(20) のようにして、劣化曲線の係数を修正する。この修正も学習がある程度進んでからおこなう。

$$c_{i+1} = \frac{c_i}{c_i + d_i} \cdot y_{\max} \quad (19)$$

$$d_{i+1} = \frac{d_i}{c_i + d_i} \cdot y_{\max} \quad (20)$$

ここで、

$c_i, d_i$  : 修正前の係数

$c_{i+1}, d_{i+1}$  : 修正後の係数

次に、式(20)の劣化曲線をニューラルネットワークで実現するために、図-6のように構成した。

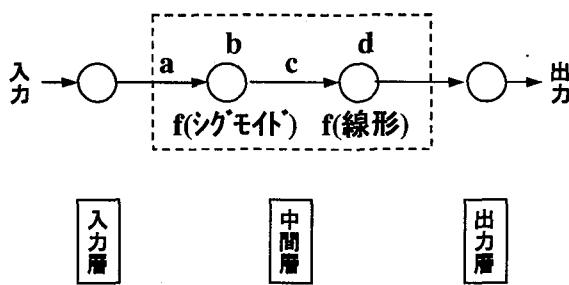
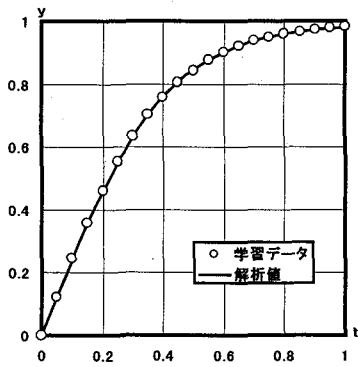
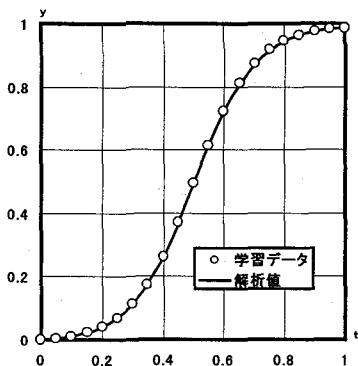


図-6 経年劣化予測システムの構成

図-5に示した2種類の劣化曲線を同定できるかを確認するために、学習条件を最小自乗誤差  $1e-6$  以内、または学習回数 10万回とし、サンプルデータを用いて検証をおこなった。その結果を図-7に示す。離散値として与えられたデータによって、このシステムが2種類の劣化曲線を同定できること、および、ニューラルネットワークの学習機能により、最小自乗近似の数値計算法が可能であることが確認できた。



(a) タイプI



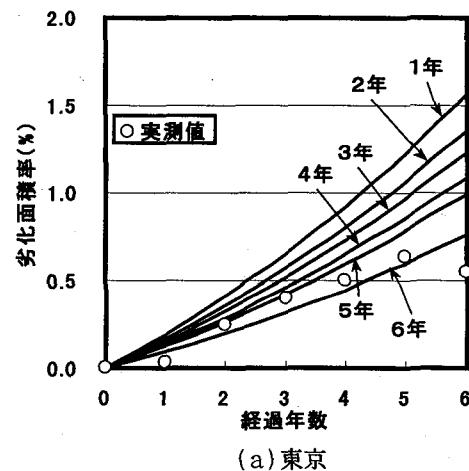
(b) タイプII

図-7 2種類の劣化曲線の同定結果

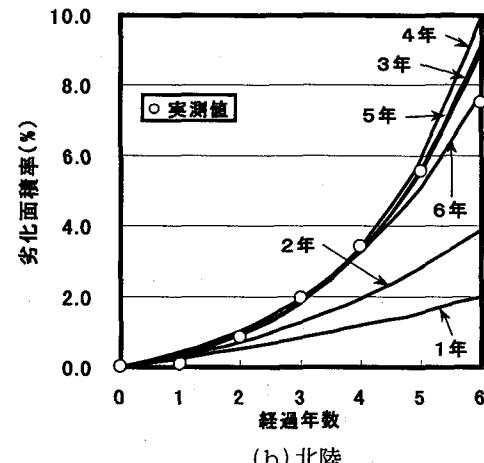
#### 4. 実データによる経年劣化予測システムの検証

3章では、経年劣化予測システムが最小自乗近似の数値計算法として動作し、2種類の劣化曲線を同定できることを確認した。そこで本章では、実際の調査結果のデータを用いて、経年データが徐々に蓄積されるにつれ、劣化曲線の形状がどのように変化していくかを追跡する同時に、2種類の劣化曲線自体の妥当性も検証する。

経年劣化予測システムの妥当性を検証するために、文献 13) のデータを用いた。この文献では、塗膜の劣化面積を塗装劣化の指標としており、3箇所の地域(東京、北陸、沖縄)で6年間、暴露試験を実施している。この調査結果を用いるために、経年劣化予測システムでの評価値を塗膜の劣化面積率(対象とする面積に対する劣化面積の割合)とし、データが1年のみのときから、6年までの各1年毎のデータが存在するときまでの、それぞれの場合について劣化曲線の同定をおこなった。学習条件は最小自乗誤差  $1e-6$  以内、または学習回数 10万回とし、仮想データを設定する経過年数を 100 年とした。その結果を図-8 に示す。図中の同定された各劣化曲線に示されている数字は、その経過年数までのデータを用いた場合の劣化曲線である。



(a) 東京



(b) 北陸

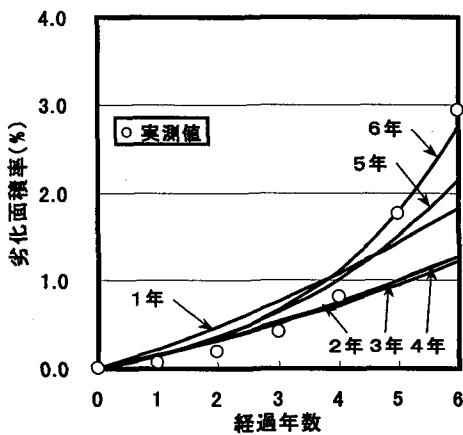


図-8 劣化曲線の同定結果

また、6年までのデータを用いた場合の、各地域の劣化曲線を図-9に示す。

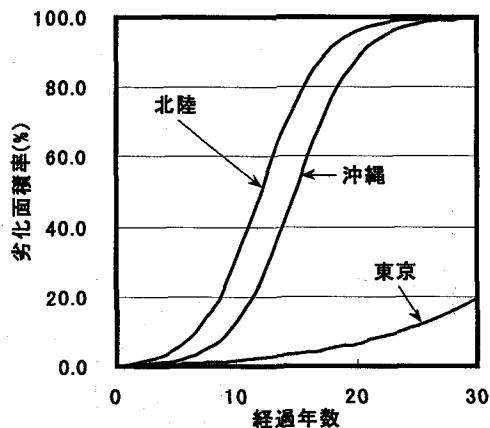


図-9 各地域の劣化曲線

3つの地方うち、北陸と沖縄の調査結果では、データが増えるにしたがって、経年劣化予測システムが妥当な劣化曲線を同定していると思われる。東京地方も6年までのデータがあれば、妥当な劣化曲線をあらわしているが、データ数が少ない場合では、劣化曲線は調査結果にあまり適合していない。その理由としては、経年劣化予測システムの制約条件の設定が挙げられる。東京地方の劣化面積率の値が、他の地方に比べて非常に小さく、例えば、東京地方の調査結果を原点で通る直線で近似した場合、劣化面積率が100%に達する年数は1000年にもなる。したがって、制約条件で設定した仮想データの経過年数100年よりも非常に大きいので、データの数が少ない程、劣化曲線はデータに対して適合していない。また、学習条件である平均自乗誤差は、評価値の最大値で正規化しているために、あまり適合していないても、平均自乗誤差は小さな値を取る。そこで、仮想データの経過年数が変化することによって、同定される劣化曲線がどのように変化するかを調べる。使用するデータとして、最も劣化進展が速い北陸地方のものを用い、経過年数6年

までのデータを使って、仮想データの経過年数を10年から40年まで変化させて、学習させた。他の学習条件は同じとした。その結果を図-10に示す。

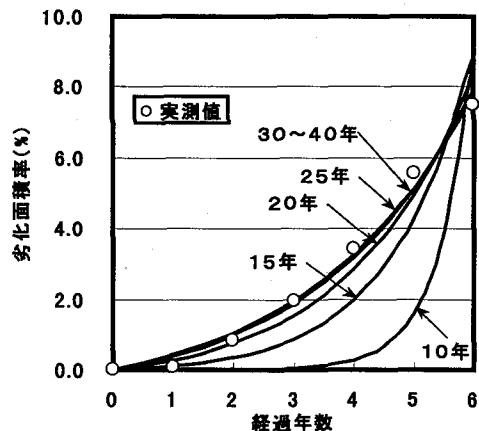


図-10 制約条件の違いによる劣化曲線の同定結果

図-10をみると、仮想データの経過年数が少ないと、その影響で劣化曲線はデータに適合していないが、逆に大きくなるとデータと良く適合し、30年以降は劣化曲線に変化はみられなくなっている。このことから、仮想データの経過年数をできるだけ大きな値に設定すれば、データには適合すると考える。しかし、実際の塗装劣化の現象を考えてみると、対象断面に対して、全面に発錆するまでに、100年や1000年もかかるとは考えにくく、劣化曲線の形状の妥当性や、データ自体のバラツキについて考える必要があると思われる。

##### 5. データのバラツキによるシステムの拡張

前章では、実際の劣化調査結果のデータを使用して、経年劣化予測システムの妥当性を検証した。そして、劣化曲線の妥当性とデータのバラツキについて検討する必要があると述べた。そのうち、劣化曲線の妥当性については、経年劣化予測システムの利点が基本的な劣化曲線の修正・追加であるので、新たな基本的な劣化曲線を定義すればよい。しかしデータのバラツキに関しては、最小自乗近似により劣化曲線を同定するだけでは、考慮できない。そこで、最小自乗近似によって劣化曲線を求めるのと同時に、バラツキのあるデータは全て同等の信頼性があるとし、データのバラツキを考慮して、評価値の上限値を通る劣化曲線(上限劣化曲線)と下限値を通る劣化曲線(下限劣化曲線)を新たに定義する。この方法は区間回帰分析に相当する。学習方法は、最小自乗近似の場合と同じであり、式(7)の代わりに、上限劣化曲線の場合には式(21)に、下限劣化曲線の場合には式(22)に変更することによって、上限・下限劣化曲線を求めることができる。

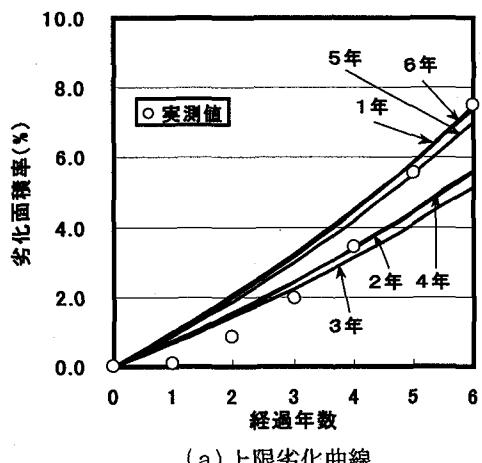
$$E[p] = \begin{cases} \frac{1}{2} \left( \frac{T[p] - o_1^3[p]}{T_{\max}} \right)^2 : T[p] > o_1^3[p] \\ r \cdot \frac{1}{2} \left( \frac{T[p] - o_1^3[p]}{T_{\max}} \right)^2 : T[p] \leq o_1^3[p] \end{cases} \quad (21)$$

$$E[p] = \begin{cases} r \cdot \frac{1}{2} \left( \frac{T[p] - o_1^3[p]}{T_{\max}} \right)^2 : T[p] \geq o_1^3[p] \\ \frac{1}{2} \left( \frac{T[p] - o_1^3[p]}{T_{\max}} \right)^2 : T[p] < o_1^3[p] \end{cases} \quad (22)$$

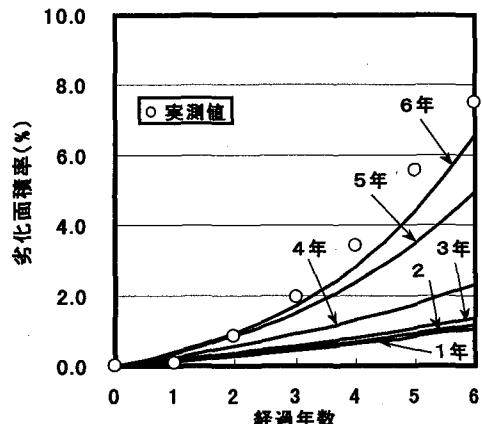
ここで、

$r$  : 自乗誤差に関する重み ( $0 < r < 1$ )

文献 12) の調査結果のうち、北陸地域のデータを用いて、上限・下限劣化曲線を求めた。その結果が図-11 である。学習条件は 4 章での条件と同じとし、自乗誤差に関する重み  $r$  を 0.01 とした。



(a) 上限劣化曲線



(b) 下限劣化曲線

図-10 上下限を通る劣化曲線の同定結果

経年劣化予測システムを拡張することにより、データにバラツキがある場合には、その上下限を通る劣化曲線の同定が可能となった。しかし、上限劣化曲線で、データが少ない場合、特に経過年数 2 年までのデータしかないときには、4 章の検証結果と同じ理由により、あまり一致していない。また、6 年までのデータがある場合の劣化曲線について、下限劣化曲線の傾きの方が上限劣化曲線の傾きよりも急であることから、6 年以降には上限劣化曲線と下限劣化曲線が交差してしまう。したがって、上限劣化曲線および下限劣化曲線を同定するには、前に述べた制約条件の他に、上下限の劣化曲線についても制約条件を設定する必要がある。

## 6. あとがき

著者らは、これまでに維持管理の効率化を図るために鋼橋の塗装劣化に着目し、塗装劣化に対する劣化原因の影響を求めることが可能なシステムの開発をおこなった。このシステムの方法論の 1 つとしてニューラルネットワークを採用した。ニューラルネットワークは、内挿的な予測は得意であるが、逆に外挿的な予測は不得意であるという性質がある。したがって、過去の経年データから将来の劣化を予測するためには、既存のシステムを拡張するのではなく、別のシステムとして開発することにした。また、将来の劣化予測をおこなうシステムを別のシステムとすることにより、既存のシステムは劣化原因の影響度を求めるシステムとして簡素化がはかれる。そこで、本論文では、新しく開発した経年劣化予測システムについて、その概要・構成およびその妥当性について述べた。

劣化予測の基本的な考え方として、最小自乗法による劣化曲線を同定させる方法とした。しかし、劣化曲線の選定や最小自乗法への定式化の困難さなどの問題が伴うことから、最小自乗法の近似計算としてニューラルネットワークの学習機能を採用した。そこで、実際の調査結果を用いて妥当性を検証した結果、このシステムによって、劣化曲線が同定することができた。また、実際のデータにはバラツキが存在することから、学習方法を改良して、データの上下限値を通る劣化曲線も同時に同定する方法を採用した。そして、実際の調査結果を用いて検証したところ、実際のデータに対しては、妥当性が示されていたが、上限劣化曲線と下限劣化曲線に関する条件を設定しなかったため、互いの曲線が交差した。また、方法論がニューラルネットワークである以上、制約条件の設定により、解が平均自乗誤差の極小値に陥ったり、平均自乗誤差が発散する可能性もあるので、今後の検討課題である。

## 謝 辞

本研究を遂行するにあたり、点検資料を提供して頂いた大阪市港湾局の港湾維持管理委員会、ならびに日本工

業試験所(株)の皆様に、謝意を表します。

## 参考文献

- 1) 松井繁之：コンクリート構造物の耐久性上の問題点とその対策、コンクリート工学、Vol.33、No.6、pp.59-67、1995.6.
- 2) 土木学会：構造物のライフタイムリスクの評価、1988.
- 3) 土木学会関西支部：既存橋梁の耐荷力と耐久性、1985.7.
- 4) 吉川 紀、細井義弘：橋梁の安全と快適のために、構造工学論文集、土木学会、Vol.42A、pp.881-889、1996.3.
- 5) 近田康夫、橘 謙二、城戸隆良、小堀為雄：GAによる既存橋梁の補修計画支援の試み、土木学会論文集、No.513/I-31、pp.151-159、1995.4.
- 6) 森 弘、大島俊之、三上修一、天野政一、井上 実：コンピュータ・グラフィックスと数量化理論を応用した橋梁の維持点検評価法、土木学会論文集、No.501/I-29、pp.113-121、1994.10.
- 7) 鋼構造委員会鋼橋の余寿命評価小委員会、鋼橋の劣化現象と損傷の評価：土木学会論文集、No.501/I-29、pp.21-36、1994.10.
- 8) 有馬博人、松井繁之、田中成典：鋼橋の劣化原因を考慮した塗装劣化予測システムに関する基礎的研究、構造工学論文集、土木学会、Vol.43A、pp.609-619、1997.3.
- 9) 船橋賢一：ニューラルネットワークの Capability について、信学技報、電子情報通信学会、MBE88-52、1988.
- 10) B. Irie and S. Miyake : Capabilities of three-layered perceptrons, Proc. ICNN 88, IEEE, pp.I-641, 1988.
- 11) D. E. Rumelhart, et al. : Parallel Distributed Processing, MIT Press, 1986.
- 12) 栗山 寛：防錆塗膜の寿命予測に関する一つの試み、防錆管理、Vol.34、No.5、pp.182-186、1990.5.
- 13) 藤原 博、三宅 将、菅野照造：鋼橋塗膜の余寿命推定のための塗膜劣化曲線に関する考察、土木学会第52回年次学術講演会講演概要集第I部門、I-A204、pp.406-407、1997.9.

(1997年9月26日受付)