深層学習を用いたクラス分類に基づく RC 造建築物の三次元点群からの局所損傷検出

北山耕平1 硴崎賢一2 向井智久3 荒木俊輔2

概要:地震によって被災した RC 造建築物を効率的に調査するために,損傷した RC 造建築物の三次元点群を用いた 深層学習によって,RC 造建築物の局所損傷を検出する手法を提案した.三次元点群ベースの深層学習手法である PointNet や PointNet++を活用し,局所領域に分割した三次元点群に対してクラス分類を行うことで,分割した領域単 位での損傷判定を行った.手法を評価するための実験においては,分割領域の大きさやスケール等が損傷検出精度に 影響を及ぼすことを確認した.適切に教師データを作成し学習を行った結果,耐震実験で用いられた RC 造建築物に おいては9割を超える精度で損傷を検出することができた.

キーワード: RC 造建築物,局所損傷検出,深層学習,クラス分類,三次元点群

A Study on Local Damage Detection in RC Buildings using Deep Learning-Based Classification of 3D Point Cloud

Kohei KITAYAMA¹ Ken'ichi KAKIZAKI² Tomohisa MUKAI³ Shunsuke ARAKI²

Abstract. To efficiently inspect earthquake-damaged RC buildings, we propose a method to detect local damage of RC buildings by deep learning using 3D point cloud of RC buildings. By using PointNet and PointNet++, which are point cloud-based deep learning methods, damage classification was performed for each divided region by classifying the 3D point cloud divided into local regions. In experiments to evaluate the method, it was confirmed that the size, scale, etc. of the divided regions affected the damage detection accuracy. As a result of properly preparing and learning the teacher data, we were able to detect damage with an accuracy of more than 90% in the RC building used in the seismic test.

Keywords: Reinforced Concrete Buildings, Local Damage Detection, Deep Learning, Classification, 3D Point Cloud

1. はじめに

近年日本では鉄筋コンクリート(RC)造建築物に被害を 与える大地震が多発している.地震後には被災した建築物 の損傷調査を行う必要があり、従来は近接目視による調査 が行われてきた.しかし、目視では調査困難な箇所が存在 する上、膨大な数の建築物を調査する必要があるため多く の人手と時間を要することや、調査員が余震等による二次 災害に巻き込まれる危険性が高いことが問題となっていた. そこで我々は三次元レーザー計測によって得られる三次元 点群に着目した.

三次元レーザー計測は広範囲における物体の三次元形 状を計測でき,非接触かつ短時間で行われるため,建築物 の調査においては調査員の危険性や負担を軽減することが できる.さらに,計測対象の三次元形状を稠密に取得でき るため,ひび割れといった微細な損傷や壁面の歪みなどを

3 国立研究開発法人建築研究所

Building Research Institute

確認することができる.しかしながら, 稠密に計測された 三次元点群は数千万点から数億点といった膨大な数の点で 構成されており,その中から迅速に局所的な損傷の発生箇 所を特定する方法はこれまで確立していなかった.

本稿では、三次元点群を用いた深層学習により RC 造建 築物に生じた局所損傷を検出する手法を提案し、提案手法 を用いた被災 RC 造建築物の損傷検出結果について述べる.

2. RC 造建築物の三次元レーザー計測

2.1 レーザースキャナ

三次元レーザー計測はレーザースキャナを用いて実施される.レーザースキャナは、対象物にレーザーを照射する ことで、対象物の詳細な表面形状を膨大な点数の三次元点 群として取得する測量機器である.地形の測量や建築物の 三次元計測等に利用されており、地上に設置して周囲の計 測を行う地上型レーザースキャナは、測量においては十分 な計測誤差 5mm という精度で計測することができる.

2.2 三次元点群における RC 造建築物の局所損傷

地震により被災した RC 造建築物には,建築物全体の損 傷として外壁や柱の傾斜,局所的な損傷としてコンクリー トのひび割れ,剥落等が発生する.建築物に生じたコンク リートのひび割れや剥落は実際に目視で確認可能であるが,

¹ 九州工業大学 大学院情報工学府

Graduate School of Computer Science and Systems Engineering, Kyushu Institute of Technology

² 九州工業大学 大学院情報工学研究院

Faculty of Computer Science and Systems Engineering, Kyushu Institute of Technology

情報処理学会研究報告 IPSJ SIG Technical Report

稠密に計測された三次元点群においても目視で確認するこ とができる.

2015年に国立研究開発法人建築研究所にて実物大の RC 造建築物を用いた静的載荷実験[1]という耐震実験が行わ れた.実験用に建てられた実大 5 層 RC 造建築物の外観を 図 1 に示す.



図 1 実大5層 RC 造建築物の外観

実験の際には実大5層 RC 造建築物に直接取り付けられ た計測器による変位計測とともに三次元レーザー計測が行 われており,実験後の建築物が高密度な三次元点群として 記録されていた.実大5層 RC 造建築物の三次元点群を図 2 に示す.実験後の実大5層 RC 造建築物には,コンクリー トの剥落やひび割れといった局所損傷が発生しており,図 3 に示すように三次元点群でもそれらを確認することがで きる.



図 2 実大5層 RC 造建築物の三次元点群



図 3 実大5層 RC 造建築物における損傷の三次元点群

3. 三次元点群を用いた深層学習

3.1 三次元点群の性質と深層学習

三次元点群とは三次元直交座標系で表された点の集合で あり,物体の三次元形状を表現することができる.三次元 点群には以下に示す二つの特徴的な性質が存在する.

- 点の順序不同性
- 近接する点間の相互作用性

図 4 に示すように、三次元点群は三次元座標情報を持っ た多数の点によって三次元モデルを形成する.一方、三次 元点群は単なる点の集合であるため、これらの点には順序 が存在しないという性質がある.また、各点は一定の間隔 で分布しているとは限らない.点の密度が一定ではないた め、点同士の隣接関係が不明瞭である.しかしながら、単 一の点では特に意味を持たず、近接した複数の点によって 三次元形状を表現するため、近接する点同士の位置関係が 非常に重要となる.



図 4 三次元点群の拡大図 (Stanford bunny[2])

このような性質を考慮した上で深層学習を行うために, 三次元点群をある特定の手法によって画像に変換し,畳み 込みニューラルネットワーク(CNN)で学習を行うという 画像ベースの手法[3]が従来は一般的であった.しかし,三

情報処理学会研究報告 IPSJ SIG Technical Report

次元データを二次元データにするという処理によって,オ リジナルの詳細な形状情報や空間的情報が変化あるいは失 われるという問題点が存在した.そこで近年は,三次元点 群を画像に変換することなく,三次元点群を直接入力し学 習を行う三次元点群ベースの手法が主流となりつつある.

3.2 PointNet

三次元点群を直接入力として扱うために,前節で述べた 三次元点群の性質を考慮してどのように処理するかが問題 となっていた.Qiらによって提案されたPointNet[4]は,点 に順序が存在しないという三次元点群の性質を考慮し,三 次元点群を直接入力することを可能にしたニューラルネッ トワークである.PointNet の構造を図 5 に示す.PointNet では入力の順序を入れ替えても出力が変化しない性質を持 つ対称関数(Symmetric function)に着目し,対称関数の一 つである Max pooling を組み込むことで点の順序不同性に 対処している.



図 5 PointNet の構造

3.3 PointNet++

PointNet++[5]はPointNetの改良版としてQiらが提案した ニューラルネットワークである.PointNet は三次元点群を 直接入力し学習を行うことができたが、局所的な特徴を抽 出できないという問題点があった.そこでPointNet++では 局所領域ごとにPointNetによる特徴抽出を行う階層的なネ ットワーク構造となっている.PointNet++の構造を図 6 に 示す.局所特徴を抽出する部分は、サンプリング層、グル ーピング層、PointNet 層の三種類の層から構成される.サ ンプリング層では入力された三次元点群のサンプリングを 行い、グルーピング層ではサンプリングされた点を中心と する近傍点群を抽出し、PointNet 層では抽出された近傍点 群から特徴量を計算する.これらの処理によって入力され た三次元点群の局所特徴を学習することができるようにな っている.



図 6 PointNet++の構造

4. 損傷検出システムの提案

PointNet や PointNet++は三次元モデルのクラス分類で高 い成果を挙げたニューラルネットワークである.これらの ニューラルネットワークを RC 造建築物の局所損傷検出に 適用することを考え,以下の手順により損傷検出を行うシ ステム (図 7) を提案する.

- ある一定の大きさの立方体領域を建築物の三次元点
 群内に設定し、損傷判定領域とする.
- 損傷判定領域内の三次元点群を抽出し,損傷判定モデルに入力する.
- 損傷判定モデルによって、入力された三次元点群に損 傷が存在するかどうか判定を行う。
- 損傷判定領域の位置をずらす.
- 上記手順を繰り返し、建築物の三次元点群を網羅的に 判定する.



図 7 損傷検出の流れ

損傷判定モデルとは, RC 造建築物の損傷形状を学習した PointNet や PointNet++である.これらのクラス分類を行うニューラルネットワークを用いて RC 造建築物の局所損傷を検出することを考えた場合,建築物の三次元点群から検出したい損傷の大きさに合わせた領域の三次元点群を抽出し,抽出された三次元点群に対して損傷の有無を判定することができる.この処理を建築物全体で網羅的に行うことにより,損傷の発生箇所と発生していない箇所に分けることができ,建築物における局所損傷を検出することができる.

5. 実験と評価

5.1 損傷形状の学習のための教師データ作成

提案手法における損傷判定モデルを作成するためには, RC 造建築物の局所損傷を学習する必要がある.学習を行うためには教師データが必要となるが,現時点では被災建築物の調査において三次元レーザー計測が一般的ではないため,損傷が存在する RC 造建築物の三次元点群は少なく, 実際の被災建築物の損傷データを確保することが困難である.そこで,22節で示した実大5層RC 造建築物の三次元 点群から教師データを作成した.

まず,実大5層RC造建築物の三次元点群を損傷の大き さに合わせるように1m間隔で格子状に空間分割した.分 割後の各三次元点群を本稿では分割点群と呼称する.各分 割点群が学習を行う際の入力データとなる.ここで,分割 の際に一つの損傷箇所が二つ以上の領域に分割され,一つ の分割点群に損傷箇所の一部しか含まれないものがあった. 損傷の形状を適切に学習するためには,分割点群に損傷の 全体がほぼ含まれた状態が望ましいと考えた.そこで,分 割する境界を 50cm ずらした分割点群も同時に生成し,一 つの損傷全体が含まれた分割点群が生成されるようにした.

生成した各分割点群に対して目視で損傷の有無を確認し、 手作業でラベリングを行った.少しでも損傷が含まれたデ ータには「損傷あり」とラベリングし、それ以外のデータ を「損傷なし」とした.ラベリングを行った結果、「損傷あ り」のデータが442個、「損傷なし」のデータが1906個と なった.このようにクラスごとのデータ数に偏りが生じて いる教師データで学習を行った場合、データ数の少ないク ラスの検出率が低下することが分かっている[6].本研究で は損傷検出を目的としているため、「損傷あり」のデータ数 が少ない状態では損傷形状の学習を行うことができず、目 的を達成することができない.そこで、「損傷あり」のデー タにおいて、X座標値を正負反転させたデータ、Y座標値 を正負反転させたデータ、Z座標値を正負反転させたデー タをそれぞれ追加することでデータ拡張を行い、クラスご とのデータ数の偏りを軽減した.

「損傷あり」とラベリングを行ったデータの例を図 8 に, 「損傷なし」とラベリングを行ったデータの例を図 9 に示 す. 各図の下段は壁面の奥行き方向の座標値をもとに色を 付けた図で,赤色が手前側,青色が奥側であることを表し ている.



図 8 「損傷あり」のデータの例



5.2 損傷の有無によるクラス分類

本節では既報[7]の実験内容を簡単に記述する.

5.2.1 実験内容

作成した教師データ(「損傷あり」:1768 個,「損傷なし」: 1906 個)を用いてどの程度学習を行うことができるのか確 認するために実験を行った.教師データの5分の1をテス トデータ,残りを訓練データとして200 エポック学習を行 った. PointNet, PointNet++それぞれで学習を行い,学習結 果の比較を行った.

5.2.2 損傷判定結果

PointNet の学習結果を表 1 に, PointNet++の学習結果を 表 2 に示す.これらの表は学習後のモデルを用いて教師デ ータの分類を行った結果をまとめたもの(混同行列)であ る.それぞれの分類結果から算出された損傷の検出率 (Recall),判定精度(Precision),正解率(Accuracy)を表 3 に示す.表 3 に示すように,いずれの指標を比較しても PointNet++の方が PointNet よりも高い数値となっており,

PointNet		正解	
		損傷あり	損傷なし
出力結果	損傷あり	1507	450
	損傷なし	261	1456

表 1 PointNet の分類学習結果

学習能力が高いことが確認できた.

表 2 PointNet++の分類学習結果

PointNet++		正解	
		損傷あり	損傷なし
出力結果	損傷あり	1708	101
	損傷なし	60	1805

表 3 各学習モデルの学習精度

	検出率[%]	判定精度[%]	正解率[%]
PointNet	85.2	77.0	80.6
PointNet++	96.6	94.4	95.6

分類結果を可視化したものを図 10 に示す.赤色で示す 箇所が正しく損傷を判定できた箇所,青色で示す箇所が損 傷の誤検出箇所,緑色で示す箇所が損傷の検出漏れ箇所で ある.図 10より,(b)の PointNet++の方が(a)の PointNetよ りも正しく分類できていることが明らかではあるが, PointNet の分類結果に注目すると,青色で示す損傷の誤検 出箇所が比較的多いことが分かる.さらに,PointNet では 建築物の3階以下を「損傷あり」,4階以上を「損傷なし」 と判定している傾向が見られた.





(a) PointNet (b) PointNet++図 10 各学習モデルの学習結果の可視化

5.2.3 座標情報の影響調査

損傷判定結果から三次元点群の座標情報の影響があるの ではないかと考えられた.実験では教師データの各分割点 群の座標値を直接入力としており、各分割点群は三次元形 状に加え座標情報を保持していたと考えられる. したがっ て、PointNet は三次元点群の高さ情報をもとに損傷判定を 行っていた可能性が懸念された.もし座標情報が損傷判定 結果に影響しているならば、三次元座標系において各分割 点群を平行移動させると判定結果が大きく変わるのではな いかと考えられた. そこで, 各分割点群を損傷の存在しな い5階相当の高さに平行移動させたデータを損傷判定モデ ルに入力した場合、教師データがどのように分類されるの か調査を行った.分類結果を表 4 および表 5 に示す.表 5 を見ると、PointNet++では平行移動前と同様に分類ができ ているのに対し、表 4 を見ると PointNet では損傷を一切検 出できなかったことが分かる. したがって, PointNet では 点群の高さ情報が損傷判定において重要な要素となってい たことが確認できた.

表	4	PointNet	における	る座標情報	の影響調査
~~		1 011111 101	1-101/ 0		· · 제가 티 베이 프

PointNet		正解	
		損傷あり	損傷なし
出力結果	損傷あり	0	0
	損傷なし	1768	1906

表 5 PointNet++における座標情報の	影響調査
-------------------------	------

PointNet++		正解	
		損傷あり	損傷なし
出力結果	損傷あり	1697	148
	損傷なし	71	1758

5.3 座標情報の正規化

5.3.1 座標正規化データでの学習

実験[7]の結果から,損傷形状を適切に学習し損傷検出率 を高めるためには,座標情報の影響を排除した教師データ の作成が必要であることが分かった.そこで,各分割点群 の中心座標が三次元座標系における原点となるように,全 ての分割点群を平行移動させることによって座標情報の正 規化を行った.座標正規化を行ったデータでの学習結果を 表 6 および表 7 に示す.また,それぞれの結果から算出し た各学習モデルの検出率,判定精度,正解率を表 8 に示す. PointNet の学習結果に関しては,座標の正規化を行うこと で損傷検出率が 85.2%から 55.9%に低下した.PointNet++ の学習結果に関しても,座標正規化によって損傷検出率が 96.6%から 89.2%に低下した.これらの結果から,座標正規 化前のデータを用いた学習においては PointNet のみならず PointNet++でも損傷判定に座標情報の影響があったことが 考えられる.

PointNet		正解	
		損傷あり	損傷なし
出力結果	損傷あり	989	37
	損傷なし	779	1869

表 6 座標正規化データでの PointNet の学習結果

表 7 座標正規化データでの PointNet++の学習結果

PointNet++		正解	
		損傷あり	損傷なし
出力結果	損傷あり	1577	10
	損傷なし	191	1896

表 8 座標正規化データでの各学習モデルの学習精度

	検出率[%]	判定精度[%]	正解率[%]
PointNet	55.9	96.4	77.8
PointNet++	89.2	99.4	94.5

5.3.2 損傷を検出できなかったデータ

座標正規化を行うことで損傷検出率が低下したが,検出 率を改善するためにどうすべきかを考えるために,各学習 モデルにおいて損傷検出ができなかったデータについて調 査を行った.損傷検出できなかったデータの例を図 11 に 示す.図の上段は損傷検出できなかったデータそのもの, 下段は壁面の奥行き方向の座標値を色で表現した図を示し ている.(a)のデータに関しては,図の右下部分にわずかに コンクリートの剥落が生じていることが確認できる.(b) から(e)のデータは一見すると損傷が存在しないように見 えるが,詳しく見るとひび割れが生じた箇所であることが 分かる.これらのデータでは検出対象の損傷が分割点群に 対して非常に小さいために損傷が埋もれてしまい,検出が 困難になっていると考えられる.



図 11 損傷を検出できなかったデータの例

5.4 微細な損傷形状の特徴抽出

5.4.1 10cm 分割データでの学習

1辺1mの分割点群において埋もれてしまっていた微細 な損傷を検出するために、各分割点群の分割サイズを小さ くすることで特徴を抽出できるのではないかと考えた.本 実験では10cm分割を行ったデータで学習を行い、1m分割 データとの損傷検出精度の比較を行った.10cm分割データ の例を図12および図13に示す.図12より、コンクリー トの剥落箇所の三次元点群では凹凸が大きく表れており、 図13より、ひび割れ箇所の三次元点群ではひびに沿って 壁面の奥に点が分布していることが確認できる.



図 12 コンクリート剥落箇所の 10cm 分割データの例



図 13 ひび割れ箇所の 10cm 分割データの例

10cm 分割データでの学習結果を表 9 および表 10 に示

す. また, それぞれの結果から算出した検出率, 判定精度, 正解率を表 11 に示す. PointNet での損傷検出率を算出す ると 33.8%, PointNet++での損傷検出率を算出するとわず か 6.1%となった. いずれの学習モデルも正解率が 5 割程度 となり, 損傷判定が全くできていないことが確認された.

表 9 10cm 分割データでの PointNet の学習結果

PointNet		正解	
		損傷あり	損傷なし
出力結果	損傷あり	1436	1054
	損傷なし	2814	3196

表 10 10cm 分割データでの PointNet++の学習結果

PointNet++		正解	
		損傷あり	損傷なし
出力結果	損傷あり	259	9
	損傷なし	3991	4241

表 11 10cm 分割データでの各学習モデルの学習精度

	検出率[%]	判定精度[%]	正解率[%]
PointNet	33.8	57.7	54.5
PointNet++	6.1	96.6	52.9

5.4.2 損傷判定精度低下の原因

各分割点群の分割サイズを小さくすることで微細な特徴 を抽出し,損傷検出率が向上することを期待したが,意に 反して全く損傷判定できないという結果となった.この原 因は,各分割点群のスケールが小さすぎるためであると推 測した.教師データの作成に使用した三次元点群の座標値 はメートル単位で記録されていた.すなわち,1m 分割デ ータの座標値は-0.5から+0.5の範囲,10cm分割データの座 標値は-0.05から+0.05の範囲であった.したがって,各学 習モデルに入力される値の大きさが小さすぎたため,特徴 抽出が困難になっていたのではないかと考えられる.



また, PointNet++においては局所特徴を抽出するために, 特徴抽出空間となる球体の半径がパラメータとして複数存 在するが,それらの半径パラメータが 0.1 から 0.8 の値と なっていた.したがって,図 14 に示すように,局所特徴 を抽出する際に特徴抽出空間の球体内に全点群が含まれて しまい,局所特徴が全く抽出されていなかったと考えられ る.

5.5 局所特徴抽出のための分割点群のスケール拡大

前節の結果より、PointNet++によって三次元点群から局 所特徴を抽出するためには、入力する三次元点群がある程 度の大きさを持つ必要があることが分かった. PointNet++ の半径パラメータの最大値は 0.8 となっていたため,分割 点群の大きさは少なくとも直径となる 1.6m よりも大きく すべきであると考えた.本実験では 10cm 分割データのス ケールを100倍に拡大し、分割点群の大きさを最大10mと することで損傷検出率が改善されるのか実験を行った.実 験結果を表 12 に示す. また, スケール拡大前後の学習結 果を比較したものを表 13 に示す.表 13 に示すように,ス ケール拡大後の損傷検出率は 86.0%, 正解率は 90.7%であ った.スケールの拡大を行う前は損傷検出率が 6.1%, 正解 率が 52.9% であったため、 大幅に改善されたことが分かる. 一方, 1m 分割データでは損傷検出率が 89.2%, 正解率が 94.5%であったため、分割サイズを小さくすることで分類 精度がわずかに低下したことを確認した.損傷が検出でき なかったデータを調査したところ、ほとんどがひび割れ箇 所のデータであることを確認した.

PointNet++		正解	
		損傷あり	損傷なし
山土休田	損傷あり	3657	197
田刀棺未	損傷なし	593	4053

表	12	スケー	-ル拡大デ	ータでの	PointNet+	+の学習結:

表 13 スケール拡大前後の学習精度比較

	検出率[%]	判定精度[%]	正解率[%]
スケール拡大前	6.1	96.6	52.9
スケール拡大後	86.0	94.9	90.7

5.6 3 クラス分類によるひび割れの検出

5.6.1 ひび割れの検出

これまでの実験により,「損傷あり」と「損傷なし」の2 クラス分類を行った場合,形状の変化が小さなひび割れの 検出精度が,形状の変化が大きな剥落の検出精度に比べ低 くなることを確認した.これは,ひび割れのデータと損傷 のないデータの形状が類似しているためであると考えられ る.そこで,「損傷あり」のデータを「剥落」と「ひび割れ」 のデータに分け、その内「ひび割れ」のデータのみを用い て「ひび割れ」と「損傷なし」の2クラス分類学習が行え るのか実験した.「剥落」と「ひび割れ」のデータの例を図 15 および図 16 に、実験結果を表 14 に示す.表 14 から算 出した検出率、判定精度、正解率を表 15 に示しているが、 正解率は95.0%となり、「ひび割れ」と「損傷なし」を高精 度で分類可能であることが確認できた.



図 16 「ひび割れ」とラベリングしたデータの例

表 14 「ひび割れ」と「損傷なし」の分類結果

PointNet++		正解	
		ひび割れ	損傷なし
山力法用	ひび割れ	7195	474
山刀棺木	損傷なし	265	6986

表 15 「ひび割れ」の学習精度

	検出率[%]	判定精度[%]	正解率[%]
ひび割れ	96.4	93.8	95.0

5.6.23クラス分類学習

「ひび割れ」と「損傷なし」を分類可能であることが確認できたため、これらの2クラスに「剥落」を加えた3クラスで分類が行えるのか実験を行った.3クラス分類学習結果を表16に示す.また、各クラスの検出率、判定精度を表17に示す.表17より、いずれのクラスも9割を超える検出率となっており、高精度で分類できたことが分かる. 全体の正解率を算出すると93.0%となった. 教師データと3クラス分類学習結果を比較したものを図 17 に示す.赤色の箇所が「剥落」,緑色の箇所が「ひび割 れ」,青色の箇所が「損傷なし」を示している.(白色は教 師データのクラスごとのデータ数を調整するために,学習 に使用しなかった未分類の箇所である.)図 17 を見ると, 損傷箇所とそれ以外の箇所との境目で判定の誤りが見られ るが,概ね正しく損傷判定ができていることが確認できた. したがって,壁,柱,梁といった基本的な部材で構成され た実験用建築物における局所損傷は,我々が提案した損傷 検出手法によって検出可能であると言える.

PointNet++		正解		
		ひび割れ	剥落	損傷なし
	ひび割れ	6960	255	297
出力結果	剥落	41	6814	123
	損傷なし	459	391	7040

表 16 3 クラス分類学習結果

表 17 クラスごとの検出率および判定精度

	検出率[%]	判定精度[%]
ひび割れ	93.3	92.7
剥落	91.3	97.6
損傷なし	94.4	89.2





(a) 教師データ
 (b) 学習結果
 図 17 教師データと学習結果の比較

6. まとめ

本研究では、三次元点群ベースの深層学習によって鉄筋 コンクリート造建築物の三次元点群から損傷箇所を検出す る手法を提案し、手法を評価するための実験を行った.実 験の結果、教師データの作成方法によっては意図通りに学 習が進まず、損傷形状を適切に学習することができないこ とが分かった.一方で教師データを適切に作成した場合は、 学習に用いた実験用の建築物において9割を超える正解率 で損傷検出を行うことができた.今後は実際の被災建築物 での損傷検出を行い,実用性の評価を行っていく.

謝辞

本研究は,建築研究所との共同研究「3次元データを用 いた地震後の損傷評価手法の構築に関する基礎的検討」に 基づき実施した.なおここで使用したデータは建築研究所 指定研究課題「既存建築物の地震後継続利用のための耐震 性評価技術の開発」により得られたものである.関係各位 に謝意を表する.

参考文献

- [1] 壁谷澤寿一,向井智久,福山洋,加藤博人,諏訪田晴彦,坂下 雅信,勅使川原正臣,田尻清太郎,"損傷低減のために袖壁・ 腰壁・垂れ壁を活用した実大5層鉄筋コンクリート造建築物 の静的載荷実験(その2:試験体概要),"日本建築学会大会学 術講演梗概集,pp.211-212,2016.
- [2] The Stanford 3D Scanning Repository, http://www.graphics.stanford.edu/data/3Dscanrep/
- [3] D. Maturana, S. Scherer, "VoxNet: A 3D Convolutional Neural Network for Real-Time Object Recognition," 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), pp. 922-928, 2015.
- [4] C. R. Qi, H. Su, K. Mo, L. J. Guibas, "PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation," The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 652-660, 2017.
- [5] C. R. Qi, L. Yi, H. Su, L. J. Guibas, "PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space," Proceedings of the 31st International Conference on Neural Information Processing System (NeurIPS), pp. 5105-5114, 2017.
- [6] N. V. Chawla, N. Japkowicz, A. Kołcz, "Editorial: Special Issue on Learning from Imbalanced Data Sets," ACM SIGKDD Explorations Newsletter, vol. 6, no. 1, pp. 1-6, 2004.
- [7] 北山耕平, 硴崎賢一, 荒木俊輔, 向井智久, "三次元点群と深 層学習を用いた鉄筋コンクリート造建築物の損傷検出," 電 気・情報関係学会九州支部連合大会, pp. 192-193, 2019.