

ニューラルネットワークを用いたデータマイニングによる トンネルひび割れの一考察

Analysis of crack characteristics of tunnel by data mining using newral network


北海道大学大学院工学研究科 ○学生員 松田奈緒子(Naoko Matsuda)
北海道大学大学院工学研究科 フェロー 三上隆(Takashi Mikami)
株式会社地崎工業 正員 須藤敦史(Atsusi Sutoh)

1. まえがき

近年、データベースに蓄積された膨大な生データから価値ある情報を発見することを目的とした「KDD (データベースからの知識発見)」あるいは「データマイニング(Data Mining)」に関する研究やその処理システムの構築が行われてきている。データマイニングとは膨大な生データの中に存在する隠れた知識や規則を客観的に経発見することである。本研究ではニューラルネットワークを用いたデータマイニングを道内のAトンネルのひび割れ問題に適用し、構造諸元、施工条件等の諸データとクラックとの関係の解析を試みたものである。ここではデータマイニングの基本概念に従って、環境に関する専門知識は全く参照せずに行われた生データのみからクラック発生に関する要因や関連性の同定を試みている。

2 ニューラルネットワーク

ニューラルネットワークのニューロン(神経細胞)をモデル化したものを図-2に示す。ここでニューロンは信号を受け取る‘入力部’と信号を発信する‘出力部’に分かれている。入力部では前のニューロンからの入力の総和を計算し、その結果を出力部においてシグモイド関数などにより出力が判定され、次のニューロンへと情報が伝達される。ここで図-2において x_i :前細胞の出力値、 w_i :結合の強さ(重み)、 $f(y)$:出力関数である。



以下に本解析で用いた重みの学習法であるB P法、仮想インピーダンス法と成長抑制学習を記述する。

ある時刻 t における入力信号 p に対する絶対誤差を次式で定義する。

$$E_p(t) = \frac{1}{2} \sum_i (T_{pi} - O_i^n)^2 \quad (1)$$

T_{pi} : 入力信号 p に対する出力ニューロン i のための教師信号

ネットワークの平均誤差は次式で与えられ

$$E(t) = \frac{1}{P} \sum_p E_p(t) \quad (2)$$

この式で与えられる誤差が限りなく小さくなるように重みを調整し、重みの変化量は次式に従う。

B P法:

$$\Delta W_{ij}^k(t) = -\varepsilon \frac{\partial E(t)}{\partial W_{ij}^k(t)} + \alpha \Delta W_{ij}^k(t-1) \quad (3)$$

ε 、 α は学習を効率よく行わせるための定数
仮想インピーダンス法:

$$\Delta W_{ij}^k(t) = -\varepsilon \frac{\partial E(t)}{\partial W_{ij}^k(t)} + \alpha \Delta W_{ij}^k(t-1) - \beta \Delta W_{ij}^k(t-2) \quad (4)$$

成長抑制学習法:

$$\Delta W_{ij}^k(t) = -\varepsilon \frac{\partial E(t)}{\partial W_{ij}^k(t)} + \alpha \Delta W_{ij}^k(t-1) - \beta \Delta W_{ij}^k(t-2) + s \quad (5)$$

3. 解析

3.1 クラック問題の設定

表-1 観測項目

		説明
	C1	施工条件
	C2	施工条件
	D1	施工条件
	D2	施工条件
A	坑口からの距離	(m)
B	スパン長	(m)
	打設季節	冬, 冬以外
C	インバート長	(m)
	断熱材	
D	コンクリート温度	
E	スランプ	(cm)
F	空気量	(mm ³)
	クラック	

データマイニングに用いるデータベースは表-1に示す項目で55観測点のデータを用いている。ここで観測データは平成10年~11年に観測されたものである。ここで観測データの基本的な統計量として各観測データの属性を平均値以上・以下のブール属性としている。

3.2 ニューラルネットワークによる関連性の分析




図-2 BP法による解析結果




図-3 成長抑制学習の結果




図-4 再構築の学習結果




図-5 観測項目と7種類のクラックとの属性

図-2にBP法による解析結果を示す。また、ネットワークがある程度進んだ段階で成長抑制法に切り替えた結果を図-3に示す。ここで図中のネットワークにおいて「+」結合は各項目における平均値以上の属性とクラックとの属性を示しており、「-」結合は平均値以下の属性とクラックとの関連性を示している。

さらに、簡素化、明確化を図るために、ネットワークの構築がある程度進んだ段階で、重みの小さくなった結合の削除を行い、その結果を図-4に示す。

また、図-5は観測項目と7種類のクラック（表-2）との属性を調べた結果を示す。

以上から、クラックと結びつきが強い項目として坑口からの距離、スパン長、断熱材の有無、コンクリート温度が上げられる。例えば、クラックA（天端のクラック）と結びつきが強い項目は打設季節、コンクリート温度である。

4. まとめ

本研究はデータマイニング法を用いて寒冷地トンネルの覆工ひび割れに影響を与える要因の検討を行ったものである。今後はより詳細なデータを用いた解析を行う予定である。

表-2 クラックA～Hの特性

パターン	向き	長さ	幅
A	縦	長	広
B	縦	長	狭
C	縦	短	広
D	縦	短	狭
E	横	短	広
F	横	短	狭
G	その他	短	広
H	その他	短	狭

幅は最大値0.4mmが基準

参考文献

1) 矢川元基編：ニューラルネットワーク，培風館，1992。
2) 江原淳，佐藤栄作共訳：データマイニング手法，海文堂，1999
3) 山本栄子，梅村恭司訳：データマイニング，共立出版，1998。
4) 須藤敦史，高須光郎，星谷勝：ニューラルネットワークを用いたデータマイニングによる非構造システムの同定，応用力学論文集 Vol2，pp. 83-90,1998。