

## リアルタイム情報を利用した水道管被害箇所 の 逐次推定

Sequential Estimation of Damaged Portions of Water Pipe  
by Utilizing Real-time Information齋竹 良介<sup>1</sup>, 荒井 幸代<sup>1</sup>Ryosuke SAITAKE<sup>1</sup> and Sachiyo ARAI<sup>1</sup><sup>1</sup>千葉大学 工学研究科

Graduate School of Engineering, Chiba University

It is important to estimate and recover the damaged portions of water pipe just after an earthquake. In a conventional way, the damaged portions are predicted based on the earthquake-proofness of pipes and the regional strength of soil foundation. Recently, it becomes easy to collect real time information on site, so we would take advantage of utilizing the updated information to estimate the damaged portions. However, such information will be given on a piecemeal basis, then it is required to integrate these fragment information. In this study, we applied the network density of the water pipes to consider the connectivity of pipes and support vector machine. The effectiveness of our proposed method are evaluated by some empirical analysis.

**Keywords:** *real-time information, online estimation, water pipe damage, community extraction, support vector machine*

## 1. はじめに

2011年3月、東北地方太平洋沖地震が発生し、ライフラインへの被害は人々の生活に多大な影響をもたらした。電気、水、ガスの90%の復旧にはそれぞれ5日、24日、34日を要している<sup>1)</sup>。水、ガスについてはインフラが地中に埋め込まれていること、またガスについてはその危険性から水道管の修理の後に実施されることが、多くの日数が費やされる原因と考えられる。そこで、本研究では、水道管の被害推定の精度を上げることによって水道、ガスの早期復旧を実現することを目的とする。

従来、水道管の被害箇所推定に用いられる被害率は、「水道管の形状や材質」と「水道管が埋め込まれた場所の地盤の性質」の項の線形結合式によって推定されるのが一般的で、各係数は過去の地震における被害データに基づいて更新されてきた。この予測式によって得られるスカラー値は、簡便で了解性が高いものの、推定精度は、被害の有無を決めるしきい値の影響を受けやすい。また、水道管の接続関係や地震後に時々刻々と明らかになる被害箇所の情報を利用する枠組みにはなっていない。

一方、「水道管の形状や材質」と「水道管が埋め込まれた場所の地盤の性質」を用いた故障の有無のパターン分類法として近年、線形分離が困難な問題に対して有効なサポートベクタマシン<sup>2)</sup> (以下SVM) の導入が期待できる。また、安価に利用できるようになったセンサネットワークやSNSを活用した一般の人々からの情報が入手可能になってきた。そこで、筆者らは、「水道管の形状

や材質」と「水道管が埋め込まれた場所の地盤の性質」に加えて、これらの局所的な情報をSVMによる被害の有無の分類法に組み込むことを考えた。

提案法の特徴として以下の二つが挙げられる。一つは、災害後、時々刻々と明らかになる故障箇所に関する情報を用いる点である。ネットワーク構造の一部の故障が明らかになった時点で、その周辺にも故障があると考えるのは妥当であるが、水道管の接続関係の粗密に損傷の度合いが影響することから、水道管の接続関係を利用することによって、周辺の中でも故障が生じやすいメッシュを推定することができる。水道管の接続関係の利用については、ネットワーク科学の知見であるコミュニティ抽出法を応用する。

また、もう一つはそれぞれのメッシュを水道管の形状や材質、地盤の特徴を属性としたベクトル量で表し、その被害の有無を代表的なパターン分類法であるSVMを用いて識別する点である。

提案法の有用性は東北地方太平洋沖地震時の仙台市といわき市のデータを用いた計算機実験によって示している。

以下、2. で対象問題を、3. で被害推定法を説明し、4. でリアルタイム情報の活用を提案する。5. で実験結果を示し、6. で結論を述べる。

## 2. 対象問題

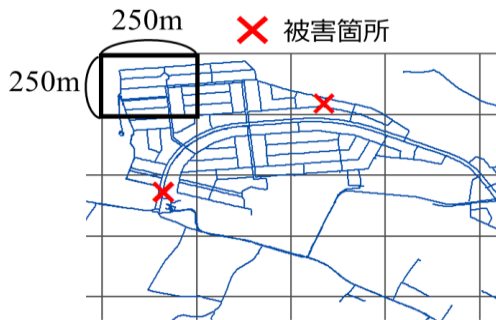


図1 仙台市における GIS データ

表1 水道管被害有無の内訳

	被害有[件]	被害無[件]	合計[件]
仙台	307	4670	4977
いわき	313	4051	4364
合計	620	8721	9341

ここでは、本研究の問題設定、および従来の水道管被害予測に関する研究を説明する。

### (1) 問題設定

本節では実験で用いるデータ、および水道管被害の逐次推定における用語を定義し、提案法に至るまでの考え方を説明する。

東北地方太平洋沖地震での仙台市といわき市の GIS データを用いる。図1は仙台市の GIS データの例で、線は水道管を、×印は被害箇所を表す。データは水道管路、被害位置、各種属性から成り、約250m四方である4分の1地域メッシュで区切られている。

本研究はメッシュ内に被害箇所が一つ以上ある場合を被害有、それ以外を被害無とし、メッシュに対する被害の有無を推定する。ここでの「被害」とは水道管の破損や管の抜けを指す。

また、本論文での用語「リアルタイムのデータ」とは、地震発生後、巡回や目視、住民からの通報などによって水道管被害に関する情報が得られる。本研究は、これらのリアルタイムな水道管被害情報を「実被害情報」と呼び、被害推定に加えることによって精度の高い被害箇所の特定を実現する。

### (2) 水道管復旧の一般的な方法

現状では、過去の地震によるデータに基づいて計算された被害率に基づいて推定した被害箇所の水の供給を停止させた後、上流側から下流側へと水を流し、漏水確認とその修繕を行っている。被害を把握しながら復旧計画を立てているのが一般的である。しかし、仙台市といわき市の GIS データにおける水道管被害有無の内訳（表1）を見ると、被害有りの件数に対して被害無しの方が多。そこで、実被害箇所の情報を加えることによって推定だけに依存せずに漏水確認作業の負担を軽減できると考えた。ここで、被害箇所から下流側に水を流す方法は、ネットワーク科学の理論における最大フロー最小カット<sup>3)</sup>の考え方に似通っており、後述する提案法で用いている「任意のノードからのコミュニティ抽出」は、漏水確認すべき箇所に関する理論的な根拠を与える。

### (3) 関連研究

### a) 被害推定法

一般に水道管被害予測<sup>4)</sup>で用いられる被害率 $R_m(v)$ [件/km]の予測式を式[1]に示す。

$$R_m(v) = C_p \cdot C_d \cdot C_g \cdot R(v) \quad [1]$$

ここで、 $C_p$ は管種・継手補正係数、 $C_d$ は口径補正係数、 $C_g$ は微地形補正係数、 $v$ [cm/s]は地震動の地表面最大速度 $15 < v < 120$ である。 $R(v)$ [件/km]は、標準被害率と呼ばれ、式[2]で表される。

$$R(v) = 9.92 \times 10^{-3} \times (v - 15)^{1.14} \quad [2]$$

標準被害率は、標準的な管路が一般的な条件で埋設されている場合の被害率を表す。式[2]はダクタイル鋳鉄管、口径100-150mm、沖積地盤に埋設された場合を想定している。この手法は、標準的な管路の被害率である標準被害率に各種補正係数をかけて、その「管種・継手」「口径」「地形」の条件を満たした管路の被害率[件/km]を算出する。また、被害率にメッシュ内の管路延長を乗ずることによってメッシュごとの被害数を求める。なお、液状化のある場合の被害予測式も存在するが、本研究では、対象とした地域に液状化が認められなかったことから、実験では上記の式に基いて提案法と比較する。

式[1]と式[2]は新潟県中越地震、能登半島地震、新潟県中越沖地震および東北地方太平洋沖地震の水道管被害のデータに基づいている。補正係数はクロス集計と、回帰分析を用いて決定し、標準被害率は式[3]に示すモデルを用いて重回帰分析によって算出される。

$$R(v) = c \cdot (v - A)^b \quad [3]$$

ここで、 $c, b$ はフィッティングのための変数である。また、 $A$ は被害が発生し始める地震動の地表面最大速度を示す。

以上の被害率は、新たな地震で得られるデータによって随時更新され、被害予測の精度を高めてきた。また、丸山ら<sup>5)</sup>は、近年の地震データも考慮に入れた上で、標準正規分布の確率密度関数を用いた新たな予測モデルによる標準被害率を提案し、予測精度の向上を図っている。

### b) 実被害情報の活用

式[1]から[3]は、過去のデータから被害率を計算する方法であるため、実被害情報に基づいて予測を更新する枠組みになっていない。

災害時に得られるリアルタイム情報を用いて推定精度を向上させようという研究も行われている。能島<sup>6)</sup>はリアルタイム情報をベイズ確率の枠組みで利用して建物被害の推定を行い、緊急対応の意思決定支援を行うシミュレータを開発している。また、森井<sup>7)</sup>は地震発生直後に地震動データを取得して、式[1]の予測式を災害時に更新するシステムを構築している。以上の最近の研究から、現場レベルでも災害時のリアルタイムな被害推定の利用法が求められていることがわかる。

本研究でも、実被害情報を利用した地震直後の水道管被害を推定する方法を考える。

## 3. 被害推定法

ここではSVMを説明し、水道管被害推定に適用する。

また、本研究で用いるデータは表 1 にみられるように、極端な不均衡データであるため、その対処法についても説明する。なお、以後はこの推定手法を、地震発生前の推定という意味で、事前推定と呼ぶ。

### (1) サポートベクターマシン (SVM)

SVM は過去のデータ (教師データ) を用いて学習し、未知のデータ (テストデータ) がどのように分類されるか出力する 2 値判別手法である。入力はベクトル  $x$ 、出力は 2 値ラベル  $t \in \{+1, -1\}$  とする。水道管の被害推定の場合、入力は「水道管の形状や材質」と「水道管が埋め込まれた場所の地盤の性質」、出力の 2 値ラベルは被害の有無となる。

教師データ  $\{(x_1, t_1), \dots, (x_n, t_n)\}$  が与えられており、関数  $y(x) = w^T \phi(x) + b$  の値の正負でデータを分類することを考える。このとき、 $t_n = +1$  である点については  $y(x_n) > 0$ 、 $t_n = -1$  である点については  $y(x_n) < 0$  が成立すると仮定する。ここで、 $\phi(x)$  は高次元へ写像する特徴空間変換関数である。写像  $\phi$  を考える理由は、もとの空間ではうまく 2 つのグループに分けられない場合でも、高次元空間なら分けられることがあるためである。しかし、高次元空間ではデータを完全に分ける超平面が複数存在する可能性がある。SVM はマージンという概念を用いて、汎化誤差が最も小さい超平面を求める。

マージンは、ある超平面  $w^T \phi(x) + b = 0$  が与えられたとき、教師データから超平面までの最短距離で定義される式[4]で表される。

$$\min_{i=1, \dots, n} \frac{|w^T \phi(x_i) + b|}{\|w\|} \quad [4]$$

求める解はマージンを最大化するパラメータ  $w$  と  $b$  である。したがって解は式[5]に示す最適化問題を解くことで得られる。

$$\arg \max_{w, b} \left\{ \frac{1}{\|w\|} \min_n [t_n (w^T \phi(x) + b)] \right\} \quad [5]$$

また、上の式をより簡単な形に変形していくと、 $\phi(x)^T \phi(x')$  で定義されるカーネル関数  $k(x, x')$  が現れる。カーネル関数を用いることで写像  $\phi(x)$  を指定せず、すべての計算を実行できる。本研究では予備実験の結果、式[6]に表すガウシアンカーネルを用いる。

$$k(x, x') = \exp(-\sigma \|x - x'\|^2) \quad [6]$$

このときパラメータは  $\sigma$  となる。

データを高次元空間に写しても、データが線形分離可能になるとは限らない。そこで、分離できない場合にはペナルティを与えて、ほぼ分かれる要因判別器を決めることを考える。ペナルティを式[7]に表す。

$$\max\{1 - t_i (w^T x_i + b), 0\} \quad [7]$$

ここで  $C > 0$  ペナルティの強さを決めるパラメータである。このペナルティを組み入れた最適化問題式[8]を解くことで解を求めることができる。

表 2 水道管被害推定における SVM の入力

属性	属性値
管種	10 種類
口径	25 種類
地形	24 種類
地震最大速度	16-89[cm/s]を 1[cm/s]ごとに離散化した 74 種類
被害	被害有/無の 2 種類

$$\arg \min_{w, b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \max\{1 - t_i (w^T x_i + b), 0\} \quad [8]$$

### (2) SVM を用いた水道管被害推定

#### a) 水道管の属性

事前推定で用いる SVM の入力を表 2 に示す。これら属性値が教師データを用いた SVM の入力ベクトル  $x = \{\text{管種, 口径, 地形, 地震最大速度, 被害}\}$  となる。テストデータの入力はラベルである被害を除いたベクトルとなる。

この属性は 2.(3) で説明した被害予測式と同じものを用いている。また、これら属性のデータは容易に用意できるものとされている<sup>4)</sup>。次にデータの処理方法について説明する。属性が管ごとに決められている「管種」「口径」は、メッシュ単位で扱えるようにするために、メッシュ内で管の延長が最も長い管種を「管種」とし、メッシュ内における口径の平均を「口径」とした。ここで、本研究では「管種」を用いているのに対して、既存手法では「管種・継手」を用いている。「管種」は単にダクタイル鋳鉄管やポリ塩化ビニル管といった水道管の種類であるのに対して、「管種・継手」は管種だけではなく継手も考慮したデータとなっており、より詳細なデータである。

また、既存手法に対し、SVM を使った事前推定は属性を追加する操作が簡単に行えるため、使用者による柔軟な被害推定が可能である。

#### b) 不均衡データの扱い


水道管の被害データは正例負例に偏りのある不均衡データである。一般的な分類器は分類精度が最も高くなるように分類を行う。しかし、仮にラベル A が 99%、ラベル B が 1% の割合で存在するデータの場合、全てをラベル A と分類すれば精度は 99% となり、割合の小さいほうのラベルが無視される結果となる。そこで本研究はランダムアンダーサンプリングを用いて負例のサンプル数を減らし、正例と負例のサンプル数の割合を調整する。具体的な数値は 5. で説明する。

以上のデータを SVM の入力とし、メッシュに対して被害の有無を出力する。既存手法のようにメッシュ毎の被害件数をカウントすることはできないが、より高い精度が期待できる。


## 4. 実被害情報の活用

### (1) 任意のノードのコミュニティ抽出

提案法で用いるコミュニティ抽出法 (Cd-based-Method : 以下 CDB 法<sup>9)</sup>) について説明する。コミュニティ抽出は、絶対評価型と相対評価型とに大別される<sup>8)</sup>。



(a) コミュニティ濃度 Cd の推移例



(b) 一つ目の極大値で抽出したコミュニティ (c) 二つ目の極大値で抽出したコミュニティ (d) 三つ目の極大値で抽出したコミュニティ

図 2 CDB 法を用いたコミュニティ抽出

**Algorithm 1** Cd-based-Method

```

Require:  $V, E, N$ 
シードノードの選択
 $Com[1] \leftarrow$  シードノード
 $Cd[1] \leftarrow 0$ 
for  $i = 2$  to  $N$  do
   $Com[i] \leftarrow$  コミュニティ内のノードと隣接しており、コミュニティに含まれたときコミュニティ濃度の値が最も大きくなるノード
   $Cd[i] \leftarrow$  コミュニティ濃度の最大値
end for

```

図 3 CDB 法のアルゴリズム

前者は、ネットワーク上の全てのノードとリンクの接続関係が既知の状況でネットワークのノード間結合の強弱にしたがって分割する方法である。一方、後者は対象とする任意のノードとその周辺の接続関係さえわかっているならば、そのノードが周辺に及ぼす影響を数値化することによって関係の強いノードを切り取る方法である。CDB法は後者に属し、任意ノードを中心とするコミュニティが抽出されるため、リアルタイム情報に基づいた逐次推定に向いている。例えば、「あるノードが故障している」とわかった場合に、そのノードと関係の強いノード集合を「故障している可能性が高い」ものとして抽出するのである。

**a) コミュニティの定式化**

高橋ら<sup>9)</sup>はコミュニティを「部分グラフ内の連結の度合いが部分グラフとその外部との連結の度合いよりも密である部分グラフ」と捉え、以下のように定式化する。ネットワーク  $G = (V, E)$  におけるノード集合  $V$  の部分集合  $V_s \subseteq V$  を考える。ノード集合  $V$  の部分集合  $V_s$  によって構成される部分グラフ  $G_s = (V_s, E_s)$  が、以下の 2 つの条件を満たすとき  $G_s$  をコミュニティと呼ぶ。

- 条件 1. 部分グラフ  $G_s$  は連結である。
- 条件 2.  $k_{G_s} > k'_{G_s}$

$k_{G_s}$  : 部分グラフ  $G_s$  内のノードの平均次数 (コミュニティ内リンク密度)  
 $k'_{G_s}$  : グラフ  $G' = (V_s, E \setminus E_s)$  におけるノード  $v_s \in V_s$  の平均次数 (コミュニティの境界リンク密度)

条件 1. はコミュニティが連結であることを示している。非連結の部分グラフは明らかに密に連結していないため、コミュニティではない。

条件 2. は部分グラフ内のリンクの連結の度合いと、部



ノードAのコミュニティ ノードBのコミュニティ




図 4 水道管ネットワークのコミュニティ抽出例

分グラフと外部とのリンクの連結の度合いを比較している。左辺の  $k_{G_s}$  は部分グラフ内の連結の度合いを示し、右辺の  $k'_{G_s}$  は部分グラフと部分グラフの外側とのリンクの連結の度合いを示している。  $k_{G_s}$  の値が  $k'_{G_s}$  の値よりも大きい場合に、対象の部分グラフはコミュニティとなる。

**b) コミュニティ濃度**

上記のコミュニティ条件に基づいた評価尺度を示す。この評価尺度はつながりの強弱を示すことから、以下ではコミュニティ濃度  $Cd$  と呼び、式[9]で表す。

$$Cd = \frac{k_{G_s}}{k'_{G_s}} = \frac{|E_s| \times 2}{(\text{境界リンク数})} \quad [9]$$

$Cd \geq 1$  を満たす部分グラフ  $G_s$  は周囲より密であることを示し、このときその部分グラフ  $G_s$  をコミュニティとみなす。また、  $Cd$  の値が大きいことは、部分グラフ内の連結の度合いが部分グラフとその外部との連結の度合いよりも密であること、つまりコミュニティ内外の相対的な密度差が大きく、かつコミュニティ内部の密度が外部の密度よりも大きいことを意味する。

**c) コミュニティ濃度に基づく抽出法**

コミュニティ濃度  $Cd$  に基づいた探索型コミュニティ抽出法を図 3 に示す。

まず、コミュニティの探索の始点となるシードノードを選択し、これをコミュニティ内の初期ノードとする。次にコミュニティ内のノードと接続している各ノードを

コミュニティに加えたとき、コミュニティ濃度  $Cd$  が最も大きくなるノードをコミュニティ内に加える。終了条件を満たすまで探索を続ける。

図4に水道管路をネットワーク化し、被害箇所 A, B をシードノードとしたコミュニティ抽出のイメージを示す。

また、CDB 法はコミュニティ内のノードの加えられた順番とそのときのコミュニティ濃度  $Cd$  を算出する。図2(a)に横軸をコミュニティ内のノード数、縦軸をコミュニティ濃度  $Cd$  としたグラフを示す。

コミュニティ濃度  $Cd$  の推移を計測し、図2(a)中の丸印に囲まれた箇所のようにコミュニティ濃度が極大値を示したときに、等高線を引きシードノード中心のコミュニティ図を作成することができる。ここで抽出されるコミュニティを図2(b)から(d)に示す。

## (2) コミュニティ抽出による被害箇所の逐次推定

実被害情報を用いた水道管被害逐次推定法を提案する。まず水道管路をネットワーク化し、接続関係を表現する。そして3.(1)で示したコミュニティ抽出法によって被害ノードを中心としたコミュニティ濃度を算出し、その値に基づいて被害ノードとのつながりの強さを表す属性  $dens$  を定義する。これは、被害ノードとつながりの強いノードは被害ノードと同様に被害を受けているであろうという仮定に基づくものである。実被害情報を得るたびに  $dens$  を更新して推定を行う。

### a) 水道管路のネットワーク化

水道管の接続関係を考慮するために管路をネットワーク化する。ネットワークはノードとリンクの集合で構成され、様々なものの関連性を表すことができる。本手法はノードに対して被害推定を行うため、水道管路全てをノードとして扱う必要がある。また、ノード化の粒度として、既存手法と同じ枠組みであるのが妥当であると考え、水道管をネットワーク化する際は、GIS データのメッシュをノードとし、隣接するメッシュ間に管が通っている場合をリンクありとする。これにより、最大次数4の平面グラフが構築される。

### b) 属性 $dens$ の定義

水道管の属性に、被害ノードとのつながりの強さを表す指標  $dens$  を追加する。実被害情報を得たとき、その実被害ノードをシードノードとし、水道管ネットワークからコミュニティを抽出する。このとき、コミュニティは等高線のように層で抽出されるため、どの層まで抽出するか別途決める必要がある。そして、コミュニティ抽出と同時に算出されるコミュニティ濃度に基づいて  $dens$  を決定する。 $dens$  を式[10]に定義する。

$$dens = \frac{1}{caの極大値} \quad [10]$$

$dens$  の初期値は 0 とする。ここで、コミュニティ濃度  $Cd$  の極大値とは図2(a)の丸印で囲まれているコミュニティを決定する値であり、ノードが属するコミュニティにおける  $Cd$  の極大値に基づいて  $dens$  を決定する。またシードノードに近いコミュニティであるほど小さな値を取る。 $dens$  はコミュニティ濃度  $Cd$  の逆数であるため、シードノードとのつながりが強いほど値は大きくなる。被害ノードとつながりが強いノードも被害有であろうという仮定に基づいているため、 $dens$  の値が大きいサンプルは被害有であることが望ましい。あるコミュニティがほか

のコミュニティと重なり合う場合、どちらのコミュニティからも影響を受けると考えられるため、重なるコミュニティの  $dens$  を足し合わせた値をそのノードの  $dens$  とする。また、 $dens$  を足し合わせず、重なるコミュニティ内で最大の  $dens$  を用いる方法と比較した結果、足し合わせる方法がより高い精度を示すことを確認している。

この  $dens$  を表2の入力に加えて、SVMの入力は  $x = \{$  管種, 口径, 地形, 地震最大速度, 被害,  $dens\}$  となる。実被害情報が得られるたびに  $dens$  を更新し、SVMで被害推定を行う。

実被害情報を用いた逐次推定の手順を示す。

1. 水道管路をネットワーク化する
  2. 水道管の属性に  $dens$  を追加し、初期値を 0 とする
  3. 実被害情報を得たとき、その被害箇所をシードノードとしてコミュニティ抽出を行い、コミュニティ濃度  $Cd$  を求める
  4. コミュニティ濃度に基づいて  $dens$  を更新する
  5. 表2の属性と  $dens$  を SVM に入力し、被害有無を出力させる
3. から 5. を実被害情報を得るたびに繰り返し行う。  
この手法は対象地域の管路網データさえあれば、どの地域に対しても適用することができる。

## 5. 計算機実験

以下の2つの実験を行い、提案手法の有効性を示す。


実験1: 3.(2) に示した SVM を用いた事前推定と既存手法の比較

実験2: 4.(2) に示したコミュニティ抽出を用いた逐次推定と3.(2) に示した事前推定の比較


本実験では提案法のうち、SVM を用いた事前推定を提案法(事前)、コミュニティ抽出を用いた逐次推定を提案法(逐次推定)と呼ぶ。評価は F 値を用い、実験では表2に示した属性値を平均0、分散1となるように標準化する。本研究の実験データは仙台市といわき市であるのに対し、既存手法は新潟県中越地震、能登半島地震、新潟県中越沖地震および東北地方太平洋沖地震のものを用いており汎化性能に優れる。そこで、本実験では未知データに対する誤差を推定する交差検証法を適用する。未知データに対する誤差推定の基本的な考え方は、データを教師データとテストデータの2つに分割し、教師データを用いて分類器を学習させ、テストデータを用いて性能を評価するというものである。交差検証法はデータを複数に分割し、その中から学習に使うデータを変えて学習と評価を行い、それぞれの評価結果の平均を最終的な評価をする方法である。データを  $k$  個に分割する方法を  $k$ -交差検証と呼ぶ。また、2つの提案手法は共にアンダーサンプリングを用いているため、通常の変差検証を行うと、負例を減らすほどよい評価値となる。そこで、本実験では交差検証において、教師データはアンダーサンプリングしたデータを用い、テストデータはアンダーサンプリングしていないデータを用いる。

### (1) SVM を用いた事前推定法

提案法(事前)の学習には仙台市といわき市のデータを用い、13-交差検証を100回行った平均を結果とする。



(a) 仙台市における比較



(b) いわき市における比較

図5 提案法(逐次推定)と提案法(事前)の推定精度の比較

表3 既存手法と提案法(事前)の推定精度の比較(かっこ内は標準偏差)

	再現率[%]	適合率[%]	F 値[%]
既存手法	28.1	13.7	18.4
提案法(事前)	28.3(0.42)	18.3(0.17)	22.1(-)

既存手法はメッシュごとの被害件数が1件以上の場合を被害有りとし、仙台市といわき市に適用した平均を結果とする。SVMのカーネルはガウシアンカーネルを用いる。アンダーサンプリングによって負例の数を1800件に調整する。また、ガウシアンカーネルのパラメータ $\sigma = 10$ 、SVMのコスト $C = 10$ とする。パラメータは、負例の数、 $\sigma$ 及び $C$ の3つのパラメータを変化させて交差検証を行い評価値が最も高かった組み合わせを採用した。

既存手法と提案法(事前)のF値における推定誤差の比較結果を表3に示す。表3より、提案法(事前)は既存手法よりF値が高いことがわかる。よって提案法(事前)は既存手法より推定精度が高いといえる。また、提案法(事前)は管種の情報が既存手法より粗いデータを用いるが、既存手法より高いF値を示していることから、提案法(事前)は詳細な情報が手に入らない場合でも用いることができると考えられる。

### (2) コミュニティ抽出を用いた逐次推定法

負例の数、カーネルの種類、 $\sigma$ 及び $C$ は5.(1)と同じ設定とする。抽出するコミュニティの層は1から10まで変化させ、最も評価値の高かった3層までとした。提案法(逐次推定)はネットワークの構造に依存しているため、教師データとテストデータは同一である必要があり、評価は仙台市といわき市それぞれで行う。

実被害情報は全被害がランダムに逐次得られるとする。逐次推定は10試行の平均を、事前推定は100試行の平均を結果とする。

仙台市といわき市における提案法(逐次推定)と提案法(事前)の実験結果を図5に示す。図5の縦軸はF値を、横軸は実被害情報数を示している。実被害情報数は、時間に対してほぼ線形で増加することから、図5の、仙台市、いわき市ともに提案法(逐次推定)は提案法(事前)の精度を上回り、実被害情報数が増えるたびに(時間を経て)F値が上昇していることがわかる。

### (3) 考察

本研究ではコミュニティ濃度に基づいた故障ノードとのつながりの強さを表す $dens$ という指標を用いている。

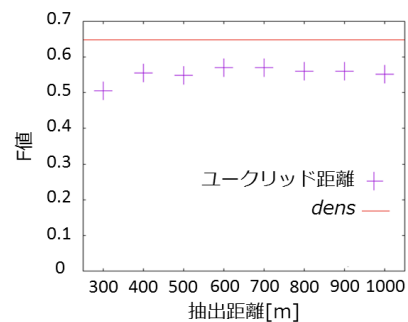


図6 densとユークリッド距離の推定精度の比較

しかし、 $dens$ を用いずとも被害箇所からの距離を考慮すれば十分である可能性も考えられる。そこで、 $dens$ の有用性を検証するために、コミュニティ抽出の代わりにユークリッド距離を用いた実験を行ない、その結果を比較する。具体的には、故障ノードとのつながりの強さを表す指標 $dens$ の代わりに被害有メッシュの重心からそれぞれのノードの中心までのユークリッド距離の逆数を水道管の属性に加えて被害推定を行い、 $dens$ を用いた結果と比較する。

被害メッシュの重心から300mから1000m以内に重心があるメッシュに対して、ユークリッド距離の逆数を属性として追加し、5.(2)と同様の設定で実験を行なう。

$dens$ を用いた場合とユークリッド距離を用いた場合の比較結果を図6に示す。この結果から、 $dens$ を用いた結果が常によりよいF値を示していることがわかる。これより、つながりを考慮した指標である $dens$ は、被害ノードからのユークリッド距離という情報より、被害推定において有用であると考えられる。

## 6. 結論

本研究では、水道管の被害箇所推定法を提案した。提案法は、(1)地震後に明らかになるリアルタイムの被害箇所情報を利用した逐次推定法であること、また、(2)水道管の接続関係に着目し、コミュニティ抽出の考え方を導入した面的な推定法であることを特徴とする。さらに、従来の予測式による被害予測に比べて、地域依存の傾向にある係数を用いる必要のないSVMを用いたパターン分類を導入した。実験の結果、提案法の推定精度は高く、また、実被害情報を活用する逐次推定は、情報が集まるほど精度を向上させること、さらに、コミュニティを導

入した場合は、SVM だけを用いた被害推定より高い精度を示すことを確かめた。

本手法は、ネットワークの任意のノードから結合の強いノードを特定する方法であることから、現状で用いられている上流側から水を流し被害箇所情報を取得する復旧システムにおいては、漏水しやすい箇所を予め特定する方法として利用できると考えている。今後は、本手法をガス管に関しても適用した実験を実施し、その精度を評価することを課題とする。

## 参考文献

- 1) 能島暢呂：東日本大震災におけるライフライン復旧概況（時系列編）Ver.3, 土木学会東日本大震災情報共有サイト, 2011
- 2) C. M. ビショップ：パターン認識と機械学習 下, 丸善出版, 2012
- 3) Elias, P., Feinstein, A. and Shannon, C. E.: A note on the maximum

flow through a network, Information Theory, IRE Transactions, vol.2, no.4 pp.117-119, 1956.

- 4) 水道技術研究センター：地震による管路被害予測の確立に向けた研究報告書【概要版】, 2013.
- 5) 丸山喜久, 山崎文雄：近年の地震被害データを加味したマクロな配水管被害予測式の改良, 土木学会論文集 A, vol.66, no.3, pp.561-567, 2010.
- 6) 能島暢呂：被害推定の逐次更新機能を有する緊急対応の意思決定支援シミュレータの開発, 地域安全学会論文集, no.9, pp.295-304, 2007.
- 7) 森井淳司：横浜市における地震時の水道管路被害予測システム, 水道技術ジャーナル, vol.44, pp.9-16, 2007.
- 8) 林幸雄 編著：ネットワーク科学の道具箱 つながりにも隠れた現象をひもとく, 近代科学社, 2007
- 9) 高橋篤, 荒井幸代：任意ノードの視点からのコミュニティ抽出, 第23回人工知能学会全国大会, 1H4-2, 2009.

(原稿受付 2015.9.19)

(掲載決定 2016.1.23)