Ⅵ-297　構造部材損傷原因推定のための自己学習型エキスパートシステム

正会員　武蔵工大　皆川　勝
正会員　武蔵工大　吉川弘道

１.序論　近年、コンピュータの普及を背景として、土木の業界にもそれを取り入れようとする動きが盛んである。一方、構造物の複雑化にともない技術者への負担は増大し、熟練技術者の不足は否めない。その不足を補う手段の一つに、エキスパートシステムがある。本論文では構造部材の損傷原因推定に用いることを念頭に階層型のニューラルネットワークを用いた自己学習型のエキスパートシステムを提案し，その性能を数値実験により調べた．

２.階層型ネットワークによる原因推定　吉川らは、表１に示すように、建設現場において観測されるひびわれ症状からひびわれ原因候補を選定し、設計・施工・配合条件などの基礎的条件からさらに発生原因をしぼりこむエキスパートシステムを提案した[1]。ここでは、原因と症状の因果関係をファジィ関係方程式の逆解法で記述している。しかしながら、このシステムは当然ではあるが知識ベースに依存した解を与えるのみであり、事例から知識ベースを自動更新することはできない。本研究では、エキスパートシステムに対する学習機能付与の可能性を探る目的で、各結合間に意味を持たせた階層型ネットワークを診断問題へ適用する。

表１　損傷原因診断のための知識ベース

条件																									
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	
打ち込み温度	打設時期	締め固め	養生	支保工	型枠撤去時期	鉄筋かぶり	打ち込み高さ	単位セメント量	単位水量	スランプ	空気量	水セメント比	反応性骨材の使用	海砂の使用	部材断面の種類	部材形式	最小部材厚	配筋量	気温	湿潤状態	設計外荷重	支持地盤	拘束	構造物の環境	原因
																					1.0	1.0	1.0		X１構造物の不等沈下
				1.0	1.0		1.0														1.0	0.5	1.0		X２支保工施工時応力
		0.5				1.0						0.5		1.0				0.5						1.0	X３鉄筋の発錆
0.5	1.0		1.0																					1.0	X４初期凍害
		0.5									1.0	0.5							1.0					1.0	X５凍結融解
1.0	1.0							1.0								1.0	1.0		1.0			1.0	1.0		X６温度応力（外部拘束）
1.0	0.5		0.5		0.5			1.0							1.0		1.0		1.0						X７温度応力（内部拘束）
		1.0	0.5			1.0			1.0	1.0								0.5	0.5	1.0					X８沈降
	0.5	1.0	1.0						1.0	1.0									0.5	1.0					X９プラスチック収縮
								0.5				0.5	1.0						0.5	0.5					X１０アルカリ骨材反応
	0.5	0.5	1.0						1.0	1.0									0.5	1.0					X１１乾燥収縮

症状																					
Y1	Y2	Y3	Y4	Y5	Y6	Y7	Y6	Y9	Y10	Y11	Y12	Y13	Y14	Y15	Y16	Y17	Y18	Y19	Y20	Y21	Y22
規則性				パターン				発生時期				ひび割れ幅			方向性					スケーリング	
部材長手直交方向	配筋方向	その他	なし	網状 亀甲状	一本のみ	一方向複数	二方向複数	数時間から一日	数日	数十日から数カ月	一年以上	微細 0.1mm	中 0.2mmから0.5mm	大 1.0mm以上	鉛直方向	水平方向	斜め方向	打設面上	ランダム	有り	無し
		1.0				0.8				1.0	0.8	0.6	1.0	0.6	0.6	0.6	1.0				1.0
		1.0				0.8		0.8	1.0			0.6	1.0	0.6	0.6	0.6	0.8				1.0
	0.6					0.6					0.6	0.2	0.4	1.0	0.6	0.6			0.2	0.8	
		0.2	0.8	0.8			0.2	1.0	1.0			0.4	1.0	0.4					0.8	0.6	
		0.2	0.8	0.8			0.2			0.2	1.0	0.4	1.0	0.8					0.8	1.0	
0.6					0.4	1.0				1.0	0.8	0.8	1.0	1.0	1.0	1.0					1.0
0.2					1.0	0.6			0.2	1.0		0.8	0.8	0.2	1.0	1.0					1.0
	1.0			0.6			1.0	1.0	0.2	0.2		0.6	0.6					1.0			1.0
			0.8	0.8		0.2		1.0	0.2			1.0	0.8	0.4				1.0	0.8		1.0
			1.0	1.0							1.0	0.6	0.8	0.6					1.0	0.6	
1.0						1.0			1.0	1.0	0.2	1.0	0.8	0.2	1.0	1.0					1.0

３.提案するシステム　諸条件、原因、症状は図１に示すように相互結合したユニットからなる階層型のネットワークを構成すると考える。原因推定のプロセスでは、諸条件が原因を誘発し、その原因が症状を発生させるという方向性を持つこのような階層型ネットワークの同定問題に対しては誤差逆伝播に代表されるニューラルネットワークが威力を発揮する。ここで提案するシステムでは、各結合がおのおのの因子間の因果関係を直接表わすことになり、ユニット間の結合は意味を持つ。このことは、通常のニューラルネットワークのように望ましい出力が得られれば重み係数は極端なことを言えば何でもよいということでなく、解の唯一性が保証されなければならない。しかし、ひとたびこれが保証されれば、事例による学習を行うたびに知識ベースは自動的に更新され得る。入出力値は施工条件などの諸条件と症状であり、すべて既存構造物に対して既知の情報である。これらはすべて［0,1］の範囲の実数値をとるものとする。重み係数は因果関係を直接表わすものとする。したがって、既存の知識ベースから重み係数が決定される。重み係数値はすべて［0,1］の範囲の実数値をとるものとす

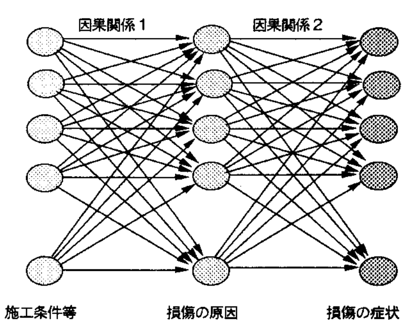

図１　システムの概念

る。つまり、重み係数の大きさは、因果関係の強さを表わすと同時に、不確定さの度合を表わす。したがって、重み係数値が" 0.5" に近いほど不確定さが大きいとみなす。式(1)～式(5)に示される誤差逆伝搬アルゴリズムを修正して用いることにより、原因推定と知識更新を同時に実行することができる．式(5)中のγは図２に示す関数であり、本研究で新たに導入したものである。これは、「重み係数値が" 0.5" に近いほど不確定さが大きいとみなす」ことに対応している。すなわち、重み係数値が0.5に近いほど不確定さが大きいことから、その更新速度を速めるのが妥当であると考えた。また、本システムでは重み係数値は0.5がもっとも不確定な値であると定義しているため、学習により、重み係数が0.5の方向へ更新されるべきではない。そこで、本システムでは、重み係数の更新アルゴリズムに次の方法を採用する。すなわち、

各ユニットの誤差が$\delta>0$であり、さらに$W>0.5$であるとき

各ユニットの誤差が$\delta<0$であり、さらに$W<0.5$であるとき

上記のどちらかを満たすときにのみ、重み係数の更新は行われる。この更新アルゴリズムを用いることで、学習速度が遅くなるが、重み係数値は適切な値へ更新される。

$$S_{j,k+1}=\sum_{l} a_{lk}w_{jlk} \tag{1}$$

$$a_{j,k+1}=f(S_{j,k+1}) \quad (k=1,2) \tag{2}$$

$$\delta_{j3}=(t_j-a_{j3})\dot{f}(S_{j2}) \tag{3}$$

$$\delta_{j2}=\left[\sum_{l}\delta_{l3}w_{lj2}\right]\dot{f}(S_{j3}) \tag{4}$$

$$\Delta w_{ji,k-1}=\eta a_{i,k-1}\delta_{jk}\gamma(w_{ji,k-1}) \tag{5}$$

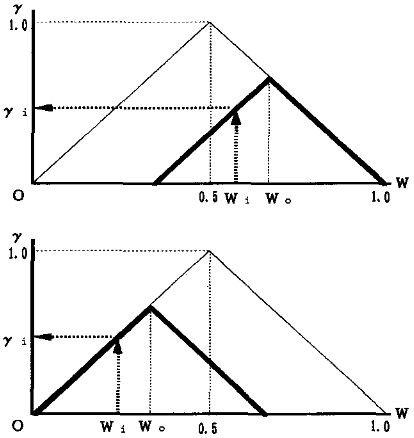

図２　係数γの定義

４．数値実験結果　表１の知識ベースを用いることから，エキスパートシステムは入力（条件）ユニット25個，中間（原因）ユニット11個，出力（症状）ユニット22個からなる．ここでは、乱数を発生させ，その値を入力（条件）とし順伝播により出力（症状）を求め，これを教師データとし、重み係数に以下の方法で誤差を与え，初期値$W^{(init)}_{jik}$を出発点として，学習させた．

$$W^{(init)}_{jik}=\begin{cases} W_{jik}-(W_{jik}-0.5)\alpha & (W_{jik}>0.5) \\ W_{jik}+(0.5-W_{jik})\alpha & (W_{jik}<0.5) \end{cases}$$

ここで，W_{jik}は第k層のユニットｉから第(k+1)層のユニットｊへの出力値に対する重み係数である．また，αは0.05，0.1，0.15，0.2の4通りとした．学習の収束判定としては，出力層のユニット値の平均二乗誤差（RMS）が10^{-6}を満足するまで学習を行うよう設定した．ただし，RMS値が学習過程で増加する場合には，RMSが最小となるところで学習を打ち切った．また，本システムでは重み係数値は，学習により不確定さが減少するように0または1の方向へのみ更新される．そのため，重み係数の真値が知識ベースにより，0.5と与えられている重み係数については，学習による更新は行われないものとした．教師データの内容、教師データ数、学習率等を種々変えて数値実験を行った．一例として教師データの影響を調べた結果を図３に示す．結果は、学習事例の量が多いほど重み係数（知識ベース）がより確かなものへと更新されることを示しており，理にかなっている．また、初期に与えられた知識ベースの正確さに依存して学習後の知識ベースの誤差が変わることも定性的には、妥当な結果である．

５．おわりに　学習前の知識ベースの精度がよくなければ，学習後の誤差も大きくなることが示されたが，このことは既存の知識ベースの値に学習後に得られる知識ベースの良否が影響されることを示しており，矛盾のない結果であると思われる．今後，諸条件から原因にいたる知識ベースの学習を含めて，本手法の有効性を検討する必要がある．

［参考文献］1)吉川・大塚・三浦・小玉：ひびわれ診断におけるファジィ関係方程式の適用と逆解法，コンクリート工学年次論文報告集，Vol13,No.1,pp.497-502,1991

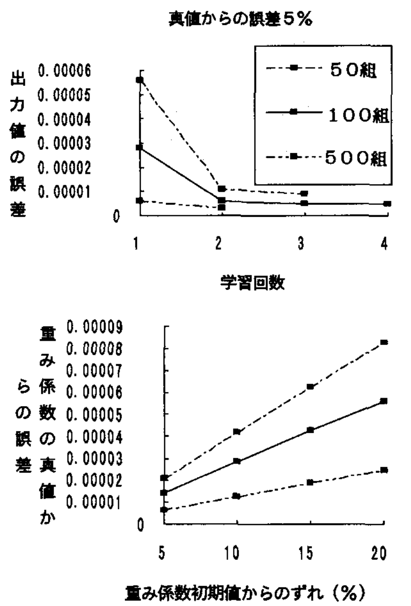

図３　数値計算結果（教師データによる相違）