

現地写真を用いた畳み込みニューラルネットワークによる建物の被災度判別

16T0297W 戸澤 謙弥
指導教員：丸山 喜久，劉 ウェン

1. はじめに

地震をはじめとした種々の自然災害では、住家や公共施設などの構造物に何らかの被害が生じる。災害発生後は、被災地やその周辺の自治体職員等がそのような構造物の被害程度を調査によって明らかにすることで、災害対応や復旧・復興支援施策を計画するための足掛かりとしている。その取り組みの一つとして、内閣府の被害認定調査基準に基づき実施される被害認定調査がある。この調査では、外観目視を基本とした第1次調査や、必要に応じて内観等を含む詳細な調査を実施し、建物の被害を5段階で評価する。得られた調査結果は、罹災証明書として被災者に交付され、被災者支援措置に活用される。

しかしながら、このような調査は災害の規模が大きく被害が広範囲に及ぶと、調査対象となる建物が急増することから、人員不足やそれに伴う調査時間の遅延などが問題視されている。2016年に発生した熊本地震を例に挙げると、地震発生から1ヶ月の時点で罹災証明書の申請件数に占める交付数の割合は3割程度に留まっており、証明書発行の遅れが問題となった。

そこで本研究では、建物の被災度を判別するために行う被害認定調査の効率化を目的として、建物の外観画像データに畳み込みニューラルネットワーク（CNN）を適用することで、建物の被災度判別手法の開発を目指す。

2. CNN と使用データの概要

CNN は全結合層のみで構成される多層ニューラルネットワークとは異なり、畳み込み層やプーリング層と呼ばれる層を持つことが特徴である。本研究では、複数の CNN とデータセットを用いて学習結果を比較することで、被災度判別により適したモデルの構築を目指す。使用した CNN の一つを図 2-1 に示す。




図 2-1. CNN の構成例

CNN の中間層において多く利用されている畳み込み層では、カーネルと呼ばれる重みパラメータを保持する積分核を用いて、畳み込み処理が行われる。この層には一般的に、様々なバリエーションのカーネルが存在し、カーネルの数だけ特徴マップと呼ばれるテンソルが出力される。

その後、プーリング層にて、入力画像の注目領域における平均値や最大値を、特徴マップの出力値とする処理がなされる。この処理により、データサイズの削減や、領域内の特徴をロバストに取得することができる。なお、本研究で使用するネットワークでは、対象領域内の最大値を取る Max-pooling を採用している。

また、CNN における重みの学習には Nesterov の加速勾配法⁹⁾を使用した。この更新則は、最急降下法の更新式に慣性による更新式 (2) を加えることで、学習の効率化を実現した Momentum 法から派生した手法である。具体的には、更新前の出力値 x_t に対し、学習率 η 及び 0~1 の任意定数 γ を設定し、以下の更新式 (1) を適用することで、更新後の出力値 x_{t+1} が得られる。

$$x_{t+1} = x_t + v_t - \eta \nabla f(x_t + v_t) \tag{1}$$

$$v_t = \gamma(x_t - x_{t-1}) \tag{2}$$

この更新則の特徴として、勾配の更新時に慣性による更新式 (2) を引数に組み込んでいることが挙げられる。様々な更新則で同じデータセットに対して学習を行ったところ、この更新則を用いた際に最も高い精度が得られたことから、本研究ではこれを用いることとした。

本研究では熊本県益城町、宇城市、熊本市を対象として、2016 年の熊本地震発生後に実施された被害認定調査の際に撮影された現地写真（木造建物の全体画像）を用いて、データセットの作成を行った。また、ラベル付けは内閣府の被害認定調査基準に基づいて判定された調査結果に準拠する。図 2-2 に被災度別建物全体画像の例を示す。

画像例					
被災度	全壊	大規模半壊	半壊	一部損壊	無被害

図 2-2. 被災度別の建物全体画像の例

3. データセットの詳細と学習条件について

本研究では、被害認定調査の第1次調査のうち、建物の被害を全壊か否か目視で判定する外観による判定ⁱⁱ⁾をCNNにより補完することを目的とする。そのため、第一次調査にて全壊判定がなされた建物画像をクラス1、それ以外の判定がなされた建物画像をクラス2としたデータセット1と、クラス2を一部損壊、または無被害判定がなされた建物画像のみで構成したデータセット2を作成し、2クラス分類を行う。なお、クラス2には異なる被災度判定がなされた建物画像が混在しているが、クラス1の画像データ数と差異が生じないように、被災度別に分けられた建物画像群から無作為に抽出しデータセットを構築している。

さらに、画像データは、事前に64×64pixelにリサイズした上でグレースケール変換を行う。また、訓練データは、鏡像反転と回転処理を施し、オリジナル画像の4倍の枚数に拡張したものを使用する。今回は訓練データとテストデータの構成比を8:2とし、訓練画像4772枚、テスト画像1194枚に対して計算処理を行った。CNNの学習条件と各種パラメータを表3-1に示す。

表 3-1. CNN の学習条件

活性化関数	Relu (中間層)
	Softmax with Loss (全結合層)
パラメータ更新則	Nesterov の加速勾配法
ミニバッチサイズ	64
学習回数	30000
学習率更新則	Multi-step
学習率初期値	0.1
Weight Decay	0.0001 (default)

4. 学習結果

図1-1に示したネットワークと表3-1に示した学習条件に基づき、各データセットを適用して得られた結果を表4-1に示す。さらに、データセット別の訓練データ及びテストデータの正答率推移を図4-1、4-2に示す。訓練データの正答率は繰り返し計算100回ごとに記録した数値を、テストデータの正答率は1000回ごとに記録した数値からグラフ化している。

表 4-1. データセット別の学習結果

	データセット1	データセット2
Accuracy[%]	69.0	77.8
Loss	2.07	1.28

*表中の数値は計算回数30000におけるテスト結果




図 4-1. データセット1使用時の正答率の推移




図 4-2. データセット2使用時の正答率の推移

5. 考察

2つのデータセットを使用して検証を行ったところ、クラス2が一部損壊または無被害判定がなされた画像のみで構成されているデータセット2の方が高い精度となった。この結果から、大規模半壊及び半壊判定がなされた画像群には、全壊と判別され得る建物画像が多く含まれることが分かる。

また、図4-1、4-2では、訓練データとテストデータの正答率の推移が乖離しており、過学習の恐れがある。一般に過学習は、データ数の不足やモデルの複雑化、不適切なハイパーパラメータの設定などに起因して発生する。今回は、訓練データの画像データ数4772枚で学習を行ったことから、データ数の不足に伴って過学習に陥ったものと考えられる。

6. 結論と今後の展望

今回作成したモデルによって、全壊建物を8割近い精度で抽出することができた。今後は、過学習の発生を抑制するため、他市町村の画像データを随時追加していくことで、より汎化性能の高いモデルの作成を目指す。また、より詳細な被災度判別を実現するため、建物の部位（屋根・外壁・基礎）ごとに損傷率を算出した上で判別を行うモデルの検討も進めていく予定である。

ⁱ⁾ Y. Nesterov: A method of solving a convex programming problem with convergence rate $O(1/k^2)$, Soviet Mathematics Doklady, 27, pp. 372–376 (1983).

ⁱⁱ⁾ 内閣府：災害に係る住家の被害認定, <https://www.bousai.go.jp/taisaku/unyou.html>