

東北地方太平洋沖地震における都市ガス導管の被害位置の推定

14T0203B 有田 京平
指導教員：丸山 喜久

1. 研究背景と目的

2011 年に発生した東北地方太平洋沖地震では、東京ガスの供給エリアでは耐震性の劣る低圧ガス導管に被害が発生した. 設備区分ごとの被害数を表-1 にまとめ、低圧ガス導管の設備区分を図-1 に示す.

既往研究¹⁾では、東北地方太平洋沖地震の際に被害の大半を占めたネジ継手の本支管被害率について、SUPREME に搭載されている被害推定式の精度検証が行われており、本支管のネジ継手に関しては被害推定式の精度が高いことが確認されている.

そこで、本研究では、被害数の概数を予測する次の取り組みとして、被害位置を評価することを試みる. 本支管のうち特に被害が多く発生したネジ継手の被害分析を行い、被害発生地点の推定精度の向上を図ることを目的とする.

2. 分析対象データ

本研究では、東京ガスの東北地方太平洋沖地震の際のガス管の被害データをもとに分析を行った. ガス管の被害は、被害位置・設備区分・管種・接合方法などが取りまとめられている. また、管種・接合方法ごとにガス導管の延長が 50m メッシュ単位でまとめられている.

被害発生地点を推定する際、50m メッシュごとの管路延長データ・SI 値・地形区分・地盤の固有周期・AVS20・基盤深さ・耐震化率・SI 値増幅度の 9 項目を素因とした. 地形区分は、東京ガスが定めている地形区分（50 m メッシュ）を使用した.

表-1 設備区分ごとの被害数

設備区分		被害箇所数
製造設備		0
高圧ガス導管		0
中圧ガス導管		0
低圧ガス導管	道路下	本支管 145
		供給管(引き込み管) 131
	民地	灯外内管 929




図-1 低圧ガス導管の設備区分

3. 被害位置の推定

3.1 機械学習手法

本研究では、2つの機械学習手法による分析を行った.

(1) サポートベクターマシン(SVM)

本研究では、教師あり学習によるパターン認識手法の一つであるサポートベクターマシン(SVM)を用いて被害発生地点の推定を行う. 式(1)、式(2)のハイパーパラメータC,γは分類結果に影響するため²⁾、交差検証法により最適なC,γを求めた.

$$\min_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \sum_{i \in [n]} \xi_i \tag{1}$$

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \tag{2}$$

ここで、wは実数ベクトル、bはスカラー、ξは非負の変数、K()はカーネル関数であり、本研究では RBF カーネルを用いた.

(2) ランダムフォレスト(RF)

決定木（弱識別器）の集団学習により分類・回帰を行う機械学習アルゴリズムである³⁾. 学習データから複数の決定木を作成し、それらの結果から多数決で最終的な結果を出す. 図-2 に RF の概要を示す.




図-2 ランダムフォレストの概要

3.2 不均衡データのクラス分類

本研究で使用するガス管の被害データには正例と負例のデータ数に大きな偏りがある. このような不均衡データでは、少数派のデータが抽出されにくくなり、分類精度の低下につながる⁴⁾. そこで、Synthetic Minority Over-sampling Technique (SMOTE)により少数派である正例の各点に対して、k-最近傍点との間の点

をランダムに選んで正例に加えることで人工的に正例を増やし、多数派である負例をランダムに削除することで、正例と負例の学習データ数の偏りを補正し、SVM・RF による分類を行った。

分類を行う際、SVM・RF とともに学習率は 10%～50% の範囲で 10%ずつ増加させ、学習データの正例と負例の数が等しくなるように SMOTE で調整した。

4. 被害発生地点の評価図

最も推定精度が高かった RF 学習率 30% の場合の結果を、東北地方太平洋沖地震の際の本支管ネジ継手の被害位置と比較し、被害発生地点の評価図を作成した(図-3)。




図-3 SMOTE-RF(学習率 30%) 被害発生地点評価図

SMOTE により学習データの正例と負例の数の偏りを補正して分析を行ったが、実際には被害がない地点を被害ありと分類していることが多いことから、50m メッシュ単位での予測が困難であることが分かる。そこで、都市ガスの供給ブロックごとに精度の評価を行った。図-4 に供給ブロックごとの被害数を示す。50m メッシュ数に対する被害ありと予測したメッシュ数の割合を供給ブロックごとに算出し、それを実際の被害の有無で比較したものを図-5 に示す。この割合が 0～0.3 の範囲では、被害がない供給ブロックの割合が大きいが、被害がある供給ブロックも混在している。被害があった供給ブロックでこの割合が 0.1 以下と小さかったものは、実際の被害数が 1 箇所だけであった。本研究では、腐食による被害と地震動による継手被害を分離せずに分析しているため、このような結果になった可能性もあり、今後は被害形態を分けるなどの対応も必要と考えられる。




図-4 供給ブロックごとの被害数




図-5 供給ブロック内の 50m メッシュ数に対する被害ありと予測したメッシュ数の割合

5. まとめ

本研究では、東北地方太平洋沖地震において被害が多かった本支管のネジ継手の被害発生地点の推定精度の向上を目的とし、Synthetic Minority Over-sampling Technique (SMOTE)により不均衡データを補正し、サポートベクターマシン(SVM)とランダムフォレスト(RF)により被害発生地点を推定した。RFの方がSVMよりも高い精度の推定結果が得られたが、実際には被害がない地点を被害ありと分類していることが多かった。今後は、より詳細な被害形態に分けての分析やアンダーサンプリング及びオーバーサンプリングの際のデータの選択方法やデータ数の検討、地形区分ごとの分析や勾配ブースティング等の他の手法を用いた分析を行い、推定精度を向上させる必要がある。

参考文献

- 1) 猪股渉, 乗藤雄基, 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, Vol. 13, No. 2, pp. 37-44, 2013.
- 2) 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
- 3) 平井有三: はじめてのパターン認識, 森北出版株式会社, 2012
- 4) N.Japkowicz: Learning from Imbalanced Data Sets: A Comparison of Various Strategies, AAAI2000 Workshop, Technical Report WS-00-05, pp. 10-15, 2000.