

## TAM ネットワークを用いたコンクリート床版の健全性評価に関する研究

### Application of TAM Network to Integrity Assessment of Concrete Slabs

○田中 健太, 宮口 昂, 広兼 道幸, 林 勲

Kenta Tanaka, Takashi Miyakuchi, Michiyuki Hirokane, Isao Hayashi

関西大学

Kansai University

**Abstract:** In recent years, it demonstrate that concrete structure occur to decline quality by enlarged load, environment - temperature, humidity, carbon dioxide, acid rain and external pressure - materials, quality of work and it is recognized that maintenance and care are important. During maintenance and care, it is important to estimate and judge health of concrete structure. One of estimation and judgement of health, visual inspection of an expert is existent. Connecting visual information on the surface with state of declining quality inside of concrete is knowledge and experience of expert. This research focused TAM (Topographic Attentive Mapping) network as a method deal with visual information of expert. TAM network is neural network which models visual system processing from the retina down to first visual cortex and get same result which is human visual. We extract several amount of feature which based on cracking check pattern of surface of concrete board, and by using TAM network, have to master these expert knowledge by learning expert estimation and judgement. Moreover, by adopting Pruning Methods, we try to rise correct rate of TAM network and we extract special features which are factors of expert estimation and judgement from knowledge of learn.

#### 1. はじめに

わが国では、戦後、特に経済成長期において多くのコンクリート構造物が建設され、橋梁や道路等に代表される社会資本の整備が行われてきた。構造物にとって重要なことは、力学的に十分な強度と耐久性を有し、安全性を保つことである。コンクリート構造物は、これらの条件を満たしているメンテナンスフリーな構造物と称される時代があった。しかし、近年、コンクリート構造物も荷重増大や環境(温度や湿度、二酸化炭素や酸性雨、外力)の影響、材料や作業の質によって劣化が起ることが明らかになり、維持管理の必要性が認められてきた。現状では既設の土木構造物の劣化に伴い、その維持管理をいかに効率的かつ確実にを行うかが課題となっている[1]。

コンクリートの維持管理には点検、評価・判定、記録、対策などがある。その中で評価・判定についてであるが、コンクリート構造物において一般

的に行われている健全性評価手法の一つに専門家による目視点検がある。例えば、橋梁のコンクリート床版を対象にした目視点検では、専門家はコンクリート表面に顕在化したひびわれなどの損傷要因に関する視覚的な情報から、床版内部の健全性を評価する。この表面的な視覚情報とコンクリート内部の劣化状況を結びつけているのは、専門家の知識と経験である。実際に、専門家は視覚的な情報を損傷や劣化の程度というクラスに対応させる処理を行っていると考えられる[2][3]。

本研究ではこれらの専門家の視覚的な情報を取り扱う方法として TAM (Topographic Attentive Mapping) ネットワークに着目した。TAM ネットワークとは、人間の網膜から外側膝状体、第一視覚野に至る視覚系処理過程をモデル化したニューラルネットワークであり、人の目視と同じ結果が得られると考えられる[4]。そこで、本研究ではパターン認識過程の識別部として、TAM ネットワ

ークを用いて、コンクリート床版表面のひびわれパターンより健全性を評価する方法を提案する。

## 2. 入力データ

本研究では、市販のデジタルカメラによって高架橋（阪神高速道路）の橋梁、床版部分を撮影した、床版部分にひびわれによる損傷のみを含む画像 48 枚を使用した。

図 1 は本研究で使用したひびわれ画像の例である。それぞれの画像には、床版ひびわれの各点検項目におけるそれぞれの判定基準に基づき、専門家によって床版の損傷度の大きなものから、a, b, c の 3 段階の評価が行われている。表 1 は床版のひびわれに基づく点検項目および判定基準を示したものである。最終的にこれらの判定基準の評価

を総合して床版の総合評価 A, B, C を判断する。また、床版画像に対する評価結果は、識別部における種類（クラス）として用いる。

### 2.1. 前処理

デジタル画像処理手法に基づき、ノイズ除去、2 値化処理によるひびわれ抽出、正規化などの前処理を行う。

### 2.2. 特徴量抽出

一般には、特徴量は 1 種類だけではなく、複数の特徴量を計測し、それらを同時に用いる特徴空間を設定する。専門家によるひびわれの評価手法は、ひびわれの連続性、ひびわれの集中性、亀甲状・線状の種類、一方向性・二方向性の種類の 4 つの点検項目において判定がなされている。そこで本研究では、これらの情報を反映する特徴量と




図 1 本研究で用いた床版画像

表 1 床版ひびわれ判定基準

ひびわれの種類		判定要素		判定
		平均ひびわれの幅	平均ひびわれの間隔	
二方向性のひびわれ	平均的ひびわれ発生密度による判定	0.1mm 程度以上	40cm 以下	a
			40cm ~ 60cm	b
			60cm 以上	c
二方向性のひびわれ	局所的に集中したひびわれ、または局部的に発生した亀甲状ひびわれに対する判定	0.2mm 程度以上		a
		0.1 ~ 0.2mm 程度		b
	ひびわれに角落ち、ずれを伴う場合			a
一方向性のひびわれ	平均的ひびわれ発生密度による判定	0.2mm 程度以上	50cm 以下	a
			50cm ~ 1m	b
			1m 以上	c
	一方向性のひびわれ	0.1 ~ 0.2mm 程度	1m 未満	b
			1m 以上	c
一方向性のひびわれ	局所的に集中したひびわれ、または局部的に発生した亀甲状ひびわれに対する判定(※)	0.2mm 程度以上		a
		0.1 ~ 0.2mm 程度		b

※：局所的に集中したひびわれとは、主桁近傍で橋軸方向に連続した線状ひびわれや、部分的にひびわれの発生密度が高くなっている箇所を示す。

して、ひびわれの連続性と集中性にはひびわれ画素のヒストグラムを用い、亀甲状・線状の種別と一方向性・二方向性の種別を特徴点の出現度数を特徴量として用いる。さらにひびわれによって囲まれた領域は剥離が発生する恐れがあるため、専門家はこれらの領域が大きい場合の損傷度を高くすると考えられる。したがって、ひびわれ画素によって囲まれた領域のヒストグラムも特徴量とする。本研究では、デジタル画像を4つの領域に分割し、それぞれの領域において上述した4つの特徴量を考え、16次元の特徴ベクトルを抽出する。

### (1) ひびわれ画素の密度

細線で表現されたひびわれパターンは、方向を持った線素の集合によって構成されていると考えることができ、ヒストグラムによる特徴抽出は有効であると考えられる。図2は2値化した床版画像ひびわれパターンより、垂直方向に射影したヒストグラムで、次元数に応じて量子化し、領域全体の画素数で割って密度を求め特徴量としている。




図2 ひびわれ画素のヒストグラム

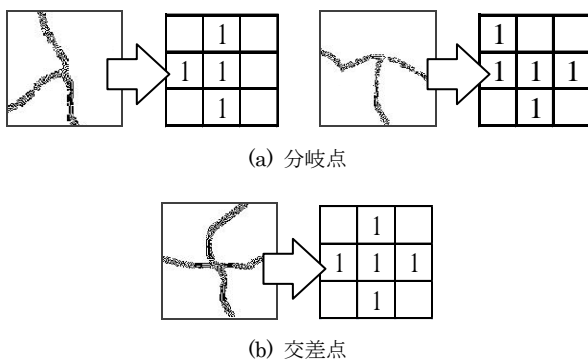


図3 特徴点の種類

(2) ひびわれ線図形における特徴点  
一方向性・二方向性の種別を分ける場合、分岐点・交差点を特徴量とする。図3は分岐点・交差点とそれぞれの特徴をマスクで現した例である。

### (3) ひびわれによって囲まれた領域

図4はひびわれパターンからひびわれ画素によって囲まれた領域の抽出を行った例であり、これらの特徴ベクトルの次元数に応じて量子化し、ひびわれ画素の密度と同じく領域全体の画素数で割り、密度を求め特徴量としている。ひびわれによって囲まれた領域を特徴量とする理由は床版のひびわれによって囲まれた領域は剥離が起こる可能性があるためである。

### 2.3. TAM ネットワーク (識別部)

研究では、前節で抽出した特徴量を用いて、TAM ネットワークによる学習・識別を行う。TAM ネットワークとはWilliamsonによって提案された視覚系ニューラルネットワークである[4]。図5はTAM ネットワークのモデルである。下位層から上位層にむかって、入力層、基盤層、カテゴリー層、出力層の4層からなる。まず、量子化した特徴量




図4 ひびわれ画素によって囲まれた領域

を入力信号とする。入力層は受容野を想定し、入力信号を分布データとして受信し、ランク法を用いて属性ごとに正規化する。基盤層とカテゴリー層は神経節細胞もしくは外側膝状体に対応し、視覚野への中継機能と興奮性、抑制性学習を構造化している。出力層は視覚野を構造化している。TAM ネットワークのアルゴリズムを次に示す。

[Step 1]  $s$  番目の属性データ  $f_{sih}$ ,  $s = 1, 2, \dots, R$ ,  $i = 1, 2, \dots, M$ ,  $h = 1, 2, \dots, L$  に対する TAM ネットワークの出力値  $K$  を得る。

$$K = \{k | \max_k \sum_{j=1}^N y_{js} p_{jk}\} \quad (1)$$

$$y_{js} = \prod_{i=1}^M x_{jis} \quad (2)$$

$$x_{jis} = \frac{\sum_{h=1}^L f_{sih} w_{jih}}{1 + \rho^2 b_{ji}} \quad (3)$$

[Step 2]  $K$  が教師値  $K^*$  と一致しない場合、ビジランスパラメータ  $\rho$  を上昇させる。  $\rho$  が最大値になった場合に、カテゴリー層のノードを1個分増加させる。

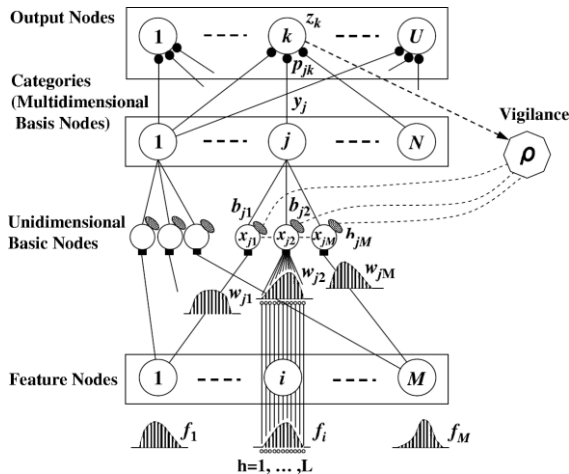


図5 TAM ネットワーク

[Step 3]  $K$  が教師値  $K^*$  と一致する場合、学習モードに入り、学習パラメータ  $w_{jih}$ ,  $p_{jk}$ ,  $b_{ji}$  を更新する。

[Step 4] ステップ1~3 を学習データがなくなるまで繰り返す。

## 2.4. TAM -プルーニング手法 (識別部)

TAM ネットワークは学習性に優れているが、カテゴリー層ノードは単調増加的に付加されるので、過学習となる傾向がある。また、ネットワークの構造を明示的に表現できず、入力属性の削減問題も存在する。これらの問題を解決する手法として、プルーニング手法を用いる。

属性の選択過程において、次の三つの観点から各リンクとノードとを評価し、不必要なリンクとノードを削除する。

- 第  $j$  番目のカテゴリー層ノードにおいて、クラス層ノードとの結合の強さを評価し、不要な結合を削除する。閾値  $\eta$  とする。
- 第  $j$  番目のカテゴリー層ノードにおいて、入力層の各属性との結合の強さを評価し、不要な結合を削除する。閾値  $\theta$  とする。
- 第  $k$  番目のクラス層ノードにおいて、カテゴリー層ノードとの結合の強さを評価し、不要な結合を削除する。閾値  $\xi$  とする。

## 3. 実験と考察

まず、抽出した特徴を量子化し、TAM によって識別を行う。デジタルデータは4分割することによって4つの領域の特徴を表す4次元のデータとみなして評価する。実験データは4次元の量子化された特徴量4種類で行う。ノードは下位層から上位層にむかって、入力層、基盤層、カテゴリー層、出力(クラス)層の4層からなる。学習回数(エポック)は5とした。

学習データには48枚の床版データのうち47枚を使用し、残りの一枚を評価データとして識別させ、それをそれぞれのデータで48回繰り返した。データの特徴点(交差点, 分岐点)はその個数を入力しているが、入力データはすべて正規化した。識別機にかけた回数は3回である。表2は評価データの識別結果である。縦軸は回数, 最大値, 最小値, 平均値, 横軸はそれぞれの特徴を示し、個々の値は識別の認識率を示している。ひび画素の密度, 特徴点1(交差点), 特徴点2(分岐点), ひび

で囲まれた領域の認識率の平均は 53.5%, 54.9%, 63.9%, 70.8%となった。ひび画素の密度, 特徴点 1 (交差点), 特徴点 2 (分岐点), ひびで囲まれた領域すべての特徴量 (4次元×4種類=16次元) を用いて学習し評価した結果は 1, 2, 3 回目それぞれ 66.7, 68.8, 85.4%の値になり, 平均で 73.6%の認識率になった。ひとつひとつの特徴を見ていくとひび画素の密度, 特徴点 1 (交差点) 個別では認識率はそれほど高くない。それに比べ, 特徴点 2 (分岐点), ひびで囲まれた領域は平均 63.9%, 70.8%とそれなりに高い値を示している。さらに 4 種類の特徴量をすべて考慮した実験では平均で 73.6%, 最高 85%とかなり高い認識率を得ることができた。

次に, プルーニングを行う TAM によって全特徴量を用いての識別を行った。デジタルデータは 4 分割することによって 4 つの領域の特徴を表す 4 次元のデータとみなす。実験データは 4 次元の量子化された特徴 4 種類全てを特徴量とする 16 次元で評価した。ノードは下位層から上位層にむかって, 入力層, 基盤層, カテゴリー層, 出力 (クラス) 層の 4 層からなる。学習回数 (エポック) は 5 とした。閾値  $\eta$  は 0.9 とし閾値  $\theta$  は 0.01 とし閾値  $\xi$  は 0.9 とした。それぞれの値は林らの研究報告でより高い認識率を得たケース [5] を参考に設定した。学習データには 48 枚の床版データのうち 47 枚を使用し, 残り一枚を評価データとして識別させ, それをそれぞれのデータで 48 回繰り返した。データの特徴点 (交差点, 分岐点) はその個数を入力しているが, 入力データはすべて正規化

した。識別機にかける回数は TAM のみのときと同じく 3 回である。Pruning を行わなかった場合と行った場合との TAM による識別結果の比較を表 3 に示す。右の行から方法, 上段には TAM のみでの 1,2,3 回の結果, 平均, 行った中での最大・最小値を示し, 下段では Pruning を用いた場合の TAM のそれぞれの場合を示した。また, 3 行目では正答率, 4 行目では図 5 で上から 2 段目の列で示される生成したカテゴリー数, 5 行目では同じく図 5 一番下の列で示される特徴 (ベクトル) 数, 6 行目では図 5 で最上段にしるされる評価 (等級) の数を示した。正答率の最大値は 85.4%と変わらないものの, すべての回数で TAM + Pruning の結果が TAM の結果より上昇しており, 平均も 8.3%上がった。これは Pruning を行うことで余計な属性を省き, 少ない属性から特徴を導き出しているためである。

表 3 プルーニング後の識別結果

Methods		Correct Rate [%]	Categories	Features	Class
TAM	Once	66.7	23	16	3
	Twice	68.8	25	16	3
	Three	85.4	21	16	3
	Average	<b>73.6</b>	-	-	-
	Min	66.7	23	16	3
	Max	85.4	21	16	3
TAM + Pruning	Once	79.2	13	16	3
	Twice	81.2	17	16	3
	Three	85.4	10	16	3
	Average	<b>81.9</b>	-	-	-
	Min	79.2	13	16	3
	Max	85.4	10	16	3

表 2 評価データの識別結果

Check	ひび画素の密度	特徴点1 (交差点)	特徴点2 (分岐点)	ひびで囲まれた領域	全特徴量 (16次元)
Once	43.8	22.9	45.8	66.7	66.7
Twice	47.9	79.2	72.9	72.9	68.8
Three times	68.8	62.5	72.9	72.9	<b>85.4</b>
Average	53.5	54.9	63.9	70.8	73.6
Min	43.8	22.9	45.8	66.7	66.7
Max	68.8	79.2	72.9	72.9	<b>85.4</b>



TAM ネットワークは、それぞれの特徴から似た特徴があるものを1つのカテゴリとして生成する(図5)。そうでないものが現れた場合、また新たなカテゴリを生成する。それを繰り返し行い、複数のカテゴリを生成する仕組みをとっている。生成されたカテゴリを評価 A,B,C へ分類するという過程においては、生成されたカテゴリは全てが A,B,C いずれかの評価に属することになる。しかし、評価 A,B,C を分類するに当たっては影響の少ないもの、A,B,C 判定を妨げるカテゴリも現れてくる。TAM のみではこれら全てが A,B,C いずれかの評価に属することになる。Pruning を用いた場合、それらは省かれる。余計な属性を省くというのはそのことである。表3, 3行目のカテゴリ、Pruning を行わなかった場合と行った場合を比較してもらえばわかる。Pruning を行わなかった場合では生成されたカテゴリ数が20以上なのに対し、Pruning を行った場合では、20未満である。つまり特徴から生成されたカテゴリの中に A,B,C に分類する上で判定を有意に働かなくするカテゴリがおおよそ10程度存在していたことが表よりわかる。具体的には属性特徴点1(交差点)、ひびで囲まれた領域は評価に関係しているものが少なく、ひび画素の密度の属性、特徴点2(分岐点)の属性が総合評価 A, B, C の判定に強く影響しているものが多くあることが分かった。

#### 4. おわりに

本論文では、コンクリート評価に対する3つのことを行った。まず、視覚系ニューラルネットワークである TAM ネットワークを用いて高架橋、橋梁のコンクリート床版のひび割れ判定を行った。識別機である TAM ネットワークにかける前段階として、ノイズ除去、2値化処理によるひびわれ抽出、正規化などの前処理、ひびわれの連続性、ひびわれの集中性、亀甲状・線状の種別、一方向性・二方向性の種別の4つの点検項目の決定、4つの点検項目を用いた特徴量抽出、抽出した特徴の量子化を行った。また、判定の精度を向上させ

るため、不必要なリンクとノードを削除するブルーニング(枝刈り法)を用いた。これにより、識別の正答率は上昇した。また、ブルーニングを用いることにより、ネットワークの構造を明示し、コンクリート構造物の目視点検を行う専門家の評価・判定知識をビギナーに示すこと、どのような特徴が判定に影響しているのかを示すことができた。なお、今回49枚と少ない教師データで行ったが、より高い認識率を得るためには、今回以上に多くのサンプルが必要であると考えられる。次元数に関して、先行研究で20次元以上になると精度が落ちることが示されていたため、今回データを4つの領域に分けて16次元で行ったが、識別機として TAM を用いた場合の前例がないため、他の次元数についても考察する必要がある。今後、認識率の精度をより正確に示すために、識別機にかける回数を増やしていく予定である。

#### 参考文献

- [1] 魚本健人, 加藤潔, 広野進: コンクリート構造物の非破壊検査, 森北出版, pp4-26, 1990
- [2] 楠瀬芳之・広兼道幸・古田均: パターン認識手法を用いた床版のひびわれ形状の抽出と分類に関する研究, ファジイシステムシンポジウム, 日本知能情報ファジイ学会, pp. 232-236, 2003.9
- [3] Y.Kusunose, M.Hirokane, H.Furuta: Classification of Crack in Concrete Slabs Using Pattern Recognition Methods, The Seventh International Conference on the Application of Artificial Intelligence to Civil and Structural Engineering, Civil Comp Press, Paper 69, pp.1-10, 2003.9
- [4] 林 勲, ジェームズ R. ウィリアムソン: TAM Network のブルーニング手法の提案, システム制御情報学会論文誌, Vol.17, No.2, pp.81-88, 2004

#### 連絡先

関西大学総合情報学部 広兼 道幸

E-mail: hirokane@res.kutc.kansai-u.ac.jp