

事例ベースを援用した知識洗練機能付 診断エキスパートシステムの開発

皆川 勝¹・佐藤 茂²・上谷 丈和³

¹正会員 工博 武蔵工業大学助教授 工学部土木工学科(〒158-8557 東京都世田谷区玉堤 1-28-1)

²正会員 工修 株式会社 マエダ(〒163-0907 東京都新宿区西新宿 2-3-1)

³学生員 武蔵工業大学大学院 工学研究科 土木工学専攻(〒158-8557 東京都世田谷区玉堤 1-28-1)

エキスパートシステムの開発にあたっては、知識獲得の困難さがボトルネックであり、不確定情報を扱えること、知識の更新機能をもつことが重要である。本研究では、仮説と仮説間の関係を構成要素とするネットワークで表現された、ルールベース洗練機能付汎用型推論システムを構築した。適用例として、道路橋 RC 床版の損傷要因推定のための既存エキスパートシステムのルールベースを用いて、提案するシステムの有効性を検討した。その結果、適切な事例を教師データとして提示することによって、ルールベースが洗練され損傷要因推定の精度が顕著に向上することが示された。

Key Words: expert-systems, knowledge acquisition, case base, diagnosis, network-systems

1. はじめに

エキスパートシステムを開発する上で最も解決が困難な問題は、エキスパートが持っている問題解決能力、経験的な知識を陽な形式でルール化することに多大な時間と労力を要し、しかも完全にそれを行うことが容易でないことである^{1),2)}。そのため知識獲得をメインに行うシステムの開発³⁾、過去に研究・開発された豊富なエキスパートシステムの知識ベースを再利用する方法⁴⁾、開発するエキスパートシステム中に知識獲得機能をもたせる方法^{4),5)}、及び過去の事例を用いて提示された問題解決する事例ベース推論の研究^{6),7)}が活発に行われている。

また、経験的なノウハウをルール化するためには、不確定な情報を取り扱い得ることが、必須条件である。更に、不確定な知識を取り扱う場合には、その不確定さ故に、知識の更新機能をもつことが重要視されてきた。

一方、土木工学の分野では、維持管理、施工管理、構造計画及びデータ解析など多様な役割をになう技術者を支援するために、解析、診断、モニターリング、予測、計画及び設計などを対象とする、エキスパートシステムが多数開発されてきた。

中村らは水力鋼構造物の寿命予測のために前向き

推論と後向き推論の機能をもつプロダクションシステムを構築した^{8),9)}。ここでは、主観的なデータ値に対して、個々のスコアを計算し、その重み付き平均を用いて相互的な判断を行うという方法で不確定さを取り扱った。また、ルールベースは、システムを利用評価していく過程で追加及び修正して行くものとしているが、具体的な方法は示していない。

白石・古田らは過去の設計例のデータから概念毎にデータを分類し、ルールを生成する設計支援エキスパートシステムを構築した⁵⁾。また、推論過程においては、言語評価値を扱うためファジィ理論を用いた。

串田・宮本は、コンクリート橋診断ファジィ・エキスパートシステムにおいて、メンバーシップ関数及び影響度を変更することで、知識を洗練する方法を提案し⁴⁾、また、宮本らはニューラルネットワークを用いたルールの更新や連想記憶を組み合わせた不確定さをもつ推論方法を提案した¹⁰⁾。更に、宮本らは可能性や必然性の概念をファジィ理論を適用した知識表現手法に導入し、知識の洗練度を考慮した知識更新方法を提案した¹¹⁾。

三上らは、鋼橋疲労補修方法選定システムを因果ネットワークで表現し、これにニューラルネットワークを用いて学習機能を付加する方法¹²⁾、未定義の因

果関係を自動的に生成して知識ベースのルールを獲得する方法などを提案した^{13),14)}。更に、田中・三上らは、推論精度の向上のためにルールベース推論と事例ベース推論を併用したシステムを構築した^{6),15)}。

このように、アンケート等による通常の方法から、個々の事実から一般的な規則を導き出す帰納的な推論方法や、事例ベース推論のように、過去の事例を直接利用して解を導く等、設計例などのいわゆる個別の事例からルールを生成する方法へと、知識獲得手法は発展しつつある。しかし、事例ベース推論においては、ルールベースシステムで必要なルールを必要としないという利点はあるが、事例ベースを構築する際に、事例を特徴付けるための索引群によって構成される、システムのための事例構造を獲得する必要が生じ、これが知識獲得問題に代わり、事例構造獲得問題として、新たな問題となってくる等の課題もあり、実用化には至っていない。

また、これまで構築されてきたエキスパートシステムは、様々な知識表現手法を用いており、知識の共有化あるいは再利用という観点からは、既存システムによる推論結果を容易に反映してルールベースを再構築できる方法論を確立することは重要である。

そこで本研究は、現状では、推論方法としては、ルールベース推論が最も多用されていると考えられることから、ルールベースを基本として、汎用的な相互結合ネットワークで推論システムを構成し、既存システムの推論結果を教師データとして提示することによって、ルールベースを洗練するアルゴリズムを提案した。これにより、既存システムとほぼ同じルールベース推論が可能で、教師データとして示された事例に合致するような因果関係の強さをきわめて容易に陽形で求めることができるばかりでなく、将来的には、複数のルールベースシステムの統合へと発展させることができる。応用例として、三上・田中らの道路橋 RC 床版の損傷要因推定のためのルールベースに提案アルゴリズムを適用して、ルールベースを洗練するための教師データの提示方法による影響を含め、本システムの有効性を検討した。

2. 提案する知識洗練機能付診断エキスパートシステム

(1) 提案するシステムの概要

本研究では、仮説と仮説間の関係を構成要素とする相互結合ネットワークで表現されたルールベース洗練機能付汎用型推論システムを構築した。ここで述べる相互結合ネットワークは、知識を相互に結合してネットワークで表現することである。したがって、因果

関係が存在し得る仮説間の関係のみを結合してネットワークを構成する。本推論システムは、アンケート用紙に従って解答してもらうなどの従来の方法で獲得されたエキスパートの知識をルール化することにより通常の推論を行えるばかりでなく、具体事例に対する既存システムの推論結果を教師データとして用いることによって、ルールベースを洗練することができる。

ここで述べる事例とは、前例となる事例のことである。通常、後に発生する問題に対処するためにある事例を参考とする場合には、その事例を誤りを含む可能性のない事実として用いるよりも、誤りを含む可能性のある過去の経験的事実として考慮される。経験的事実であれば、どの程度信頼してよいかの判断が必要になることは言うまでもない。

そこで、本推論システムでは、ルールベースが事例すなわち教師データより信頼度が高い場合には、いわゆる min-max 合成による推論を行う。また、ルールベースの信頼度に比べて高い教師データが得られている場合には、階層型ニューラルネットワークで用いられる誤差逆伝播の概念を応用して教師データに対応するようにルールベースを洗練する。ここで、上述の信頼度をどのように設定するかは、重要な問題である。本研究では、高度の専門知識を持つ技術者と知識技術者が判断して設定すべきものとしてとらえている。

(2) 仮説間の関係及び仮説の数値表現

本研究で構築した推論システムでは、ネットワークを構成するノード及び結合がそれぞれ仮説及び仮説間の関係を示している。それらの属性値は、仮説の成立する可能性(以後、“ノード値”と呼ぶ。)及び仮説間の関係の強さ(以後、“結合係数”と呼ぶ。)であり、これらを区間[0, 1]の実数値で表現している。更に、ノード値及び結合係数に対して確信度を付与し、それらの確信度をノード確信度及びルール確信度と呼ぶ。また、各ノードは、過去の事例から得られる教師データをもつことができる。教師データは、各仮説の属性値である[ノード値, ノード確信度]に対応して[ノード教師値, ノード教師確信度]を属性値としてもつ。この確信度を付与することにより、不確定さを表現できるばかりではなく、仮説推論及びルールベース洗練の2つの機能を併せもつ本推論システムの動作もまた制御することができる。すなわち、推論を実行する前の事前情報として、ルールの属性値としての[結合係数, ルール確信度]及びノードの教師データの属性値としての[ノード教師値, ノード教師確信度]があり、それによって[ノード値, ノード確信度]を得たり、[結合係数, ルール確信度]を更新することになる。

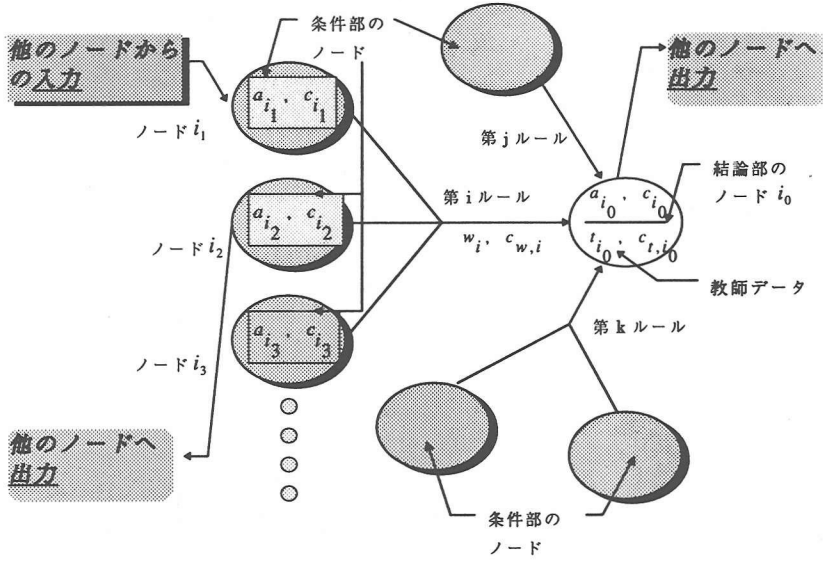


図-1 本推論システムの全体構成

(3)推論アルゴリズム

本推論システムの全体構成を図-1に示す。各ルールは複数の条件部を持ちうることにした。図-1中の左側の i_1, i_2, i_3 などのノードは、第 i ルールの条件部を示し、また、 i_0 ノードは同じルールの結論部を表している。第 i ルールは、結合係数 w_i とルール確信度 $c_{w,i}$ で定義されている。また、それぞれのノードは、ノード値 a_i 及びノード確信度 c_i で定義されるものとする。図-1の例では、第 i, j, k のルールが同一のノードを結論部としてもっている。それぞれのノードは、ある場合は、他のノードへの入力(すなわち条件部)となり、ある場合には他からの出力(すなわち結論部)となり得る。以下で、これらの属性値を用いた推論アルゴリズムを示す。

まず、ある一つのルールから導かれるノード値を次の式(1)のようにいわゆる \min 演算により求める。

$$\bar{a}_i = \wedge \left(\wedge_l a_{i_l}, w_i \right) \quad (1)$$

また、同じルールから導かれる確信度を次の式(2)により求める。

$$\bar{c}_i = c_{i_l} \cdot c_{w,i} \quad (2)$$

あるノードがただ一つのルールの結論部となっている場合には、式(1)及び(2)で求まる値が結論部のノード値とノード確信度となる。

$$a_{i_0} = \bar{a}_i \quad (3)$$

$$c_{i_0} = \bar{c}_i \quad (4)$$

あるノードが2つ以上のルールの結論部となっている場合には、それらのルールについて式(1)及び(2)から得られた値を次の式(5)及び(6)を用いて統合して、その結論部のノード値及びノード確信度を求める。

$$a_{i_0} = \vee_m \left(\bar{a}_m \right) \quad (5)$$

$$c_{i_0} = \dot{+} \left(\bar{c}_m \right) \quad (6)$$

ここで、 $\dot{+}$ は $a \dot{+} b = a + b - a \cdot b$ を示す記号であり、 $\dot{+}(\)$ は $c_{m_1} \dot{+} c_{m_2}$ for $\forall m_1, m_2 \in m$ であることを示す。

(4)洗練アルゴリズム

図-1に示したように、各ノードは教師データをもつ。教師データは全ノードについてノード教師値及びノード教師確信度の対で定義される。

通常のルールベース・システムの推論は、ルールベースを確定情報としてもち、これからある特定な事例に対する仮説の状態を推定することになる。本推論システムでは、ノード教師確信度がルール確信度より低い場合に、このような推論が行われるものとしている。また、確信度の高い情報としての事例を持つ場合には、ルール確信度がノード教師確信度にくらべて低くなり、ルールベースが洗練されることになる。

例えば、ルール確信度を“1.0”に設定し、求めるノードのノード確信度を“0.1”等の低い値に設定すればノード値がルールベースにより求められることになる。反対に、ルール確信度を“0.1”に設定し、ノード確信度を“1.0”にすれば、ルールベースが洗練されることになる。また、より一般的な場合には、ルール確信度とノード教師確信度の大小により、同時進行的にルール洗練とノード値更新がなされる。以下に、ノード確信度とルール確信度の大小関係から、仮説とルールベースを洗練(すなわち、ノード値及び結合係数を更新)するアルゴリズムを示す。

推論によって求められる第 i ルールの結論部のノード確信度と、同じノードに与えられたノード教師確信度を比較し、ノード確信度またはノード教師確信度の低い方のノード値を更新する。まず、推論によって求めたノード値及びノード教師値、ノード確信度及びノード教師確信度の差を次の式(7)及び(8)より求める。

$$\Delta a_{i_0} = a_{i_0} - t_{i_0} \quad (7)$$

$$\Delta c_{i_0} = c_{i_0} - c_{t,i_0} \quad (8)$$

ここで、 $\Delta c_{i_0} \geq 0$ なら、教師データが確信度の低い情報と見なされ次の式(9)及び(10)によりノード教師値及びノード教師確信度が更新される。

$$t_{i_0} \leftarrow t_{i_0} + \eta \cdot \Delta a_{i_0} \quad (9)$$

$$c_{t,i_0} \leftarrow c_{t,i_0} + \eta \cdot \left| \Delta c_{i_0} \right| \quad (10)$$

ここで、 η は学習率である。 $\Delta c_{i_0} < 0$ の場合、実行された推論における min-max 演算において採用されたものが \bar{m} ルールの条件部に対応するノード \bar{m}_i のノード値であるならば、そのノードに対応するノード値及びノード確信度が次の式(11)及び(12)を用いて更新される。

$$a_{\bar{m}_i} \leftarrow a_{\bar{m}_i} + \eta \cdot \Delta a_{i_0} \quad (11)$$

$$c_{\bar{m}_i} \leftarrow c_{\bar{m}_i} + \eta \cdot \left| \Delta c_{i_0} \right| \quad (12)$$

また、min-max 演算により採用されたものが \bar{m} ルールの結合係数であるなら、そのルールの結合係数とルール確信度が次の式(13)及び(14)を用いて更新される。

$$w_{\bar{m}} \leftarrow w_{\bar{m}} + \eta \cdot \Delta a_{i_0} \quad (13)$$

$$c_{w,\bar{m}} \leftarrow c_{w,\bar{m}} + \eta \cdot \left| \Delta c_{i_0} \right| \quad (14)$$

この方法は、階層型ネットワークの学習アルゴリズムである誤差逆伝播法に類似した方法であり、推論は、観測や経験によって既知の事前情報に対応したノードから始まって、ノード間の結合をたどる。入力を持つノードではすべての入力からの情報がそろったところで推論し、順次下流側の結合へ推論が続く。この流れは最終的に出力を持たないノードまで行って終了する。その後、この推論結果と教師データを用いて、再度、上述の既知情報に対応したノードから出力を持たないノードまで、ノードの各属性、または結合の各属性が更新される。このプロセスを各属性値が変化しなくなるまで繰り返し、ある一定の値に到達した時点で解を提示する。相互結合型のニューラルネットワークの場合には、完全結合で外からの入力がない場合には安定状態を持つことが知られている¹⁶⁾。一方、本研究で用いているネットワークは、外からの入力を持ち、また不完全結合である。したがって、安定状態が存在しない場合が考えられる。しかし、提案システムでは仮説と結合に確信度が付与されており、これがシステムを安定して収束させる作用をしており、後述の適用例においても解が発散する現象はまったく見られていない。

本アルゴリズムの特徴は、本来ブラックボックスであるニューラルネットワークにおける学習アルゴリズムの考え方を、1つ1つの結合が具体的なルールを表すネットワークに対して適用している点にある。したがって、ニューラルネットワークでは、全結合であるために入出力関係を柔軟に表現できるものの、その関係は明示的でなく陰な形でルールを獲得するのに対し、本システムでは、ルール洗練により陽な形で具体的なルールの重要度を獲得することができる。この点において、ニューラルネットワークと本システムとは、本質的に利用目的が異なっている。

更に、各仮説の成立する可能性及び仮説間の関係の強さに加えて、それらの信頼度を示す確信度を付与した点も特徴である。現段階では、この確信度は、前述のように高度の専門技術者の判断により設定することになっているが、将来的には、情報理論的なアプローチにより客観的に設定できるようにすることが望ましいが、本論文では、この問題には深く立ち入らない。

3. 適用した診断エキスパートシステム¹⁷⁾

適用したルールベースは、三上・田中らにより開発された道路橋 RC 床版の損傷要因推定エキスパートシ

表-4 既存システムの推論結果¹⁷⁾

損傷要因(表1) 提示事例(表2)	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47
事例	0.73	0.73	0.92	0.9	0.88	0.92	0.85	0.4	0.71	0.77	0.74	0.32	0.32	0.32	0.55	0.38	0.38	0.24	0.18	0.58
事例	0.9	0.77	0.5	0.73	0.73	0.6	0.3	0.4	0.59	0.65	0.6	0.4	0.52	0.56	0.58	0.1	0.2	0.1	0	0.05
事例	0.86	0.86	0.47	0.76	0.86	0.85	0.3	0.33	0.31	0.31	0.31	0.37	0	0.5	0	0.48	0.54	0	0	0.75
事例	0.73	0.73	0.92	0.9	0.88	0.89	0.85	0.4	0.71	0.77	0.74	0.32	0.32	0.32	0.55	0.38	0.38	0.24	0.18	0.58
事例	0.73	0.73	0.92	0.85	0.83	0.89	0.78	0.16	0.59	0.77	0.63	0.32	0.32	0.32	0.55	0.38	0.38	0.24	0.18	0.58
事例	0.73	0.73	0.9	0.88	0.86	0.9	0.85	0.4	0.72	0.73	0.73	0.32	0.32	0.32	0.48	0.38	0.38	0.24	0.18	0.45
事例	0.72	0.72	0.88	0.85	0.85	0.86	0.85	0.3	0.68	0.68	0.68	0.25	0.25	0.25	0.35	0.27	0.35	0.2	0.35	0.18
事例	0.53	0.53	0.65	0.65	0.65	0.65	0.65	0.3	0.53	0.53	0.53	0.12	0.12	0.12	0.12	0.12	0.12	0.12	0	0.05




図-3 事例1の損傷要因の可能性(ルール洗練なし)




図-4 既存システムと本システムにより求めた
損傷要因の可能性の誤差(ルール洗練なし)




図-5 事例2の損傷要因の可能性
(単独事例によるルール洗練後)




図-6 誤差と洗練回数の関係
(単独事例によるルール洗練後)

用した。例として、ハンチ部付近の損傷種類-損傷要因の因果関係を表-3 に示す。◎, ○, △はそれぞれ確信度が 0.5, 0.3, 0.1 であることを表している。三上・田中らは、あいまいな知識を記述するのであるならば、あまり細分化しても無意味であると考え、3 段階としたものであり、確信度の計算には MYCIN による方法を用いた。

本研究では既存システムのルールベースにおける確信度◎, ○, △に対応させてそれぞれ 3/4, 2/4, 1/4 の値をルールの結合係数として与えた。既存システムの確信度に比べて結合係数が高いのは、2. (3) で述べたように推論が min-max 演算に基づいていることによるものである。用いるノードすなわち仮説の総数は 63, ルール数は 872 である。更に、既存システムを用いて表-2 の事例に対して推論した結果を表-4 に示した。表中の番号 28~47 は表-1 の損傷要因番号を示す。

4. ルールベース洗練前の損傷要因の推定

はじめに、ルールベースを確定情報とし、損傷要因の可能性を推定した。用いた事例は、表-2 に示した

ものである。例として、図-3 に事例 1 の推論結果と教師データを、損傷要因の可能性を縦軸に、損傷要因のノード番号を横軸にとって示した。ここでいう、教師データとは、表-4 に示した、各事例に対して既存システムが推論した損傷要因の可能性である。更に、教師データと本システムによる推論結果との誤差を次の式(15)により求め、縦軸に誤差、横軸に事例番号をとって図-4 に示した。

$$\text{誤差} = \frac{\sum_i |t_i - a_i|}{n} \quad (15)$$

ここで、 t_i は既存システムにより求めた第 i 損傷要因の可能性、 a_i は本推論システムにより求めた第 i 損傷要因の可能性を示しており、 n は対象としている損傷要因の個数を表している。

これらの結果で、既存システムと本システムの推論結果に相違が現れた原因は、既存のルールベースを移植する際に用いた 3/4, 2/4, 1/4 という結合係数に明確な根拠が必ずしもないこと、推論過程において min-max 演算を用いていることがあげられる。しかし、傾向としては、事例 1 以外も含めて損傷要因の可能性











図-7 各事例の損傷要因の可能性(8事例の同時提示)




図-8 既存システムと本システムにより求めた
損傷要因の可能性との誤差
(8 事例の同時提示)




図-9 事例 4 の損傷要因の可能性
(損傷場所が同一の 6 事例を同時提示)




図-10 既存システムと本システムにより求めた
損傷要因の可能性との誤差
(損傷場所が同一の 6 事例を同時提示)




図-11 既存システムと本システムにより求めた
損傷要因の可能性との誤差
(損傷場所が同じ未提示事例の推定)

の大小の分類において比較的良く一致している。

5. ルールベース洗練後の損傷要因推定

既存システムの推論結果を確定的な情報とみなし、これを教師データとして提示して、ルールベースを洗練し、その後、洗練されたルールベースを用いて損傷要因を推定した。ただし、ルールベースの洗練途中において教師データが変化しないように、すべてのノード教師確信度を“1.0”にし、またすべてのルール確信度を“0.1”に設定した。更に、損傷要因を推定する際には、ルールベース洗練後のルール確信度をそのまま使い、損傷要因の可能性は未知情報であることからノード値及びノード確信度をそれぞれ“0.5”及び“0.1”とした。教師データは表-2 及び 4 に示した既存システムの推論結果である。

(1) 単独事例を用いたルール洗練

はじめに、事例 1 から事例 8 の教師データを各々単独に提示し、ルールベースの洗練を行った。例として、事例 2 の結果を、損傷要因の可能性を縦軸に、損

傷要因のノード番号を横軸にとり、図-5 に示した。また、図中には、洗練における反復回数(以後、“洗練回数”と呼ぶ。)の影響を見るため、洗練回数異なる場合の結果も示した。また、比較のために教師データも示した。更に、式(15)により各事例の誤差を算出し、誤差と洗練回数の関係を図-6 に示した。

これらの結果から、単独事例を提示してルールベースを洗練すると、各事例の推論結果が教師データとほぼ一致することが分かった。しかし、単独事例によるルール洗練ということは、各事例に対して異なるルールを求めることになるため、実用上の価値は低い。そこで、次節では複数事例を用いてルールを洗練する。

(2) 複数事例を用いたルール洗練

本節では、複数の事例を同時に提示した場合、提示された事例によって、ルールベースの洗練後の推論結果及びその他の事例に対する推論結果がどのような影響を受けるかを検討した。

a) すべての事例を同時に提示した場合

8 事例をすべて同時に提示し、ルールベースの洗練を行った。その後、各事例に対する損傷要因の可能性

を推定した。その推論結果を図-7 に示した。図中には、比較のため既存システムの推論結果及び単独事例を提示した場合の結果も併せて示した。更に、既存システムと本システムによる推論結果の誤差を式(15)で算定し図-8 に示した。

これらの結果から、すべての事例を同時に提示してルールベースを洗練した場合、単独事例による洗練より、教師データと一致する割合は低くなった。これは、すべての教師データに合致することを目標にルールベースが洗練されているために、個々の事例に対する推定精度が低下していることによる。しかし、本来、ある時点で得られる情報から決定されるルールベースは1つに特定されるべきであり、図-8 に示した結果は、全事例を教師データとしてただ1組のルールベースを求めたにも関わらず誤差は小さく、ルール洗練の効果が顕著であるといえる。このことは、既存システムの推論性能を取り込んだ推論システムを、きわめて容易に構築できることを示している。

b) 損傷場所が同一の事例を同時に提示した場合

損傷要因と損傷種類の因果関係が損傷場所の影響を強く受ける¹⁶⁾ことから、ここでは、損傷場所が同一の事例のみを同時に提示してルールベースを洗練した。

損傷場所の一致する事例は、表-2 より事例 1, 4, 5, 6, 7 及び 8 の計 6 つである。これらはすべてハンチ部付近に損傷を生じた事例であり、これらをすべて同時に提示してルールベースの洗練を行った。例として、事例 4 の推論結果を図-9 に示した。図中には、比較のために、8 つの事例を同時に提示した結果と教師データも併せて示した。更に、各事例の推論結果と教師データとの誤差を式(15)で算定し、図-10 に示した。

これらの結果から、損傷場所の情報異なる事例 2 及び 3 を提示しない場合と、それらも同時に提示した場合(図-8)を比べると、当該場所に対する教師データとの一致度は同程度であることが分かる。それに対して、損傷場所異なる事例 2 及び 3 に対する推論結果の誤差は未洗練の場合(図-4)よりも更に大きい。

次に、これら 6 つの事例から 5 つの事例を選択し、それらを用いてルールベースを洗練した。事例の組み合わせは以下に示す 6 パターンとなる。

Ex.6-8:事例 1, 事例 4, 事例 5, 事例 6, 事例 7

Ex.6-7:事例 1, 事例 4, 事例 5, 事例 6, 事例 8

Ex.6-6:事例 1, 事例 4, 事例 5, 事例 7, 事例 8

Ex.6-5:事例 1, 事例 4, 事例 6, 事例 7, 事例 8

Ex.6-4:事例 1, 事例 5, 事例 6, 事例 7, 事例 8

Ex.6-1:事例 4, 事例 5, 事例 6, 事例 7, 事例 8

ここで、例えば、Ex.6-8 は 6 事例の中から事例 8 を除いたものである。

各パターンの事例を用いてルールベースを洗練し、それぞれ提示事例に含まれない事例について推論結果を求め、教師データとの誤差を算定し図-11 に示した。

事例として提示していない事例に対する推論結果を見ると、すべての事例を推定した場合(図-8)や損傷場所が同一のすべての事例を提示した場合(図-10)に比べると、誤差が同程度のもの(事例 4,6,7)と大きく開いているもの(事例 1,5,8)がある。しかし、ルールベース洗練をしない場合(図-4)に比べれば、明らかに推定精度は向上している。このことは、提示する事例の質が良い場合には、未提示事例に対しても良い推論結果を与える機能を本システムがもっていることを示すものである。

6. 結論

本研究では、仮説と仮説間の関係を構成要素とする相互結合ネットワークで表現されたルールベース洗練機能付汎用型推論システムを構築した。本推論システムは、エキスパートシステムの知識をルール化することにより、通常の推論を行えるばかりではなく、具体事例に対する既存システムの推論結果を教師データとして用いることによって、ルールベースを洗練することができる。適用例としては、三上・田中により開発された道路橋 RC 床版の損傷要因推定エキスパートシステムのルールベースを用いて本システムの性能を検討した。得られた主な結論を以下に示す。

- (1) ルールベースを確定情報として、損傷要因の可能性を推定した場合、傾向としては損傷要因の可能性の大小の分類が可能である。
- (2) 既存システムの推論結果を確定的な教師データとして提示してルールベースを洗練し、その後、洗練されたルールベースを用いて損傷要因を推定した場合、
 - ・単独事例を提示してルールベースを洗練すると各事例の推論結果が教師データとほぼ一致する。
 - ・複数事例を同時に提示した場合、提示された事例によって、ルールベースの推論結果及びその他の事例に対する推論結果は影響される。
 - ・複数事例をすべて同時に提示しても、単独事例提示の場合と比べて推定精度の悪化は著しくない。
 - ・未提示事例に対する推論では、洗練のための教師データの良否が推論精度に強く影響する。

このように本論文で提案した手法を用いることによって既存システムと同等の推論性能をもつルールベースシステムを容易に構築することができる。また、提示する事例が適切に選択されれば、未提示事例の推定

精度を確保することが可能である。今後の課題として、複数のルールベースシステムの機能を併せ持つシステムの構築とそれによる知識の共有・再利用を計ることが挙げられる。

謝辞：本研究を行うに当たり、関西大学の三上市蔵教授並びに田中成典助教授に有益なご助言を頂きました。

参考文献

- 1) 矢田光治: AI 入門, オーム社, 1987. 5.
- 2) 古田 均, King-Sun Fu · James. T. P. Yao: 知識工学-エキスパートシステムの構造工学への応用, 土木学会誌, pp. 28-33, 1985. 9.
- 3) 溝口理一郎: 知識の共有と再利用研究の現状と動向, 人工知能学会誌, Vol. 9, No. 1, pp. 3-9, 1994. 1.
- 4) 串田守可, 宮本文穂: 橋梁診断システム構築における知識獲得手法の提案, 土木学会論文集, No. 513/I-31, pp. 139-150, 1995. 4.
- 5) 白石成人, 古田 均, 中林正司, 細谷 学: 学習機能を持った橋梁設計支援システムに関する研究, 構造工学論文集, Vol. 36A, pp. 525-535, 1990. 3.
- 6) 田中成典, 三上市蔵, 前田秀典, 小林 篤: 鋼道路橋の疲労亀裂に対する補修・補強方法の類推推論選定システム, 構造工学論文集, Vol. 42A, pp. 421-432, 1996. 3.
- 7) 小林重信: 事例ベース推論の現状と展望, 人工知能学会誌, Vol. 7, No. 4, pp. 559-565, 1992. 7.
- 8) 中村秀治, 松浦真一, 松井正一, 寺野隆雄: 知識工学的手法に基づく水力鋼構造物の寿命予測, 土木学会論文集, No. 368/I-5, pp. 301-310, 1986. 4.
- 9) 中村秀治, 松浦真一, 寺野隆雄, 篠原靖志: 水力鋼構造物の寿命予測エキスパート・システムとその適用, 土木学会論文集, No. 374/I-6, pp. 513-521, 1986. 10.
- 10) 宮本文穂, 森川英典, 古川正典: 知識更新機能を有するコンクリート橋診断エキスパートシステムの開発, 構造工学論文集, Vol. 38A, pp. 543-556, 1992. 3.
- 11) 宮本文穂, 森川英典, 益成一郎, 古川正典: 橋梁診断エキスパートシステムにおける知識の更新手法, 構造工学論文集, Vol. 37A, pp. 643-654, 1991. 3.
- 12) 三上市蔵, 田中成典, 倉地 晶: 鋼橋疲労損傷の補修方法選定のための学習機能のあるニューラルネットワークシステム, 構造工学論文集, Vol. 38A, pp. 543-556, 1992. 3.
- 13) 三上市蔵, 田中成典, 土田貴敬, 北岸秀一: ネットワークモデルによる知識生成機能を持った損傷型推論エンジン, 土木学会論文集, No. 453/VI-17, pp. 41-50, 1992. 9.
- 14) 三上市蔵, 田中成典, 北岸秀一, 神戸和仁: 鋼橋疲労損傷の補修方法選定システムにおける知識の再利用, 構造工学論文集, Vol. 38A, pp. 529-542, 1992. 3.
- 15) 田中成典, 三上市蔵, 前田秀典, 小林 篤: 事例ベース推論とルールベース推論を併用した鋼橋疲労損傷の補修方法選定システムの開発, Vol. 41A, pp. 575-586, 1995. 3.
- 16) J. デイホフ, 桂井 治訳: ニューラルネットワークアーキテクチャ入門, 森北出版株式会社, 1993. 9.
- 17) 三上市蔵, 松井繁之, 田中成典, 新内康芳: 道路橋鉄筋コンクリート床版の損傷要因推定のためのルールとフレームによる知識ベース・エキスパートシステム, 構造工学論文集, pp. 551-562, 1988. 3.

(1997.7.8 受付)

AN EXPERT SYSTEM FOR CRACK DIAGNOSIS OF DAMAGED BRIDGE SLABS WITH KNOWLEDGE REFINEMENT FUNCTION BASED ON CASE-BASES

Masaru MINAGAWA, Shigeru SATOH and Takekazu KAMITANI

Knowledge acquisition is one of the most crucial requirement for expert systems, because knowledge is usually based on experiences or subjective judgement of engineers. In this paper, a knowledge refinement method is proposed for crack diagnostic expert system. The inference engine is constructed for a reciprocal network based on min-max composition algorithm. Knowledge refinement function is installed into the engine by using the concept of back propagation algorithm usually used for layer-type neural networks. The inference and refinement method are applied to the rule-base system for crack diagnosis of damaged bridge slabs. It is confirmed that existing knowledge-base can be easily transferred to another system for rule-base shearing by using the algorithm proposed here.