

ドローンで取得した 3 次元点群データと深層学習を用いた家屋構造部の自動抽出および被災度判定手法の構築

代表研究者 久保 栞 香川大学 四国危機管理教育・研究・地域連携推進機構 特命講師
共同研究者 吉田 秀典 香川大学 創造工学部 教授

1 はじめに

日本では、2016 年熊本地震や 2024 年能登半島地震をはじめとする大規模地震が頻発しており、今後も南海トラフ巨大地震や首都直下地震の発生が懸念されている。こうした災害において、被災者の生活再建を支える公的支援の初動の遅れが繰り返し問題となっている。その一因が、各種支援の前提となる罹災証明書の発行遅延である。罹災証明書¹⁾は、公費による家屋の解体、修理や仮設住宅への入居といった支援を受けるために不可欠な書類であり、その発行には、自治体職員が被災家屋を一軒ずつ訪問し、国の指針に基づいて損壊状況を評価する被害認定調査が必要となる²⁾。この現地調査は、災害規模が大きくなるほど膨大な人員と時間を要する。令和 6 年能登半島地震後の調査では、被災自治体職員の約 85%が業務量の増加を、約 70%が人手不足を訴えており³⁾、限られた人員で広範囲に点在する膨大な家屋を一軒ずつ調査することには限界がある。さらに、内閣府の指針⁴⁾によれば、被害認定は屋根、壁、基礎といった構造部の損傷割合および家屋全体の傾斜に基づいて行われ、特に傾斜が 1/20 を超える場合は「全壊」と判定されるなど、傾斜は極めて重要な評価指標である。しかし、実際の調査は調査員の目視に依存するため判定にばらつきが生じやすく、また余震下で倒壊の危険がある家屋に接近することは安全上も困難である。その結果、被害が過小評価されて再調査が必要となる事例⁵⁾も生じており、迅速かつ安全で客観的な被害把握手法の確立が強く求められている。

こうした発行遅延や判定のばらつきは、過去の災害でも繰り返し指摘されている。1995 年の兵庫県南部地震では罹災証明制度が十分に整備されておらず、判定基準や調査手順が自治体ごとに異なっていたため再調査が増加し、公的支援の開始に時間を要した⁶⁾。加えて、恒久住宅への移行が進まず仮設住宅での生活が長期化し^{7),8),9)}、地域コミュニティの分断や孤立を招いたことも報告されている¹⁰⁾。2011 年の東北地方太平洋沖地震では、津波による広域かつ甚大な被害に対して調査人員が不足し、他都市からの応援職員を含む体制でも判定結果に差異が生じた^{11),12)}。2016 年の熊本地震では、度重なる余震により被害状況が変化し、再調査が必要となる事例が多発したこと^{13),14)}で、公費解体や更地化が進まず復旧作業に支障をきたした¹⁵⁾。これらの事例からも、人手や主観に過度に依存しない、安全かつ迅速で客観的な被害把握手法の確立が求められている。

災害時の建物被害把握に関する研究は、これまで主に衛星画像や航空画像といった 2 次元データを用いて行われてきた。Wang ら¹⁶⁾は畳み込みニューラルネットワークを用いて衛星画像から被災建物を自動分類し、広域被害把握における有効性を示した。Ji ら¹⁷⁾も同様に衛星画像から倒壊建物を検出し、Matsuoka ら¹⁸⁾は地震前後の SAR 強度画像の散乱特性の変化を利用することで、雲や夜間の影響を受けずに広域の被害を把握できることを示した。これらの衛星画像を用いた手法は広域把握に有効である一方、解像度の制約により軽微・部分的な損傷の把握が難しく、2 次元情報であることから被害認定で重要となる建物の傾斜や構造的損傷を捉えることが困難である。

航空画像を用いた研究も多く、Li ら¹⁹⁾は SSD などの物体検出と SVM を適用して瓦礫や崩壊建物を特定し、Ye ら²⁰⁾は複数の機械学習アルゴリズムを組み合わせることで損傷箇所の検出精度を高め、Tu ら²¹⁾は災害前後の画像の差分から損壊領域を特定した。近年ではドローンの普及により高解像度な空撮画像の活用も進み、神野ら²²⁾はインスタンスセグメンテーションにより屋根の損傷度を定量的に分類し、Duarte ら²³⁾はオルソ画像から建物外観の損傷把握の有効性を示した。しかし、これらの 2 次元画像は取得方法を問わず、屋根に損傷がなくとも家屋全体が傾斜している場合など、上方からの撮影では検知できない 3 次元的な構造変状を捉えられないという根本的な制約を有する。

こうした制約を補完する手法として、LiDAR や SfM など 3 次元情報を取得できる技術の活用が注目されている。Maturana ら²⁴⁾はボクセルベースの 3 次元 CNN である VoxNet を提案して 3 次元形状認識における深層学習の有用性を示したが、被災地のような広域かつノイズの多い環境では、ボクセル化に伴う計算コストの増大や解像度制約による微細な形状変化の消失が課題となる。これに対し Sun ら²⁵⁾は都市スケールの点群に深層学習を適用して屋根・壁のセグメンテーションと屋根形状の再構築を実現し、Ntiyakunze ら²⁶⁾は点群の空間依存関係を利用して床、柱、梁といった構造要素を自動分割した。また、Xiu ら²⁷⁾は航空機 LiDAR 点群から倒壊建物を検出し、Folk²⁸⁾は PCA から得られる固有値比に基づく指標により目視では困難な構造的歪みを定量的に捉えた。しかし、これらの多くは都市計画や維持管理を主目的とし、あるいは個別

に切り出した家屋への手動処理にとどまっており、被害認定に不可欠な傾斜度算出を都市スケールで自動的に行う研究は限られている。

以上の既往研究をふまえると、衛星・航空画像に基づく手法は広域被害把握には有効であるが建物全体の变形や傾斜の定量化には限界があり、3次元点群に基づく手法は部材抽出や倒壊検出には有効であるものの、傾斜度算出への応用を明確に意識した研究は十分とはいえない。そこで本研究では、ドローンに搭載したLiDARで取得した高解像度3次元点群データに深層学習を適用し、家屋の構造部を自動的に抽出したうえで、幾何学的解析により傾斜度等を算出して被災度を判定する一連の手法を構築することを目的とした。具体的には、深層学習による点群のセマンティックセグメンテーション、家屋単位での点群分割、数理モデルによる傾斜度算出と被害判定から構成される手法を提案し、能登半島地震の被災地で取得した実データを用いてその有効性を検証する。

2 研究手法

2-1 研究対象地域と取得データ

本研究では、令和6年能登半島地震により被災した石川県河北郡内灘町、珠洲市蛸島町、七尾市田鶴浜町の3地域を対象とした(図1)。これらの地域には、液状化による傾斜被害や強震による倒壊・部分損傷が混在している。点群データは、LiDARセンサを搭載したドローンを用いて、2024年5月15日から17日にかけて、撮影高度25mまたは50mで取得した。取得したデータは、各点がxyz座標とRGB情報を持つ都市スケールの高密度3次元点群である。

分類対象は、Roof(屋根)、Wall(壁)、Ground(道路や庭を含む地面)、Others(植生、電柱、車両等)の4クラスとした。学習データには七尾市、内灘町の8データ(総点群数63,217,352点)、検証データには珠洲市の4データ(総点群数6,887,898点)を用いた。学習データにおけるクラス分布は、Roof 27.0%、Wall 10.1%、Ground 35.5%、Others 27.4%であり、Wallクラスの割合が小さい不均衡が存在する。そのため、後述する損失の重み付けに加え、データ拡張として5%のランダムドロップアウトを適用したうえで、建物が重力方向に整列していることを踏まえ、Z軸周りに0度、90度、180度、270度の回転処理を行った。

2-2 点群データのセマンティックセグメンテーション

3次元点群の処理では、ボクセル化^{24)・29)}や多視点画像の投影³⁰⁾といった従来手法には、計算コストの増大や幾何情報の欠損といった課題があった。これに対し、Qiらにより提案されたPointNet³¹⁾は、非構造の点群を直接ニューラルネットワークに入力し、各点に独立に多層パーセプトロン(MLP)を適用したのちMax Poolingにより順序不変なグローバル特徴を抽出する手法である。しかし、PointNetは全点を一括処理するため、近傍点同士の関係性や局所的な幾何構造を十分に捉えられないという課題を有していた。




図1 研究対象地域(内灘町、珠洲市、七尾市)




図2 PointNet++の階層的ネットワーク構造³²⁾

本研究では、これを改良した PointNet++³²⁾を採用した(図2)。PointNet++は、Farthest Point Samplingによる代表点抽出、近傍探索によるグルーピング、局所領域へのMini-PointNet適用からなるSet Abstraction(SA)モジュールにより、低次の幾何特徴から高次の意味特徴へと階層的に学習する。セマンティックセグメンテーションでは入力と同解像度の予測が必要となるため、Feature Propagation(FP)モジュールによりダウンサンプリングした特徴を元の点群密度まで補間し、エンコーダ側の対応階層の特徴とスキップ接続することで、局所的な詳細とグローバル特徴の双方を保持する。

実装には、GitHub上で公開されている屋内環境向けのオープンソースをベースとし、本研究の対象である広域屋外データに適用できるように、入力層やハイパーパラメータの調整を行った。具体的には、ブロックサイズを1mから20mへ拡張し、ストライドを5mとして検出漏れを防ぐとともに、座標の正規化により位置関係の学習を強化した。モデルは4層のSA層と4層のFP層で構成し、分類クラスは前述の4クラスとした。最適化関数にはAdam(初期学習率0.001)を用い、ラベル平滑化を適用した重み付きCross Entropyを損失関数とした。クラス不均衡を緩和するため、サンプル数の少ないWallクラスの重みを1.520から1.976に増加させ、Roofを1.095、Groundを1.000、Othersを1.090とした。

性能評価には、IoU、mIoU、Overall Accuracy(OA)、Mean Class Accuracy、Precision、Recall、F1-scoreを用いた。真陽性をTP、真陰性をTN、偽陽性をFP、偽陰性をFNとすると、各指標は式(1)~(6)で定義される。なお、Cはクラス数、全点数は検証データの総点数を表す。

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$F1 - score = \frac{2(Precision \times Recall)}{Precision + Recall} \quad (3)$$

$$IoU = \frac{TP}{TP + FP + FN} \quad (4)$$

$$mIoU = \frac{1}{C} \sum IoU_i \quad (5)$$

$$OA = \frac{\sum TP_i}{\text{全点数}} \quad (6)$$

2-3 家屋単位での点群分割

都市スケールの点群から家屋単位の解析を行うため、国土地理院が提供する建物外周線データを用いて家屋ごとの点群を抽出した。処理手順は、セグメンテーション結果のUTM座標系への変換、建物外周線データとの重ね合わせ、外周線への一定距離のバッファ処理、そして外周線内点群の抽出と家屋単位での分割である。このうち、バッファ処理は、座標誤差や点群欠損への対応を目的としている。分割後の各家屋点群は、xyz座標、RGB情報、クラスラベルを保持する独立ファイルとして保存される(図3)。なお、点群数が極端に少ない家屋は平面推定の信頼性が低いため解析対象から除外しており、解析対象となった家屋は全体の約95%であった。




図3 家屋ごとの切り出し結果

2-4 傾斜度算出と被害判定

家屋一棟ごとに分割された点群に対し、RANSACによる平面推定、ベクトル解析による幾何的特徴抽出、主成分分析（PCA）による局所形状評価を統合した数理モデルを適用し、傾斜度等を算出した。まず、抽出された屋根・地面点群に対しRANSAC³³⁾法を適用し、外れ値の影響を排除しつつ支配平面の法線ベクトルを頑健に推定する（図4）。3次元空間における平面は式(7)で表され、その法線ベクトルは $\mathbf{n} = (a, b, c)$ で与えられる。

$$ax + by + cz + d = 0 \quad (7)$$

次に、切妻屋根を構成する2平面の法線ベクトル $\mathbf{n}_1, \mathbf{n}_2$ の外積³⁴⁾から棟方向ベクトル $\mathbf{r}$ を式(8)により求め、これと鉛直軸とのなす角から家屋全体の傾斜度を算出する。

$$\mathbf{r} = \mathbf{n}_1 \times \mathbf{n}_2 \quad (8)$$

さらに、屋根点群の局所近傍の分散行列の固有値 $\lambda_1 \geq \lambda_2 \geq \lambda_3$ を求め、最小固有値の寄与率を屋根の荒れ具合（Roughness）の指標として式(9)のように定義した³⁵⁾（図5）。この値が大きいほど屋根面の平滑性が失われ、瓦礫化や崩壊が進行していることを示唆する。加えて、屋根点群と地面点群の平均高さの差を相対高さとして算出し、圧壊の有無を推定する。

$$Roughness = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} \quad (9)$$

これらの指標を統合し、各家屋を全壊、損傷あり、損傷なしの3段階で判定した。内閣府の住家被害認定基準を参照しつつ、屋根点群に基づく評価という本手法の特性を考慮して閾値を設定した。全壊は、相対高さが2.5m以下（一階層の圧壊を示唆）、屋根の荒れ具合が0.08超（原形をとどめない瓦礫状態）、または傾斜度が5.0度（1/11.4）以上のいずれかに該当するものとした。損傷ありは、屋根の荒れ具合が0.04以上、または傾斜度が2.86度（1/20）以上5.0度未満のものとした。いずれにも該当しないものを損傷なしとした。なお、被害認定では本来6段階の評価が行われるが、本手法では屋根点群から外壁や基礎の損傷割合を直接評価することが困難であるため、これらを「損傷あり」として一括して扱っている。




図 4 RANSAC による平面推定例




図 5 PCA による局所形状評価の比較


3 結果と考察

3-1 セグメンテーション結果


正解ラベルおよび提案手法によるセグメンテーション結果を図 6～図 8 に示す。いずれも上段が正解ラベル、下段が提案手法による結果であり、屋根を青、壁を緑、地面を赤、その他を黄色で表している。

図 6 は検証対象地域全体の結果である。一部に壁（緑）の誤分類が見られるものの、全体としては正解ラベルとおおむね一致しており、電線や塀などもその他クラスとして高精度に分類されている。なお、検証に用いた珠洲市のデータは学習に使用していない地域であり、未学習地域に対しても全域にわたり高い再現性が得られたことは、本手法が特定地域に過適合せず一定の汎化性能を有することを示している。また、電線、塀、樹木といった非建物の線状、小規模な物体がその他クラスへ安定して分類されている点は、多様な物体が混在し家屋が密集する都市点群においても、後段の幾何解析の対象となる屋根、地面を選別できることを意味する。一方、局所的に見られる壁の誤分類は、3.2 節で定量的に示す Wall クラスの分類精度の低さに対応しており、俯瞰計測に起因する壁面点群の不足という本手法の課題を反映したものと考えられる。

図 7 は、損傷が軽微な家屋を拡大した結果である。対象家屋の屋根は複数の面で構成され、敷地内に樹木も存在するが、これらもおおむね正確に分類されている。特に、建物中央手前の玄関ポーチの屋根のような小さな構造物も、一部が壁と誤分類されているものの大部分が屋根として適切に分類されており、今後の傾斜度算出といった幾何学的解析を行う上で十分な精度が得られている。このことは、被害が比較的軽微で原形を保つ家屋に対しては、提案手法が屋根面を安定して抽出でき、後段の傾斜度算出に必要な平面情報を十分な品質で供給できることを示している。一方で、玄関ポーチ（下屋）のような小規模かつ点群が疎になり




(a) 正解ラベル




(b) セグメンテーション結果

図6 検証対象地域全体の分類結果




(a) 正解ラベル




(b) セグメンテーション結果

図7 軽微な損傷を受けた家屋の分類結果



(a) 正解ラベル



(b) セグメンテーション結果

図8 倒壊・傾斜による大規模損傷家屋を含む領域の分類結果

やすい部位では局所的に壁への誤分類が生じており、これは後述する壁クラスの誤分類傾向と同根の課題であって、軒先や小屋根の形状をより精緻に捉える局所特徴の強化が有効と考えられる。

図8は、倒壊あるいは傾斜した家屋を含む領域の結果である。左から、損傷の少ない家屋、1階部分が圧壊して傾斜した家屋、全壊した家屋が密集する領域が含まれる。損傷の少ない家屋は屋根、壁ともに境界付近まで正確に分類され、傾斜した家屋も主要な構造は正しく認識されている。一方、全壊家屋が密集する領域では、地面の一部が壁として誤分類される傾向が見られた。これは、当該エリアの地面に瓦礫が散乱し平坦でなかったことが原因と考えられる。以上より、本手法は軽微な損傷の家屋では高精度に構造部を抽出できる一方、全壊に近い家屋では瓦礫等の影響で屋根や地面を壁と誤分類する場合があることがわかった。

3-2 性能評価

提案手法の全体的な性能評価結果を表 1 に、クラス別の分類性能を表 2 に示す。検証データセット全体に対する mIoU は 77.3%，OA は 88.6%，Mean Class Accuracy は 87.1% であり、高い分類性能が確認された。クラス別では、Roof と Ground の IoU がそれぞれ 84.8%，87.0% と非常に高い一方、Wall の IoU は 59.4% と低く、F1-score も 74.6% と 4 クラス中で最も低かった。Wall クラスの分類性能が低い主な要因は、学習・検証データにおけるクラス不均衡にあると考えられる。学習データにおける Wall の割合は 10.1% であり、最も多い Ground の 3 分の 1 以下である。損失の重み付けによる緩和を行ったが、IoU は 59.4% にとどまった。

混同行列（図 9）を見ると、本来は Roof や Others である点の一部を Wall と誤分類していることがわかる。これは、点群が疎になる屋根の軒先や、家屋に隣接する塀、散乱した瓦礫を壁と誤認していることが原因と考えられる。加えて、ドローンを俯瞰的に飛行させてデータを取得する性質上、垂直面である壁は水平面である屋根や地面に比べて点群数が少なくなり、特徴の学習に必要なデータが不足していた可能性がある。

表 1 セグメンテーションの全体性能

評価指標	算出値 (%)
mIoU	77.3
OA	88.6
Mean Class Accuracy	87.1

表 2 クラス別の分類性能

クラス名	IoU (%)	Precision (%)	Recall (%)	F1-score (%)
Roof	84.8	92.2	91.4	91.8
Wall	59.4	68.7	81.8	74.6
Ground	87.0	94.2	91.9	93.0
Others	78.0	92.4	83.4	87.6




図 9 混同行列

3-3 家屋の被害判定結果

3.2 節のセグメンテーション結果を基に、家屋単位での点群分割を行い、各家屋の傾斜度、相対高さ、荒れ具合を算出して被災度を判定し、目視判定結果と対応づけた判定結果を表 3 に示す。目視で損傷なしとした家屋（表 3 の損傷なし(1), (2), (3), 図 10）のうち 2 例は、屋根の荒れ具合により「損傷あり」と判定された。空撮画像と比較すると、これらはわずかに瓦が剥離しており、実際には損傷なしとは言い切れない状態であった。図 10 には、損傷なしと目視判定された家屋の屋根形状データ（左）と空撮画像（右）を示しているが、このうち「損傷あり」と判定された家屋では、空撮画像で瓦が部分的に剥離している箇所に対応して、屋根形状データ上にも局所的な凹凸が認められ、荒れ具合が 0.076 まで上昇している（表 3）。一方、判定が損傷なしのまま維持された家屋では、屋根面が平滑に再構成され、荒れ具合も 0.038 にとどまる。このことから、図 10 は、屋根の荒れ具合という幾何指標が、目視では見落とされやすい軽微な瓦の剥離を捉えていることを視覚的に裏づけている。

また、目視で損傷ありとした家屋（表 3 の損傷あり(1), 図 11）では、屋根部分に大きな剥離が確認され、屋根の荒れ具合に基づく「損傷あり」判定は妥当であった。ただし、この家屋と、損傷なしから「損傷あり」と判定された家屋とでは損傷の程度が大きく異なっており、両者を同一区分とすることには検討の余地がある。一方、全壊と判定した家屋（表 3 の全壊(1), (2), (3), 図 12）は、相対高さ、傾斜度、荒れ具合のいずれにおいても全壊基準に該当し、空撮画像からも大規模な崩壊が確認され、判定は妥当であった。

これらより、本手法は軽微な屋根損傷、傾斜、低層化を伴う圧壊といった異なる被害形態を識別できることが確認された。特に、損傷なしと目視判定された家屋が屋根の荒れ具合により「損傷あり」と判定された

表 3 家屋の被災度判定結果

目視判定	判定結果	被害の原因	相対高さ	傾斜度	荒れ具合
損傷なし(1)	損傷なし	-	4.90	1/15.4	0.038
損傷なし(2)	損傷あり	屋根損傷	2.95	1/17.8	0.076
損傷なし(3)	損傷あり	屋根損傷	4.73	1/24.3	0.076
損傷あり(1)	損傷あり	屋根損傷	3.24	1/34.1	0.053
全壊(1)	全壊	圧壊、傾斜	2.14	1/11.3	3.390
全壊(2)	全壊	圧壊、傾斜	2.00	1/7.64	1.460
全壊(3)	全壊	屋根損傷、圧壊、傾斜	1.61	1/3.75	0.080




図 10 損傷なしと判定された家屋の屋根形状データ（左）と空撮画像（右）




図 11 損傷あり(1)と判定された家屋の屋根形状データ（左）と空撮画像（右）




図 12 全壊と判定された家屋の屋根形状データ（左）と空撮画像（右）

事例（図 10）は、本指標が瓦のわずかな剥離にも反応する高い感度を持つことを示す一方で、過検出につながる可能性も示唆しており、損傷の程度に応じた段階的な閾値設定の必要性を裏づけている。また、損傷あり(1)（図 11）と全壊（図 12）の屋根形状を比較すると、前者では屋根面の平滑性が部分的に保たれるのに対し後者では相対高さの低下と荒れ具合の顕著な増大が認められ、これらの幾何指標が被害形態の違いを定量的に反映していることが視覚的にも確認できる。なお、図 11 の家屋では、屋根面の大半が平面として再構成される一方で、剥離に由来する乱れが局所的に現れるのに対し、図 12 の家屋では、屋根形状データそのものが原形を失って点群が大きく散乱し、圧壊と急峻な傾斜が同時に認められる。このように図 11, 12 は、荒れ具合、相対高さ、傾斜度の数値差（表 3）が屋根形状データの見え方の違いとして明瞭に対応することを示しており、本手法の幾何指標が被害形態の識別に有効であることがいえる。

3-4 実測値との比較

ドローンに基づく傾斜度推定の精度を検証するため、一部の被災家屋について地上からデジタルカメラで撮影し傾斜度を実測した（図 13, 表 4）。算出値と実測値には、家屋 1 を除いて比較的大きな乖離が見られた。これは、本手法が屋根点群全体を対象として家屋全体の平均的な傾斜特性を評価しているのに対し、実測は壁や柱といった局所的な構造部材を基準としており、評価対象とする構造スケールが本質的に異なることに起因すると考えられる。

もっとも、内閣府の被害認定の 6 段階基準に照らすと、家屋 1～4 の判定はそれぞれ全壊、全壊、準半壊



図 13 家屋 1 の空撮画像と計測の様子

表 4 実測値を含む家屋の被災度判定結果

	判定結果	被害の原因	相対高さ	傾斜度(算出)	傾斜度(実測)	荒れ具合
家屋 1	全壊	傾斜, 屋根損傷	4.99	1/2.04	1/1.54	0.0447
家屋 2	全壊	屋根崩壊	5.85	1/143.2	1/8.14	0.1042
家屋 3	損傷あり	屋根損傷	6.57	1/133.3	1/26.0	0.0564
家屋 4	全壊	屋根崩壊	5.97	1/220.3	1/7.12	0.0828

以上, 全壊となり, 傾斜度が正確に算出されない場合でも, 相対高さや荒れ具合を併用することで妥当な判定が得られた. 特に荒れ具合は屋根の崩壊の程度を直接的に反映するため, 傾斜度の誤差を補完する有効な指標であった. これは, 複数の幾何指標を統合する本手法の有効性を示している.

3-5 考察

本研究の検証結果から, 提案手法は屋根・地面クラスにおいて約 85%という高い IoU を達成し, 複雑な都市点群から主要構造物を高精度に抽出できることが示された. 特に, 傾斜した家屋に対しても主要な構造を認識できた点は, 従来の 2 次元画像では困難であった 3 次元的な被害状況の把握に向けて重要である. これは, 先行研究が示してきた 3 次元点群による構造把握の有効性を, 被害認定という防災実務の文脈へと展開しうることを示唆するものである.

一方, 壁クラスの分類精度は IoU 59.4%と他クラスに比べて低く, 本手法の主要な課題である. この要因として, 第一に学習データにおけるクラス不均衡が挙げられ, 損失の重み付けによる緩和を行ったものの十分ではなかった. 第二に, ドローンを俯瞰的に飛行させてデータを取得する性質上, 鉛直面である壁は水平面である屋根や地面に比べて点群密度が低くなり, 特徴学習に必要なデータが本質的に不足する. 混同行列に見られた屋根の軒先や隣接する塀の壁への誤分類も, これらの幾何学的, データ量的要因によるものと考えられる. 今後は, 不均衡データに特化した学習手法やより局所的な情報を捉えるモデルの導入に加え, 定期的な旋回飛行や可能な範囲での低空飛行, あるいは据置型の 360 度計測機器の併用など, 壁面データの取得方法そのものの高度化が必要である.

被害判定については, 傾斜度, 相対高さ, 荒れ具合という複数の幾何指標を統合することで, 傾斜度の算出誤差を補完し妥当な判定が得られることを確認した. これは単一指標に依存しない本手法の頑健性を示すものである. ただし, 軽微な屋根損傷から全壊に至らない損傷までを一律に「損傷あり」とする現行の 3 区

分は粗く、実務で行われる無被害を含む 6 段階評価との対応づけには課題が残る。屋根点群に基づく幾何指標は建物全体の変状を俯瞰的に捉える上で有効である一方、外壁や基礎の局所的な損傷割合を直接評価することはできない。したがって、閾値の妥当性検証と判定区分の細分化に加え、空撮画像から得られる屋根損傷分類の結果や、必要に応じて外壁の高解像度画像解析の結果と統合した、マルチモーダルな評価体系の構築が望まれる。

実用面では、本手法は現地調査を完全に代替するものではないものの、広域被災地において短時間で被害傾向を把握し、全壊候補や優先調査対象を抽出するスクリーニング技術として有用である。点群に基づく定量指標は調査員の主観によるばらつきを低減し、判定の客観性向上にも資する。また、上空からデータを取得でき、被災地に立ち入らずに評価できる点は、安全面や即時性の観点からも大きな利点である。なお、本研究の検証は能登半島地震の特定地域を対象としたものであり、地域特性や家屋構造の異なる他の被災地への適用可能性、すなわち汎化性能の検証は今後の重要な課題である。

4 まとめ

本研究では、罹災証明書発行の迅速化と客観性向上を目的として、ドローンで取得した高解像度 3 次元点群データを用い、深層学習による構造部抽出と幾何的解析に基づく家屋被害判定手法を構築した。都市スケールの点群に PointNet++ を適用した結果、mIoU 77.3%、OA 88.6% を達成し、特に屋根・地面クラスで高い抽出性能を示した。壁クラスにはクラス不均衡や俯瞰計測に起因する課題が残るものの、傾斜度算出に必要な屋根平面の抽出精度は確保できた。さらに、建物外周線データを用いて家屋単位に点群を分割し、RANSAC・ベクトル解析・PCA を統合した数理モデルにより傾斜度、相対高さ、荒れ具合を算出して、全壊、損傷あり、損傷なしの 3 段階判定を実現した。

本手法は現地調査を完全に代替するものではないが、広域の被災地において短時間で被害傾向を把握し、全壊候補や優先調査対象を抽出するスクリーニング技術として有用であり、被害認定調査の効率化と罹災証明書発行の迅速化への寄与が期待される。今後は、壁クラスの分類精度の向上、被害判定に用いる閾値の妥当性検証と判定区分の細分化、および空撮画像から得られる屋根損傷分類結果との統合によるマルチモーダルな被災度判定体系の構築を進め、自治体との実証的検証を通じた社会実装を目指す。

【参考文献】

- 1) 田中孝和：被災者生活再建支援制度と罹災証明書について(1)、福岡大学法学論叢、第 68 巻第 3 号、pp.303-326、2023.
- 2) 内閣府（防災担当）：災害に係る住家被害認定業務 実施体制の手引き、2020.
- 3) 自治労石川県本部：能登半島地震による被災自治体におけるメンタルヘルス等に関する実態調査結果、2024.
- 4) 内閣府（防災担当）：災害に係る住家被害認定基準運用指針（令和 5 年 3 月改訂）、2023.
- 5) 折橋祐希、浦川豪：風水害における住家の被害認定調査の簡易化手法の現状と課題の考察、地域安全学会論文集、Vol.41, No.S09, pp.237-252, 2022.
- 6) 内閣府（防災担当）：阪神・淡路大震災教訓情報資料集 2-03.被害把握・り災証明【01】被害調査、【02】り災証明書の発行.
- 7) 復興庁：阪神・淡路大震災後の住宅再建および応急仮設住宅の推移、震災の教訓と復興施策アーカイブ.
- 8) 復興庁：阪神・淡路大震災後の住宅再建および応急仮設住宅の推移、2013.
- 9) 内閣府：阪神・淡路大震災の教訓、内閣府防災情報ページ.
- 10) 田中正人、高橋和子、上野易弘：応急仮設住宅における「孤独死」の発生実態とその背景、日本建築学会計画系論文集、第 75 巻、第 654 号、pp.1815-1823, 2010.
- 11) 仙台市：第 9 章 罹災証明・災害給付、仙台市震災復興資料、2012.
- 12) 藤生慎、沼田宗純、大原美保、目黒公郎：東日本大震災における自治体の建物被害認定調査の実践状況に関する考察、生産研究、Vol.64, No.4, pp.433-437, 2012.
- 13) 熊本県教育庁：熊本地震の対応に関する検証報告書、2018.
- 14) 総務省九州管区行政評価局：大規模災害時における罹災証明書の交付等に関する実態調査—平成 28 年熊本地震を中心として—、行政評価調査報告書、2017.
- 15) 益城町：平成 28 年熊本地震による益城町災害廃棄物処理事業記録、第 3 章 損壊家屋等の解体・撤去、2018.

- 16) Wang, Y., Chew, A. W. Z., and Zhang, L.: Building damage detection from satellite images after natural disasters on extremely imbalanced datasets, Automation in Construction, Vol.140, 104328, 2022.
- 17) Ji, M., Liu, L., Buchroithner, M., and Zhang, Z.: Building damage detection from satellite imagery using convolutional neural networks, ISPRS Journal of Photogrammetry and Remote Sensing, Vol.142, pp.45-54, 2018.
- 18) Matsuoka, M. and Yamazaki, F.: Use of Satellite SAR Intensity Imagery for Detecting Building Areas Damaged Due to Earthquakes, Earthquake Spectra, Vol.20, No.3, pp.975-994, 2004.
- 19) Li, Y., Hu, W., Dong, H., and Zhang, X.: Building Damage Detection from Post-Event Aerial Imagery Using Single Shot Multibox Detector, Applied Sciences, Vol.9, No.6, 1128, 2019.
- 20) Ye, S.-J., Nourzad, S., Pradhan, A., Bartoli, I., and Kontsos, A.: Automated Detection of Damaged Areas after Hurricane Sandy using Aerial Color Images, Computing in Civil and Building Engineering, pp.1796-1803, 2014.
- 21) Tu, J., Li, D., Feng, W., Han, Q., and Sui, H.: Detecting Damaged Building Regions Based on Semantic Scene Change from Multi-Temporal High-Resolution Remote Sensing Images, ISPRS Int. J. Geo-Information, Vol.6, No.5, 131, 2017.
- 22) 神野麻衣, 久保栞, 吉田秀典: インスタンスセグメンテーションを利用した被災屋根の検出, 計算数理工学論文集, Vol.24, pp.97-105, 2024.
- 23) Duarte, D., Nex, F., Kerle, N., and Vosselman, G.: Towards a more efficient detection of earthquake induced building damage using UAV images, ISPRS Journal of Photogrammetry and Remote Sensing, Vol.140, pp.1-14, 2018.
- 24) Maturana, D. and Scherer, S.: VoxNet: A 3D Convolutional Neural Network for Real-Time Object Recognition, Proc. IEEE/RSJ IROS, pp.922-928, 2015.
- 25) Sun, X., Guo, B., Li, C., Sun, N., Wang, Y., and Yao, Y.: Semantic Segmentation and Roof Reconstruction of Urban Buildings Based on LiDAR Point Clouds, ISPRS Int. J. Geo-Information, Vol.13, No.1, 19, 2024.
- 26) Ntiyakunze, J. and Inoue, T.: Segmentation of Structural Elements from 3D Point Cloud, Sensors, Vol.24, No.3, 1924, 2023.
- 27) Xiu, H., Shinohara, T., Matsuoka, M., Inoguchi, M., Kawabe, K., and Horie, K.: Collapsed building detection using 3D point clouds and deep learning, Remote Sensing, Vol.12, No.24, 4057, 2020.
- 28) Folk, B. D.: Evaluating Geometric Properties of Structural Damage in 3D Point Cloud Data, Master's Thesis, Univ. of California, Berkeley, 2022.
- 29) Wu, Z., Song, S., Khosla, A., Yu, F., Zhang, L., Tang, X., and Xiao, J.: 3D ShapeNets: A Deep Representation for Volumetric Shapes, Proc. IEEE CVPR, pp.1912-1920, 2015.
- 30) Su, H., Maji, S., Kalogerakis, E., and Learned-Miller, E.: Multi-view Convolutional Neural Networks for 3D Shape Recognition, Proc. IEEE ICCV, pp.945-953, 2015.
- 31) Qi, C. R., Su, H., Mo, K., and Guibas, L. J.: PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation, Proc. IEEE CVPR, pp.652-660, 2017.
- 32) Qi, C. R., Yi, L., Su, H., and Guibas, L. J.: PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space, NeurIPS, Vol.30, pp.5099-5108, 2017.
- 33) Fischler, M. A. and Bolles, R. C.: Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography, Communications of the ACM, Vol.24, No.6, pp.381-395, 1981.
- 34) Strang, G.: Introduction to Linear Algebra, 6th ed., Wellesley-Cambridge Press, 2023.
- 35) Jolliffe, I. T.: Principal Component Analysis, 2nd ed., Springer, 2002.

〈発 表 資 料〉

題 名	掲載誌・学会名等	発表年月
Semantic Segmentation of Building Components from UAV LiDAR Point Clouds for Structural Analysis	The 46th Asian Conference on Remote Sensing 2025 (ACRS2025 Proceedings)	October 2025