A-28

深層学習による異管種の混在状況を考慮した低圧ガス管の被害箇所予測

19T0229H　岡田　健嗣
指導教員：丸山　喜久

1. 研究背景と目的

熊本地震や東日本大震災などの規模の大きい地震では低圧ガス管の被害が多数発生した[1),2)]．これらの被害形態には，機械的接合部での継手緩みやねじ接合部の亀裂などがある．一般的に，都市ガスは水道や電気といった他のライフラインに比べて復旧に時間がかかる．これは，地中埋設管の修繕前にガス栓の閉栓作業などを伴うためである．さらに，都市ガスは可燃性かつ目視ができないため，ガス漏れをしていないか専用機での確認作業が必要になっている．このことから，ガス導管の被害箇所を予測することは，復旧作業の迅速化に貢献することができる．

一方，兵庫県南部地震と同様に，近年の地震時ではポリエチレン(PE)管での被害は見られなかった．そこでガス管の耐震化対策として，PE 管への取替が進められている．本研究では，管網画像の深層学習によって，異管種の混在状況を考慮した低圧ガス管の被害箇所予測モデルを構築することを目的とする．これによって，都市ガスの復旧の迅速化と PE 管の敷設計画の立案に貢献することを目指す．

2. 対象地域と使用画像データ

本研究は，東北地方太平洋沖地震における宮城県仙台市の被害データおよび管網画像を対象として検討を行う．市内の南北方向約 30km，東西方向約 24km の範囲を 1km 四方で区切ることにより管網画像を作成する．管網画像では，管種ごとに色が分けられており，深層学習時に異管種の混在状況を考慮することができる(図-1)．また計算速度を上げるために元画像 1000×1000 px を 64×64 px にリサイズした．被害データをもとに，管網画像を被害ありと被害なしの２クラスにラベル付けしたのち，それぞれ訓練画像とテスト画像を 8:2 の比率にランダムに分類した．また，学習精度を高めるため，被害なしデータは２倍，被害ありデータは８倍に拡張することで使用データとする．

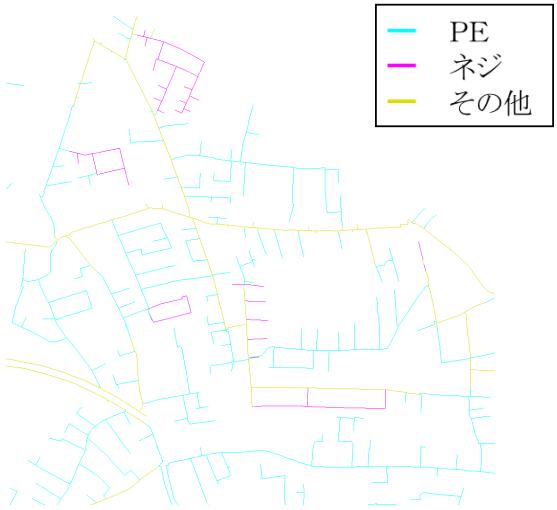

図-1　本研究で用いた管網画像の例

3. 深層学習について

本研究では深層学習のフレームワークとして Keras を使用した．Keras は GPU での計算が可能である．また，他のフレームワークと比べモデルの構築が簡単にできる．Keras を用いて畳み込みニューラルネットワーク(CNN)[3)]による画像認識モデルを構築する．CNN は，畳み込み層とプーリング層を用いたニューラルネットワークであり，画像認識や音声認識などいたるところで使われている．プログラム言語には Python を用いる．

4. 判別モデルの構築

(1)最適化手法

モデルの最適化手法は勾配法のうち Adam を採用した．Adam は学習の更新度合いが適応的に調整されることで重みパラメータを効率的に探索することが出来る．

(2)損失関数

モデルの性能の指標である損失関数値はクロスエントロピー誤差により求める．この値は 0 に近づくほど性能が高いことを示す．

(3)活性化関数

活性化関数は入力信号の総和がどのように活性化するかを決める役割がある．学習の速度が速い Relu 関数を中間層に用い，全結合層ではソフトマックス関数を用いた．

(4)学習回数

学習回数を増やすほどモデルの精度は上がっていくのが理想だが，訓練データに過度に適応した過学習が起きてしまうことがある．本研究では過学習が起きるタイミングも確認できるように学習回数を 300epoch に設定した．この間の最も精度の高い重みを保存する．

(5)ネットワークの構造とパラメータ

ネットワークの構造とパラメータは Optuna[4]により定める．Optuna は Preferred Networks 社が開発しているハイパーパラメータ自動最適化フレームワークである．本研究では，畳み込み 5 層，プーリング 2 層，ドロップアウト 2 層，全結合 2 層のネットワークが最適となった．

5. 学習結果

上記で述べたモデルでの学習結果を示す．図-2 では epoch ごとの精度の推移，表-1 では最も精度が高い時の混同行列を示し，精度指標を求めた．

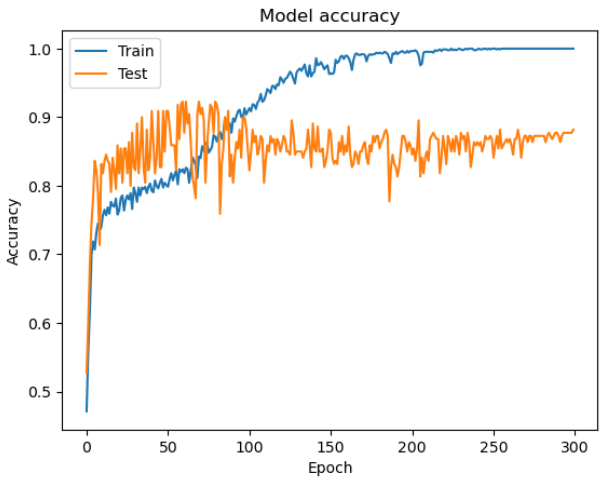

図-2 epoch ごとの精度の推移

表-1 最も精度が高い時の混同行列(枚)と精度指標

混同行列		予測	
		被害なし	被害あり
実際	被害なし	95	13
	被害あり	4	108

正答率	適合率	再現率	F 値
0.92	0.89	0.96	0.93

6. 考察

図-2 より学習始めは訓練データ，テストデータともに精度が上がっていくのが確認できる．ところが，80epoch あたりから，訓練データの精度だけが上がり，テストデータの精度は下がっている．これは過学習が原因と考えられる．今回のデータは管網画像と被害データのみを使用しているためデータ不足から過学習が発生したと考えられる．しかし，表-1 の精度指標を見ると，非常に良好な精度で管網画像の被害有無を判別できていることがわかる．

7. 結論と今後の展望

今回作成したモデルでは正答率 0.92 で判別することができた．今後は管網図と被害データのみでなく，地盤情報や地震動データを用いることでより判別精度を上げることを目指す．

参考文献

1)産業構造審議会　保安分科会　ガス安全小委員会：平成 28 年度熊本地震を踏まえた都市ガス供給の地震対策検討報告書, p8，2016.

2)統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, p4，2012.

3) 斉藤　康毅：ゼロから作る Deep Learning, p205~p220，2016.

4) T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama: Optuna: A Next-generation Hyperparameter Optimization Framework. In KDD, 2019.