

階層構造ニューラルネットを用いた コンクリート橋診断エキスパートシステムの開発

宮本文穂¹・河村 圭²・中村秀明³・山本秀夫⁴

¹正会員 工博 山口大学教授 工学部知能情報システム工学科 (〒755-8611 宇部市常盤台2-16-1)

²学生会員 修士 (工学) 山口大学大学院 理工学研究科博士後期課程 (同上)

³正会員 博士 (工学) 山口大学助教授 工学部知能情報システム工学科 (同上)

⁴正会員 修士 (工学) 山口県宇部土木建築事務所 (〒755-0033 宇部市琴艺町1-1-50)

本研究は、従来より著者らが開発してきた「コンクリート橋診断ニューロ・ファジイエキスパートシステム」の推論機構を各ニューロンに意味を持たせた階層構造ニューラルネットワークで新たに再構築し、さらに、この推論機構に誤差逆伝播法を応用することで、体系的な学習を可能としたものである。なお、システムによる診断結果の信頼性を向上させるために行う推論機構の学習で利用する教師データは、専門技術者による実橋梁の目視点検および耐用性診断にもとづいて作成した。また、本診断システムを実橋梁の耐用性診断に適用し、専門技術者による診断結果と比較することで、新たに構築した推論機構の学習能力の検証を行った。

Key Words : bridge rating, serviceability assessment, expert system, machine learning,
hierarchical neural network, back propagation, questionnaire

1. はじめに

我が国の道路整備は、昭和 29 年を初年度とする第 1 次道路整備五箇年計画から本格的に始まり¹⁾、現在、平成 5 年度を初年度とする第 11 次道路整備五箇年計画によって高規格幹線道路の延長は 7,806km にまで達しようとしている。我が国は、多くの島々を抱え、また急峻な地形と多数の河川を擁しており、都市部では高度な土地利用が要求されるなど、厳しい空間的制約があることから、橋梁は道路整備を進めていくためにも、さらには道路ネットワークを維持していくためにも必要不可欠な道路構造物の一つといえる。実際、現在までに道路整備五箇年計画に基づく道路整備の積み重ねにより、60 万橋（支間長 2m 以上）を超える橋梁が架設されている²⁾。しかし、これらの多くは昭和 30 年代から 40 年代にかけて架設されたものであり、供用開始時から 30 年ないし 40 年が経過していることから、何らかの維持管理対策を必要としているものが少なくない。このように適切な維持管理対策を怠るべき橋梁が増加しているにもかかわらず、国内の極めて悪化した経済事情を反映して公共投資予算は、大幅

な削減の方向にあることから、近年、既存橋梁に対して合理的な維持管理対策を行っていくことの重要性が指摘され、橋梁維持管理支援システム（Bridge Management System : BMS）の必要性が各方面で叫ばれ始めている。すでに、我が国よりも早い時期から道路網整備が進んできた米国では、連邦交通局が「PONTIS」^{3), 4)}という BMS を構築し、限られた予算のもとで維持管理対策を優先的に講じて行くべき橋梁選定のシステム化を試みている^{5), 6)}。また、他の先進諸国においても同様な目的の BMS の開発が進んでいる⁷⁾。著者らも、橋梁諸元データやひび割れ状況などの主として目視点検データに基づいて既存橋梁の損傷程度を診断し、それを基に橋梁の維持管理計画を策定する BMS（以下、本 BMS と略記する）の開発を行ってきた⁸⁾。橋梁の維持管理は、「点検・調査」→「診断」→「補修・補強」といった流れに沿って行われるが、体系的な「補修・補強」を行うためにも「診断」は重要になる。しかし、我が国では実際の点検結果より橋梁の診断を行える専門技術者（以下、専門家と略記する）の数は比較的に少ないのが現状であり、今後の維持管理業務の増加に対してその人材不足が懸念される。そこで、

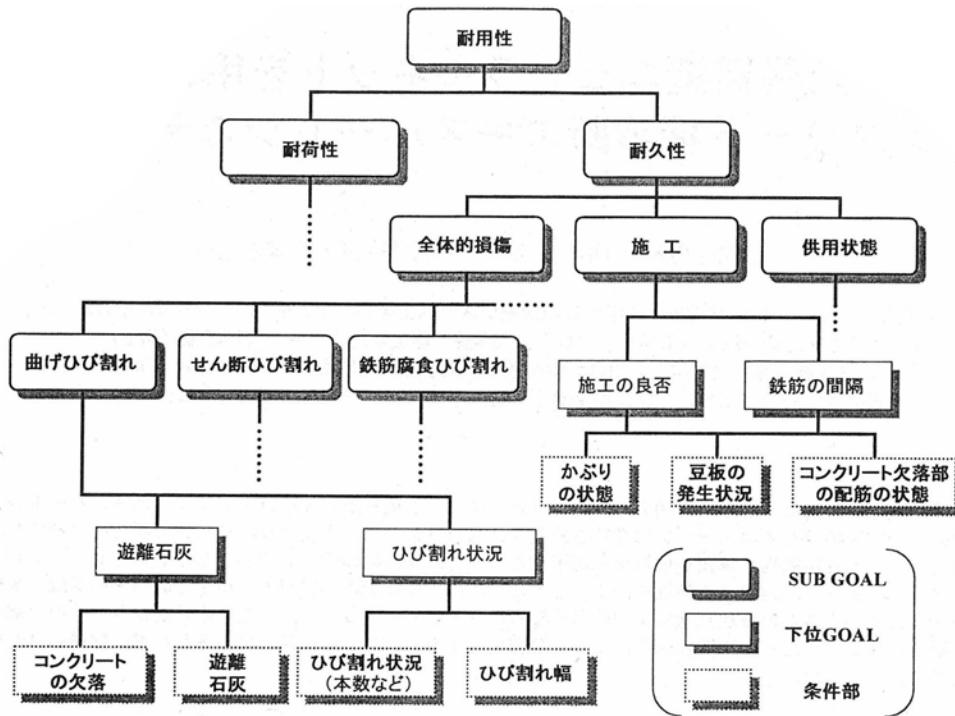


図-1 診断プロセス（主軸）の例

著者らは本 BMS の診断部として機能する「コンクリート橋診断ニューロ・ファジイエキスパートシステム」（以下、診断システムと略記する）の開発を進めてきた。

この診断システムは、橋梁の維持管理に長年携わってきた専門家の橋梁診断における経験的な知識をコンピュータ上に移植し、橋梁諸元、環境条件、交通量、各ひび割れの状態といった橋梁台帳や目視点検結果等から得られた定量的、定性的なデータを入力することにより、橋梁の総合的な耐用性診断を行うシステムである。現在までの研究において、専門家の有する診断過程が診断プロセスとして床版及び主軸それぞれについて階層構造化（例えば、図-1 参照）されている⁹⁾。また、このプロセスに従ったさまざまな推論手法が著者らによって検討されている¹⁰⁾。近年では専門家が所有している橋梁診断における経験的な診断および評価知識をアンケート調査により導出し、これを II 関数を用いることでメンバーシップ関数として表現し、先に述べた診断プロセスに従ってこのメンバーシップ関数同士を Dempster の結合則¹¹⁾を用いて結合させて推論を行う診断システムが提案されている（以下、旧診断システムと略記する）¹²⁾。さらに、旧診断システムでは知識更新機能、すなわち学習機能が不十分であることから、ニューラルネットワークを適用すること

で学習を可能にした診断システムを開発している¹³⁾。具体的には、誤差逆伝播法（Back Propagation;BP）による知識更新と双方向連想記憶（Bidirectional Associative Memories;BAM）によるファジイ推論を可能にしている（以下、前診断システムと略記する）。しかし、BAM を用いた推論機構は、推論機構自体が大規模なものとなり、また推論機構が分散型の構造となっているために体系的な学習が困難であるといった問題点を抱えていた。そこで、本研究では、プロダクションルールを基に推論機構が構築でき、かつ推論機構の構造もシンプルで、学習も容易に実施可能な階層構造ニューラルネットワーク（Hierarchical Neural Network）^{14), 15)}を用いて診断システムの推論機構の再構築を行った。また、旧診断システムの推論手法を利用することにより、新たに診断プロセスに沿ったファジイ変数を含む初期プロダクションルールを作成した。なお、システムによる診断結果の信頼性を向上させるために行う推論機構の学習で利用する教師データは、専門技術者に実橋梁の目視点検および耐用性診断を行ってもらうことにより作成した。さらに、本診断システムを実橋梁の耐用性診断に適用し、専門技術者による診断結果と比較することで、新たに構築した推論機構の学習能力および診断結果の妥当性の検証を行った。

2. 階層構造ニューラルネットワークの基本構成と学習アルゴリズム

(1) ルールの抽出と作成

本論文において提案する階層構造ニューラルネットワークによる推論機構を構築するには、初期プロダクションルールが必要とされる。従って本節では、旧診断システム¹²⁾からファジィ変数を含んだ if-then 形式のプロダクションルールを抽出および作成する手法について述べる。なお、本研究で用いるプロダクションルールは、式(1)のように設定される。

$$R^i : \text{if } x_1 \text{ is } A_1 \text{ and } \cdots \text{ and } x_m \text{ is } A_m \text{ then } y \text{ is } B_i \quad (1)$$

ここで、 R^i は i 番目のルール、 x_1, \dots, x_m は入力変数（条件）すなわち点検項目、 y は出力（結論）すなわち診断項目になる。また A_1, \dots, A_m はファジィ変数、 B_i はクリスピ変数（平均健全度）である。

旧診断システムは、専門家が所有している橋梁診断における経験的な知識をアンケート調査により導出している。これをメンバーシップ関数として表現し、図-1 で示した診断プロセスに従ってメンバーシップ関数同士を Dempster の結合則で結合させることにより最終的な推論（診断）を行うものである。従来から、メンバーシップ関数の形状を定義する合理的な手法がいくつか提案されてきたが¹⁰⁾、旧診断システムでは、アンケート調査結果が定量的に獲得できることを考慮し、Π 関数を用いてきた。なお、Π 関数は式(2)で表され、Π 関数の概念図を図-2 に示す。なお、図中の x 軸は、診断項目の評価点数（0～100 点）である。

$$\Pi(x; a, b, c) = \begin{cases} 0 & (x \leq c-a) \\ \omega \times 2 \left\{ \frac{x-(c-a)}{a} \right\}^2 & \left(c-a < x \leq c - \frac{a}{2} \right) \\ \omega \times \left\{ 1 - 2 \left(\frac{x-c}{a} \right)^2 \right\} & \left(c - \frac{a}{2} < x \leq c \right) \\ \omega \times \left\{ 1 - 2 \left(\frac{x-c}{b} \right)^2 \right\} & \left(c < x \leq c + \frac{b}{2} \right) \\ \omega \times 2 \left\{ \frac{x-(c+b)}{b} \right\}^2 & \left(c + \frac{b}{2} < x \leq c+b \right) \\ 0 & (x > c+b) \end{cases} \quad (2)$$

ここで、 ω はメンバーシップ関数のピークの高さを変化させるパラメータである。このようにメンバーシップ関数はパラメータ a, b, c により決定される。次に a, b, c 各パラメータの性質をそれぞれ示す。

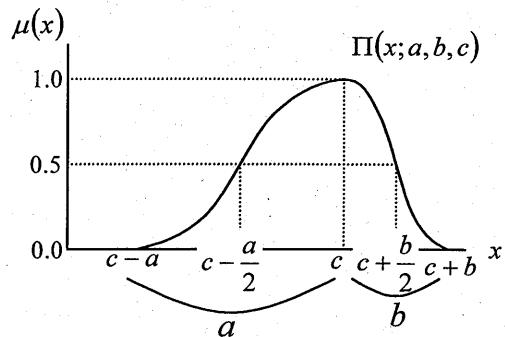


図-2 Π 関数の概念図

a : c より左側 ($x \leq c$) のあいまいさのばらつきの程度を表す。

b : c より右側 ($x \geq c$) のあいまいさのばらつきの程度を表す。

c : メンバーシップ関数のピークの位置を表す。

また、旧診断システムでは、アンケート調査結果をもとに、各パラメータを次のように定義している。

a : c と評価点の最小値との差の 2 倍

b : c と評価点の最大値との差の 2 倍

c : 全評価点の平均値

本研究では、この診断プロセスおよびΠ 関数のパラメータを利用して初期プロダクションルールを作成している。以下に旧診断システムの推論手法およびルール構築手法について説明する。

a) 条件部-下位 GOAL 間のルール作成

旧診断システムでは、条件部に橋梁諸元データもしくは点検結果が入力されると、下位 GOAL の状態を決定するメンバーシップ関数が選択される。このプロセスを具体的に説明すると、図-1 に示される条件部の内、例えば[豆板の発生状況]および[コンクリート欠落部の配筋の状態]に、点検結果による入力値としてそれぞれ {かなり発生} および {かなり密} が入力されると、下位 GOAL の一つである「鉄筋の間隔」の状態を評価するメンバーシップ関数が選択される。この例では、表-1 中のΠ 関数の各パラメータの欄にある数値、 $a=40.0$, $b=40.0$, $c=20.0$ が式(2)に代入され、この結果が下位 GOAL 「鉄筋の間隔」の状態を表すメンバーシップ関数となる。なお、このメンバーシップ関数の形状を決定するΠ 関数の各パラメータは、事前の専門家に対するアンケート調査によって獲得されており、旧診断システムの知識ベースに保存されている（表-1 参照）。

続いて、初期プロダクションルールの作成方法について記述する。本研究では、旧診断システムの知

表-1 プロダクションルールの構築結果の例

a) 下位 GOAL 「鉄筋の間隔」におけるプロダクションルール

No.	条件部 (前件部)		Π関数の各パラメータ			下位 GOAL(後件部) 「鉄筋の間隔」の平均健全度 ((Π関数の重心の値)→ (スケーリング後の値))
	豆板の発生状況	コンクリート欠落部の配筋の状態	a	b	c	
1	かなり発生	かなり密	40.0	40.0	20.0	20.0 → 0.0
2	かなり発生	普通	21.6	28.4	35.8	37.8 → 22.2
3	少し発生	かなり密	50.0	30.0	35.0	29.2 → 11.5
4	少し発生	普通	18.4	31.6	54.2	58.1 → 47.6
5	発生なし	かなり密	18.4	31.6	54.2	58.1 → 47.6
6	発生なし	普通	25.0	25.0	100.0	100.0 → 100.0

b) 下位 GOAL 「ひび割れ状況」におけるプロダクションルール

No.	条件部 (前件部)		Π関数の各パラメータ			下位 GOAL(後件部) 「ひび割れ状況」の平均健全度 ((Π関数の重心の値)→ (スケーリング後の値))
	ひび割れ状況	ひび割れ幅	a	b	c	
1	かなり多い	かなり大きい	26.6	23.4	13.3	12.4 → 0.0
2	かなり多い	大きい	20.0	10.0	20.0	17.1 → 7.5
3	かなり多い	小さい	21.6	48.4	35.8	43.6 → 49.9
4	かなり多い	極小さい	25.0	25.0	50.0	50.0 → 60.1
5	多い	かなり大きい	25.0	35.0	22.5	25.4 → 20.8
6	多い	大きい	20.0	20.0	30.0	30.0 → 28.2
7	多い	小さい	16.6	43.4	48.3	56.1 → 69.9
8	多い	極小さい	25.0	25.0	60.0	60.0 → 76.1
9	少ない	かなり大きい	20.0	30.0	35.0	37.9 → 40.8
10	少ない	大きい	25.0	35.0	42.5	45.4 → 52.8
11	少ない	小さい	33.4	26.6	61.7	59.7 → 75.6
12	少ない	極小さい	25.0	25.0	75.0	75.0 → 100.0

知識ベースに保存されている各パラメータによって形成されるメンバーシップ関数の重心を式(3)により得ており、この値を、下位 GOAL の評価値すなわち平均健全度としている。なお、ここでの平均健全度は見かけの平均健全度と呼ぶことにする。

$$G = \frac{\int x \cdot \mu(x) dx}{\int \mu(x) dx} \quad (3)$$

すべての条件の組み合わせに対して同様に重心を評価値とするが、このままではどのような最悪な条件下でも 0 点、逆にどのような最良な条件下でも 100 点の値を出力しないことから、実際に後件部命題において用いる平均健全度は、式(4)を用いてスケーリングを行った値(G')とすることとした。

$$G' = \frac{G - G_{\min}}{G_{\max} - G_{\min}} \times 100 \quad (4)$$

ここで G_{\max} , G_{\min} は、それぞれ見かけの平均健全度の最大値、最小値である。

このスケーリングを行うことにより最も悪い条

件の組み合わせに対しては 0 点、逆に最も良い条件の組み合わせに対しては 100 点が出力される。

以上に述べた手順により、次に示すような条件部から下位 GOAL のルールが抽出できる（表-1 参照）。

例) if ([豆板の発生状況]=かなり発生) and ([コンクリート欠落部の配筋の状態]=かなり密) then 「(鉄筋の間隔)=0.0」

b) 下位 GOAL-SUB GOAL 間および SUB GOAL-SUB GOAL 間のルール作成

旧診断システムでは、システムへの入力値より下位 GOAL の状態を示すメンバーシップ関数が決定されると SUB GOAL の状態を評価するために、それぞれ選択された下位 GOAL のメンバーシップ関数を Dempster の結合則により結合し、さらに、上位の SUB GOAL を評価する場合には、下位の SUB GOAL をこの結合則により結合することにより推論を行っていた。このプロセスを具体的に説明すると、図-1 に示される条件部の内、例えば「[かぶりの状態]」、「[豆板の発生状況]」および「[コンクリート欠落部

の配筋の状態]に点検結果が入力されると、下位 GOAL である「施工の良否」および「鉄筋の間隔」の状態を評価するメンバーシップ関数が選択される。この関数を Dempster の結合則により結合することで、SUB GOAL の一つである『施工』の状態を評価するメンバーシップ関数が得られる。さらに、上位 SUB GOAL である『耐久性』の状態を評価する場合は、下位 SUB GOAL である『全体的損傷』、『施工』および『供用状態』の状態を示すメンバーシップ関数を Dempster の結合則により結合する。

続いて、まず下位 GOAL の状態から SUB GOAL の状態を決定するルールの構築手法について解説する。

SUB GOAL の状態を評価するルールを抽出する場合では、下位 GOAL の状態が前件部となり SUB GOAL の状態が後件部となる。そこで、先に求めた下位 GOAL の平均健全度の中で 0 点、50 点、100 点の状態に最も近いメンバーシップ関数をそれぞれ danger, moderate, safe の状態の代表として Dempster の結合則を用いて他の下位 GOAL のメンバーシップ関数と結合させる。なお、Dempster の結合則を用いた具体的な結合手法は、文献 11) を参照されたい。このように SUB GOAL ごとに下位 GOAL の状態を示すメンバーシップ関数全ての組み合わせについて結合し、結合したメンバーシップ関数の重心をとる。続いて結合により得られた重心値に対して式(4)を用いてスケーリングを行う。上述のような方法により、下位 GOAL から SUB GOAL を評価するプロダクションルールを抽出できる。

例) if (「施工の良否」=danger) and (「鉄筋の間隔」=danger) then (『施工』=0.0)

また、同様にして下位 SUB GOAL から上位 SUB GOAL を評価するプロダクションルールを抽出できる。

(2) 階層構造ニューラルネットワークの基本構成と学習アルゴリズムの概説^{14), 15), 17)}

本節では、本診断システムの推論機構を構成する階層構造ニューラルネットワークの基本構成および学習アルゴリズムについて概説する。なお、ここでの説明では、式(I)のように if-then ルールの前件部に記述されている命題は、すべてファジィ命題であり、後件部命題はすべてクリスピ変数を用いて記述されているとする。

a) 推論機構の基本構成

階層構造ニューラルネットワークの基本構成は、図-3 に示すように 5 層の階層構造ニューラルネットからなる。この 5 つの層はそれぞれ (A) 層の入

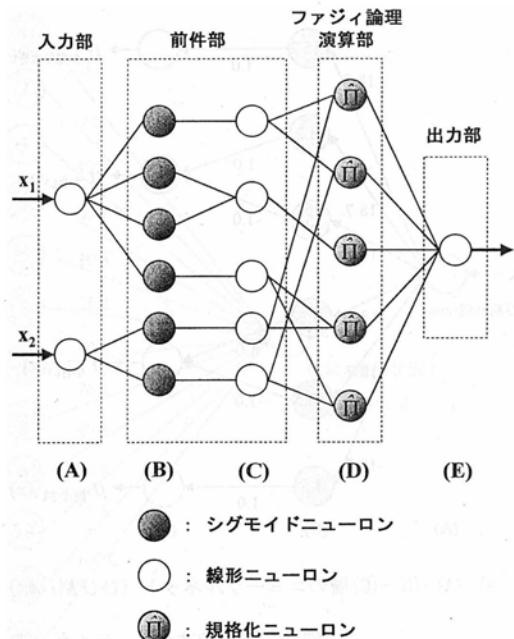
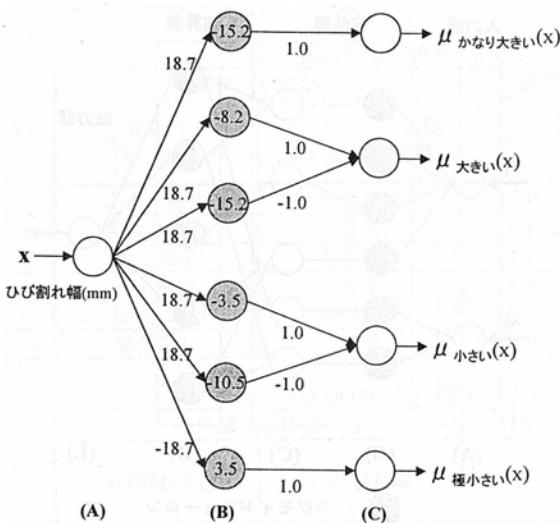
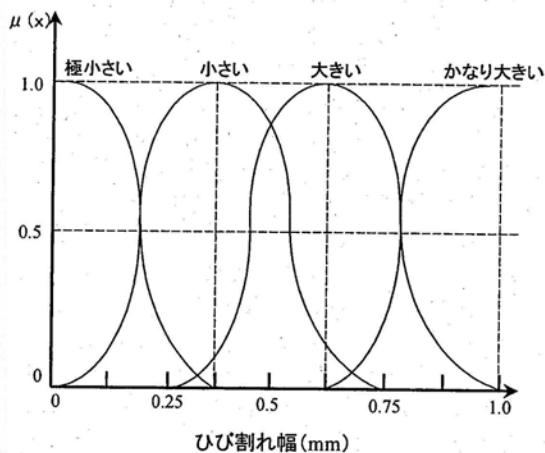


図-3 推論機構 (階層構造ニューラルネットワーク)
の構成

力部、(B) 層および(C) 層の前件部、(D) 層のファジィ論理演算部、(E) 層の出力部から成り立っている。入力部 (A) 層のニューロンは、入力された値を次層の (B) 層のニューロンに分配する役目を担っており、ニューロンの数は、プロダクションルール前件部の入力変数 (ファジィ変数の数) に等しい。前件部 (B) 層および (C) 層により、前件部ファジィ命題におけるファジィ集合のメンバーシップ関数を同定する。このように、(A)-(B)-(C) 層は、プロダクションルール前件部に存在するファジィ命題に対応している。なお、(C) 層のニューロンの数は、前件部ファジィ変数が有するファジィ集合の数に等しい。図-3 の前件部のように (B) 層において、(C) 層のニューロンに対して 1 つのニューロンが結合しているものはメンバーシップ関数の中でも単調増加型あるいは単調減少型の関数を表し、2 つのニューロンが結合しているものは疑似台形型のメンバーシップ関数を表す。ファジィ論理演算部 (D) 層のニューロンは、それぞれルールに対応しておりその数はルール数に等しい。このように、(D) 層のニューロンは、対応するプロダクションルールに記述されている前件部ファジィ命題を表現している (C) 層のニューロンと結合する。ここでは、代数積によるファジィ演算処理を行った後、正規化することにより、入力データに対する各プロダ



a) (A)-(B)-(C)層のニューラルネット (ひび割れ幅)



b) ひび割れ幅の程度を示すファジ集合

図-4 階層構造ニューラルネットワークにおける入力部および前件部の例

クションルールの適合度を出力する。出力部(E)層は、(D)層より出力された各ルールに対する適合度とプロダクションルールの後件部クリスピ変数の値である(D)層-(E)層間の結合重みを掛け合わせた値の和を診断結果として出力する。このように、推論機構が階層構造ニューラルネットより構成されていることから、誤差逆伝播法により容易に学習を行うことができる。

統いて、プロダクションルールを基に推論機構を構築する方法について具体的に説明する。ここでは、下位 GOAL 「ひび割れ状況」を評価する階層構造ニューラルネットワークの構築を例に説明する。なお、このネットワークの構築に必要とされるプロダクションルールは、表-1の b)を参照されたい。

下位 GOAL 「ひび割れ状況」を評価する条件部には、[ひび割れ状況 (本数など)]および[ひび割れ幅]がある。このうち条件部[ひび割れ幅]には、点検時に見られたひび割れの幅(mm)が入力される。本研究では、この点検によって確認されたひび割れ幅(mm)の程度を示すファジ集合を図-4 の b)のようになして設定している。階層構造ニューラルネットワークでは、図-4 の a)に示される(A)-(B)-(C)層によりこのファジ集合を近似しており、(A)層のニューロンにひび割れ幅(mm)が入力されると、(C)層より、それぞれのファジ集合に適合する程度つまりグレードが出力される。また、図-4 の a)から分かるように、推論機構の(A)層から(C)層の前件部においては単調増加型あるいは単調減少型のメンバーシッ

プ関数は1つのシグモイド関数を応答関数として持つニューロン（以下、シグモイドニューロンと略記）で近似され、疑似台形型のメンバーシップ関数は2つのシグモイドニューロンで近似される。ここで、(A)-(B)層間の重みWとシグモイドニューロンのしきい値Θを以下のように算出することによってメンバーシップ関数を近似する。疑似台形型のメンバーシップ関数の場合、2つのシグモイド型ニューロンで近似するため、重みおよびしきい値をそれぞれ2つ算出する必要がある。

① 単調減少型の場合

$$\begin{cases} \omega = -h/A \\ \theta = hB/A \\ x_1 = B-A, \mu(x_1) = 1.0, x_1 \in X \\ x_2 = B+A, \mu(x_2) = 0.0, x_2 \in X \\ x_1, x_2 \in X \end{cases} \quad (5)$$

② 単調増加型の場合

$$\begin{cases} \omega = h/A \\ \theta = -hB/A \\ x_1 = B+A, \mu(x_1) = 1.0, x_1 \in X \\ x_2 = B-A, \mu(x_2) = 0.0, x_2 \in X \\ x_1, x_2 \in X \end{cases} \quad (6)$$

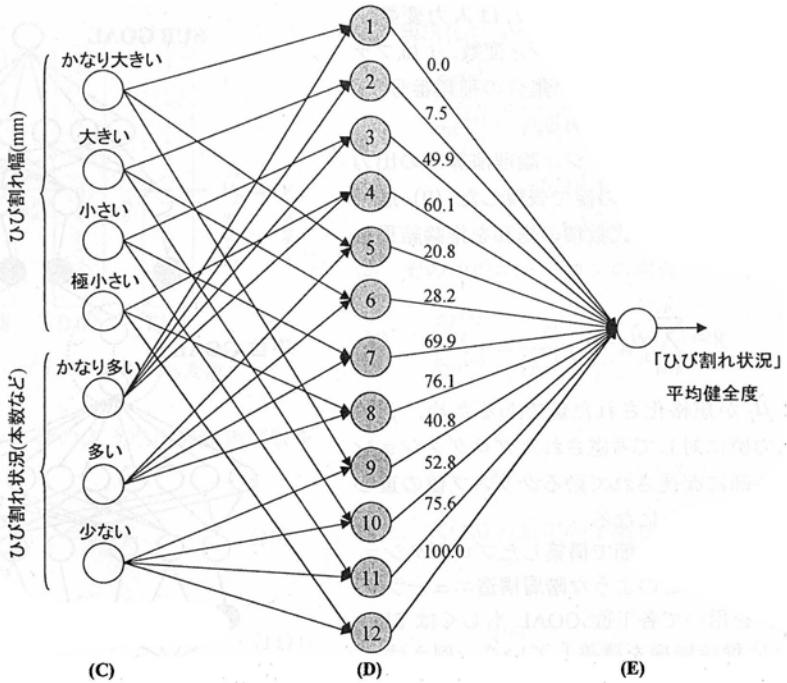


図-5 (C)-(D)-(E)層のニューラルネット

③疑似台形型の場合

$$\left\{ \begin{array}{l} \omega_1 = h/A \\ \omega_2 = h/C \\ \theta_1 = -h(B-A)/A \\ \theta_2 = -h(B+C)/C \\ x_1 = B, \mu(x_1) = 1.0 \\ x_2 = B-2A, \mu(x_2) = 0.0 \\ x_3 = B+2C, \mu(x_3) = 0.0 \\ x_1, x_2, x_3 \in X, x_2 < x_3 \end{array} \right. \quad (7)$$

なお、 h はシグモイド関数 $f(h) \approx 1.0$ を満足する実数で、例えば $h=3.5$ と設定する。また、単調増加型あるいは単調減少型の関数を近似する場合の (B)-(C) 層間の重みは常に 1.0 と設定され、疑似台形型の場合は常に -1.0 と 1.0 に設定される。以上のように設定した入力部および前件部に対して入力データを入力すると、その入力データが、プロダクションルールに記述されている前件部ファジィ命題にどれほど適合しているかを表すメンバーシップ関数のグレードが (C) 層より出力される。

続いて、図-5 に示されるような推論機構の (C)-(D)-(E) 層の構築について記述する。なお、図中の (D) 層の番号は、プロダクションルール番号を示しており、表-1 の b) に記述されている番号に対応し

ている。このように、下位 GOAL 「ひび割れ状況」を評価する階層構造ニューラルネットワークでは、(C)-(D) 間のワイヤーは、表-1 の b) に示されるプロダクションルールに従って設定され、その重みの初期値は 0.5 としている。また、(D)-(E) 間は、プロダクションルールの後件部を表現しており、その重みは、プロダクションルールの後件部に記述されている平均健全度の値と等しい。

ファジィ論理演算部の (D) 層では、(C) 層より出力されたメンバーシップ関数のグレードのうち、(D) 層の各ニューロンが表現するプロダクションルールの前件部に存在するファジィ命題との適合度を表すメンバーシップ関数のグレード $\mu_{ij}(x_j)$ に対して代数積を行い、入力データに対する各ルールの適合度を算出する。その際、(D) 層は規格化ニューロンであり、以下の式で規格化を行う。

$$\left\{ \begin{array}{l} \text{入力 : } \mu_i = \prod_j \mu_{ij}(x_j) \\ \text{出力 : } \hat{\mu}_i = \frac{\mu_i}{\sum_{k=1}^n \mu_k} \end{array} \right. \quad (8)$$

ここで、 i は (D) 層におけるニューロンの番号 (プロダクションルール番号)、 j は入力変数

(ファジィ変数) の種類番号, x_j は入力変数, μ_{ijj} は入力変数 x_j に対するファジィ変数, i_j はファジィ変数 μ_{ijj} が有するファジィ集合の種類番号, n はプロダクションルール数である。

出力部 (E) 層では、ファジィ論理演算部の出力 $\hat{\mu}_i$ と後件部クリスピ変数の値で表現した (D) 層—(E) 層間の重み ω_i との代数積の総和を推論結果として出力する。

$$y = \sum_{k=1}^n \hat{\mu}_k \omega_k \quad (9)$$

式(9)は $\hat{\mu}_i$ が規格化された値であるため、システムへの入力値に対して考慮されたプロダクションルールの後件部に記述されているクリスピ値の重心演算を行っていることになる。

上述してきたように前節で構築したプロダクションルールをもとに、このような階層構造ニューラルネットワークを用いて各下位 GOAL もしくは SUB GOAL ごとに推論機構を構築していく。例えば、下位 SUB GOAL の推論機構は、図-6 に示される構造を取り、さらに上位 SUB GOAL の評価を行うネットワークと連結される。

本論文に適用した階層構造ニューラルネットの特徴は、各ニューロンやそれを結ぶ重みなどに意味を持たせることにより、ニューラルネット内の推論処理がブラックボックスとならず、さらに学習後のプロダクションルールの更新も確認することが可能となっていることである。

b) 学習アルゴリズム

前節では、階層構造ニューラルネットワークの基本構成ならびに内部処理について述べた。階層構造ニューラルネットワークを用いた推論機構は、推論機構全体が一つの階層的なネットワークとして表現されていることから、誤差逆伝播法 (Back Propagation : BP) を用いることにより、2.(1)節において作成した初期プロダクションルールを基に設定した初期状態 (プリワイヤ) から学習することができる。本節ではその学習アルゴリズムについて説明する。

階層構造ニューラルネットワークでは、各層間の結合重みが特定の意味を持って設定されているが、この結合重みを変化させることにより、ファジィプロダクションルールの同定およびメンバーシップ関数の調整を行い学習をしていく。具体的に学習する箇所は、図-4 および図-5 を例にすると、(A) 層—(B) 層間の重み、(B) 層のしきい値、(C) 層—(D) 層

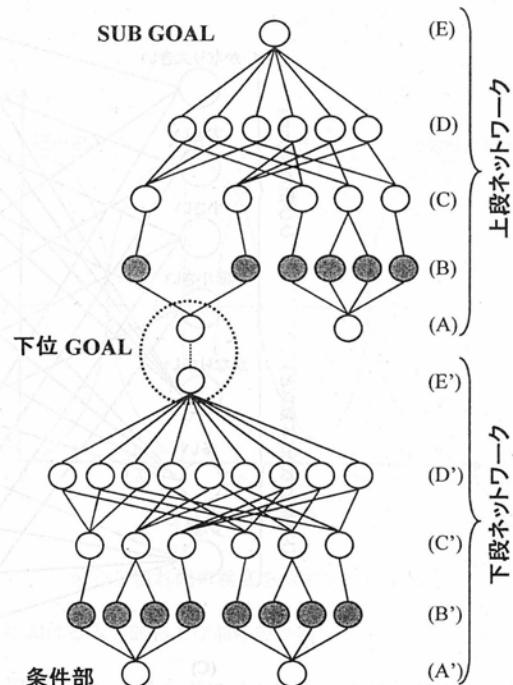


図-6 下位 SUB GOAL の推論機構

間の重みおよび(D)層—(E)層間の重みである。前節で述べてきたように、(A)層—(B)層間の重みと(B)層のしきい値は、前件部ファジィ集合のメンバーシップ関数の形状を表現するのに用いられていることから、学習データによるネットワークの学習後に、これらの値より学習後のメンバーシップ関数を読み取ることができる。すなわち、学習後の重みは、メンバーシップ関数の傾きの変化を表しており、また学習後のしきい値は、メンバーシップ関数の左右への軸の移動を表している。(C)層—(D)層間の重みの学習では、あるルールに記述されている前件部命題の重要度が変更される。例えば、図-5 の場合では下位 GOAL 「ひび割れ状況」を評価するのに[ひび割れ状況 (本数など)]と[ひび割れ幅 (mm)]のどちらの命題を重要視するかが重みの変化よりわかる。(D)層—(E)層間の重みの学習では、後件部命題が更新される。例えば、学習前の後件部の重みが 7.5 であり、学習後の重みが 15.5 の値になったとすると、後件部命題が「ひび割れ状況」 = 7.5 から「ひび割れ状況」 = 15.5 に変化したことが分かる。

続いて、誤差逆伝播法 (BP) を用いた学習アルゴリズムを示す。なお、図-7 には、学習アルゴリズムで用いた変数を示す。

一般的に、 N パターンの入力データと教師データ

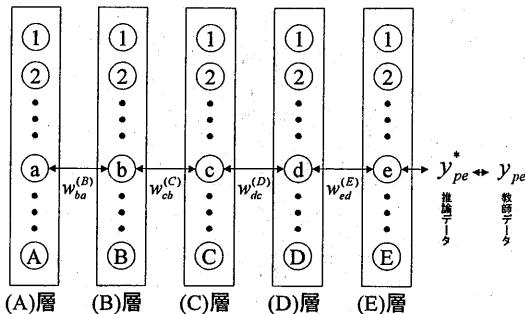


図-7 学習アルゴリズムで用いる変数

の組が与えられたとき、次のような出力誤差関数を定義する。

$$E_p = \frac{1}{2} \sum_j (y_{pj} - y_{pj}^*)^2 \quad (10)$$

$$E = \sum_{p=1}^N E_p \quad (11)$$

ここで、 y_{pj} は p 番目の学習データにおける出力値（教師データ）であり、 y_{pj}^* は y_{pj} に対する出力層ニューロンの出力値（階層構造ニューラルネットの推論値）である。また、 j はニューロンの番号である。このとき、学習データ全体による出力誤差 E の最小化のため、 p 番目の学習データに対する出力誤差 E_p を最小にするには、ネットワークの重み $w_{ji}^{(n)}$ の更新量 $\Delta w_{ji}^{(n)}$ を、次式のように定める。

$$\Delta w_{ji}^{(n)} \propto -\eta \frac{\partial E_p}{\partial w_{ji}^{(n)}} \quad (12)$$

ここで $w_{ji}^{(n)}$ は $(n-1)$ 層の i 番目のニューロンと (n) 層の j 番目のニューロンの結合重み、 η はどの程度学習が進むかを決める学習率である。式(12)の右辺は、 $I_j^{(n)}$ を n 層のニューロン j への入力和とすると $w_{ji}^{(n)}$ の定義により、次式のように変形できる。

$$-\frac{\partial E_p}{\partial w_{ji}^{(n)}} = -\frac{\partial E_p}{\partial I_j^{(n)}} \frac{\partial I_j^{(n)}}{\partial w_{ji}^{(n)}} \quad (13)$$

ここで、式(13)の右辺の 2 項目は n 番目の層が規格化ニューロンかどうかにより以下のように変形できる。

① 規格化ニューロンの場合

$$\begin{aligned} \frac{\partial I_j^{(n)}}{\partial w_{ji}^{(n)}} &= \frac{\partial}{\partial w_{ji}^{(n)}} \prod_k w_{jk}^{(n)} O_k^{(n-1)} \\ &= O_i^{(n-1)} \left(\prod_{k \neq i} w_{jk}^{(n)} O_k^{(n-1)} \right) \end{aligned} \quad (14)$$

② その他のニューロンの場合

$$\begin{aligned} \frac{\partial I_j^{(n)}}{\partial w_{ji}^{(n)}} &= \frac{\partial}{\partial w_{ji}^{(n)}} \sum_k w_{jk}^{(n)} O_k^{(n-1)} \\ &= O_i^{(n-1)} \end{aligned} \quad (15)$$

ここで、 $O_j^{(n)}$ は n 層のニューロン j の出力とする。

また、式(13)の右辺の 1 項目を、次式のように定義する。

$$\delta_j^{(n)} = -\frac{\partial E_p}{\partial I_j^{(n)}} \quad (16)$$

式(16)は各ニューロンにおける出力誤差を意味する。誤差逆伝播 (BP) 法による学習は、この $\delta_j^{(n)}$ を出力層から入力層に向かって逆伝播させることによって行われる。以下、階層構造ニューラルネットにおける逆伝播規則である各層のデルタルールを示す。

$$\delta_e^{(E)} = y_{pe} - O_e^{(E)} \quad (17)$$

$$\delta_d^{(D)} = \sum_k \delta_k^{(E)} \frac{w_{kd}^{(E)} - I_k^{(E)}}{\sum_l I_l^{(D)}} \quad (18)$$

$$\delta_c^{(C)} = \sum_k \delta_k^{(D)} w_{kc}^{(D)} \left(\prod_{i \neq c} w_{ki}^{(D)} O_i^{(C)} \right) \quad (19)$$

$$\delta_b^{(B)} = f'(I_b^{(B)}) \sum_k \delta_k^{(C)} w_{kb}^{(C)} \quad (20)$$

ここで、 $I_i^{(n)}$ 、 $O_i^{(n)}$ は n 層の i 番目のニューロンへの入出力を表している。

以上より、各層間の重みの更新量は、次式となる。なお、図-3 の (B) 層 - (C) 層間の結合重み $w_{cb}^{(C)}$ は、シグモイド関数の形状を利用して、単調増加、単調減少あるいは疑似台形型のメンバーシップ関数を表すために、シグモイド関数を x 軸に対して反転させるかどうかを表しているだけなので更新は行わない。

$$\Delta w_{ed}^{(E)} = \eta (y_{pe} - O_e^{(E)}) O_d^{(D)} \quad (21)$$

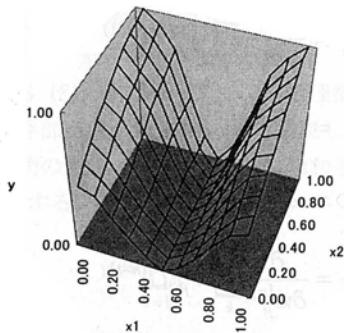


図-8 動作検証用入出力関係

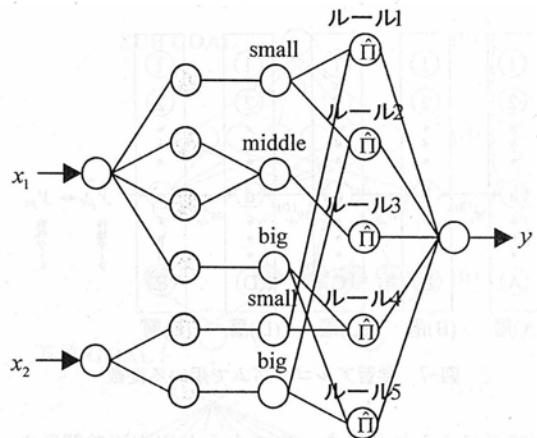


図-9 新推論機構の構成

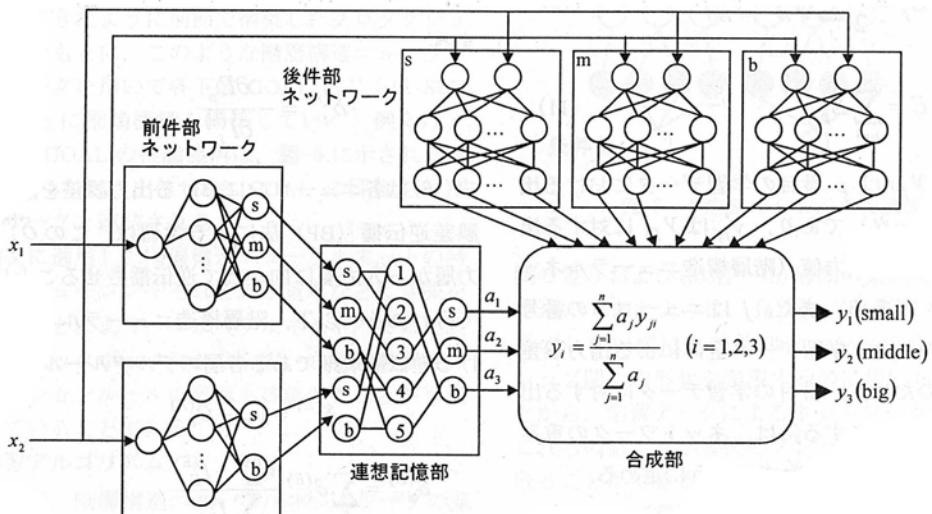


図-10 BAM を用いた前推論機構の構成

$$\Delta w_{dc}^{(D)} = \eta \sum_k \delta_k^{(E)} \frac{w_{kd}^{(E)} - I_k^{(E)}}{\sum_l I_l^{(D)}} O_c^{(C)} \left(\prod_{k \neq c} w_{dk}^{(D)} O_k^{(C)} \right) \quad (22)$$

$$\Delta w_{ba}^{(B)} = \eta f(I_b^{(B)}) \left[1 - f(I_b^{(B)}) \right] \sum_k \delta_k^{(C)} w_{kb}^{(C)} O_a^{(A)} \quad (23)$$

また (B) 層のしきい値 $\theta_b^{(B)}$ の更新量 $\Delta \theta_b^{(B)}$ は、次式となる。

$$\Delta \theta_b^{(B)} = \beta f(I_b^{(B)}) \left[1 - f(I_b^{(B)}) \right] \sum_k \delta_k^{(C)} w_{kb}^{(C)} \quad (24)$$

一般的に、(n-1) 層 - (n) 層間の重み $w_{ji}^{(n)}$ の更新量 $\Delta w_{ji}^{(n)}$ から、結合重みの更新は次のように行う。

$$w_{ji}^{(n)}(t+1) = w_{ji}^{(n)}(t) + \Delta w_{ji}^{(n)}(t) + \alpha \Delta w_{ji}^{(n)}(t-1) \quad (25)$$

ここで、右辺の第 3 項はモーメント項（慣性項）と呼ばれるもので、学習の高速化を図るために採用している。また、 α は定数である。

以上に記述したアルゴリズムにより、入力データと教師データを示すことで誤差逆伝播 (BP) 法により学習を行うことが可能になる。

(3) 推論動作の検証

本節では、前診断システムにおいて適用されている双向連想記憶 (BAM) を用いた推論機構（以下、前推論機構と略記する）と今回新たに導入した階層構造ニューラルネットワークを用いた推論機構

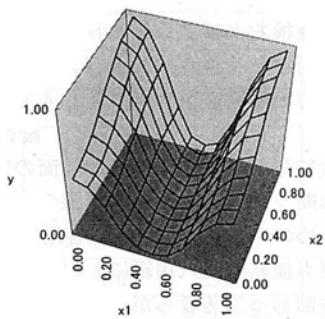


図-11 新推論機構の推論結果

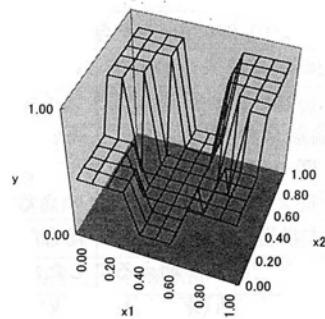


図-12 前機構の推論結果

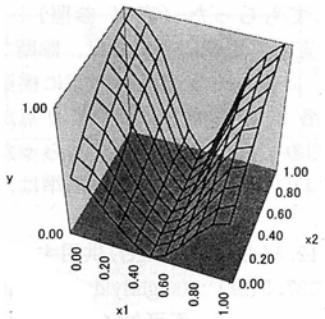


図-13 新推論機構の学習後の推論結果

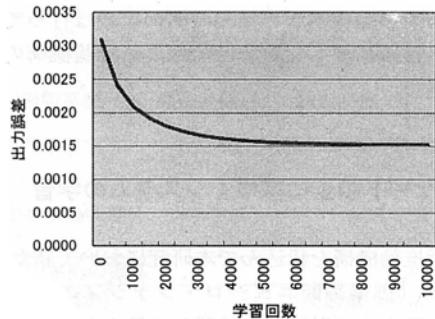


図-14 学習回数と出力誤差の関係

(以下、新推論機構) がどちらも if-then 形式のプロダクションルールを基に構築されており、ファジィ推論を行うということに着目し、共通のプロダクションルールを用いて 2 つの推論機構の推論動作について比較検討した結果を示す。

今回、2 つの推論機構に推論させる対象は図-8 に示すような 2 入力 (x_1, x_2) 1 出力 (y) の非線形な入出力関係である。この入出力関係から if-then 形式のプロダクションルールを作成すると、以下のように記述できる¹⁷⁾。

- Rule1: if (x_1 is small) and (x_2 is small) then (y is middle)
- Rule2: if (x_1 is small) and (x_2 is big) then (y is big)
- Rule3: if (x_1 is middle) then (y is small)
- Rule4: if (x_1 is big) and (x_2 is small) then (y is middle)
- Rule5: if (x_1 is big) and (x_2 is big) then (y is big)

以上の 5 つのプロダクションルールを基に、新推論機構および前推論機構をそれぞれ図-9、図-10 のように構築し、実際に推論を行わせた。その推論結果をそれぞれ図-11、図-12 に示す。どちらの推論

結果もプロダクションルールを基に構築した初期段階（プリワイア）で得られたものであるが、図-12 の前推論機構から得られた推論結果が平面的に 5 つの部分に分割されているのに対して、図-11 の新推論機構から得られた推論結果は連続的となっており、図-8 で示した入出力関係の特徴をかなり良好に再現しているということがいえる。前推論機構の場合、双方向連想記憶が各層間の関係をパターンの組み合わせとして記憶し、入力されたパターンから、それに対応するパターンを連想するネットワークであり、前件部ネットワークからの出力がある程度近似している場合、連想される各後件部に対する重みが同じものとなってしまうことに起因すると考えられる。

また、図-10 に示すように前推論機構では推論機構が分散型の構造となっているため、プリワイアの状態から学習していくことは困難であるが、新推論機構では推論機構が 1 つの階層ニューラルネットで構成されていることから、前節で述べた学習アルゴリズムにより推論機構の学習を行うことができる。

図-8の格子（ 11×11 ）上の各点におけるデータを教師データとし、プリワイヤの状態の結合重みを初期値として、学習回数を10,000回とした学習を行った。学習が完了した後の新推論機構から得られた推論結果を**図-13**に示す。今回の例では、プリワイヤの状態で得られた推論結果の精度がかなり高いものであったことから、**図-11**と**図-13**を比較しても、視覚的に学習の効果を捉えることは難しいといえる。そこで、**図-14**に示す学習回数と学習時の総合誤差の関係に着目すると、学習回数が増えるにしたがって、総合誤差が単調に減少し、収束していることが分かる。このことからも、新推論機構では学習により推論動作の精度の向上が図られることが伺える。また、前推論機構の連想記憶部は、入力値によって平衡状態に達する時間が異なることから、具体的な数値による新推論機構との推論時間の比較は行っていないが、推論を要した計算時間は、新推論機構の方が短かった。

3. アンケート調査に基づくシステムの学習

前述の新推論機構を組込んで本研究において新たに開発した「橋梁診断ニューロ・ファジィエキスパートシステム」（以下、本診断システムと略記する）による診断結果の検証、ならびに診断システムの知識ベース更新に用いるデータ、すなわち学習用データの作成のために、橋梁の維持管理業務あるいは設計業務に携わる専門家に対してアンケート調査を実施した。このアンケート調査は、本診断システムへの入力データとなる項目に関する目視点検を専門家が行い、さらに本診断システムが橋梁を診断する過程と同様に本研究室で考案している診断プロセスに従って診断を行った。本章では、これらの実橋点検およびアンケート調査の概要を述べるとともに、アンケート集計結果の学習への適用方法についても記述する。

（1）実橋点検およびアンケート調査

a) 点検実施橋梁の概要

今回、点検を実施した橋梁は、山口県が管理している「HA 橋」、「NI 橋」、「NO 橋」、「MI 橋」、「GE 橋」、「TO 橋」および「OU 橋」の7 橋梁である。本診断システムの診断および学習は 1 つのスパンを対象としているため、点検についても 1 つ 1 つのスパンを対象とした。今回、「MI 橋」および「TO 橋」は 2 つのスパンの点検を実施したことから、最終的な点検箇所は 7 橋梁 9 スパンとなった。

表-2には、各橋梁の概要を示す。また、**表-3**には、各橋梁の損傷状態（床版および主桁）の概要を示す。

b) 実橋点検およびアンケート調査の概要

実橋に対する目視点検およびアンケート調査は、山口県周辺の建設コンサルタント 4 社から専門家 7 名を招いて 2 日間の日程で行った。配付した資料は、目視点検結果記入用紙、橋梁の図面の入ったメモ用紙、本診断システムを学習する際の教師データを獲得するためのアンケート調査回答用紙の 3 種類である。目視点検結果記入用紙において、橋梁諸元等橋梁台帳や前もって著者らが行った橋梁調査により明らかな項目については、あらかじめ記入しておいた。専門家には、経験的な評価および知識から主観的な判断により回答してもらう点検項目についてのみ 0.0 点から 1.0 点まで 0.1 点刻みで 11 段階の評価を記入してもらった（**表-4** 参照）。また、アンケート調査回答用紙については、診断プロセス（**図-1** 参照）に従って実際に専門家に橋梁を診断してもらい、各 SUB GOAL について 0 点から 100 点まで 5 点刻みで評価を記入してもらった（**図-15** 参照）。なお、評価点数 (p) の基準は、以下のとおりである。

$0.0 \leq p < 12.5$ (点)	: (danger) 供用すべきでない状態
$12.5 \leq p < 37.5$ (点)	: (slightly danger) 補修・補強が不可欠になる状態
$37.5 \leq p \leq 62.5$ (点)	: (moderate) 劣化はみられるが、特に補修・補強を考慮すべき状態ではなく、良くも悪くもない普通の状態
$62.5 < p \leq 87.5$ (点)	: (slightly safe) 僅かに劣化しているがなんら憂慮もなく健全な状態
$87.5 < p \leq 100.0$ (点)	: (safe) 全く問題のない状態

このように、点検項目および診断項目の結果の記入は、「かなり」あるいは「僅かに」といった定性的かつあいまいな表現を使っている。このような表現を用いた理由は、今回行ったアンケートが点検結果を基に経験的な知識から直感的に回答してもらうことを目的としており、これらの定義や点数指標を定量的に設定することは、回答時の自由度を損ねてしまうと考えたからである。しかし今後、回答時の自由度は失うことなく、アンケート用紙制作側と回答側の診断項目の定義や点数指標に対する意識については統一を図っていくことが必要であり、そのような手法の考案は今後の重要な課題の一つであろう。

（2）アンケート調査結果の学習への適用

第 2 章で述べたように、本診断システムの推論機

表-2 対象橋梁の概要

梁名橋	HA橋	NI橋	NO橋	MI橋	GE橋	TO橋	OU橋
橋格	一等橋	不明	二等橋	一等橋	一等橋	一等橋	一等橋
橋梁形式	RC単純T桁						
橋長	18.00m	90.00m	33.20m	33.25m	36.50m	24.80m	25.20m
幅員	4.50m	4.50m	6.00m	8.90m (車道部)	3.25m	5.10m	6.60m
径間割	2径間	6径間	3径間	3径間	3径間	2径間	2径間
路線	主要県道	主要県道	一般県道	一般国道	主要県道	一般国道	一般国道
架設年月 (橋齢)	S29年3月 (43年)	S14年9月 (58年)	S31年3月 (41年)	S41年3月 (31年)	S40年9月 (32年)	S30年3月 (42年)	S43年7月 (29年)
適用示方書	大正15年版	大正15年版	大正15年版	昭和39年版	昭和39年版	大正15年版	昭和39年版
構造概要	主桁本数	3本	3本	4本	6本	3本	3本
	主桁間隔	2@1.70m	2@1.80m	3@1.60m	5@1.60m	2@1.48m	2@2.00m
	横桁	有	有	有	有	無	有
	高蘭	コンクリート製高欄	コンクリート製高欄	鋼コンクリート合成高欄	鋼製高欄	鋼製高欄	ガードレール高欄

注) 橋齢は、点検を行った時点で換算してある。

表-3 対象橋梁の主な損傷状態

	床版の損傷	主桁の損傷	その他
HA橋 (①)	目立った損傷なし	曲げひび割れ(僅か) 鉄筋腐食ひび割れ(多い) 腐食した鉄筋の露出 豆板(一部)	交通量(非常に少ない)
NI橋 (⑥)	ハンチ沿いのひび割れ(多い) 支点付近のひび割れ(僅か) 床版中央部のひび割れ(格子状、多い) ひび割れに沿った遊離石灰 腐食した鉄筋の露出	曲げひび割れ(かなり多い) せん断ひび割れ(多い) 鉄筋腐食ひび割れ(多い) ひび割れに沿った遊離石灰 腐食した鉄筋の露出 豆板(一部)	大型車の交通量(多い) 排水管の詰まり
NO橋 (①)	床版中央部のひび割れ(僅か) 腐食した鉄筋の露出	曲げひび割れ(僅か) ひび割れに沿った遊離石灰	車両進入時に大きな音の発生
MI橋 (①, ③)	ハンチ沿いのひび割れ(多い, ①)(かなり多い, ③) 支点付近のひび割れ(僅か, ①) 床版中央部のひび割れ(多い, ①③) ひび割れに沿った遊離石灰(①③) 腐食した鉄筋の露出(①③)	曲げひび割れ(僅か, ①)(多い, ③) 鉄筋腐食ひび割れ(僅か, ③) ひび割れに沿った遊離石灰(③)	交通量(かなり多い)
GE橋 (③)	床版中央部のひび割れ(僅か) ひび割れに沿った遊離石灰 豆板(一部)	曲げひび割れ(僅か) 豆板(一部)	拡幅部が剛結により拡幅路面ひび割れ(少し)
TO橋 (①, ②)	目立った損傷なし	曲げひび割れ(僅か, ①②) 鉄筋腐食ひび割れ(僅か, ①)(多い, ②) ひび割れに沿った遊離石灰(①②) 腐食した鉄筋の露出(①②)	交通量(多い)
OU橋 (②)	床版中央部のひび割れ(僅か) 豆板(一部)	曲げひび割れ(僅か) 鉄筋腐食ひび割れ(僅か) 腐食した鉄筋の露出	交通量(多い)

注) 表中に記述されている丸囲みの数字は、スパン番号を示す。

表-4 目視点検結果の記入表の一部

G1	曲げひび割れ	<input type="checkbox"/> 発生している(次へ)	<input type="checkbox"/> 発生していない(G1-3へ)
G1-1	ひび割れ状況	0.0 <input type="checkbox"/> <input type="checkbox"/> 0.5 <input type="checkbox"/> <input type="checkbox"/> 1.0 <input type="checkbox"/>	0.5 <input type="checkbox"/> 1.0 <input type="checkbox"/>
G1-2	ひび割れ幅	mm	
G1-3	遊離石灰の発生状況	0.0 <input type="checkbox"/> <input type="checkbox"/> 0.5 <input type="checkbox"/> <input type="checkbox"/> 1.0 <input type="checkbox"/>	0.5 <input type="checkbox"/> 1.0 <input type="checkbox"/>
G1-4	コンクリートの欠落	0.0 <input type="checkbox"/> <input type="checkbox"/> 0.5 <input type="checkbox"/> <input type="checkbox"/> 1.0 <input type="checkbox"/>	0.5 <input type="checkbox"/> 1.0 <input type="checkbox"/>
G1-5	鉄筋の露出	<input type="checkbox"/> 露出している(次へ)	<input type="checkbox"/> 露出していない(G1-7へ)
G1-6	鉄筋の腐食状況	0.0 <input type="checkbox"/> <input type="checkbox"/> 0.5 <input type="checkbox"/> <input type="checkbox"/> 1.0 <input type="checkbox"/>	0.5 <input type="checkbox"/> 1.0 <input type="checkbox"/>
G1-7	錆汁の発生状況	0.0 <input type="checkbox"/> <input type="checkbox"/> 0.5 <input type="checkbox"/> <input type="checkbox"/> 1.0 <input type="checkbox"/>	0.5 <input type="checkbox"/> 1.0 <input type="checkbox"/>

①主桁に発生した『曲げひび割れ』、『せん断ひび割れ』、『鉄筋腐食ひび割れ』、『付着ひび割れ』の損傷状態は、どの程度と考えられますか？点検結果（図-1の条件部）をもとに、100点満点で評価して下の升目にチェックを入れて下さい。

曲げひび割れ

(非常に傷んでいる)

(良くも悪くもない)

(全く傷んでいない)

↓

↓

↓

0	5	10	15	20	25	30	35	40	45	50	55	60	65	70	75	80	85	90	95	100
---	---	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----	-----

せん断ひび割れ

⋮

図-15 アンケート用紙の一例（主桁）

構を構成している階層構造ニューラルネットワークの学習には誤差逆伝播（BP）法を応用しており、この誤差逆伝播（BP）法による学習には学習データとして入力データとそれに対する教師データの組が必要である。そこで、今回の専門家による実橋に対する

目視点検およびアンケート調査結果を本診断システムの学習に用いる際には、入力データとして専門家による目視点検結果を利用し、その入力データによる本診断システムの診断結果に対する教師データとして専門家からのアンケートの回答結果を用いる。

しかし、それぞれの橋梁に対する目視点検および診断における各専門家の回答には、経験年数や業務内容、アンケート調査における定義や指標に対する解釈における相違により、多少のばらつきが見られた。そこで、本診断システムの学習に利用する教師データは、橋梁に携わった経験年数にして 10 年以上の専門家 4 人（以下、ベテランと略記する）の回答の平均値を採用した。ここで、ベテランの回答を採用したのは、長年橋梁に関わってきており、橋梁に対する知識が豊富でより的確な判断が下せるのではないかと考えたためである。また、アンケートの回答の平均値を採用した理由は、各専門家から得られたアンケート調査結果はそれぞれ目視点検結果から各専門家が有している経験的な知識を基に直感的に導いたものであるが、大まかな傾向はあることから、それらの平均値を教師データとして採用したとしても、各専門家の診断における意向を大幅に崩してしまうことはないと考えたからである。また、入力データとなる目視点検結果についても同様な理由により、主観的に採点する箇所はベテランの平均値を用いた。このように、本論文では、本研究で適用した推論機構の学習能力を考察するために、その学習データとして単純にベテランの点検および診断結果の平均点を用いた。しかしながら、今後、本診断システムの実用化に向けて必要不可欠となる信頼性の向上を考えると、専門家へのアンケート内容やその数が極めて重要になることから、学習データの作成方法やその扱い方を注意深く検討しなければならない。

4. システムの実橋への適用

本章では、本診断システムを実際に架設されている橋梁に適用した結果について述べる。なお、本診断システムに適用した橋梁は第 3 章で述べた 7 橋梁 9 スパンである。まず、第 2 章で記述した手法より抽出した耐用性診断用プロダクションルールを用いて初期化（プリワイヤ）した推論機構に実橋に対する目視点検結果を入力して診断を行う。これまで、本研究室で開発してきた診断システムでは体系的な学習機能が付加されていなかったため、診断結果の検証はプリワイヤの状態の推論機構による出力に対するもので終わっていた。しかし、本診断システムは、誤差逆伝播（BP）法を応用して推論機構を学習させることができある。そこで、橋梁の点検結果および専門家へのアンケート調査により得られた回答を基に誤差逆伝播（BP）法を用いて推論機構を学

習させる。そして、その学習が終了した推論機構に橋梁の点検データを入力して診断を行い、プリワイヤの状態で得られた診断結果およびアンケート調査結果と比較することにより学習の効果について考察を行う。

（1）入出力データ

本診断システムに入力するための入力データは、実橋点検における専門家の目視点検結果を用いた。その際、各専門家が経験的な知識を用いて主観的な判断により点検を行う項目については、3. (2) で述べたようにベテランの点検結果の平均値を入力データとした。また、システムより出力された診断結果に対する有効性を表す指標としては、ベテランより得られたアンケート調査結果の平均値（表-5 参照）を診断結果の正解値、すなわち教師データとして用い、診断結果と教師データとの誤差が小さいほど有効性の高い診断結果が得られていると解釈した。なお、表中における橋梁名の下に記述している丸囲みで示した数値は、スパン番号を表している。また、（ ）内の値が、アンケート調査結果の平均値であり、英文字（S, s-s, M, s-d, D）は、それぞれ safe, slightly-safe, moderate, slightly-danger, danger を示している。これらは、3. (1) a) で示した基準に従って（ ）内の平均値を 5 つの各カテゴリーに分類したものである。

（2）プリワイヤにおける診断結果

前節で述べたようにベテランが行った点検結果の平均を、その橋梁の点検データとし、推論機構に入力して診断を行った。本診断システムのプリワイヤの状態における主桁に関する診断結果を表-6 に示す。ここで、先にも述べたようにプリワイヤの状態とは、2. (1) に示したルール抽出手法によって旧診断システムより作成された if-then 形式のプロダクションルールに従って、階層構造ニューラルネットワークを用いて推論機構を構築した初期状態である。なお、表中の（ ）内の値は、本診断システムより出力された値（平均健全度）である。また、表中の各種網掛け部は、それぞれ次のことを示している：■は、教師データ（表-5）と比較したときに本診断システムより出力された値のカテゴリーが一ランクずれているものである。一方、■は、出力された値のカテゴリーが二ランク以上離れているものである。表-5 に示した教師データ（ベテラン平均）とプリワイヤの状態における診断結果（以下、プリワイヤ診断結果と略記する）を比較した場合、診断項目によってはかなりの誤差が見られる場合がある。

表-5 学習用教師データ

	HA橋①	NI橋⑥	NO橋①	MI橋①	MI橋③	GE橋③	TO橋①	TO橋②	OU橋②
「主桁設計」	M (57.5)	M (46.3)	M (57.5)	s-s (66.3)	s-s (65.0)	s-s (68.8)	s-s (72.5)	s-s (72.5)	s-s (76.3)
「主桁施工」	M (51.3)	s-d (31.3)	s-s (65.0)	s-s (71.3)	s-s (63.8)	s-s (71.3)	s-s (71.3)	M (50.0)	s-s (72.5)
「主桁供用状態」	s-s (67.5)	M (45.0)	s-s (68.8)	s-s (78.8)	s-s (81.3)	s-s (80.0)	s-s (76.3)	s-s (75.0)	s-s (75.0)
「主桁材料劣化」	M (50.0)	s-d (35.0)	s-s (78.8)	s-s (78.8)	s-s (70.0)	s-s (86.3)	s-s (81.3)	s-s (68.8)	s-s (82.5)
「曲げひび割れ」	s-s (76.3)	s-d (35.0)	s-s (78.8)	s-s (77.5)	s-s (68.8)	s-s (85.0)	s-s (81.3)	s-s (73.8)	s-s (71.3)
「せん断ひび割れ」	S (95.0)	s-s (66.3)	S (96.3)	S (97.5)	S (93.8)	S (97.5)	S (93.8)	S (97.5)	S (97.5)
「鉄筋腐食ひび割れ」	M (41.3)	M (47.5)	S (87.5)	s-s (82.5)	s-s (67.5)	S (90.0)	s-s (77.5)	M (57.5)	s-s (75.0)
「付着ひび割れ」	S (90.0)	s-s (80.0)	S (92.5)	S (87.5)	s-s (85.0)	S (90.0)	S (92.5)	S (90.0)	S (90.0)
「主桁の全体的損傷」	M (52.5)	s-d (26.3)	s-s (82.5)	s-s (77.5)	s-s (70.0)	s-s (86.3)	s-s (76.3)	s-s (66.3)	s-s (77.5)
「主桁耐荷性」	s-s (66.3)	s-d (36.3)	s-s (71.3)	s-s (75.0)	s-s (71.3)	s-s (81.3)	s-s (72.5)	s-s (66.3)	s-s (80.0)
「主桁耐久性」	M (51.3)	s-d (28.8)	s-s (73.8)	s-s (78.8)	s-s (70.0)	s-s (85.0)	s-s (73.8)	s-s (62.5)	s-s (78.8)
「主桁耐用性」	s-s (62.5)	s-d (30.0)	s-s (71.3)	s-s (75.0)	s-s (65.0)	s-s (85.0)	s-s (72.5)	s-s (66.3)	s-s (80.0)

注) S : safe, s-s : slightly-safe, M : moderate, s-d : slightly-danger, D : danger

表-6 プリワイヤによる診断結果

	HA橋①	NI橋⑥	NO橋①	MI橋①	MI橋③	GE橋③	TO橋①	TO橋②	OU橋②
「主桁設計」	M (60.3)	M (58.5)	M (50.5)	M (59.9)	M (59.9)	M (62.0)	M (56.1)	M (56.1)	M (54.1)
「主桁施工」	M (44.9)	M (41.4)	s-s (69.6)	s-s (69.6)	M (51.8)	M (46.6)	M (51.8)	M (51.8)	M (51.8)
「主桁供用状態」	S (92.9)	S (92.7)	S (91.4)	S (97.4)	S (97.4)	S (94.9)	S (97.5)	S (97.5)	S (97.4)
「主桁材料劣化」	s-d (32.0)	s-d (25.1)	M (51.0)	s-s (66.3)	M (59.2)	M (47.1)	M (52.9)	s-d (28.9)	M (48.7)
「曲げひび割れ」	M (51.2)	s-d (16.7)	M (53.9)	S (96.1)	S (91.8)	S (87.5)	S (91.1)	s-s (67.5)	S (95.2)
「せん断ひび割れ」	S (99.9)								
「鉄筋腐食ひび割れ」	s-d (20.3)	D (9.1)	S (99.9)	S (99.9)	M (52.3)	S (99.9)	S (99.9)	D (7.1)	M (57.8)
「付着ひび割れ」	S (99.9)								
「主桁の全体的損傷」	s-d (23.3)	s-d (27.7)	s-s (67.4)	s-s (80.2)	M (55.1)	M (58.2)	s-s (65.4)	s-d (15.1)	M (47.4)
「主桁耐荷性」	s-s (70.8)	s-s (74.1)	S (89.0)	S (89.4)	S (89.0)	s-s (74.9)	s-s (67.3)	M (47.6)	s-s (73.1)
「主桁耐久性」	s-d (22.1)	s-d (29.7)	s-s (62.7)	s-s (83.7)	M (52.2)	M (53.9)	M (60.1)	D (10.0)	M (48.9)
「主桁耐用性」	M (43.9)	M (53.3)	s-s (75.6)	S (91.4)	s-s (72.4)	s-s (63.2)	M (58.9)	s-d (27.2)	M (60.6)
誤差合計	195.0	253.5	158.5	128.4	161.0	197.7	174.6	311.1	238.8

表-7 学習後の診断結果（全標本学習法、学習回数 150 回）

	HA橋①	NI橋⑥	NO橋①	MI橋①	MI橋③	GE橋③	TO橋①	TO橋②	OU橋②
「主桁設計」	s-s (65.4)	s-s (66.7)	s-s (67.6)	s-s (65.1)	s-s (65.1)	s-s (64.5)	s-s (66.6)	s-s (66.6)	s-s (67.7)
「主桁施工」	M (53.0)	M (39.3)	s-s (69.4)	s-s (69.4)	s-s (66.6)	M (56.5)	s-s (66.6)	s-s (66.6)	s-s (66.6)
「主桁供用状態」	M (59.4)	M (59.5)	s-s (68.0)	s-s (80.4)	s-s (80.4)	s-s (71.4)	s-s (76.3)	s-s (76.3)	s-s (77.5)
「主桁材料劣化」	M (58.7)	M (40.1)	s-s (79.2)	s-s (78.7)	s-s (72.5)	s-s (76.8)	s-s (80.0)	M (61.2)	s-s (84.6)
「曲げひび割れ」	s-s (75.0)	s-d (35.0)	s-s (70.7)	s-s (76.6)	s-s (77.2)	s-s (77.8)	s-s (76.1)	s-s (74.0)	s-s (77.0)
「せん断ひび割れ」	S (93.3)								
「鉄筋腐食ひび割れ」	M (43.8)	M (51.6)	s-s (84.9)	s-s (84.9)	s-s (66.8)	s-s (84.9)	s-s (84.9)	M (52.5)	s-s (75.5)
「付着ひび割れ」	S (90.1)								
「主桁の全体的損傷」	M (57.6)	s-d (27.8)	s-s (79.0)	s-s (79.2)	s-s (71.7)	s-s (78.4)	s-s (79.6)	M (60.9)	s-s (78.7)
「主桁耐荷性」	s-s (75.7)	M (53.3)	s-s (79.4)	s-s (77.7)	s-s (72.9)	s-s (68.1)	s-s (67.9)	M (54.4)	s-s (71.3)
「主桁耐久性」	M (52.0)	s-d (31.7)	s-s (75.9)	s-s (79.8)	s-s (70.5)	s-s (76.1)	s-s (79.3)	M (58.0)	s-s (78.5)
「主桁耐用性」	s-s (67.6)	M (40.3)	s-s (77.7)	s-s (78.4)	s-s (70.6)	s-s (69.2)	s-s (69.9)	M (58.1)	s-s (72.3)
誤差合計	52.3	120.9	51.9	23.7	30.4	99.6	43.4	70.9	47.5

表-8 学習後の診断結果 (leave-one-out 法, 学習回数 150 回)

	HA橋(①)	NI橋(⑥)	NO橋(①)	MI橋(①)	MI橋(③)	GE橋(③)	TO橋(①)	TO橋(②)	OU橋(②)
「主桁設計」	s-s (66.8)	s-s (72.2)	s-s (71.5)	s-s (64.5)	s-s (64.9)	s-s (62.9)	s-s (65.3)	s-s (65.3)	M (61.3)
「主桁施工」	M (53.5)	M (53.7)	s-s (70.0)	s-s (67.5)	s-s (67.1)	M (51.3)	s-s (65.4)	s-s (71.7)	s-s (64.6)
「主桁供用状態」	M (54.4)	s-s (70.6)	s-s (65.9)	s-s (81.1)	s-s (79.1)	s-s (67.3)	s-s (76.4)	s-s (77.0)	s-s (78.4)
「主桁材料劣化」	s-s (69.8)	s-d (32.4)	s-s (77.0)	s-s (67.5)	s-s (84.6)	s-s (71.2)	s-s (73.9)	M (44.7)	s-s (84.3)
「曲げひび割れ」	s-s (64.6)	s-d (20.1)	s-s (63.6)	s-s (76.3)	s-s (79.1)	s-s (76.1)	s-s (74.5)	s-s (76.0)	s-s (78.8)
「せん断ひび割れ」	S (93.1)	S (96.0)	S (94.1)	S (92.4)	S (92.8)	S (92.4)	S (92.9)	S (92.3)	S (92.3)
「鉄筋腐食ひび割れ」	M (50.0)	M (54.0)	s-s (84.5)	s-s (85.3)	M (61.0)	s-s (82.8)	s-s (87.3)	M (48.8)	s-s (73.0)
「付着ひび割れ」	S (90.0)	S (90.9)	S (89.7)	S (90.2)	S (90.5)	S (89.9)	S (89.5)	S (89.9)	S (89.9)
「主桁の全体的損傷」	M (58.9)	M (45.6)	s-s (77.7)	s-s (73.7)	s-s (73.4)	s-s (74.3)	s-s (77.7)	M (47.8)	s-s (77.9)
「主桁耐荷性」	s-s (64.1)	s-s (76.6)	s-s (83.2)	s-s (75.2)	s-s (75.3)	M (59.4)	s-s (64.3)	M (46.9)	s-s (64.8)
「主桁耐久性」	M (53.5)	M (49.7)	s-s (76.1)	s-s (72.7)	s-s (71.1)	s-s (68.7)	s-s (77.0)	M (51.8)	s-s (77.8)
「主桁耐用性」	M (59.7)	s-s (66.6)	s-s (80.4)	s-s (73.2)	s-s (73.5)	s-s (62.7)	s-s (66.6)	M (51.7)	s-s (67.9)
誤差合計	80.3	255.6	75.0	42.9	60.5	147.5	59.8	134.4	71.6

例えば、「TO 橋（第②スパン）」の『主桁耐久性』の項目ではプリワイヤ診断結果と教師データの間に 52.5 ポイント（以下、p と略記する）もの誤差があることが分かる。また、表の最下行の誤差合計は、各診断項目の誤差を各スパン毎に合計したものである。この誤差合計は、128.4p から 311.1p となっており、プリワイヤ診断結果は教師データと比べて、診断項目当たり、平均しておよそ 10p から 26p の差違があることが分かる。しかしながら、出力された値のカテゴリー分類をみると、プリワイヤの状態においても専門家が行う橋梁診断の傾向は、おおまかにつかめていることが分かる。すなわち、本論文で提案したルール作成手法は、妥当であるといえる。

(3) 知識更新後の診断結果

プリワイヤ診断結果の中にはスパンによっては、あるいは診断項目によっては専門家によるアンケート調査から得られた橋梁の健全度を表す教師データとの誤差が大きいものが見られた。そこで、本診断システムの有する学習機能により、これらの誤差を小さくしていくことを試みる。ここでは、専門家による各橋梁の目視点検結果を入力データとし、それに対する各橋梁のアンケート調査結果を教師データとして 7 橋梁 9 スパンについてそれぞれ入力データと教師データの組で構成される学習データを作成した。学習を行う際に、学習するサンプル数が多いことに越したことはないが、今回は、9 スパン分のサンプルしか収集することができていない。そこで、本診断システムで診断するスパンも学習データとして用いる全標本学習法¹⁸⁾と、学習サンプル数が少な

いなかでも、最大の学習サンプル数を確保できる leave-one-out 法¹⁸⁾の 2 つの学習方法で推論機構の学習を試みた。leave-one-out 法の学習方法を具体的に説明すると、「HA 橋(①)」をテストサンプルとして推論機構の学習の効果を計る際には、推論機構の学習に用いる学習サンプルとしては、「HA 橋(①)」以外の 8 つのスパンを学習データとして利用するものである。続いて以下、「NI 橋(⑥)」、「NO 橋(①)」、「MI 橋(①)」、「MI 橋(③)」、「GE 橋(③)」、「TO 橋(①)」、「TO 橋(②)」、「OU 橋(②)」についても同様に、テストサンプルとして用いるスパン以外の 8 スパンの学習データを学習に用いるサンプルとした。

以上のような手法により、leave-one-out 法では学習の効果を検証するための推論機構の学習済み結合重みは、各スパンに対して 1 つずつ、合計 9 種類作成することができた。このように leave-one-out 法に従って学習を行ったあとで、学習に用いなかった唯一のスパンの診断を行うことは、そのシステムにこれまでいくつかのスパンについて学習をしてきて、今回新たにこれまでシステムを適用したことのない 1 つのスパンを診断することに相当する。以上に述べた全標本学習法および leave-one-out 法に従って学習した結合重みを用いてプリワイヤの状態の時と同様に、目視点検結果を入力データとして本診断システムに推論させた結果（以下、それぞれ全学習の診断結果および leave-one-out 診断結果と略記する）を表-7 および表-8 に示す。全学習の診断結果を見ると、すべてのスパンにおいて誤差が大幅に減少していることがわかる。また、この誤差合計は、23.7p から 120.9p となっており、全学習の診断結果は教

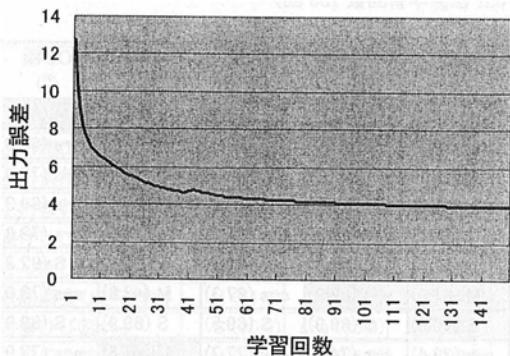


図-16 学習回数と出力誤差の関係

師データと比べて、診断項目当たり、平均しておよそ 2p から 10p の差違に小さくなっている。また、全標本学習法により 150 回の学習を行ったときの、推論機構における学習回数と学習総合誤差の関係を図-16 に示す。学習回数が進むにつれて、多少の振幅があるものの学習総合誤差はほぼ単調に減少し収束していることから、学習が良好に行われたと考えることができる。

続いて、leave-one-out 診断結果に対する考察を行う。表-6 および表-8 中の誤差合計を比較すると「NI 橋（第⑥スパン）」以外は、プリワイヤ診断結果の誤差より小さくなつたことから、テストサンプルとなる橋梁以外の学習用データで診断結果の有効性の向上が図れることがわかる。さらに、表-7 および表-8 中の誤差合計を比較すると、「NI 橋（第⑥スパン）」の誤差が大幅に減少しているのに反して、「MI 橋（第①スパン）」および「TO 橋（第①スパン）」の誤差は、あまり減少していない。これから、学習用サンプルとして、「NI 橋」は貴重であることが分かる。表-5において、教師データの各診断項目の数値が小さいことからも分かるように、今回点検を行つた 7 つの橋梁のうちでは「NI 橋」が一番損傷が進んでいると専門家は考えている。特に「NI 橋（第⑥スパン）」の主桁に対しては、これほどまでに損傷が進んでいる主桁は残りの 6 橋のどのスパンにも見られないとしている。そのため、「NI 橋（第⑥スパン）」について leave-one-out 法により学習を行つた後に診断を行う場合、これまで学習したことのないケースの損傷程度の橋梁に対して診断を行おうとすることになり、実際の専門家が診断する場合とは大きくかけ離れた診断結果が得られたと考えられる。また、「MI 橋（第①スパン）」および「TO 橋（第①スパン）」は、他のサンプルによって十分学習が行えることが分かる。

一方、全標本学習法を用いた場合、診断しようとする橋梁と全く同様な損傷程度の橋梁について以前学習を行つたことがある状態となり、leave-one-out 法を用いたときよりもほとんどのスパンの部材において誤差合計の減少が見られた。特に leave-one-out 法を用いてもあまり誤差が減少しなかつたスパンの部材において、誤差合計が大幅に小さくなつており、専門家の下す診断結果に近い出力が得られるようになった。また、それ以外のスパンでも、誤差の減少が見られた。以上のことから判断すると、本診断システムにおいてシステムを学習していく際には、様々な損傷状態の橋梁について学習をしておくことが必要であると言える。また、現在の学習サンプルの数は、まだまだ少ないと言える。今回はベテランにより得られたアンケート調査結果を正解値と仮定し、教師データとして用いて学習を行つたが、学習そのものの効果に期待ができる場合、逆に矛盾の無い精度の高い教師データを作成していく必要がある。

5. まとめ

本研究は、これまでに開発されていたコンクリート橋診断ニューロ・ファジィエキスパートシステムの推論機構を階層構造ニューラルネットワークで構築することにより、システム内に蓄積された知識の体系的な学習を可能としたものである。また、実橋を専門家に目視点検して頂くと同時にアンケート調査にも回答して頂くことにより、教師データを作成した。さらに、本エキスパートシステムの診断結果に対する信頼性について考察した。本研究で得られた成果を以下にまとめる。

- ① 本診断システムのプリワイヤを設定するために必要とされる if-then 形式の初期プロダクションルールを、旧診断システムを利用することにより作成した。また、本システムプリワイヤの状態での診断より、このプロダクションルール作成手法において専門家の診断傾向を抽出することができる事が確認された。
- ② 前システムでは双方向連想記憶を核とする分割されたネットワーク構造より構成される推論機構を用いていたが、これを階層構造ニューラルネットワークにより構築したことで、推論機構が一つのネットワークにより表現されるようになった。ここで、推論機構が一つのネットワークにより表現されたことに着目し、誤差逆伝播 (BP) 法を応用した学習アルゴリズムを考案し、

目視点検結果を入力データとして、それに対する専門家の評価を教師データとした体系的な学習を可能とした。

- ③ 簡単なプロダクションルールで記述された例題を用いて、双方向連想記憶を核とする前推論機構と階層構造ニューラルネットワークを用いて構築した推論機構の基本動作について比較を行った。その際、階層構造ニューラルネットワークを用いた推論機構については誤差逆伝播(BP)法を応用した学習の効果についても確認した。
- ④ エキスパートシステムの診断結果に対する信頼性の検証および学習データ作成のために、専門家に対するアンケート調査を実施した。さらに、目視点検を行った橋梁の点検結果を用いてエキスパートシステムにより診断を行った。その結果、推論機構が診断プロセスに沿って作成したif-thenルールに基づいて構築した初期状態(ブリワイヤ)の場合には、得られる診断結果は専門家の評価した橋梁の状態と比べて差違の大きいものであったが、学習を行うことでその差違は小さくなり、診断結果の信頼性の向上が図られた。

次に、現段階のエキスパートシステムが抱える問題点および、さらに診断結果の信頼性を向上させ実用性を高めるための今後の課題を以下に記す。

- ① エキスパートシステムの推論機構の学習は、一般的な誤差逆伝播(BP)法を応用したアルゴリズムを用いて行っているが、学習率の設定は試行錯誤的に行ったものであり、今後、学習によりシステムの診断結果の信頼性を向上させるためには最適な学習率を設定することが重要である。
- ② 入力データおよびそれに対する教師データが存在すれば、推論機構の学習を行えることが今回の研究によりある程度明らかとなつたことから、今後はシステムの内部処理面だけではなく、アンケートの方法等を改善していくことにより、精度の高い学習データを収集あるいは生成する必要がある。
- ③ 現在のところ、エキスパートシステムの入力データとしては定性的なデータ、すなわち橋梁を点検した者の主観的判断に任されているものが多い。今後は、誰が点検した場合であっても同等な診断結果が得られるよう、また橋梁に関するデータ入力時のあいまいさをなるべく小さくするためにも、定量的なデータを入力することで診断を行うシステムへと移行する必要がある。

る。

謝辞：本研究をまとめるにあたり、種々のご援助を頂いた株式会社栗本鐵工所 串田守可氏、および山口大学大学院生 三宅秀明氏に感謝の意を表します。また、現地での橋梁点検およびアンケート調査に快くご協力頂いた山口県土木建築部道路整備課 師井努氏に深く感謝します。

参考文献

- 1) 村上圭三：「人間道路」の時代、人間道路会議報告 第66号、1997.
- 2) 高島春生：道路橋の実用診断学－上巻－、現代理工学出版、1988.
- 3) US.Department of Transportation : PONTIS Technical Manual, 1993.12.
- 4) 藤井学、前川義雄：米国における橋梁の維持管理システム、橋梁と基礎、建設図書、pp.33-37、1995.6.
- 5) Thompson, P., Small, E., Johnson, M. and Marshall, A. : The Pontis Bridge Management System, *Structural Engineering International, Journal of IABSE*, Vol. 8, pp.303-308, 1998.
- 6) Hawk, H. and Small, E. : The BRIDGIT Bridge Management System, *Structural Engineering International, Journal of IABSE*, Vol. 8, pp.309-314, 1998.
- 7) Soderqvist, M. and Veijola, M. : The Finnish Bridge Management System, *Structural Engineering International, Journal of IABSE*, Vol. 8, pp.315-319, 1998.
- 8) 宮本文穂、河村圭、中村秀明：Bridge Management System(BMS)を利用した既存橋梁の最適維持管理計画の策定、土木学会論文集、No. 588/VI-38, pp. 191-208, 1998. 3.
- 9) 宮本文穂、森川英典、松原拓磨：アンケートを利用した知識更新と橋梁診断エキスパートシステムの実用化、建設工学研究所報告 第33号, pp. 23-65, 1991. 11.
- 10) 串田守可：橋梁診断における知識獲得手法とエキスパートシステムの開発に関する研究、山口大学博士学位論文、1998. 3.
- 11) 古田均、小尻利治、宮本文穂、秋山考正、大野研、背野康英：ファジイ理論の土木工学への応用、森北出版、1992. 8.
- 12) 宮本文穂、益成一郎、西村昭：コンクリート橋診断エキスパートシステムの開発と実用化、材料、Vol. 40, No. 450, pp. 256-262, 1991. 3.
- 13) 宮本文穂、串田守可、森川英典、木下和哉：コンクリート橋診断ニューロ・ファジイエキスパートシス

- テムの開発と信頼性の向上, 土木学会論文集, No. 510/VI-26, pp. 91-101, 1995. 3.
- 14) 堀川慎一, 古橋武, 内川嘉樹: ファジィニューラルネットワークの構成法と学習法, 日本ファジイ学会誌, Vol. 4, No. 5, pp. 906-928, 1992.
- 15) 林勲, 古橋武: ファジィ・ニューラルネットワーク, 朝倉書店, 1996. 5.
- 16) 西村昭, 藤井学, 宮本文穂, 富田隆弘: 橋梁診断における主観的あいまいさの取り扱い, 建設工学研究
- 所「研究報告」第28号, pp. 77-97, 1986. 12.
- 17) 甘利俊一, 向殿政男: ニューロとファジイ, 培風館, 1994. 5.
- 18) 鳥脇純一郎: 認識工学, コロナ社, 1993. 3.
- (1999. 3. 24 受付)

DEVELOPMENT OF CONCRETE BRIDGE RATING EXPERT SYSTEM BY USING HIERARCHICAL NEURAL NETWORKS

Ayaho MIYAMOTO, Kei KAWAMURA, Hideaki NAKAMURA
and Hideo YAMAMOTO

The present study is an attempt to develop the concrete bridge rating expert system with machine learning employing the hierarchical neural network to implement an inference mechanism. This network enables the system to facilitate the refinement of knowledge base by using the back propagation method. In this study, the training set (teaching data) for machine learning is obtained by the inspection for actual in-service bridges and questionnaire surveys on bridge experts. Furthermore, comparisons between the diagnostic results of bridge experts and the ones of this proposed system are presents so as to demonstrate the validity of the learning capability of this system.