

下水道協会誌論文集

— 目 次 —

◇ 論 文 ◇

下水管網に起因する道路陥没の位置推定と危険度及び原因の予測に関する
 手法の提案 109
 松 川 努 宮 本 文 穂 中 村 秀 明

◇ 論 文 ◇

下水処理場の環境影響評価におけるオキシデーションディッチ法と
 標準活性汚泥法の比較 122
 澤 田 哲 平 宮 原 高 志 小 松 敏 宏

◇ 報 告 ◇

汚泥脱水設備における CO₂ 排出量に関する基礎的研究 131
 吉 田 一 子 大 森 康 弘 若 松 重 幸

〈下水道協会誌論文審査委員会〉

(平成20年11月21日現在・順不同)

委員 長	古 米 弘 明				
委 員	田 中 宏 明	長 岡 裕	李 玉 友	徐 開 欽	
	藤 生 和 也	中 沢 均	阿 部 義 博	三 神 景 信	
	小 浜 一 好	楠 本 光 秀	浅 田 一 洋	西 脇 正 人	

本協会は日本学術会議の「協力学術研究団体」として 指定されております。

日本学術会議は、日本学術会議法（昭和 22 年法律第 121 号）に基づき、わが国の科学者の内外に
 対する代表機関として、科学の向上発達を図り、行政、産業および国民生活に科学を反映浸透させ
 ることを目的として設置されたものであります。本協会は、平成 3 年 5 月 1 日付けをもって、同会議
 から「広報協力学術団体」として指定されましたが、日本学術会議法の一部が改正され「協力学術
 研究団体」として名称が変更になりました。

この指定は、学術研究の向上発達を図ることを主たる目的とする団体であって、かつ、その目的
 とする分野における学術研究団体として活動しており、個人会員である構成員が原則として 100 名
 以上であるという基準を満たしていることと認められたことによるものであります。

この学術研究団体に指定されますと、「全国学術研究団体総覧」に掲載され、その団体が発行して
 いる機関雑誌等（本協会の場合は、下水道協会誌）に掲載された論文は、高い評価が受けられるこ
 とになります。下水道関係の論文については、是非、下水道協会誌へご投稿下さるようお願いいた
 します。

CONTENTS

- Development of a Preventive Maintenance Planning System for Sewage Pipe Networks
Considering the Prevention of Road Caving Damage 109
Tsutomu MATSUKAWA, Ayaho MIYAMOTO, Hideaki NAKAMURA
- Comparison of Oxidation Ditch and Conventional Activated Sludge in
Environmental Impact Assessment of Wastewater Treatment Plant 122
Teppei SAWADA, Takashi MIYAHARA, Toshihiro KOMATSU
- Basic Resarch on Amount of Carbon Dioxide Emissions from the Sludge
Dewatering Equipment 131
Kazuko YOSHIDA, Yasuhiro OMORI, Shigeyuki WAKAMATSU

■ 論 文 ■

下水管網に起因する道路陥没の位置推定と危険度及び原因の予測に関する手法の提案

松 川 努* 中 村 秀 明***
宮 本 文 穂**

要 旨：本研究では、下水管網の予防保全計画策定支援の一つである道路陥没に関する予測情報を提供すべく、下水道台帳と過去の調査点検記録及び道路陥没履歴データに着目して、その有効活用を図ると共に、道路陥没の位置推定と危険度及び原因の予測を可能とするシステムの開発を行うことを目的とする。筆者らが提案するシステムは、予防保全の必要性を認識しつつも事後保全体制から脱却できず、予防保全計画策定に思慮している管理者に対して、埋没している過去の蓄積情報を活用し、クラスター分析やニューラルネットワークを援用することで、道路陥没の位置推定や危険度予測が行えることを特徴とする。本論文は、この予測手法を構築するプロセスと手段を提案すると共に、本システムの有効性を検証した。

キーワード：下水管網，道路陥没，予測，保全計画，クラスター分析，ニューラルネットワーク

1. はじめに

筆者らの研究室では、山口県宇部市と共同で、下水管網の維持管理支援に関するシステムの研究開発に取り組んでいる。宇部市の下水道事業は歴史が古く、1948年から敷設事業が行われてきた。1955年頃からは下水道の敷設延長が増加し始め、1968年頃から急増し、2006年度末時点で、宇部市の公共下水道処理人口普及率は65.7%、敷設延長は600.9kmに達している。

すでに宇部市では、道路陥没の問題が深刻化しつつあり、2005年度で53件（2006年度38件）発生し、年度を追って増加傾向にある。**写真-1**は、実際に宇部市内で発生した道路陥没と修繕状況である。現時点では、道路陥没が発生した場合は、通常、開削工法による事後保全となる。ただし、

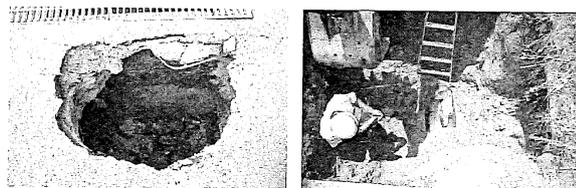


写真-1 道路陥没と修繕の様子

下水道は、断水や停電のように使用を制限することが難しく、交通量の多い道路では通行規制が必要なため難工事が予想され、修繕費用は膨らむこととなる。一方、予防保全計画を適切に行うことができれば、人孔からの修繕といった非開削工法も活用でき、道路陥没の未然防止が図れ、経費の節減へとつながる。今後、一斉に下水管網が老朽化すると保全費用が膨大となることから、早期に計画的な予防保全が行える体制作りが必要である。

しかし、宇部市ではこれまで、予防保全の必要性は認識しつつも、予防保全計画の策定着手に思

慮していた。その一番の理由は、予防保全計画に必要な情報が十分に得られないことにあった。逆に、何らかの劣化や危険度予測に関する情報が得られれば、予防保全計画が打ち立てられ、事後保全体制から脱却することが可能となる。このような問題は、宇部市にとどまらず全国の下水道先進都市に存在するものと考ええる。

2. 危険度及び原因を予測する手法の開発

(1) 本研究のねらい

宇部市では、これまで下水道台帳の他に調査点検記録や道路陥没履歴など数多くの情報が大切に保管されてきた。しかし、そのほとんどが有効に活用されているとは言い難い状況にあった。その理由の一つに、どのように過去の情報を活用すればよいか、その方法が新たに見出せないことが課題であった。また、未だに下水道に関する劣化予測等の手法が確立していないことや、予防保全計画への新たな取り組みに対する手段の開発や有効性の検証等ができないため、これまで道路陥没後の事後保全に終始してきた。

そこで筆者らは、予防保全計画策定支援の一つとして、下水道台帳や調査点検記録及び道路陥没履歴データなど数多く保管されてきたこれらの過去の記録をもとに、道路陥没の位置推定と危険度及び原因の予測を可能とするシステムの研究開発と予測情報の妥当性の検証を行った。

(2) 本研究における開発プロセスの概要

本予測システムの開発プロセスを図-1に示す。本プロセスは、改良を随時行いながら研究を推し進めたことから、大きく2つのプロセス(レベル)と合計11のステップから成り立っている。

まずLEVEL1のうち、STEP1で使用すべきデータの選択(下水道台帳や調査点検記録、道路陥没履歴の抜粋)を行い、STEP2でこれらのデータの洗浄及びコード化を行う(ここで得られた1件当たりのデータを、以下=サンプルと称す)。次に、STEP3-5で全サンプルを危険度及び原因別にグルーピングし、各グループにおいて非階層的クラスター分析法を用いてニューラルネットワークに学習させる代表サンプルの抽出を行う。続いて、

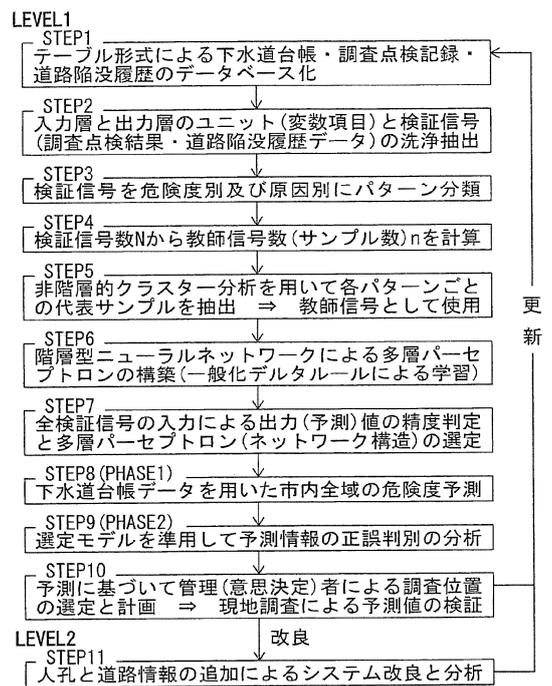


図-1 本予測システムの開発プロセス

STEP6-9でニューラルネットワークによる複数の予測モデルを構築し、予測精度を判定基準としてモデルを選定した後、道路陥没の位置推定及び危険度と原因の予測(以下、PHASE1と称す)と、その予測情報の正誤判定(以下、PHASE2と称す)を行う。最後に、STEP10で予測情報に基づいて現地調査を実施し、予測情報の妥当性と本システムの有効性を検証する。

検証の結果、さらに予測精度を向上させる必要があることが判明し、また、システムの改良の余地が残されていたことから、LEVEL2(STEP11)で人孔と道路の情報を追加して、前述のSTEP1-9のプロセスを再度実施して、新たな予測モデルを構築することとした。そして、どの程度予測精度が向上したか、再度有効性を検証する。

3. 検証信号の選定と教師信号の抽出

(1) データベースの構築

まず、LEVEL1で採用したデータは、①下水道台帳、②調査点検記録、③道路陥没履歴の3種類である。このうち、全下水道台帳データは予測に使用し、以下、調査点検記録及び道路陥没履歴

とこれに該当する一部の下水道台帳データを組み合わせ合わせたサンプルを「検証信号」、検証信号からクラスター分析によって抽出した学習用の代表サンプルを「教師信号」と称する。

ここで、下水道台帳は戦後から2004年末までの下水道敷設情報が記録されたもの(計24,738件)を使用することとし、戦前に敷設された下水道管は敷設履歴が不明なため、全て1945年(終戦直後)に敷設工事を完了しているものとして台帳に記載している。また、調査点検記録は1994年4月から2006年9月までの情報(1,704件)が、道路陥没履歴は1981年11月から2006年9月までの情報(565件)が記録されている。図-2に道路陥没を引き起こした管渠の諸元を示す。

なお、下水道台帳1件(1サンプル)に含まれる情報は、対象とする管路(管渠)についての詳細情報と管の呑口側(上流側)人孔についての簡易情報である。また、道路陥没の危険度予測の対象エリアは、宇部市下水道部が管轄する市町村合

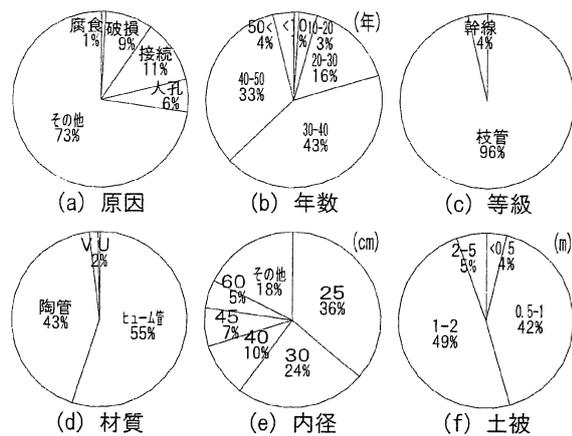


図-2 道路陥没を引き起こした管渠の諸元

併以前の市内全エリアである。

次に、ニューラルネットワークのユニットの数及び各項目諸元を表-1に示し、詳細を説明する。入力ユニット(LEVEL1)で採用した項目は、①管路諸元(質的)が7項目、②管路諸元(量的)が5項目、③平面位置が4項目、の計16項目で

表-1 各ユニットの項目諸元及び数(LEVEL1)

(a) 項目諸元及びカテゴリ一覧

入出力 PHASE	入力ユニット																出力ユニット			
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	23	24		
No	形式	地域区分	幹線番号	縦番(北)	横番(東)	供用年数	区間延長	管渠等級	管渠材質	管渠形状	管渠内径	流下勾配	副管取付	圧送採用	圧送出口	呑口土被	危険度	原因		
カテゴリ	合流 [0.3] 汚水 [0.6] 雨水 [0.9]	※地域を34に区分	※一地域で最大18の幹線No.	※縦番(北)	※横番(東)	※取付管は除外	※取付管は除外	※取付管は除外	FRP [0.55] FRP [0.65] VU [0.80]	FRP [0.05] PC [0.20] 側溝 [0.35] FRP [0.55] FRP [0.65] VU [0.80]	FRP [0.10] FRP [0.25] FRP [0.40] FRP [0.55] FRP [0.65] FRP [0.80]	FRP [0.15] FRP [0.30] FRP [0.45] FRP [0.60] FRP [0.75] FRP [0.90]	FRP [0.10] FRP [0.20] FRP [0.30] FRP [0.40] FRP [0.50] FRP [0.60]							

注記・[]は、量的データとして取り扱った場合のカテゴリ値を示す。
 ここで、上記の各カテゴリは宇部市が管理するデータベースに基づいている。そのため、項目内のカテゴリの一部に齟齬があるがそのまま使用した。
 ※は、特記事項を示す。
 「取付管は除外」とは、宇部市では取付管を図面の記載にとどめデータベース化していないことを意味する。
 ・欠損値または非該当については、[0]とする。
 ・質的データのうち、有無または適否については、無・否を[0.5]、有・適を[1.0]とする。
 ・量的データについては、値を整数項が1桁以下の小数となるように調整する。
 ・量的データのうち、地域区分の項目については、[0.「地域No.」]とする。
 ・量的データのうち、縦番と横番の項目については、[0.「縦番」]とする。
 ・量的データのうち、1をわずかに超えるサンプルが少数存在するが、分析には影響ない。
 ・上記データベースには他に、竣工年月日/改築種別/改築年月日/陥没年月日/地盤高/上流側管底高/下流側管底高/本管・取付管種別/工事内容(このうち、竣工または改築年月日から陥没年月日または現在までを「供用年数」、地盤高から上流側管底高と管径を差し引いて「呑口土被」とする)があり、上記16項目で与条件・情報を網羅していると判断した。
 ・ここで、「本管」とは「幹線管渠(幹線:φ900mm以上)」と「支線管渠(支管:φ800mm未満)」の総称である。
 ・原因のうち、「腐食」は本管または人孔を、「破損」は本管を、「接続」は本管同士または本管と人孔を、「人孔」は腐食以外の人孔異常を、「その他」は主に取付管などを取り付ける際の施工不良などに起因する本管または人孔の損傷などを対象とする。

(b) ユニット数一覧

No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	合	23	24	合	25	合
エ	状態	質的(適否)	質的(適否)	質的(適否)	量的(適否)	量的(適否)	量的(適否)	質的(適否)	質的(適否)	質的(適否)	量的(適否)	量的(適否)	量的(適否)	質的(適否)	質的(適否)	量的(適否)	計	量的(適否)	量的(適否)	計	量的(適否)	計
A	上小	3	34	18	1	1	1	2	18	6	1	1	1	1	1	1	91	(-)	1	2	(-)	1
B	状態	同上	41	同上	同上	同上	同上	同上														
C	状態	量的(適否)	同上	同上	同上	同上	同上	量的(適否)	量的(適否)	量的(適否)	同上	同上	同上	同上	同上	同上	16	同上	同上	同上	同上	同上

注記・ユニット16からユニット41への変更点は、「形式」、「材質」、「形状」の量的データ(1ユニット)を質的データ(適否:複数ユニット)へ変更。
 ・ユニット41からユニット91への変更点は、「地域区分」、「幹線番号」の目的データ(1ユニット)を質的データ(適否:複数ユニット)へ変更。
 ・上記の変更対象項目は、本来、質的データであることから、数値に直接的な意味がなく、どのような数値を当てはめても問題のない項目である。
 ・質的データへの変更とは、複数カテゴリを有する項目を分解し、カテゴリから項目へと格上げして、各項目における諸元の適否を入力(変換)する。

ある。次に、出力ユニットのうち PHASE1 で採用した項目は、①危険度 (5 カテゴリ)、②原因 (5 カテゴリ) の計 2 項目で、危険度及び原因の予測に使用する。また、PHASE2 で採用した項目は、①正誤 (2 カテゴリ) の 1 項目で、PHASE1 の出力信号と検証信号の正誤傾向を新たに学習させ、予測情報の正誤判定を行う際に使用する。

なお、出力ユニットのうち危険度は、例えば腐食のケースでは、過去の記録において、セメント成分が劣化し細骨材または粘土状物質が内壁表面に付着している状態を「軽度」、粗骨材が露出し始めている状態を「中度」、鉄筋が露出し始めている状態を「重度」、実際に陥没が発生した箇所を「陥没」とし、それ以外問題なかった調査済み箇所を「健全」と判定している。そして、これらの判断は管理者である宇部市の職員が行うと共に、本記録の保存をその担当者が併せて行っている。この一例を写真-2 に示す。

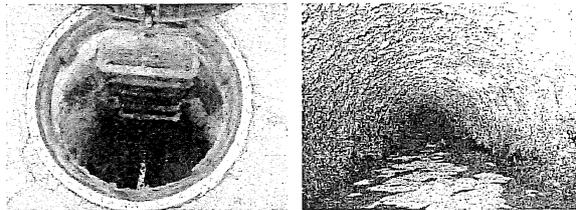


写真-2 「中度」の「腐食」劣化状況の例

LEVEL1 では、データ洗浄 (有用項目の抽出: 表-1 (a) 注記参照) に耐えられた上記の 16 項目を入力項目に設定し、道路陥没の位置推定を試みた。

続いて、入出力全ユニット (合計 19 項目) のコード化に当たっては、ニューラルネットワークの学習精度を検証するため、入力ユニットのうち、形式、地域区分、幹番号、等級、材質、形状の 6 項目はカテゴリ値が変更可能な質的データであることから、これらのユニット構造を変化させ、入力ユニット数を 16, 41, 91 の 3 タイプに区分した。

また、各項目に使用するカテゴリ値のうち、全項共通の条件として、カテゴリ値を原則として 0-1 の範囲とし、欠損値や非該当は 0 とした。その他、入力ユニットの平面位置を示す項目は番号の前に小数点を付し小数表示すると共に、量的

データの項目は単位を調整して原則として 1 を超えない値とし、質的データの項目は等間隔尺度値を用いて量的データに置換した。ただしこの場合、間隔尺度は直接意味を有しないものとする。上記のカテゴリ値を 0-1 の量的データに置換した理由は、以下で使用するクラスター分析及びニューラルネットワークでの学習の際に、項目間での値の大小のばらつきや偏りを制御するためである。

(2) 検証信号のパターン分類と教師信号数算定

検証信号として、調査点検記録 (1,704 件) と道路陥没履歴 (565 件) の計 2,269 件を用いることとした。表-2 (a) に、検証信号をグループ分けした結果を示す。今回使用したデータの分布をみると、ほぼ各項を充足しているが、サンプル数に偏りがある。ニューラルネットワークに学習

表-2 教師信号のサンプル数の絞り込み

(a) 検証信号 (全 2269 サンプル) の構成分布

原因	0.2	0.4	0.6	0.8	1.0	0	合計
危険度	腐食	破損	接続	人孔	その他	非該当	
0.2 (健全)	—	—	—	—	—	118	118
0.4 (軽度)	460	86	384	79	47	—	1056
0.6 (中度)	139	162	72	84	3	—	460
0.8 (重度)	20	25	8	17	0	—	70
1.0 (陥没)	5	49	66	34	411	—	565
0 (非該当)	—	—	—	—	—	—	—
合計	624	322	530	214	461	118	2269

(b) 教師信号 (126 サンプル) の構成分布: a=2

原因	0.2	0.4	0.6	0.8	1.0	0	合計
危険度	腐食	破損	接続	人孔	その他	非該当	
0.2 (健全)	—	—	—	—	—	7	7
0.4 (軽度)	9	7	9	7	6	—	38
0.6 (中度)	8	8	7	7	2	—	32
0.8 (重度)	5	5	3	5	0	—	18
1.0 (陥没)	3	6	7	6	9	—	31
0 (非該当)	—	—	—	—	—	—	—
合計	25	26	26	25	17	7	126

※・Min(教師信号数) ≥ log₂(検証信号数)
 ・Σ教師信号数 (=126) / Σ検証信号数 (=2269) ≒ 1/18

(c) 教師信号 (57 サンプル) の構成分布: a=5

原因	0.2	0.4	0.6	0.8	1.0	0	合計
危険度	腐食	破損	接続	人孔	その他	非該当	
0.2 (健全)	—	—	—	—	—	3	3
0.4 (軽度)	4	3	4	3	3	—	17
0.6 (中度)	4	4	3	3	1	—	15
0.8 (重度)	2	2	2	2	0	—	8
1.0 (陥没)	1	3	3	3	4	—	14
0 (非該当)	—	—	—	—	—	—	—
合計	11	12	12	11	8	3	57

※・Min(教師信号数) ≥ log₂(検証信号数)
 ・Σ教師信号数 (=57) / Σ検証信号数 (=2269) ≒ 1/40

(d) 教師信号 (23 サンプル) の構成分布: a=227

原因	0.2	0.4	0.6	0.8	1.0	0	合計
危険度	腐食	破損	接続	人孔	その他	非該当	
0.2 (健全)	—	—	—	—	—	1	1
0.4 (軽度)	2	1	2	1	1	—	7
0.6 (中度)	1	1	1	1	1	—	5
0.8 (重度)	1	1	1	1	0	—	4
1.0 (陥没)	1	1	1	1	2	—	6
0 (非該当)	—	—	—	—	—	—	—
合計	5	4	5	4	4	1	23

※・Min(教師信号数) ≥ log_{2,27}(検証信号数)
 ・Σ教師信号数 (=23) / Σ検証信号数 (=2269) ≒ 1/99

させる教師信号に偏りがあるとサンプル数の多い側へ学習が偏向する危険性があると同時に、教師信号数が多すぎるとノイズが発生し、精度の良い予測情報が得られない危険性があることから、以下の条件式に基づいて、教師信号数の絞り込みを行うこととした。

$$\text{Min}(n) \geq \log_a N \quad (1)$$

ここで、 N ：各項における検証信号数

a ：2, 5, 227のうちいずれかの数値

n ：上式を満足する教師信号数最小値

底 a への代入値については、教師信号数による学習精度を検証するため、3つの段階に絞り込みを分類した。まず、2は情報量の最小単位であることから、227は検証信号数の1/10の値を、5は検証信号数の分布や合計教師信号数（教師信号数23の2-2.5倍で教師信号数126の1/2-1/2.5の範囲：教師信号数の中間値）などを考慮して設定した。

検証信号から教師信号を抽出するためのサンプル数の算出結果を表-2 (b)-(d) に示す。計算の結果、 $a=2$ の場合は合計教師信号数が126で情報圧縮率が1/18、 $a=5$ の場合は合計教師信号数が57で情報圧縮率が1/40、 $a=227$ の場合は合計教師信号数が23で情報圧縮率が1/99となった。

(3) クラスタ分析による教師信号の抽出

教師信号の抽出で容易な方法は無作為抽出であるが、抽出の偏りを防ぎ、より確実に広範な特徴を捕捉する方法としてクラスタ分析を適用した。クラスタ分析は、データ群のいずれが類似しているかを見付け出す数学的手法の総称である。多種の手法がある中で大きく階層的クラスタ分析と非階層的クラスタ分析の2つに分類される。

このうち非階層的クラスタ分析は、**図-3** に示すように、あらかじめ分割数を指示し、その数を目標にサンプルの中から特定の割合でランダムに選ばれたサンプルに階層的クラスタ分析を行い、与えられたクラスタ数になったところで、今度は先の分析に使用されなかったサンプルを様々な形ででき上がったクラスタに結合していく。また、分類されたサンプルにはクラスタ中心からのユークリッド距離が算出される。代表

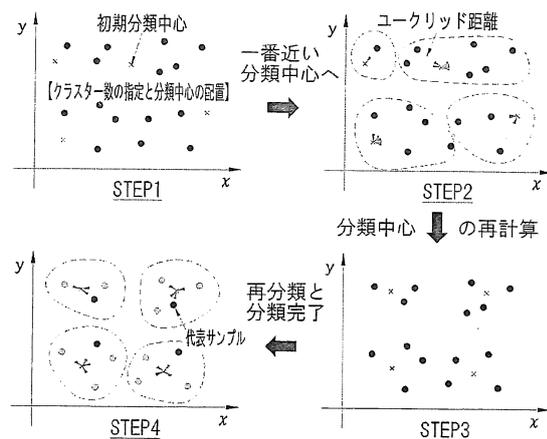


図-3 非階層的クラスタ分析の概念図

的なアルゴリズムに k-means 法がある。ただし、結び付きの階層構造が分からないことや、量的データしか扱えないなどの制約がある。

本研究でクラスタ分析を援用する目的は、大量の検証信号を表-2に基づいてパターン分類し、各グループの中から教師信号（代表サンプル）を抽出することである。このことから、非階層的クラスタ分析を援用して、検証信号の中からクラスタ中心に最も距離が近いサンプルを教師信号として抽出することとした。

4. ニューラルネットワークモデルの構築

(1) ニューラルネットワークの援用

廉価なコンピュータが高速化、大容量化した今日では、巨大データベースから有意な情報を導き出すデータマイニング技術が発達し、予測手法も数多く提案されている。代表的な手法としては、回帰分析やニューラルネットワーク、記憶ベース推論、近年注目を集めているベイジアンネットワークなどがある。その中で、本研究において着目したのはニューラルネットワークである^{1) 2)}。

ニューラルネットワークは、脳神経系の情報処理機構を模倣した数理モデルで、脳内の神経細胞をニューロンと呼ばれる素子でモデル化し、多数のニューロンを配置、結合してネットワークを構築することで、認識や記憶、判断、予測といった処理を、与えられた入出力データに基づく学習を通して実現する手法である。特に、階層型ニュー

ラルネットワークは非線形データの構造を表現でき、与えられた入出力データから、そこに内在する規則性を学習により獲得することを目的とした数理モデルで、パターン分類、規則性の抽出、時系列解析・予測、データ分析といった広範な分野に適用することが可能である³⁾。

本研究では、学習を通して予測を行うことができるこの階層型ニューラルネットワークを援用して、マクロ言語 (Excel VBA) により簡易データベース及びネットワークモデルを構築し⁴⁾、道路陥没の危険度及び原因の予測を行うこととした。

(2) 3層パーセプトロンの構築

対象データの規則性をニューラルネットワークにより獲得しようとする場合、まず、その関数近似能力が問題となる。本研究では、図-4に示すような隠れ層を1層とした3層構造モデルを採用することとした。3層階層型は、最も単純な構造であるにも関わらず、隠れ層のユニット数を増やすと、有界閉集合上の任意の連続関数を任意の精度で近似できることや、構造が単純で取り扱いが容易である。また、入力の次元数があまりにも高

いと学習効果が弱くなり認識率が低下する「次元の呪い」と呼ぶ現象を回避できることなどから³⁾、最もよく用いられている階層構造である。

以下では、図-4に示す3層パーセプトロンモデルの構成について説明する。階層数は全3層とし、左から入力層、隠れ層、出力層とする。まず、入力層に入力された信号が結合強度と閾値によって変換され、隠れ層を通り出力層の出力信号とする左から右への前向き処理を行う (= 予測)。次に、入力信号に対する結果として望ましい出力信号を教師信号として用意し、前向き処理で得られた出力信号と教師信号の差 (以下、誤差と称す) を入力層の方へ逆に伝播させ、誤差が小さくなるように結合強度と閾値を変えていく (= 学習)。その際、入力信号に対して望ましい出力が出るように結合強度と閾値を逐次調整する方法として、代表的な手法である誤差逆伝播法 (Back Propagation: 図-5参照) を適用する。

また、伝達関数の選定は、定評があるシグモイド関数を用いた¹⁾²⁾⁴⁾。この関数は、図-6に示すような線形特性を示し、次式で表される。

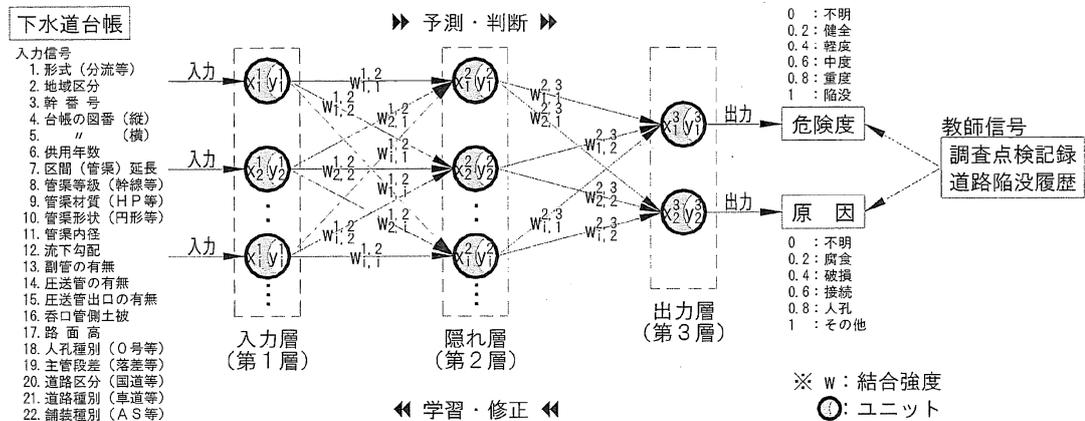


図-4 3層パーセプトロンのモデル図

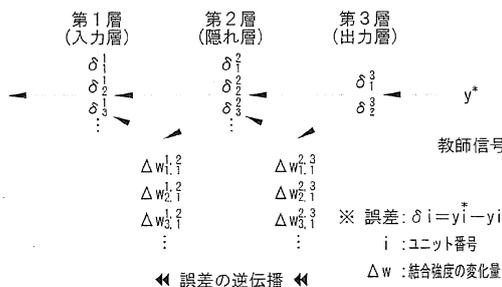


図-5 誤差逆伝播法の考え方

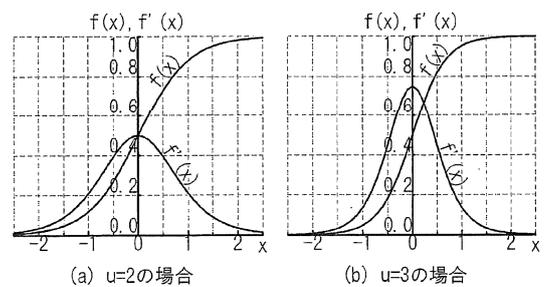


図-6 シグモイド関数のモデル

$$y = f(x) = \frac{1}{1 + e^{-ux}} \quad (2)$$

$$y' = f'(x) = \frac{df(x)}{dx} = u \cdot f(x) \{1 - f(x)\} \quad (3)$$

ここで、 u ：関数 f の勾配調整パラメータ

式(3)の微分方程式 y' は学習の際に使用し、 y 値から微分値を容易に求めることができる。

(3) 予測精度を判定基準としたモデルの選定

上記の理論に基づいて、ニューラルネットワークモデルを構築した。ただし、本モデルには選定しなければならない条件が多数存在する。そこで、予測精度の判定によって構築条件とモデルを絞り込み、選定を行った。予測精度の判定方法については、出力信号と検証信号(計2,269件)の合致における正誤判定の判別の中率を用いることとした。正誤判定基準については、出力信号と検証信号の誤差許容範囲を0.2未満とし、例えば、出力信号が0.75の場合は、0.6または0.8のどちらかのカテゴリに該当し、もし検証信号と合致していれば中であると判定することとした。

まず、学習係数と安定化係数は同値とし0.4、0.6、0.8の3通りの中から、結合強度の初期値用閾値は±0.01、±0.1、±0.3の3通りの中から、隠れ層のユニット数は入力層のユニット数に対する割合が1/3、1/2、2/3、1の4通りの中から選定し、教師信号数(23、57、126)と入力層のユニット数(16、41、91)を特定するためのモデルを各々構築し、これらの条件の相違による出力信号の予測精度の違いを比較分析した。このとき、プログラムの実行回数は原則1回とし、学習回数の違う(1,000、3,000、5,000 or 10,000回)類似モデルの誤差の推移を参考にしながら学習の妥当性を判断した。

抽出したモデルとその予測精度を表-3に示す。結局、危険度を予測するモデルと原因を予測

表-3 危険度と原因の複合モデルの予測精度

教師信号数	入力層ユニット数	学習回数	安定化係数 学習係数	結合強度初期値用の 最小値と最大値	隠れ層 ユニット数	的中率(検証信号)		
						危険度	原因	複合
57	16	10000	0.8	±0.01	16(1)	0.63	0.43	0.42
126	41	3000	0.6	±0.30	41(1)	0.30	0.62	

※()は、入力層のユニット数と隠れ層のユニット数の比を示す。

するモデルが異なる結果となり、危険度と原因の各々の予測精度は共に6割を超えた。最終的に抽出したモデルは、危険度では全ユニットを量的データで構成し(ユニットA)サンプル数が57の単純なモデルを用いて学習回数を10,000回としっかり学習させた場合が良く、原因では半カテゴリ化したユニットで構成し(ユニットB)サンプル数が126のやや複雑なモデルを用いて学習回数を3,000回と減らした場合が良い結果となり、ユーザーが得たい出力信号の内容によってモデルが大きく異なることが明らかとなった。

ここで、これら2つのモデルの出力ユニットを結果が良かった一方(1つ)に限定した場合、予測精度が低下してしまった。おそらく、本モデルの構造がシンプルになり、教師信号の特徴を鮮明に捉え過ぎて俯瞰性を失ったためではないかと考えられる。このことから、予測する際は、出力ユニット数を2つに設定しておく必要があることが判明した。また、この2つのモデルを用いて複合モデルを構築した場合、表-3右項に示すように1サンプル当たり、両ユニット(危険度と原因)が共に的中している割合は4割程度まで低下した。

(4) 選定モデルによる予測情報の正誤判定分析

絞り込みによって選定された危険度と原因の両モデルの出力信号は、検証信号に対して予測精度が6割程度であった。このモデルを採用した場合、膨大な下水道台帳データにおける道路陥没の予測精度は、おのずと6割の大体を下回るものと考えられる。

そこで、検証信号の正誤判定結果を用いて、本モデルに正誤判定に関する判別傾向を学習させることで、下水道台帳の予測情報が正しいかどうかをある程度推測することが可能ではないかと考え、予測の際に採用したモデルを準用して、表-1右項PHASE2に示すような出力ユニット数を1とする正誤判定モデルを新たに構築し、予測情報の正誤判定を行うこととした。

ここで、教師信号は、計2,269件の検証信号である。出力ユニットのカテゴリ値については、教師信号のうち正解の場合を1、誤りの場合を0、誤差許容範囲を0.5未満とし、出力信号が0.5以

上の値を1, 0.5未満の値を0とした。また、教師信号及び予測情報(出力信号)を用いて、事前に危険度, 原因それぞれについて表-4に示すよ

表-4 パターン分類での検証信号数の構成分布

カテゴリ	危険度					全体	原因					全体
	健全	軽度	中度	重度	陥没		腐食	破損	接続	人孔	その他	
正答率	0.56	0.77	0.70	0.48	0.56	0.63	0.65	0.60	0.54	0.60	0.72	0.62
約中率	0.70	0.83	0.80	0.83	0.81	-	0.74	0.62	0.76	0.63	0.74	-
カテゴリ値(予測値)												
1						(678)					(484)	
0.8						(377)					(348)	
0.6						(463)					(359)	
0.4						(794)					(507)	
0.2						(1107)					(535)	
0						(947)					(787)	
						(1231)					(911)	
						(947)					(754)	
						(1022)					(815)	
						(484)					(516)	
						(274)					(585)	
						(338)						

※1つの出力信号が2つのカテゴリに属する場合、両カテゴリに情報を存置する。
 □ : 予測によって分類されたサンプル数
 ○ : 正解と判定されたサンプル数(誤差許容範囲: 0.2未満)
 (例えば、軽度と予測されたサンプルが、実際には健全か軽度もしくは軽度か中度である場合を正解と判定)
 正答率: 正解と判定されたサンプル数(○)の全サンプル数(□)に対する割合
 □ : 予測が正解か誤りかを正しく判別できたサンプル数
 約中率: 正誤判定における正しく判別できたサンプル数(○)の全サンプル数(□)に対する割合

うな出力信号を主軸とするカテゴリ別にパターン分類し、各グループ毎に教師信号の正誤判定の傾向をモデルに学習させることとした。

正誤判定の分析結果を表-4に示す。出力信号に基づいて分類された各カテゴリのサンプルのうち、当該カテゴリに帰属する(正解している)サンプル数の割合(正答率)は、危険度では軽度と中度の危険度の場合に帰属する割合が高く、原因ではその他と腐食の場合に帰属する割合が高い結果となった。次に、教師信号のうちどのサンプルの予測情報が正解かについて正誤判定の判別分析を行った結果、危険度では健全の場合を除いて8割を超える精度で正誤判定の傾向を捉え、原因でも6割以上の精度で捕捉でき、共に正答率を上回っていることから予測情報を補完することが可能であると判断できる。

最終的には、この選定プログラムをもとに下水道台帳から得られた予測情報を用いて正誤判定を行い、その結果を下水道台帳の危険度及び原因に関する予測情報に併記し、ユーザーの意思決定における判断材料として活用してもらうこととした。

5. 陥没位置推定と予測情報の妥当性検証

(1) 現地調査の対象位置選定

LEVEL1において、このような予測情報が得られたことを踏まえ、本提案が予防保全計画策定を

支援する上で有効なモデルまたはツールであるか検証する必要がある。ここで、危険度, 原因的中率は共に約6割前後であった。

そこで、これらの予測情報をもとに、宇部市下水道部下水道管理センターの担当者に10地点の調査点検位置を選定(意思決定)してもらい、実際に、山口大学と宇部市の合同で、2007年3月12日(晴)に選定した10地点の現地調査及び点検による予測情報の妥当性検証を行うこととした。

ただし、調査点検位置の選定に当たっては、道路陥没の危険位置を推定することが本研究の目的であることから、昨今問題となっている腐食劣化に着目して、以下の4つの選定条件を筆者が任意に設定した。①道路陥没の危険度が1.0近辺で、②原因を腐食劣化(0.2近辺)に限定し、③供用開始以降一度も調査や点検などをしたことがない箇所、④これまでの経験から道路陥没を想定していない箇所とし、担当者にはこれらの条件に基づいて調査点検位置を選定してもらうこととした。

今回現地調査を実施した箇所の下水管路の諸元を表-5に示す。なお、これらの諸元は、カテゴリ分類された数値(量)で示しており、危険度や原因を予測する際に、実際に用いた入力ユニットの入力信号である。

ここで、1-10番目の箇所は、上記の条件に基づいてユーザーが選定した箇所、供用年数や呑口側人孔における管路の段差など条件が多様な箇所を対象とした。11番目の箇所は、誤って調査を行った箇所、調査後に予測情報がどうであったか検証を行った。また、12-14番目の箇所は、過去に調査点検記録がなく、今回下水管渠の腐食劣化について長期モニタリング調査を実施した箇所、これらについても予測情報の妥当性を検証することとした。

(2) 現地調査による予測の妥当性検証

ユーザーが選定した位置での予測情報と現地調査の検証結果を表-6に示す。現地調査の結果、選定対象の10地点は、全く問題がなく健全な状態であった。逆に、11-14番目の箇所は、写真-3(括弧内の番号は箇所番号)に示すように劣化等の異常が発生しており、予測情報と一部合致し

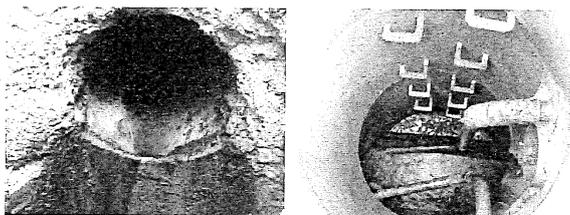
表一 5 現地調査の対象とした管路の諸元 (LEVEL1)

項目	形式	地域区分	幹線番号	縦番 (E17)	横番 (E17)	供用年数	区間延長	入力						副管付	圧送採用	圧送口	呑口被	備考
								管渠等級	管渠材質	管渠形状	管渠内径	流下勾配	管渠形状					
カテゴリ	合流 [0.3]	※地域を34に区分	※一地域で最大18の幹線 No.	※縦図番 (東西) の位置	※横図番 (南北) の位置			枝管 [0.5]	ヒ-4層 [0.05]	円形 [0.15]			※呑口人孔での状況	※無の場合は自然流下	※呑口人孔での状況			
	幹線 [1.0]							PC [0.20]	馬蹄 [0.30]	矩形 [0.45]								開渠 [0.75]
	汚水 [0.6]							※取付管は除外	FRP [0.50]	卵形 [0.60]								
	雨水 [0.9]								セメント [0.65]	その他 [0.90]								
単位						100年	km				10m							管路ID
1	0.6	0.09	0.02	0.11	0.21	0.033	0.060	0.5	0.05	0.15	0.025	0.004	0.5	0.5	0.5	0.49	14146000	
2	0.6	0.09	0.08	0.12	0.16	0.143	0.050	0.5	0.05	0.15	0.040	0.004	0.5	0.5	0.5	0.34	21053000	
3	0.6	0.09	0.06	0.12	0.22	0.183	0.052	0.5	0.05	0.15	0.050	0.003	0.5	0.5	0.5	0.41	28003000	
4	0.6	0.09	0.07	0.12	0.23	0.033	0.015	0.5	0.05	0.15	0.025	0.004	0.5	0.5	0.5	0.46	29016000	
5	0.6	0.09	0.08	0.13	0.14	0.083	0.017	0.5	0.05	0.15	0.025	0.004	0.5	0.5	0.5	0.51	35022000	
6	0.6	0.03	0.08	0.16	0.18	0.073	0.020	0.5	0.05	0.15	0.030	0.007	0.5	0.5	0.5	0.30	73097000	
7	0.6	0.10	0.07	0.24	0.14	0.103	0.036	0.5	0.05	0.15	0.025	0.003	0.5	0.5	0.5	0.45	193147000	
8	0.6	0.10	0.07	0.24	0.14	0.103	0.038	0.5	0.05	0.15	0.025	0.003	0.5	0.5	0.5	0.47	193153000	
9	0.6	0.17	0.03	0.25	0.11	0.173	0.013	0.5	0.05	0.15	0.035	0.009	0.5	0.5	0.5	0.45	202055000	
10	0.6	0.18	0.01	0.29	0.17	0.063	0.042	0.5	0.05	0.15	0.025	0.012	0.5	0.5	0.5	0.58	246003000	
11	0.6	0.16	0.01	0.23	0.19	0.213	0.037	0.5	0.05	0.15	0.100	0.003	0.5	0.5	0.5	0.30	181002000	
12	0.6	0.10	0.04	0.25	0.13	0.183	0.004	0.5	0.05	0.15	0.025	0.008	0.5	0.5	1.0	0.20	204081000	
13	0.6	0.10	0.04	0.25	0.13	0.253	0.020	0.5	0.05	0.15	0.060	0.003	1.0	0.5	0.5	0.22	204147000	
14	0.6	0.18	0.10	0.31	0.10	0.073	0.023	0.5	0.40	0.15	0.020	0.028	0.5	0.5	1.0	0.06	262014000	

表一 6 複合モデルによる予測情報及び正誤判定情報と現地調査結果の比較検証

項目	予測										現地調査		合否判定			備考			
	危険度					原因					危険度	原因	危険度	原因	複合				
カテゴリ	健全 [0.2]	正誤判定 (PHASE2)					腐食 [0.2]	正誤判定 (PHASE2)								健全 [0.2]	腐食 [0.2]	危険度	原因
	軽度 [0.4]						破損 [0.4]						健全 [0.2]	腐食 [0.2]					
	中度 [0.6]						接続 [0.6]						軽度 [0.4]	破損 [0.4]					
	重度 [0.8]						人孔 [0.8]						中度 [0.6]	接続 [0.6]					
	陥没 [1.0]						その他 [1.0]						重度 [0.8]	人孔 [0.8]					
													陥没 [1.0]	その他 [1.0]					
1	1.00	-	-	-	1	1	0.20	1	0	-	-	-	0.2	-	0	0	0	×	14146000
2	1.00	-	-	-	1	1	0.21	1	0	-	-	-	0.2	-	0	0	0	×	21053000
3	1.00	-	-	-	1	1	0.24	1	0	-	-	-	0.2	-	0	0	0	×	28003000
4	1.00	-	-	-	1	1	0.19	1	-	-	-	-	0.2	-	0	0	0	×	29016000
5	1.00	-	-	-	1	1	0.21	1	0	-	-	-	0.2	-	0	0	0	×	35022000
6	1.00	-	-	-	1	1	0.19	1	-	-	-	-	0.2	-	0	0	0	×	73097000
7	1.00	-	-	-	1	1	0.21	1	0	-	-	-	0.2	-	0	0	0	×	193147000
8	1.00	-	-	-	1	1	0.20	1	0	-	-	-	0.2	-	0	0	0	×	193153000
9	1.00	-	-	-	1	1	0.25	1	0	-	-	-	0.2	-	0	0	0	×	202055000
10	1.00	-	-	-	1	1	0.25	0	0	-	-	-	0.2	-	0	0	0	×	246003000
11	0.93	-	-	-	1	1	0.59	-	0	0	-	-	0.4	0.6, 0.8	0	1	0	△	181002000
12	1.00	-	-	-	1	1	0.87	-	-	-	1	1	0.7	0.2	1	0	0	○	204081000
13	1.00	-	-	-	1	1	0.49	-	0	0	-	-	0.7	0.2	1	0	0	○	204147000
14	1.00	-	-	-	1	1	1.00	-	-	-	1	1	0.6	0.2, 0.8	0	1	0	△	262014000

※正誤及び合否判定は、正解の場合「1」、誤りの場合「0」、非該当の場合「-」、有用性判定は、非常に有用の場合「◎」、有用の場合「○」、参考程度の場合「△」、不用の場合「×」。



(a) 腐食劣化：人孔⁽¹²⁾ (b) 施工不良：人孔⁽¹¹⁾
写真一 3 現地調査における危険度の状況

ていた。しかし、結局のところ、危険度と原因の予測精度が各々約6割であった。

LEVEL1では、主に管路の情報をもとに、16項目から成る入力情報から道路陥没の危険度及び原因の予測を行った。その検証結果は、部分的に的中していたが、ユーザーの経験的予測を超え、実用性に十分耐えられるモデルは構築できなかった。

た。モデルの構造自体は厳選していることから問題ないと考えられ、残るは入力情報の不足が主な原因ではないかと考えた。

6. 入力情報の追加によるモデルの改良

(1) 人孔情報と道路情報追加によるモデル改良

次に、予測精度の向上を図るための方策を検討し、「人孔」と「道路」に関する情報を新たに追加することとした。その詳細を表-7に示す。

表-7 入力ユニットの追加項目諸元及び数

(a) 追加項目の諸元及びカテゴリ一覧

入出力 情報種別 No	入力ユニット								
	人孔情報			道路情報					
項目	17 標高	18 人孔種別			19 主管 段差	20 道路 区分	21 道路 種別	22 舗装 種別	
カテゴリ	※ 地盤 面の 呑口 側 人 孔 の 高 度	0号 [0.10]	1号 [0.20]	特1 [0.25]	※ 本 管 路 の 呑 口 側 主 管 人 孔 の 段 差	国道 [0.25]	県道 [0.3]	市道 [0.6]	その他 [0.9]
		2号 [0.30]	特2 [0.35]	3号 [0.40]		歩道 [0.50]	その他 [0.75]	その他 [1.00]	
		特3 [0.45]	4号 [0.50]	特4 [0.55]					
		5号 [0.60]	6号 [0.70]	7号 [0.80]					
		特殊 [0.90]	その他 [1.00]						

注記：設定条件については、表-1(a)に準ずる。

(b) 追加ユニット数一覧

No	17	18	19	20	21	22	合	
項目	標高	人孔種別	主管 段差	道路 区分	道路 種別	舗装 種別	計	
ユニット	状態	量的 (100m)	質的 (選否)	量的 (10m)	質的 (選否)	質的 (選否)		
ユニットA	状態	1	14	1	4	3	5	119
ユニットB	状態	同上	同上	同上	同上	同上	同上	69
ユニットC	状態	同上	量的 (-)	同上	量的 (-)	量的 (-)	量的 (-)	22
	状態	1		1	1	1		

注記：設定条件については、表-1(b)に準ずる。

入力ユニットで新たに追加した項目は、④人孔諸元(量的(2), 質的(1))が3項目、⑤道路諸元(質的)が3項目の計6項目である。人孔情報を対象とした理由として、管路の構造の一部を担い、危険度や原因に直接影響を与える因子であると判断したからである。また、道路情報を対象とした理由として、管路に間接的な影響(ダメージ)を与える自動車の輪荷重や路面の状況が、危険度や原因を判断するうえで重要な因子である可能性があり、上記の3項目でその影響を表現することが可能であると判断したからである。ここで、人孔情報には、さらに人孔深さを考慮すべきであるが、人孔深さは呑口管側の土被と管渠内径を組み合わせることで表現が可能である(相関が高い)こと

から、入力情報から除外した。

なお、上記の追加情報のうち、地盤面の標高と人孔種別は、別途情報管理されていた人孔台帳から抽出した。そして、主管段差の算定については、2007年度上期に担当者に作業協力頂き、新たに下水道台帳の項目として追加して頂いた。また、道路区分は、下水道台帳で管理されていなかったことから、今回は検証信号(2,269箇所)の管路を対象に、筆者が道路網図に基づいて調査した。道路及び舗装種別は、宇部市が人孔台帳と併せて把握できる範囲の情報管理を行っていたことから、欠損値については、道路区分と同様に筆者が調査し情報を補填することで入力情報を整理した。

続いて、ニューラルネットワークの学習精度を検証するため、追加ユニット(6項目)のコード化に当たり、入力ユニットのうち人孔種別、道路区分、道路種別、舗装種別の4項目はカテゴリ値が変更可能な質的データであることから、これらのユニットを変化させ、LEVEL2では、LEVEL1の入力ユニットと組み合わせて、表-7(b)に示すように合計22, 69, 119の3タイプに区分した。次に、予測モデルの選定に当たっては、LEVEL1と同様にSTEP1-9のプロセスに準拠し、最も精度の良かったモデルを抽出することとした。

(2) 改良モデルの精度分析

a) 危険度及び原因の予測精度の分析

LEVEL2において、危険度と原因の各々について予測精度が良かったモデルを表-8に示す。

表-8 改良モデルの危険度と原因の予測精度

教師 層 ユニット数	入力層 ユニット数	学習回数	安定化係数 学習係数	結合強度初期値 の最小値と最大値	隠れ層 ユニット数	的中率(検証信号)	危険度	原因	複合
23	69	10000	0.8	±0.30	69(1)	0.86	0.58	0.51	

※()は、入力層のユニット数と隠れ層のユニット数の比を示す。上記モデルは、各々単体モデルでの分析結果を示す。

LEVEL2のモデルは、LEVEL1で構築した複合モデルではなく、単体モデルでの予測が可能となった(LEVEL1のような危険度または原因の一方の精度が突出したモデルは得られなかった)。ただし、原因の予測精度は、6割を上回ることはできなかった。一方、危険度の予測精度は、8割を超えて大幅に向上し、それに伴って、危険度と原因の両ユニットが共的中している割合

も約5割となった(類似の高精度を示す他のモデルが多数存在したが、複合的中率の良否で最終的に判断した)。

また、LEVEL2のモデルでは、69のやや複雑なユニットとわずか23のサンプル数で予測精度が良い結果となった。これは、情報量が増えたことでモデルが複雑化し分類するパターン数が多くなった反面、却ってノイズが発生し易い環境が形成され、過学習を引き起こし易くなったものと考えられる。よって、情報量が多くなればなるほど、逆に、教師信号の数を少なくし、予測モデル(ユニット)を単純化する方が逆に有利であることも明らかとなった。また、入力情報によっては量的データとすべきか、質的データ(カテゴリ)とすべきかも検討する必要がある。しかし、入力情報をカテゴリ化すると入力ユニット数が増し、計算負荷が増大することから、この点については予測分析の際の作業効率も考慮して判断する必要がある。

b) 予測情報による正誤判定の判別精度の分析

続いて、検証信号(2,269件)の予測情報による正誤判定の分析を行った。しかし、LEVEL1では学習できていた正誤判定が、LEVEL2ではうまく学習できない結果となった。その理由として、ユニットの増加によりモデルが複雑になると組み合わせパターンは増加し、それに応じて教師信号数を増やすことが可能となるが、あまりに教師信号数が多すぎると、学習回数が増すにつれノイズが発生し易くなる。逆に、モデルが単純であればこの問題は回避できる。よって、この要因でうまく学習できなかったものと考えられる。

以上から、予測精度の向上と共に、LEVEL1では必要と考えていた正誤判定のプロセスは、LEVEL2ではその必要性が逡減した。ここで、PHASE2はPHASE1と同程度の作業負荷を要するため、PHASE1での予測精度に応じて、適宜、正誤判定の必要性を判断してモデルを構築する必要があると考える。

(3) 現場検証結果と予測情報の比較検証

LEVEL2で構築した予測モデルの有効性を検証するため、5.で行った検証(表-6参照)を再度実行することとした。追加した入力情報の詳細及

び改良モデルで再度予測し直した結果を表-9に

表-9 現地調査の対象管路の追加項目諸元

項目	入力						予測		合否判定
	人孔情報			道路情報			危険度	原因	
	標高	人孔種別	主管段差	道路区分	道路種別	舗装種別	健全度 [0.2] 軽度 [0.4] 中度 [0.6] 重度 [0.8] 陥没 [1.0]	腐食 [0.2] 破損 [0.4] 接続 [0.6] 人孔 [0.8] その他 [1.0]	
1	0.0991	0.30	0.2657	0.25	0.6	0.2	0.34	0.07	1 1
2	0.2290	0.20	0.2100	0.75	0.6	0.2	0.30	0.10	1 1
3	0.1124	0.30	-0.0047	1.00	0.3	0.2	0.43	0.40	0 0
4	0.0495	0.30	0.3803	1.00	0.6	0.2	0.31	0.03	1 1
5	0.7182	0.30	0.0020	0.75	0.3	0.2	0.36	0.62	1 0
6	0.3838	0.20	0.2309	1.00	0.9	0.6	0.42	0.41	0 0
7	0.2361	0.30	0.0020	0.75	0.3	0.2	0.39	0.42	1 0
8	0.2574	0.30	0.0009	0.75	0.3	0.2	0.39	0.42	1 0
9	0.0496	0.30	0.0025	1.00	0.3	0.2	0.35	0.51	1 0
10	0.0374	0.30	0.3959	0.75	0.3	0.2	0.36	0.41	1 0
11	0.0459	0.40	0.0010	0.75	0.6	0.6	0.35	0.30	1 0
12	0.2546	0.20	-0.0099	0.75	0.3	0.2	0.37	0.87	0 0
13	0.2260	0.20	0.0396	0.75	0.3	0.2	0.36	0.73	0 0
14	0.3237	0.20	0.0021	0.75	0.3	0.2	0.15	1.00	0 0

※上記の入力値は、ユニットCで用いた入力信号を示す。
正誤及び合否判定は、正解「1」、誤り「0」、非該当「-」。

示す。LEVEL2では、LEVEL1に比べて危険度の予測精度が向上し、危険度の予測値が全体的に低下したが、逆に、危険箇所を軽度の劣化であると予測するなど全体的に予測値を下げる(健全側と予測する)傾向にあることや、正誤判定ができなかったことから予測値のみで判断する必要がある。

以上から、下水管網に起因する道路陥没の予測には、下水管路に関する情報だけでなく、人孔や道路の情報を追加することで、予測精度がさらに向上することがこの検証結果から明らかとなった。また、LEVEL1のモデルとLEVEL2のモデルとでは、LEVEL2の方が圧倒的に計算時間が短く(10倍近い時間差)、得たい情報と要する時間を勘案しながら、適切なモデルをユーザー(または解析者)が選択していく必要があることも判明した。

ただし、入力情報を追加する場合、関係がありそうな情報を無条件に入力しただけでは、単にモデルが複雑化するだけで、ノイズが発生し易いことも明らかとなったことから、入力情報について検討する際には、STEP2の段階で入力情報の洗浄をしっかりと行う必要がある。

また、本研究では、終始、出力ユニットを質的データ(カテゴリ)ではなく量的データで判断してきた。その理由として、①出力信号をカテゴリとして扱うと出力ユニットが増え、モデルがさらに複雑になり計算時間を要すること、②カテゴリ別にするると解が全く得られないサンプルや、逆に、

複数の解を得てしまい、どの解が正しいか判断に迷う可能性があることから、今回は採用を棄却した。しかし、予測精度の向上の観点から考えれば、この点についても検討の余地があると考ええる。

なお、6.で行った検証は、LEVEL1で行った検証結果を対象として実施した。本来は5.と同様に、改良モデルを用いて新たに危険箇所を抽出し、再度現地調査を行って改良モデルの有効性を検証する必要がある。しかし、現在、宇部市では未だ下水道台帳を順次改良中であり、今回構築した改良モデルを適用するためには、さらに情報収集に時間を要することから、現時点では、宇部市全域を対象とした改良モデルによる道路陥没予測や、新たな現場検証を行うことができない。

しかしながら、これまでの検証結果を踏まえて、調査点検記録には反映されていないが、実際に管理者が危険であると把握している箇所と健全であると把握している箇所について、ユーザーに経験や勘に基づいて予測情報の妥当性を別途確認してもらったところ、予測精度にやや不安はあるものの有用性がある予測情報であることが確認できた。今後、上記の課題については、健全箇所も含めた調査点検を積極的に実施していくことで、その記録を逐次更新・補充し、また、下水道台帳の項目やフォーマットを随時改良していくことで、本手法の適用によって、さらに予測精度の向上が可能であると考ええる。

その他、ユーザーからの見解として、今回の初の試みによって得られたこの予測情報を、今後どのように有効活用すればよいのか、新たな課題が発生した。この課題については、筆者も今後の展開を期待している。

7. 結 論

本研究で得られた知見を以下にまとめる。

- 1) 教師信号の元データ（検証信号）数が非常に多く、また、必要とする教師信号数が多岐にわたる場合、本手法（関数）を用いて一義的に教師信号数を定義できれば、教師信号数の絞り込みや選定作業が効率良く行えるものと考ええる。
- 2) 非階層的クラスター分析の援用によるサン

ルの絞り込みは、予測精度やモデルの構造を見た限りでは、効率良く教師信号の抽出が行え、ノイズ発生軽減や計算時間の短縮などの効果があったことから、妥当であったと考える。

- 3) ニューラルネットワークの援用により、下水管網に起因する道路陥没の位置推定と危険度及び原因の予測の新たな可能性を見出した。これにより、これまで困難と考えられてきた道路陥没の予防保全活動の一助となればと期待する。
- 4) 下水道台帳や数多く保管されている調査点検記録、道路陥没履歴の有効活用を図ることで、道路陥没の予測が可能であることが判明した。このことから、下水道の管理情報を常日頃から大切に管理することの必要性を改めて認識することができた。また、今後も積極的にこれらの管理情報の蓄積を心がけていくことが望ましい。
- 5) さらに予測精度の向上を図るには、モデルの改良の他、例えば、管路の屈曲状況、管路の合流（接続）数、地下水位などの項目を充足させ下水道台帳の改良を図る必要がある。また、現在、宇部市内で供用中の下水管網の大半は耐用年数に達しておらず、健全であると考えられる。このことから、現時点では調査点検記録が少ない健全管路に関する情報をより多く収集していく工夫と、この情報をモデルへ学習させることが、予測精度の向上に繋がるものと考ええる。

〈参 考 文 献〉

- 1) 山口和範、高橋淳一、竹内光悦：凶解入門 よくわかる多変量解析の基本と仕組みー巨大データベースの分析手法入門ー、秀和システム、2004.
- 2) 脇田英治：逆解析の理論と応用ー建設実務のグレードアップとコストダウンのためにー、技報堂出版、2000.
- 3) 萩原克幸：2. ニューラルネットワークの基礎と理論的に重要な課題、プラズマ・核融合学会誌、Vol.82, No.5, pp.282-286, 2006.
- 4) 福山隆晃：エクセルで遊ぶニューラルネットワーク、三恵社、2006.

(20.2.28 受付)



* (まつかわ つとむ)
日本上下水道設計株式会社
西部支社 広島事務所



*** (なかむら ひであき)
山口大学大学院 理工学研究科
環境共生系専攻 教授



** (みやもと あやほ)
山口大学大学院 理工学研究科
環境共生系専攻 研究特任教授

Abstract

Development of a Preventive Maintenance Planning System for Sewage Pipe Networks Considering the Prevention of Road Caving Damage

Tsutomu MATSUKAWA, Ayaho MIYAMOTO, Hideaki NAKAMURA

In this paper, a preventive maintenance planning system for sewage pipe networks is described based on a prediction model for road caving damage that is one of the most important problems in preventive maintenance decision making in the sewage pipe networks under the roads. The proposed system with a database sub-system that was developed for a sewage pipe networks in Ube City area as a specific example has been applied for a comparison of the estimated results of applying the system with the results from both of the accidental road caving damage records and domain expert in Ube City office. As a result, it can be predicted accurately with some alternative plans using the system.