

都市ガス供給システムにおける導管被害予測と供給停止判断への機械学習の応用

能島 暢呂¹・森山 達哉²・猪股 渉³・小山 高寛³・山端 悠介³

¹正会員 岐阜大学 工学部社会基盤工学科（〒501-1193 岐阜市柳戸1-1）
E-mail: nojima@gifu-u.ac.jp

²学生会員 岐阜大学大学院 工学研究科社会基盤工学専攻（〒501-1193 岐阜市柳戸1-1）
E-mail: v3121029@edu.gifu-u.ac.jp

³正会員 東京瓦斯株式会社 防災・供給部（〒105-8527 東京都港区海岸1-5-20）
E-mail: inomataw@tokyo-gas.co.jp, koyama98@tokyo-gas.co.jp, yamahana@tokyo-gas.co.jp

本研究は、都市ガス供給システムにおける地震時の低圧導管被害予測と供給停止判断について、機械学習の適用性について検討したものである。まずモンテカルロ・シミュレーションに基づいて、地表面 SI 値と導管被害率に関する多くのデータセットを生成した。それらを訓練データとテストデータに分離し、訓練データについて、地表面 SI 値と導管被害率および供給停止判断の有無について、それぞれサポートベクトル回帰およびサポートベクトルマシンによる機械学習を行った。テストデータの地表面 SI 値を入力データとして、それぞれの分析結果に基づいて導管被害率と供給停止判断の有無を出力データとして結果を比較したところ、良好な結果が得られることを確認した。

Key Words: city gas supply system, SI sensor, supply shutoff judgment, machine learning, support vector machine, support vector regression

1. 目的と概要

都市ガス供給システムにおいては、地震時の安全性と供給信頼性を鑑みて、保安規程で定められた基準値以上の強い揺れを検知した場合に、ガバナ単位でガス供給を停止するブロック供給遮断が行われる。観測 SI 値に基づいて即時的に供給停止が行われる第1次緊急停止判断の遮断基準値は原則として $SI^*=60\text{kine}$ とされている¹⁾。供給ブロック内に SI センサが複数基設置されている場合は、一般に n 基のうち k 基以上で SI^* 以上を観測した場合に供給停止判断が下される。この方式は「 k -out-of- n 遮断システム」としてモデル化される²⁾。

こうした供給停止判断においては、低圧導管に予測される被害率は、少なくとも明示的には扱われない。森山ら³⁾は、 k -out-of- n 遮断システムにおける供給遮断判断と、その際の低圧導管被害率 r との関係に着目して、供給遮断システムとしての性能評価を行った。具体的には、危険域と判断される被害率基準値 r^* を設定して、被害率 r と r^* との大小関係および供給停止判断の有無からなる 2×2 の分割表を用いて、感度・偽陽性率・陽性的中度・陰性的中度⁴⁾ および ROC (Receiver Operating Curve)⁴⁾ を評価指標として遮断基準値の妥当性を検討した。その結果、

耐震管率に応じて遮断基準値 SI^* を変化させることの適切性が明らかとなった³⁾。

一方で、低圧導管の即時的な被害率予測に基づいて、遮断基準値 SI^* や k などの閾値を用いることなく、被害率基準値 r^* を閾値として供給停止判断を行う方向性も考えられる。高度なリアルタイム被害予測システム⁵⁾はすでに構築されているが、本研究では新たなアプローチとして機械学習の手法を応用して、被害率予測と供給停止判断に用いられる膨大なデータや分析アルゴリズムをモデル化することを検討する。

以下、まず 2. では、供給停止判断と被害率予測の枠組みを整理するとともに、本研究でサポートベクトル回帰⁶⁾ とサポートベクトルマシン⁷⁾ を適用する範囲を明らかにするとともに、両手法の概要を示す。3. では、モンテカルロ・シミュレーションを用いて、種々の不確定性を考慮して地表面 SI 値の観測パターンおよび被害パターンを生成する手順を示す。4. では、地表面 SI 値と被害率に関する訓練データにサポートベクトル回帰を適用して機械学習し、テストデータを用いて被害率予測の精度について検証する。5. では、地表面 SI 値と供給停止の有無に関する訓練データにサポートベクトルマシンを適用して機械学習し、テストデータを用いて分割表に基づく

感度・偽陽性率・陽性的中度・陰性的中度により供給停止判断の精度について検証する。

2. サポートベクトルマシン(SVM)とサポートベクトル回帰(SVR)

(1) 本研究における適用範囲

都市ガス供給システムにおいては、図-1 の枠組みに示すように、地表面 SI 値の観測結果に基づいて、 k -out-of- n 遮断システムの考え方により、ブロック内の n 基の SI センサのうち k 基以上で遮断基準値 SI^* を上回った場合に供給停止判断がなされる。この意思決定においては、ブロック内被害率が明示的に現れることはない。しかし本来の狙いとしては、ブロック内被害率が一定値以上の危険域に入った場合に適切に供給停止判断がなされることが望ましい。こうした被害率推定を、SI 観測値、施設データ、地盤データ、被害関数に基づいて地震直後にほぼリアルタイムに行うシステム⁵⁾も構築されているが、実際の供給停止判断の仕組みと合わせて、総合的な検討を行う必要がある。

図-1 の 2 つの図みに示すように本研究では、被害率予測および供給停止判断の部分に機械学習を導入することを試み、2.(4)で述べるサポートベクトル回帰と 2.(2)で述べるサポートベクトルマシンをそれぞれ適用して、その可能性を探る。具体的には、管路データ、地盤データ、被害関数など膨大な情報と分析アルゴリズムを機械学習することで、それらすべてを予測モデルに内在化させ、地表面 SI 値を入力情報として、被害率および供給遮断の判断を出力情報とした非線形な入出力関係をモデル化することを狙いとするものである。

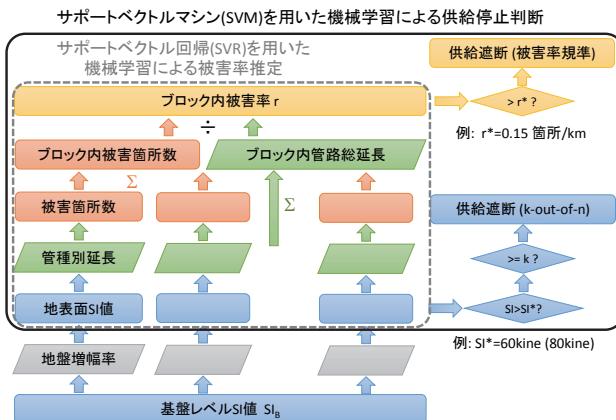


図-1 供給停止判断と被害率予測の枠組みおよび本研究における SVR と SVM の適用範囲

(2) サポートベクトルマシン(SVM)の概要⁶⁾

サポートベクトルマシン (SVM: Support Vector Machine) は、パターン認識分野で発展した 2 クラス分類法の一種である。いまベクトル \mathbf{x} に対して 1 か -1 の値をとるラベル y が割り当てられた m 個のデータ $(\mathbf{x}_i, y_i) (i=1, \dots, m)$ を考え、ベクトル \mathbf{w} を重みとする決定関数 f を次式で定義する。なお b はバイアスと呼ばれるスカラー量である。

$$f(\mathbf{x}) = \mathbf{w}^t \mathbf{x} + b \quad (1)$$

いま $f(\mathbf{x})=0$ を分類境界として、 $f(\mathbf{x})>0$ で 1, $f(\mathbf{x})<0$ で -1 となる分類器 $g(\mathbf{x})$ を定義する。分類境界を挟んだクラス間距離のことをマージンといい、その最大化を満たす決定関数 f を定める。

データが分離可能でない場合は、データがマージンを超えることを許容するように制約条件を緩和したソフトマージンを用いる。この場合のサポートベクトルマシンの最適化問題は次式で定式化される。

$$\begin{aligned} \min_{\mathbf{w}, b, \xi} & \left[\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_i \xi_i \right] \\ \text{subject to } & y_i (\mathbf{w}^t \mathbf{x}_i + b) > 1 - \xi_i, \quad \xi_i > 0 \end{aligned} \quad (2)$$

ここに $\xi_i (i=1, \dots, m)$ は誤判別の割合を表すスラック変数であり、 $\xi_i > 1$ で誤判別となる。また C は正則化係数と呼ばれるハイパーパラメータで、 C を小さくするとデータがマージンを超えることに対する許容度合いが大きくなり、逆に C を大きくすると許容度合いが小さくなり、ハードマージンに近くなる。

(3) カーネル法の概要⁶⁾

データの非線形形が強い場合は、入力空間よりも高次元の特徴空間に写像する関数 ϕ を導入する。入力ベクトル \mathbf{x} を $\phi(\mathbf{x})$ に非線形変換し、これを新たな特徴ベクトルとして、式(1)を次式で書き換える。

$$f(\mathbf{x}) = \mathbf{w}^t \phi(\mathbf{x}) + b \quad (3)$$

演算上は関数 ϕ の内積だけが問題になるので、これをカーネル関数として定義する。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^t \phi(\mathbf{x}_j) \quad (4)$$

これを用いた非線形化はカーネルトリックと呼ばれる。本研究では次式のガウス型の RBF(Radial Basis Function)カーネルを用いることとする。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (5)$$

ここで γ は事前に設定されるハイパーパラメータである。

(4) サポートベクトル回帰(SVR)の概要⁶⁾

サポートベクトル回帰 (SVR: Support Vector Regression) は、

サポートベクトルマシンの特徴を回帰分析に応用した手法である。損失関数としては、最小二乗法で用いられる二乗誤差損失関数ではなく、図-2に示すような ε -不感応損失関数が用いられる。サポートベクトル回帰は最適化問題として次式で定式化される。

$$\min_{\mathbf{w}, b} \left[\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_i \max \left\{ |y_i - (\mathbf{w}^T \mathbf{x} + b)| - \varepsilon, 0 \right\} \right] \quad (6)$$

ここで ε は不感度パラメータと呼ばれ、事前に設定する必要のあるハイパーパラメータである。また $\varepsilon=0$ とすると最小絶対誤差法と一致する。

サポートベクトルマシンと同様に、サポートベクトル回帰においても、上述のカーネルトリックを適用すれば、非線形モデルによる回帰を行うことができる。

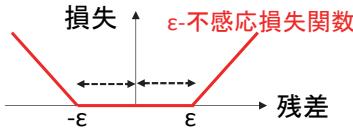


図-2 ε -不感応損失関数

3. モンテカルロ・シミュレーションによるデータ生成方法

本章では、モンテカルロ・シミュレーション(MCS)によって被災パターンを生成する。その際に、(1)表層地盤のSI値増幅度、(2)平均被害発生率に基づく被害箇所数の実現値の偶然的変動、(3)被害関数の式そのものの変動、の3種類の不確定性を考慮するものとする。

(1) SI値の観測パターンと被害パターンの設定方法

モンテカルロ・シミュレーションによる多数の観測データの模擬的生成について説明する。試行回数は $N_{sim}=10000$ 回とする。図-3にシミュレーションの概念図を示し、その手順を以下に示す。

- 1) 各試行における基盤面SI値 SI_B についてはブロック内で一様と仮定する。偏りのないサンプルを得るために層別化し、 $SI_B=5\sim100\text{kine}$ の範囲を $N_{sim}=10000$ で分割して等間隔に与える。シミュレーション試行間およびSIセンサ間でのランダム性はここでは考慮しない。
- 2) ブロック内の n 個の各SIセンサの観測値を与えるため、 n 個の標準一様乱数[0,1]を発生させる。これを、各SIセンサにおける地盤増幅度のばらつきを表す対数正規分布に従う対数正規乱数に変換し、上記1)の SI_B に乗じて地表面SI値の実現値とする。SIセンサ設置点ごとのSI値増幅度およびそのばらつきを表す対数標準偏差については、文献⁷⁾によった。
- 3) 地表面SI値に基づいて、SUPREMEの低圧ガス導管の被害予測方法⁸⁾を適用して、各SIセンサ周辺における

被害箇所数と被害率を得る。具体的な算出方法の詳細については、3.(2)～3.(4)で説明する。

- 4) 上記1)で設定した基盤面SI値 SI_B に対して上記2), 3)を試行回数 $N_{sim}=10000$ 回だけ繰り返し適用し、10000セットの観測・被害パターンを得る。

(2) 被害率の算出方法

ガス導管の本支管を対象とした被害率の推定式は、基本的にSI値に依存して被害率が増加する関数形（標準被害率関数）に各種補正係数（地盤、管種等）を乗じる関数形で表現されている⁷⁾。

$$R(SI) = C_1 \cdot C_2 \cdot R_0 \cdot \Phi \left(\frac{\ln SI - \lambda}{\zeta} \right) \quad (7)$$

$$\Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} \exp \left\{ -\frac{t^2}{2} \right\} dt \quad (8)$$

ここに、 C_p は管種補正係数、 C_g は微地形補正係数、 $R_0=2.36$, $\lambda=4.298$, $\zeta=0.387$ である。表-1および表-2にそれぞれ C_p と C_g を示す。図-4は $C_p=C_g=1$ とした標準被害率関数である。

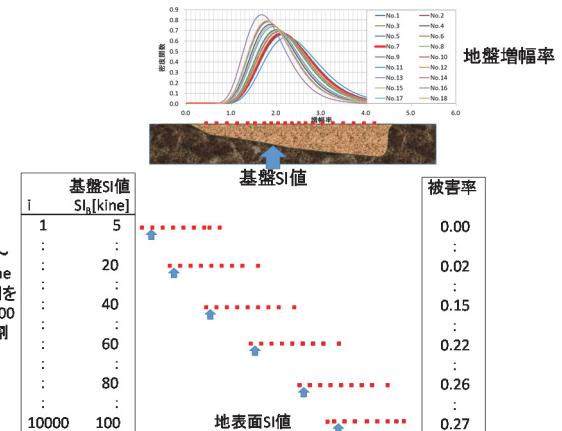


図-3 モンテカルロ・シミュレーションによるSI観測パターンと被害パターンの設定

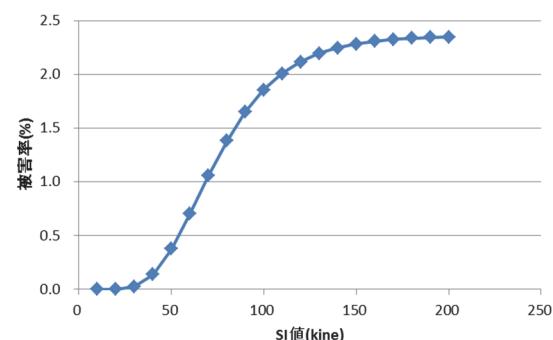


図-4 標準被害率関数

表-1 管種補正係数 C_p

導管種類	値	分類(k)
ネジ鋼管	1.00	1
DM	0.83	2
ダクタイル管	0.27	3
TM	0.02	4
鋼管メカニカル継手	0.07	5
その他(PE管等)	0.00	6

表-2 微地形補正係数 C_g

地盤種類	値	分類(l)
人工改変地	1.65	1
谷底平野	2.24	2
沖積平野	1.00	3
良質地盤	0.87	4

(3)被害箇所数および被害率の集計方法

管種別導管延長は M ブロックごとの集計値を用いる。1 つの M ブロック中には複数個の SI センサが存在することが多いが、各 SI センサが受け持つ範囲は特に定められていない。そのため、ある M ブロック j 内の SI センサの個数を n_j とした場合、暫定的に管種別導管延長を SI センサの個数 n_j で等分し、SI 値および地盤条件を割り当てる。当該 M ブロック j 内の SI センサ i に関する被害箇所数 DN_{ji} と被害率 DR_{ji} を次式で求める。

$$DN_{ji} = R_0 \cdot \Phi(SI_{ji}) \cdot C_{gi} \cdot \sum_{k=1}^6 \left(C_{pk} \cdot \frac{L_{jk}}{n_j} \right) \quad (9)$$

$$DR_{ji} = \frac{DN_{ji}}{\sum_{k=1}^6 L_{jk}} = \frac{n_j \cdot DN_{ji}}{L_j}$$

ここに、 L_{jk} は M ブロック j 内の管種 k の導管延長であり、 L_j は M ブロック j 内の導管の総延長である。M ブロック j 内の被害箇所数 DN_j と被害率 DR_j は次式で求められる。

$$DN_j = \sum_{i=1}^{n_j} DN_{ji} \quad DR_j = \frac{DN_j}{L_j} \quad (10)$$

さらに、L ブロック内の M ブロック数を m とすると、L ブロック内の被害箇所数 DN と被害率 DR は次式で求められる。

$$DN = \sum_{j=1}^m DN_j \quad DR = \frac{DN}{\sum_{j=1}^m L_j} \quad (11)$$

(4) シミュレーションによる被害箇所数および被害率の設定方法

上記の被害箇所数や被害率は決定論的に算出されるが、実現値は種々の不確定要因によりばらつくため、その結

果は期待値として捉えるべきである。ばらつきの第一の要因としては、所与の被害率のもとの偶然的変動である。被害がランダム発生すると仮定すると、被害箇所数は平均被害率をパラメータとしたポアソン分布でモデル化できる。第二の要因としては、被害関数そのものばらつきが挙げられる。平均被害率がガンマ分布に従うものと仮定すると、被害箇所数の予測分布は負の二項分布でモデル化できることを示す。

a) ポアソン分布のパラメータの不確定性を考慮した負の二項分布の導出

パラメータ（平均被害率） λ のポアソン分布に従う確率変数 X を考える。ポアソン分布の確率質量関数 PMF と平均値、分散、標準偏差、変動係数はそれぞれ次式で与えられる。

$$Po(x; \lambda) = \frac{e^{-\lambda} \lambda^x}{x!} \quad (12)$$

$$\mu_X = \lambda \quad \sigma_X = \sqrt{\lambda} \quad \delta_X = \frac{\sigma_X}{\mu_X} = \frac{1}{\sqrt{\lambda}} \quad (13)$$

いまパラメータ λ が確定値ではなく確率的に変動するものと考え、その不確定性を考慮する。ベイズ確率の方法においてポアソン分布の共役事前分布であるガンマ分布に従って変動する確率変数 Λ を考える。ガンマ分布の確率密度関数 PDF と平均値、分散、標準偏差、変動係数はそれぞれ次式で与えられる。

$$f_\Lambda(\lambda; k, \theta) = \frac{\lambda^{k-1} e^{-\lambda/\theta}}{\Gamma(k)\theta^k} \quad (14)$$

$$\mu_\Lambda = k\theta \quad \sigma_\Lambda = \sqrt{k}\theta \quad \delta_\Lambda = \frac{\sigma_\Lambda}{\mu_\Lambda} = \frac{1}{\sqrt{k}} \quad (15)$$

ガンマ分布に従うパラメータ λ の確率変数 Λ を用いると、ポアソン分布の予測分布は負の二項分布となる。その確率質量関数 PMF と平均値、分散、標準偏差、変動係数はそれぞれ次式で与えられる。

$$NB(x; k, \theta) = \int_0^\infty Po(x; \lambda) f_\Lambda(\lambda; k, \theta) d\lambda \quad (16)$$

$$= \frac{\Gamma(x+k)}{x! \Gamma(k)} \left(\frac{1}{1+\theta} \right)^k \left(\frac{\theta}{1+\theta} \right)^x$$

$$\mu_X = k\theta \quad \sigma_X = \sqrt{k\theta(1+\theta)} \quad (17)$$

$$\delta_X = \frac{\sigma_X}{\mu_X} = \sqrt{\frac{1}{k\theta} + \frac{1}{k}}$$

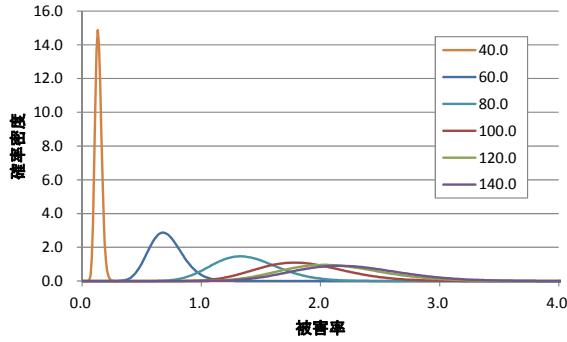


図-5 被害率の確率密度関数（変動係数 20%のガンマ分布）

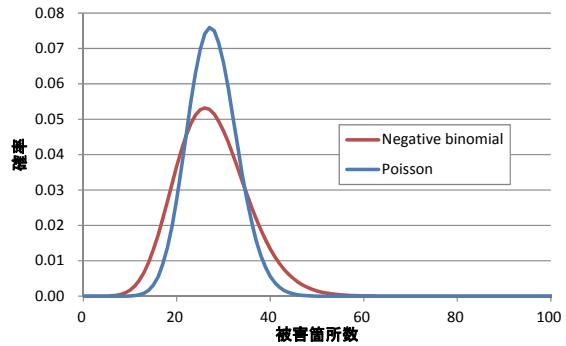


図-6 ポアソン分布と負の二項分布に従う被害箇所数の PMF

式(16)の負の二項分布は次式のように漸化式表現できる。

$$\begin{cases} \text{NB}(0; k, \theta) = \left(\frac{1}{1+\theta}\right)^k \\ \text{NB}(x; k, \theta) = \frac{x+k-1}{x} \cdot \left(\frac{\theta}{1+\theta}\right) \cdot \text{NB}(x-1; k, \theta) \end{cases} \quad (18)$$

b) 負の二項分布を用いた被害箇所数および被害率のシミュレーション

SI 値、被害関数、管路データ、地盤データによって得られる L ブロックごとの平均被害箇所数を N (式(11)の DN に相当) とし、管路延長 L で除した被害率 $\lambda=N/L$ のばらつきとして変動係数 δ_λ を見込むと、式(15)より式(19)が得られ、これらを式(16)に代入することによって、負の二項分布の確率質量関数 PMF が計算可能となる。負の二項分布の平均値、分散、標準偏差、変動係数はそれぞれ式(20)で与えられる。

$$k = \frac{1}{\delta_\lambda^2} \quad \theta = \frac{N}{k} = \delta_\lambda^2 N \quad (19)$$

$$\mu_x = N \quad \sigma_x = \sqrt{N(N\delta_\lambda^2 + 1)} \quad (20)$$

$$\delta_x = \frac{\sigma_x}{\mu_x} = \sqrt{\frac{1}{N} + \delta_\lambda^2}$$

ポアソン分布の変動係数は $\lambda \rightarrow \infty$ で 0 に収束するのにに対して、負の二項分布では $N \rightarrow \infty$ で δ_λ に収束し、 λ の変動が残る。また、 $\delta_\lambda \rightarrow 0$ で負の二項分布はポアソン分布に収束し、式(20)は式(13)に一致することがわかる。

モンテカルロ・シミュレーションにおいて、被害箇所数の実現値は、上記の負の二項分布に従う乱数 N_{NB} として得られる。本研究では累積分布関数 CDF を用いた逆変換法によって N_{NB} を発生させた。すなわち、[0,1] に従う標準一様乱数 z を発生させ、負の二項分布の累積分布関数 CDF の値 P が $z \leq P$ を満たす個数として負の二項乱

数を得る。被害発生率の実現値は、 $\lambda_{NB}=N_{NB}/L$ として得られる。

図-5 は変動係数 $\delta_\lambda=20\%$ としたガンマ分布として被害率を表したものである。図-6 はポアソン分布および負の二項分布に従う被害箇所数の確率質量関数 PMF の一例を示したものである。表示条件は、SI=80km, $C_p=1$, $C_g=1$, $\lambda=1.383$, $L=20\text{km}$, $N=27.7$ である。 δ_λ の変動を見込んだ分だけ、負の二項分布の方がポアソン分布よりもばらつきが大きくなっている。

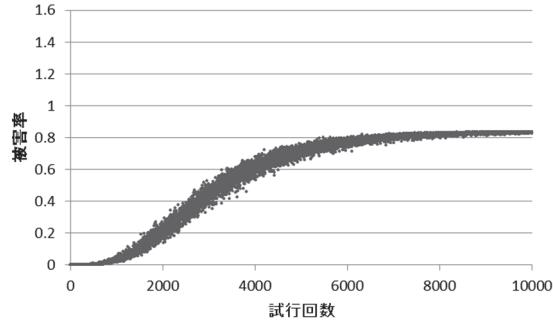
図-7 は、10000 回の試行による被害率のサンプルである（対象は後出のブロック I）。ばらつきを考慮しない場合（地盤増幅度のばらつきの影響を受ける地表面 SI 値のばらつきのみ考慮）と、被害箇所数の偶然的変動をポアソン分布で考慮した場合、さらに被害発生率のばらつきを変動係数 $\delta_\lambda=20\%$ として、被害箇所数の偶然的変動を負の二項分布で考慮した場合を比較している。以下では、こうしたばらつきの付与条件の違いが及ぼす影響についても考察する。

4. サポートベクトル回帰(SVR)の被害率推定への適用に関する検討

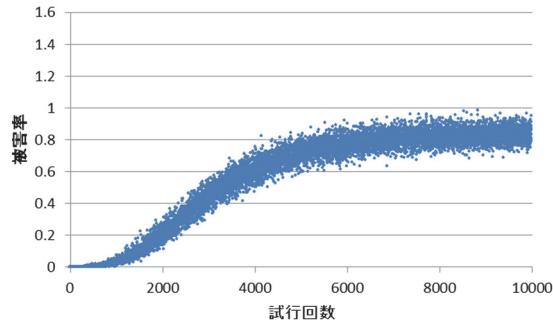
(1) 分析手順と設定条件

分析手順を以下に示す。

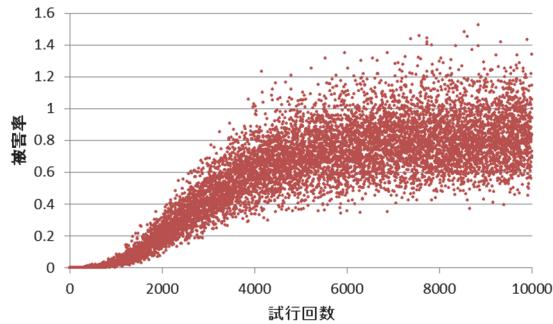
- 1) 2.で述べた 10000 回の試行によるブロック内の地表面 SI 値と導管被害率（被害率関数のばらつきを考慮して負の二項分布で発生させた被害箇所数に基づく）のサンプルデータを、表-3 に示す剩余系に基づいて訓練データとテストデータに振り分ける。
- 2) 訓練データを用いて、地表面 SI 値と導管被害率の関係を学習させ、サポートベクトル回帰による回帰分析を行う。
- 3) テストデータに対して、地表面 SI 値に基づいて導管被害率の予測を行い、その予測結果を MCS による



(a)被害箇所数のばらつきを考慮しない場合



(b)被害箇所数の偶然的変動のみを考慮した場合（ポアソン分布）



(c)被害関数のばらつきをガンマ分布（変動係数 20%）で与えた場合（負の二項分布）

図-7 被害関数に不確定性を見込んだ場合の被害率（横軸は $N_{\text{sim}}=10000$ の試行番号, $S_{\text{IB}}=5 \sim 100 \text{ kine}$ に相当）

正解と比較する。

被害率のデータセットとしては、図-7(a)～(c)に対応するデータセットを

- ・データセット A：ばらつきを考慮しない場合（図-7(a)相当）
- ・データセット B：ばらつきをポアソン分布で考慮した場合（図-7(b)相当）
- ・データセット C：ばらつきを負の二項分布で考慮した場合（図-7(c)相当）

とした。本研究では学習・予測パターンとしては、以下の3種類を比較することとした。

- ・パターン AA : A を学習して A を予測
- ・パターン CA : C を学習して A を予測
- ・パターン CC : C を学習して C を予測

サポートベクトル回帰のカーネル関数としてはガウス型の RBF カーネルを用いる。式(5)のパラメータ γ については、 $\gamma=0.01 \sim 1.0$ の範囲を対象とした。式(6)のパラメータ ε については 0.05 とし、正則化係数 C については $C=1.0 \sim 50$ の範囲を対象とした。

表-3 剰余系を用いたシミュレーション・サンプルからの訓練データの抽出方法

MCS のサンプルからの訓練データの設定条件 ($i=1, \dots, 10000$)	訓練データ個数	テストデータ個数
$i \pmod{200} = 0$	50	9950
$i \pmod{100} = 0$	100	9900
$i \pmod{50} = 0$	200	9800
$i \pmod{20} = 0$	500	9500
$i \pmod{10} = 0$	1000	9000
$i \pmod{5} = 0$	2000	8000
$i \pmod{2} = 0$	5000	5000
$i \pmod{40} \neq 0$	7500	2500
$i \pmod{10} \neq 0$	9000	1000

(2) 分析結果と考察

対象としたのは、ある L ブロック（ブロック I、導管耐震化率は低め）である。検討の結果、1000～2000 回程度で高度な学習効果があることが確認された。正則化係数 C については対象範囲内で差がほとんどないことが確認された。以上より、ここでは学習回数 2000 回、 $C=5$ とした場合を示す。

図-8 に $\gamma=0.02$ とした場合の例を示す。パターン AA では予測誤差は小さく、式(7)の非線形な被害率関数を含む SI 値と被害率との入出力関係が適切に学習されている。パターン CA ではばらつきを含む訓練データのため、被害率の上限値付近の予測誤差が大きくなっているが、低い被害率ではさほど大きくない。ばらつきが二重化するパターン CC では予測誤差がさらに拡大している。

図-9 は $\gamma=0.5$ としてカーネル関数の幅を狭めた場合である。全体的にばらつきは拡大するがパターン CA では一部縮小していることがわかる。

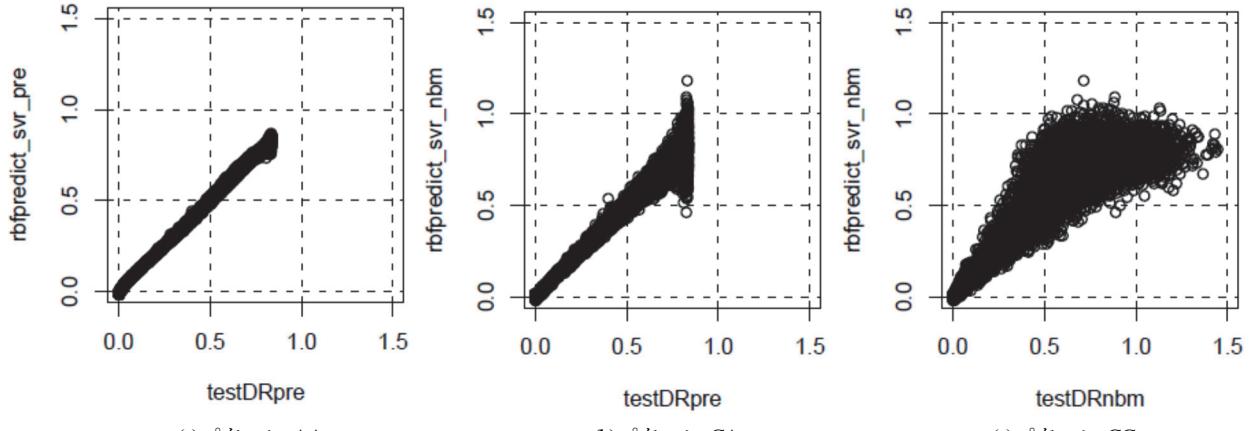


図8 サポートベクトル回帰による被害率の予測結果 ($\gamma=0.02$, 横軸: テストデータの実際の値, 縦軸: 予測値)

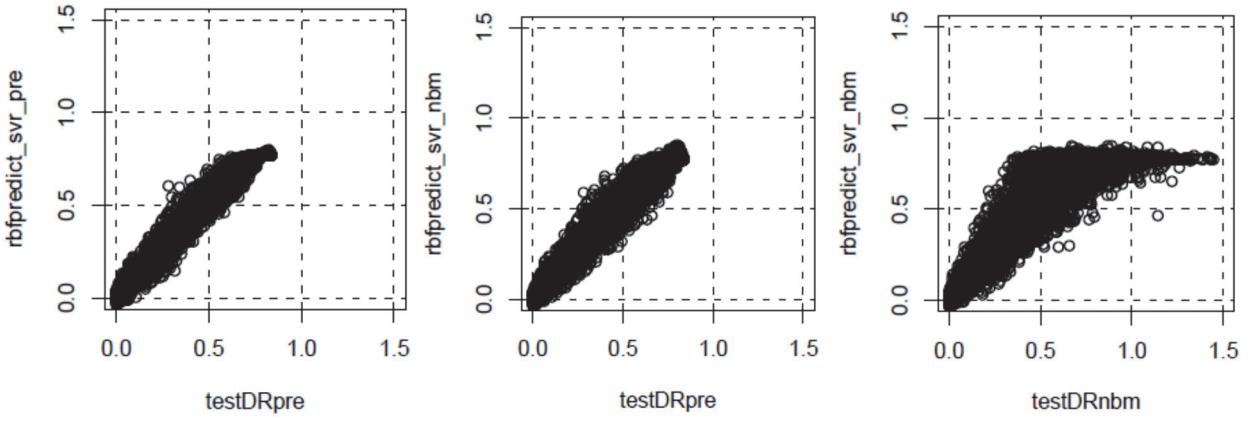


図9 サポートベクトル回帰による被害率の予測結果 (ブロック I, $\gamma=0.5$, 横軸: テストデータの実際の値, 縦軸: 予測値)

5. サポートベクトルマシン(SVM)の供給停止判断へ適用性に関する検討

(1) 分析手順と設定条件

分析手順を以下に示す。

- 1) 2で述べた 10000 回の試行によるブロック内の地表面 SI 値と導管被害率（被害率閾数のばらつきを考慮して負の二項分布で発生させた被害箇所数に基づく）のサンプルデータを、表-3に示す剩余系に基づいて訓練データとテストデータに振り分ける。
- 2) 訓練データを用いて、地表面 SI 値と導管被害率が危険域にあるか ($r \geq r^*$) 否か ($r < r^*$) の関係を学習させ、サポートベクトルマシンによる 2 クラス分類の機械学習を行う。
- 3) テストデータに対して、地表面 SI 値に基づいてサポートベクトルマシンにより導管被害率の 2 クラス分類を適用し、危険域にあるか否かの判別予測を行う。その予測結果を MCS による正解と比較して、分割表を作成し、感度 (TP rate) と偽陽性率 (FP rate) お

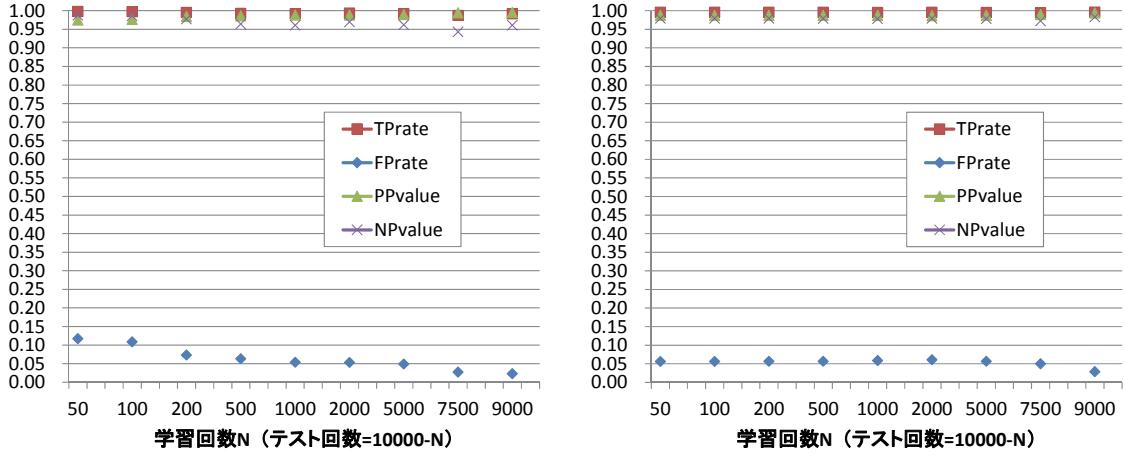
より陽性的中率 (PP value) と陰性的中率 (NP value) によって判別性能を評価する⁴⁾。

- 4) テストデータの地表面 SI 値を被害関数に入力して、ばらつきを考慮しない導管被害率を算出し、危険域にあるか否かを判別する。その結果を MCS による正解と比較して上記と同等の評価を行う。
- 5) 上記 3)のサポートベクトルマシンによる結果と上記 4)の被害関数による結果とを比較して考察を行う。サポートベクトルマシンのカーネル関数としては、前章と同じく $\gamma=0.5$ のガウス型 RBF カーネルを用い、正規化係数 $C=5$ とした。また被害率基準値については $r^*=0.15$ とした。

(2) 分析結果と考察

対象としたのは、2つの L ブロック (ブロック I: 導管耐震化率は低め、ブロック II: 導管耐震化率は高め) である。

図-10 はブロック I を対象とした結果である。サポートベクトルマシンに基づく予測結果を示す図-10 (a) より、感度(TP rate)、陽性的中率(PP value)、陰性的中率(NP

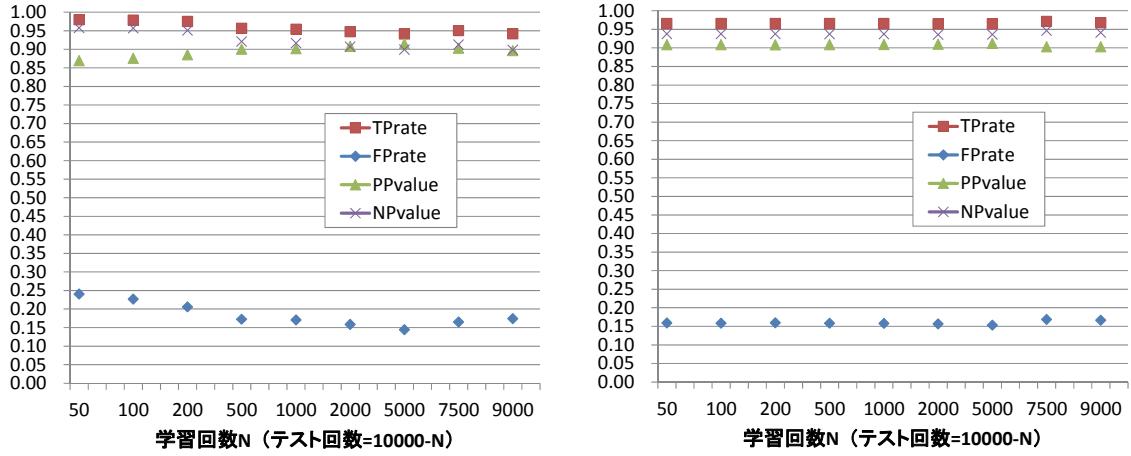


(a) MCS の実現値を学習した SVM による判別予測

(b) 被害関数による予測(ばらつきは考慮せず)

図-10 サポートベクトルマシンおよび被害関数による導管被害率の判定結果の比較

($r^*=0.15$, ブロック I)



(a) MCS の実現値を学習した SVM による判別予測

(b) 被害関数による予測(ばらつきは考慮せず)

図-11 サポートベクトルマシンおよび被害関数による導管被害率の判定結果の比較

($r^*=0.15$, ブロック II)

value) はいずれもほぼ 95%を上回り、高い水準を示している。偽陽性率 (FP rate) については、学習回数が 100 回以下では 10%程度とやや大きな値をとっているが、1000 回以上になると 5%程度以下となっており、良好な予測ができていることが見て取れる。

図-10 (b)は同じブロック I に対して、地表面 SI 値を被害関数を適用した予測結果を用いたものである。この場合は学習効果はなく、横軸方向に本来一定値となるが、用いる訓練データとテストデータの組み合わせによる偶然的変動の影響で多少のばらつきがみられる。図-10 (a) で学習回数の少ない場合と比較すると図-10 (b)の方が良い結果を与えている場合もあるものの、図-10 (a)で学習回数の多い場合には、図-10 (b)との差はごく小さい。言い換えると、サポートベクトルマシンによる予測結果は、

ばらつきを考慮しない被害関数に基づく結果とほぼ同程度の精度であるといえる。

図-11 はブロック II を対象とした結果である。図-10 と比較すると、全般的に判別精度は悪くなっているが、特に FP rate の増大が顕著である。サポートベクトルマシンによる図-11 (a)に限らず被害関数を適用した図-11 (b)でも同様であることから、この精度低下はサポートベクトルマシンに起因するものではないと考えられる。ブロック II の導管耐震化率は高く、ブロック I よりも相対的に被害は出にくいと考えられる。図-7 は導管耐震化率が低いブロック I を対象としたものであるが、同様の図を作成すると、全体的に被害率は低くなると推察される。今回の被害率基準値 $r^*=0.15$ は、ブロック Iにおいては SI 値に対する変化率が大きい領域に相当する。これに対してブロック II では SI 値に対してフ

ラットで変化率が低い領域になると考えられ、供給停止判断の地表面 SI 値に対する感度が鈍化することが考えられる。上限を有する被害率関数の関数形状にもかかわることであり、こうした問題の改善方法については、今後の課題である。

4. で示したサポートベクトル回帰による被害率の予測精度に比べると、本章で示したサポートベクトルマシンによる供給停止判断の予測精度は、高いように思われる。これは k -out-of- n 遮断システムによってブロック内の SI 観測値を集合的に扱うことによる信頼性向上効果の一つと考えられる。この点についてもさらに考察を進める方針である。

6. 結語

本研究では、都市ガスの地震時供給停止判断の合理化と高度化を目指し、サポートベクトル回帰とサポートベクトルマシンによる機械学習の適用可能性について検討したものである。得られた成果を以下に要約する。

- 1) モンテカルロ・シミュレーションにより、地表面 SI 値の観測パターンと導管被害率パターンのデータセットを生成した。表層地盤の SI 値増幅度、被害個所数の偶然変動、被害率関数のパラメータの変動という 3 種類の不確定性を考慮したデータセットをもとに、機械学習用の訓練データとテストデータを生成した。
- 2) 訓練データにサポートベクトル回帰およびサポートベクトルマシンを適用し、被害率の回帰分析と供給停止判断の分析を行った結果、1000 回ないし 2000 回程度の学習で被害関数に匹敵する性能を示すことがわかった。
- 3) サポートベクトル回帰による被害率の回帰分析によると、訓練データに持たせたばらつきの程度に影響をうけるものの、SI 値と被害率との非線形な入出力関係が適切に学習されることがわかった。
- 4) サポートベクトルマシンを用いて供給停止判断の予測を行い、分割表を用いて、感度 (TP rate) と偽陽性率 (FP rate) および陽性的中率 (PP value) と陰性的中率 (NP value) による評価を行った。その結果、ばらつきを考慮しない被害関数に基づく結果とほぼ同等の判別性能が得られることがわかった。

以上の結果は、MCS の試行結果を機械学習することで、管路データ、地盤データ、被害関数など膨大な情報を必要とする被害予測を行うことなく、SI 観測値を入力情報、供給遮断の判断を出力情報とした入出力関係がモデル化できることを示すものである。

特に、サポートベクトルマシンを用いた結果は、「閾値フリー遮断システム」すなわち「遮断基準値 SI* や k -out-of- n システムの k などの閾値を用いない遮断システム」の構築の可能性を示唆するものであり、今後さらに検討を進める方針である。

参考文献

- 1) 経済産業省 総合資源エネルギー調査会 都市熱エネルギー部会 ガス安全小委員会 災害対策ワーキンググループ：東日本大震災を踏まえた都市ガス供給の災害対策検討報告書、2012.3.
- 2) 能島暢呂、加藤宏紀： k -out-of- n 遮断システムとしてみた都市ガス供給の第 1 次緊急停止判断に関するシステム分析、土木学会論文集 A1S, Vo.71, No.4, 2015.7.
- 3) 森山達哉、能島暢呂、猪股涉、小山高寛、山端悠介：都市ガス供給システムにおける地震時供給停止判断の性能評価、第 36 回土木学会地震工学研究発表会講演論文集、2016.10.
- 4) 元田浩、津本周作、山口高平、沼尾正行：データマイニングの基礎、(株)オーム社、pp201-208, 2008.
- 5) 猪股涉、乘藤雄基、石田栄介、塚本博之、山崎文雄：東日本大震災における東京ガスの設備被害の概況と超高密度地震観測情報に基づく低圧ガス導管被害推定の精度検証、日本地震工学会論文集 第 13 卷、第 2 号 (特集号) , pp.2_37-2_44, 2013.3.
- 6) 竹内一郎、鳥山昌幸：サポートベクトルマシン（機械学習プロフェッショナルシリーズ）, 講談社, 2015.8.
- 7) (公財) 地震予知総合研究振興会：観測地震動情報等を活用した高度被害推定手法の確立に向けた検討、平成 27 年度報告書、2016.3.
- 8) (公財) 地震予知総合研究振興会：観測地震動情報等を活用した高度被害推定手法の確立に向けた検討、平成 26 年度報告書、2015.3.

APPLICATION OF MACHINE LEARNING TECHNIQUES TO DAMAGE ESTIMATION AND EMERGENCY SHUTOFF IN CITY GAS SUPPLY SYSTEM

Nobuoto NOJIMA, Tatsuya MORIYAMA, Wataru INOMATA, Takahiro KOYAMA
and Yusuke YAMAHANA

Applicability of machine learning techniques has been examined for estimation of damage of low-pressure gas pipelines and decision making of emergency shutoff of city gas supply. A number of observation patterns of SI values, damage rate and shutoff patterns was generated by Monte Carlo simulation. The relationships between SI values and damage rate in training data was learned using support vector regression analysis. The relationships between SI values and shutoff status was learned using support vector machine. The results using test data suggests that the applied techniques can be promising tools for representing non-linear relationships among those factors related to damage estimation and shutoff decision.