# 複数の立体物で構成された三次元点群の切り分け手法の検討

小倉 且也[1] 山田 遊馬[1] 梶田 宗吾[1] 山口 弘純[1] 東野 輝夫[1] 高井 峰生[1,2]

**概要**：近年，ドローンなどが捉えた地表のステレオ空撮画像を統合し，三次元点群を生成することで地表を立体的に捉える試みがなされている．例えば地震災害時の地表物の高度データを三次元情報として可視化すれば，被災による家屋やビルの形状変化（倒壊や傾斜）などの把握が容易になり，状況理解に大きく寄与する．ステレオ空撮画像から生成した点群は通常，各平面座標における物体の高さや色の情報のみを有するため，地表の物体は区分されていない．にもかかわらず，それら点群の分布状態をもとに地表の物体を区分できれば，物体毎の三次元形状情報を含む価値あるデータとなり，家屋毎の被災状況の把握，車両分布の把握，あるいは山間地域における樹木の分布状況やその統計化などに活用できる．本稿では，ステレオ空撮画像から生成した点群を物体毎に区分する手法を提案する．提案手法では，ステレオ空撮画像から市販のツールにより生成された点群に対し，国土地理院の標高データを用いて地表面に相当する点を除去するとともに，点間距離に基づくクラスタリングと，各クラスタ（部分点群）が占有する空間サイズに基づくフィルタリング，さらにクラスタ間の二次元平面上の重複度に基づく再統合などを行い，個々の物体に相当するクラスタを推定する．提案手法に対して住宅地を模した環境や，大阪北部の山間部などで撮影した画像などを用いた評価を実施した．地表面の除去については，起伏のある場合においてもそのほとんどを除去できたのみならず，特に平面上では残った物体の高さと実際の物体の高さの間の誤差を 5%以内に抑えた上で除去可能であることが確認できた．また物体間の切り分けについても，提案手法を構成する各処理が精度向上に貢献しており，結果として実用可能な程度の精度をもって切り分けられることを確かめられた．

## 1. はじめに

ドローンなどが捉えた複数の空撮画像から三次元点群などを生成する，SfM（Structure from Motion）[1] とよばれる技術が近年注目を集めている．SfM はいわゆる写真測量の一種であり，ドローンであればその三次元空間座標と撮影角を GPS やセンサーで把握し，撮影情報と撮影画像から対象物の幾何学形状を復元する．こうした技術を活用することで，従来高コストとされてきた形状把握作業（地表物測量）の効率化が期待されている．

そういった地表物測量は様々なシーンで必要とされている．例えば IoT 機器の高度化に伴い，森林地帯や山間部にフィールドセンサーを設置し，動物の生態や環境をセンシングする試みも増加しているが，そのようなセンシングシステムでは，フィールドセンサーから得られたデータを，携帯網や近年注目を集めている LPWA などの無線通信を活用して無線局へ転送する．しかし，特に山間地帯や河川域などでは，樹木や地形の起伏など，通信の障害となる様々な要因を考慮し，すべてのフィールドセンサーから安定かつ効率的にデータ集約が実現するよう，無線局の配置箇所や配置台数を工夫する必要がある．また，広域を対象としたセンシングでは無線局間のマルチホップ通信が必要となる場合も多く，通信可用性の検証が必須となる．にもかかわらず，現場での検証は容易でないことから，対象地形をモデリングし，シミュレーション等によって事前に最適運用を検討することが望ましい．特に地形のモデリングは手作業で行うことが多いものの，対象領域次第では建造物や樹木などのオブジェクトが非常に多くなるため，その再現のための手間は少なくない．ドローンによる空撮画像が活用できれば，そういった三次元オブジェクトの把握と再現が容易になり，作業効率化に繋がると期待される．

また，災害時における被災状況把握への活用も期待される．大規模地震の直後などでは道路が通行不能となり，住民の移動による渋滞も頻発する．また被災状況を把握する人員も不足するため，現地で家屋の倒壊等の調査を行うには限界がある．これに対し，簡易かつ迅速に上空からの撮影を行えるドローンが注目を集めている．被災前後の三次元測量結果を可視化すれば，状況の変化を捉えることが容

[1] 大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University
[2] カリフォルニア大学ロサンゼルス校
University of California, Los Angeles

© 2018 Information Processing Society of Japan

易になるのみならず，建造物の倒壊や傾斜などの目視発見も支援できる．

ステレオ空撮画像から生成した点群は通常，各平面座標における物体の高さや色などの情報のみを有しており，地表の物体は区分されていない．すなわち，どの箇所が地表面や物体（建造物や車両，樹木など）に相当するのかの情報を有しておらず，単純な座標点の集合でしかない．にもかからわず，それら点群の分布状態をもとに物体を区分できれば，物体毎の三次元形状情報を含む価値あるデータとなる．例えば前述の地形モデリングでは，電波減衰率など，現場の個々の物体に対するパラメータを設定でき，高度で精密なネットワークシミュレーションも可能となる．被災状況把握においても，家屋毎での被災の程度や状況の把握，車両分布の把握などに効力を発揮する．これらをふまえると，空撮画像から生成した点群をより効果的に活用するためには，検出した点群から個々の物体を推定できることが望ましい．そのためには，点群を物体毎に区分する必要がある．

本稿では、ステレオ空撮画像から生成した点群を物体毎に区分する手法を提案する．提案手法では，ステレオ空撮画像から市販のツールにより生成された点群に対し，国土地理院の標高データを用いて地表面に相当する点を除去する．次に，点間距離に基づくクラスタリング（分割）と，各クラスタ（部分点群）が占有する空間サイズに基づくフィルタリング、さらにクラスタ間の二次元平面上の重複度に基づく再統合などを行い，点群を個々の物体に相当するクラスタの切り分けを図る．

提案手法に対して，住宅地を模した環境や，大阪北部の山間部などで撮影した画像を用いた評価を実施した．地表面の除去については，起伏のある場合においてもそのほとんどを除去できたのみならず，特に平面上では残った物体の高さと実際の物体の高さの間の誤差を 5%以内に抑えた上で除去できることが確認できた．また物体間の切り分けについても，提案手法を構成する各処理が精度向上に貢献しており，結果として実用可能な程度の精度をもって切り分けられることを確かめられた．

## 2. 関連研究

### 2.1 ドローンを利用した物体検出

本研究の主題は，ドローンが捉えた空撮画像から生成した点群の活用であるが，ドローンの活用による，様々な地域やサービスにおける状況把握を目指した研究は数多くなされている．例えば [2] では，ドローンが捉えた画像にハフ変換をはじめとするアルゴリズムを適用することで，ドローン飛行において特定の形状や色を持つ物体を検出しトラッキングする方法を提案している．[3] では，機体の慣性データを用いてドローンから撮影した動画から物体を検出および追尾するアルゴリズムを開発し，一連の処理を低消費電力な小型ドローン内で完結させている．また，[4] では，ドローンから撮影した室内の画像に対して機械学習を適用することで，室内にある家電などの物体の認識を行なっている．[5] では，ドローンを自然保護の現場で利用することを目指し，ドローンから空撮した画像や動画に対する機械学習処理によって画像に映る動物の特定と個体数の計算を試みている．[6] は，都市環境を飛行したドローンが捉えた動画からの車両検出に取り組んでいる．

### 2.2 点群に対する地表面の抽出

提案手法では，点群から地表面を除去するにあたり，地表面に相当する点の抽出を行う．点群から地表面を抽出する方法についても先行研究が存在する．平坦な地表面をもつ領域を捉えた点群を対象とする場合は，地表面を 1 つの大きな平面として扱うことができる点に着目して RANSAC [7] などを利用した平面抽出を利用する例が多い．例えば [8] では，点群から平面などの基本図形を抽出する処理を確実かつ効率的に行うための改良版 RANSAC アルゴリズムを提案している．[9] では，点群の水平方向をあるウィンドウサイズで走査し，ウィンドウ内における点の高さの相対関係などに基づいて地表面を抽出する手法を提案している．

### 2.3 点群に対する物体の分類

点群が表すオブジェクトの属性判定などを行う方法論についてもいくつかの研究が存在する．例えば [10] では，地表面を除去した点群において，点間の距離関係に基づいて生成したグラフを用い，あらかじめ指定した点が属する物体と，そうでない部分（背景部）の 2 つに切り分ける手法を提案している．[11] では，点群の対象を都市部に絞り，LIDAR から生成した点群の各点に対して，機械学習に基づいて道路や建造物など 5 つの種類に分類することを目指している．

### 2.4 提案手法の位置づけ

これらに対し，提案手法では，まず地表面の分離については国土地理院が提供するデータを活用し，点群のみでの地表面抽出を目指してきた従来手法以上に精度の高い抽出を実現する点で大きく異なる．そのようなデータを活用することで，従来手法が苦手としている起伏の大きな地形についても適用可能となるなどの利点がある．特に山間部や河川行きは隆起や斜面など平地でない地形が多いことから，フィールドセンシングにおける地表把握での可用性が向上する意義は大きい．また，点群の物体ごとの切り分けについては，点間に基づく切り分けのみならず，その後の再統合処理やフィルタリング処理などを組み込むことで，屋外環境を捉えた点群を実用する上で重要である物体をそれぞれ切り出すことに成功しており，画像から生成された，完全な精度が期待できない点群に対する処理を実現している

© 2018 Information Processing Society of Japan

点において有用性が高い．

## 3. 提案手法

本研究では，入力として与えた点群に対して，地表面の除去，点群のクラスタリング，クラスタのフィルタリング，クラスタの再統合という 4 種類の処理を組み合わせることで，画像から生成された点群に対して，現実世界の物体の単位に近い形でこれを切り分ける．図 1 に本手法の概要を示す．本手法ではクラスタのフィルタリングをクラスタの再統合の前後に行うこととしている．

本章では，3.1 節において入力として与える点群の生成方法について説明し，3.2 節〜3.6 節において提案手法の詳細を述べる．

### 3.1 ドローン空撮画像からの点群生成

ドローンを利用して異なる角度から領域を捉えた複数の空撮画像を合成することで，点群を生成する技術がある．本手法では，SfM の技術に基づいて点群を生成するツールを用いることで，本手法を適用させる点群を作成した．

### 3.2 地表面の除去

地上に存在する複数の物体を区別するにあたり，まずは地表面を除去することで異なる位置にある複数の物体から点群の分布上の「連続性」を断つ必要がある．生成直後の点群は，地表および地上の物体が区別されていない．そのため，地表面の除去に先立ち地表面に相当する部分の抽出を図る．

本稿では，地表面の抽出に際して、国土地理院が提供する標高情報 [12] の数値標高モデルを活用した手法を提案する．数値標高モデルでは，国土の 5m 毎の標高情報を提供する．標高は海抜面から地表面までの高さを表すため，各点の $z$ 座標値と直下の標高情報の差分がある閾値よりも小さい場合に地表面として推定する．具体的には，以下の 3 ステップで推定を行う．

#### 3.2.1 標高情報の補間

画像から生成される点群は数 cm 単位で分布しているのに対して，数値標高モデルは 5m 毎の格子状で提供されており，標本点の平面的な密度が大きく不足している（図 2）．これに対し，点群内の各点において自身の高さと同地点の標高の比較を行えるよう，任意の 2 次元座標における標高情報を周囲の標本点に基づいて補間する．

任意の平面座標 $P(p_x, p_y)$ における標高の補間値 $h_P$ は，数値標高モデルで提供された周囲の 4 点から線形補間を用いて導出する．この周囲の 4 点の座標を $(l,t),(l+D,t),(l,t+D),(l+D,t+D)$ とし，それぞれの点の標高値を $h_A, h_B, h_C, h_D$ とする ($l \leq p_x < l+D, t \leq p_y < t+D$)．ここで $D$ は数値標高モデルの粒度を表しており，数値標高データでは $D = 5$[m] である．そして，標高の補間値 $h_P$ を次の式のように定義し，任意の点の標高を補間する．

$$\begin{aligned} h_P &= (1-r_x)(1-r_y)h_A + r_x(1-r_y)h_B \\ &\quad +(1-r_x)r_y h_C + r_x r_y h_D \qquad (1) \\ r_x &= \frac{p_x - l}{D} \\ r_y &= \frac{p_y - t}{D} \end{aligned}$$

#### 3.2.2 ヒストグラムに基づく閾値判定

この項では点群の標高情報と補間後の数値標高モデルの標高情報との相対値に基づいた地表面の閾値判定手法について述べる．ドローンで撮影した画像から点群を生成した場合，ドローンに内蔵されている高度計の精度の問題から，点群の各点が持つ海抜高度の基点が必ずしも数値標高モデルのそれと合致しないことがある．そのため，本手法では両者の間に生じた基点の違いに対応できるよう，点群を構成する全ての点 $P_i(p_x, p_y, p_z)$ について，3.2.1 項に基づいて導出された直下の標高推定値 $h_{(p_x,p_y)}$ との差 $d_i$ を導出し，$d_i$ の相対的な比較から地表面を推定する．

$$d_i = p_z - h_{(p_x,p_y)} \qquad (2)$$

本手法では，$d_i$ がある閾値以下の時にそれが地表面を表す点と見なすが，その閾値は $d_i$ の分布から決定する．点群に地表面が含まれる場合，$d_i$ の分布について，幅をパラメータとして与えた上でヒストグラムにまとめると，おおよそ図 3 に掲げるような形状を示すことが多い．[*1]

図 3 では，左ほど $d_i$ の値が小さく，点の標高と標高モデルとの標高差が小さいことを表している．ここで，グラフの左部から分布の変化を見た時に，大きな分布のピーク（第一ピークとよぶ）が見られることがわかる．これは地表面を表す点の集合であり，一般的に地表面は少なからぬ面積が画像に捉えられることから，このようなピーク値を形成すると考えられる（このときの $d_i$ が点群が全体的に有する誤差の最尤値となる）．なお，二つ目のピーク（第二ピークとよぶ）は家屋やビルなどの物体による点群により構成されたものである．この性質を踏まえて，第一ピークを包含する閾値設定を行うことで地表面を抽出できることと考えられる．なお，地表面を表す点の中で $d_i$ の値にばらつきが見られるのは，点の分布に幾らかの誤差が生じるためであり，そこで，誤差の分布が正規分布に基づくと仮定した上で，閾値を設定した．閾値の設定にあたり，第一ピークの頂点の $d_i$ を平均 $\mu'$ とみなし，その左側の標本のみを用いて擬似的な標準偏差 $\sigma'$ を求める．なお，第一ピークの右側には地表面を表す点と物体を表す点が混在すると考えられるため，ここでは用いない．これを表したものが次式となる．

[*1] このヒストグラムは，4.4 節の検証で使用した点群におけるものである．

© 2018 Information Processing Society of Japan

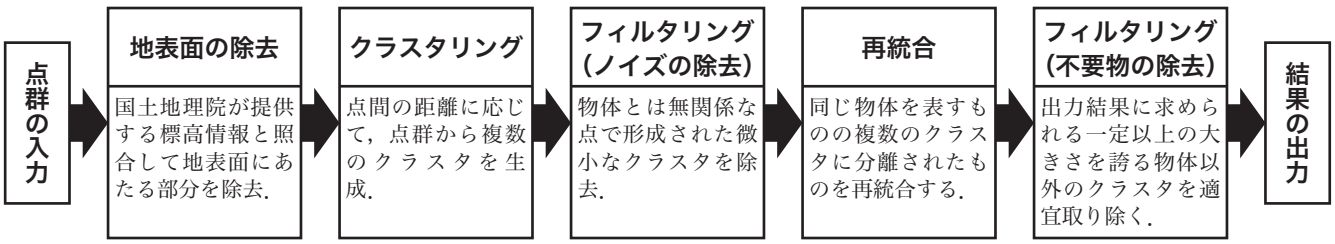


**図 1**　提案手法における処理の流れ

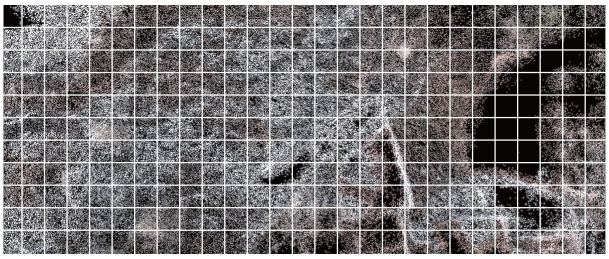

**図 2**　点群の密度と標高データの間隔の比較

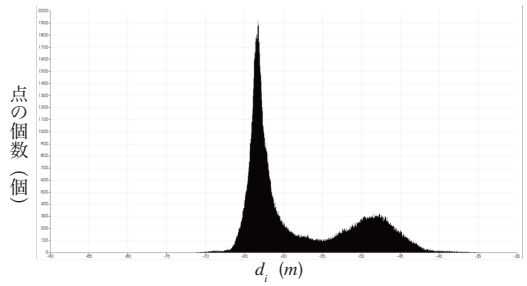


**図 3**　$z$ 座標の差 $d_i$ の分布をまとめたヒストグラムの例

$$\sigma' = \sqrt{\frac{1}{2n+1} \times 2 \sum_{d_i \leq \mu'} (d_i - \mu')^2} \tag{3}$$

$$\simeq \sqrt{\frac{1}{n} \sum_{d_i \leq \mu'} (d_i - \mu')^2} \tag{4}$$

ここで，$n$ は，$d_i < \mu'$ を満たす $d_i$ の個数である．第一ピークの右側が左側と同様の分布を行うと仮定すると式 (3) の通りとなるが，標本数の多さから式 (4) に近似した．また，閾値は，$\mu' + z\sigma'$ $(z > 0)$ で与えられるものとする，$z$ はパラメータである．

### 3.3　点群のクラスタリング

本手法では，異なる物体は両者の間に距離が生じる点に着目し，ユークリッドクラスター抽出法 [13] を用いて点間の距離に応じたクラスタリングを実施する．ユークリッドクラスター抽出法では，あらかじめ閾値 $d_{th}$ を設定する．そして，起点となる点を設定し，起点から半径 $d_{th}$ までの領域に存在する点を同一グループとして認定する．これを同一グループに属する全ての点に対して行い，同一グループに属する新しい点が発見されなくなったときに，このグループを 1 つのクラスタとして分離する．また，ユークリッドクラスター抽出法には，1 つのクラスタを構成する点の数の最小値をパラメータとして設定することができる．これにより，閾値以内の領域に点が存在しない孤立した点をノイズとして除外することができる．

ユークリッドクラスター抽出法は，上記の処理によって，物体間が $d_{th}$ より大きく離れているときに，正しく物体を分けることができる．$d_{th}$ の値を大きくするほど，近接する物体が同一物体として認識されてしまうが，一方で $d_{th}$ の値を小さくすると，本来同一の物体を示すものが，点の密度の低さなどに起因して複数のクラスタに分割されてしまう恐れがある．

本研究では，後述する再統合の処理をアルゴリズムの中に含めている関係で，細分化されたクラスタが再び物体に相当するクラスタとして統合される余地がある点を踏まえ，$d_{th}$ を 0.3〜0.5m 程度と小さく設定した．そして，クラスタを構成する点の数の最小値についても，後でフィルタリングの処理を実施することを見据えて，3 つ程度と少なめの設定を行った．

### 3.4　クラスタのフィルタリング（ノイズ除去）

本手法に適用させる点群には，実際の物体の配置とは無関係に分布する点が多少含まれており，これがノイズとして分割結果に影響を及ぼすことがある．ノイズには主に 2 種類ある．

1 つ目は，画像から点群を生成した際に生じるものである．ここで生じるノイズの多くは，点の密度が低い空間上に分布するため，ユークリッドクラスター抽出の過程でクラスタリングされることなく除去されるものの，ノイズの分布状況によっては一部のノイズが周囲のノイズと共にクラスタを形成することがある．

2 つ目は，地表面として抽出されなかった残留物である．本手法を適用させる点群は，既に地表面を除去したものであることが前提であるが，地表面抽出の精度によっては，地表面の一部がわずかに残留することも珍しくない．

点群生成時に生じるノイズ由来のクラスタは，高々数個〜数十個の点で構成されることがほとんどであり，その分布範囲も極めて小さい．一方で，地表面として抽出されなかった残留物としてのクラスタは，z 座標の範囲こそ小さいが，平面的な広がりを持つことがあり，体積を考えるとノイズでないクラスタのそれに匹敵することがある．そこ

© 2018 Information Processing Society of Japan

図 4　点群の分布領域のイメージ

で，ノイズの判定にあたって，体積による閾値設定でなく，3 つの座標軸の中で最も分布範囲が狭いものの幅を評価することで，体積の小さなもの，極度に平面的なものの双方をノイズとして判定できるようにしている．以上から，点群のノイズ判定に使用する指標を次の式で表す．

$$P_{range} = \min(x_{max} - x_{min}, y_{max} - y_{min}, z_{max} - z_{min}) \qquad (5)$$

ここで，$x_{max}$ は，対象となる点群に属する全ての点における $x$ 座標の最大値，$x_{min}$ は，$x$ 座標の最小値であり，$y$ と $z$ についても同様である．

### 3.5　クラスタの再統合

画像から生成した点群は，その性質から点の密度が低いことが多く，それゆえに 1 つの物体を表す点群が 3.3 節におけるクラスタリングの過程で複数のクラスタに分けられることがある．特に空撮画像において死角になる箇所は点の分布が疎になるため切り分けられやすい．例えば，広葉樹は樹木の上部と根元の幹のみが捉えられることが多く，枝葉の下部など，ドローンにとって陰となる箇所を境に 2 つの物体としてクラスタリングされる場合がある．こういった複数に分割されたクラスタは再統合し，実際の物体と一対一対応するクラスタを生成できることが望ましい．

空撮画像の死角に起因して生成される複数クラスタは，多くの場合が上下に重なる形で配置している．そして，樹木や建造物など，地上に固定して存在している物体のほとんどは地表面に接地しており，現実世界において異なる複数の物体が空間的に重なり合うことはまれである．この性質に着目し，1 つの物体を表す複数のクラスタを再統合するための条件として，水平面における分布領域の重複度合いを用いることとした．

点群の分布領域は，点群を構成する点の $x, y$ 成分のみに着目した際の，二次元点群の凸包とする（図 4）．凸包とは，点群を包み込む最小面積の凸多角形のことである．凸包は，ある点群に対して一意に定めることができる他，点の数が $n$，凸多角形の頂点数が $h$ の場合において $O(n \log h)$ の計算量で導出できることが知られている．このような性質と，点群が実際に分布する領域との面積における誤差が矩形などと比べて小さな点から，本手法では分布領域を表現する方法として採用した．

点群 $P_A$ の分布領域，すなわち点群 $P_A$ の $xy$ 平面的な分布に対する凸包の面積を $S_A$ で表すとき，点群 $P_A$ と $P_B$ の分布領域の重複度合いを評価する指標として，重複率を次の式で定めた．

$$R_{(A,B)} = \frac{S_{A \cap B}}{\min(S_A, S_B)} \qquad (6)$$

ここで，$S_{A \cap B}$ は，点群 $P_A$ と $P_B$ の分布領域の共通部分，いわば 2 つの凸包の重複領域の面積を表す．重複率は，その式から 2 つの点群について，分布領域の狭い小さなクラスタが，もう一方の大きなクラスタに対して自身がどれくらいの割合で重なっているのかを示す値である．これがある閾値を上回った際に，両者は共に同一の物体を表すものであると見なし，これらを統合する．

### 3.6　クラスタのフィルタリング（不要物の除去）

クラスタの再統合を経た時点で，クラスタリング直後と比べて大きなクラスタが点群内を占めることになる．しかし，本手法における活用例は，建造物や樹林などの比較的大規模なクラスタを対象にしたものがほとんどで，草の植え込みなど，小規模な物体を実際に使用する場合は少ない．よって，このような小さなクラスタを適宜取り除いた上で出力する．

この処理におけるフィルタリング手法は，3.4 節におけるものと同一である．ただし，ここでは大きな物体のみを残すことが目的であるため，フィルタリングの閾値は，より大きい 3.0m 程度に設定する．この値は出力点群の用途に応じて適切な値を設定する．

## 4.　性能評価

提案手法の評価を行うため，4 つの状況を捉えた点群に対して本手法を試みた．1 つ目は，平面に立つ車両を捉えた点群で，ここでは本手法における地表面除去の精度について検証する．2 つ目は，平面的なゆとりをもって配置された少数の建造物を捉えた点群で，ここでは切り分けの処理を経る中での点群の変化を見ることで，再統合処理やノイズ除去の効果を検証する．3 つ目は，一般的な住宅地を模して作成した複数の模型を捉えた点群を扱う．ここでは，同じく切り分けの効果を確かめると共に，災害時の家屋の倒壊を想定して一部の模型に変形を加えた同様の点群との比較を通じて，点群のクラスタリングによって家屋の倒壊を捉えられるかを検証する．4 つ目は，森林の中に佇む建造物を捉えた点群であり，起伏のある状況下における本手法の地表面除去の結果を検証し，前の 2 事例のような人工的な地域と比べたときの切り分け結果の違いについて評価する．

評価に使用する点群の生成には，OSS である Open Drone Map[14] を用いた．また，生成した点群に対して，物体の表面とは無関係な位置に散在する外れ値の点を除去し，これを入力点群としている．点群に対する処理には，Point Cloud Library[15] を使用した．

© 2018 Information Processing Society of Japan

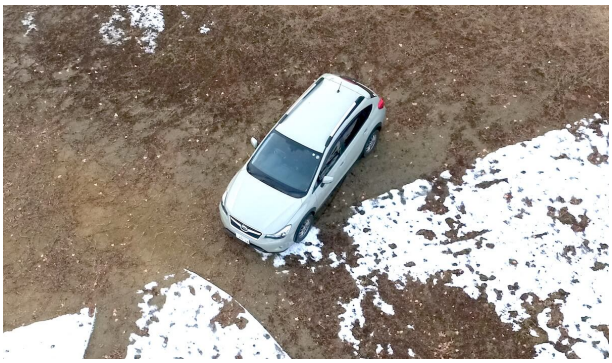

図 5　点群の対象物である地表面上の自動車

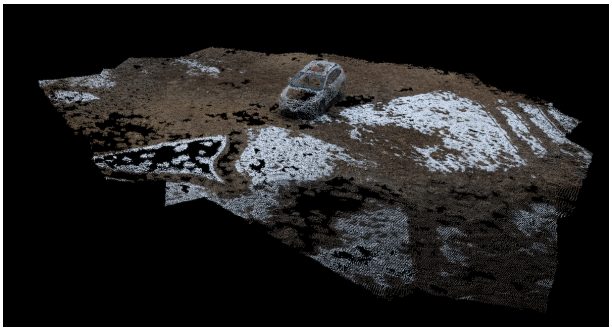

図 6　地表面上の自動車を捉えた画像から生成した点群

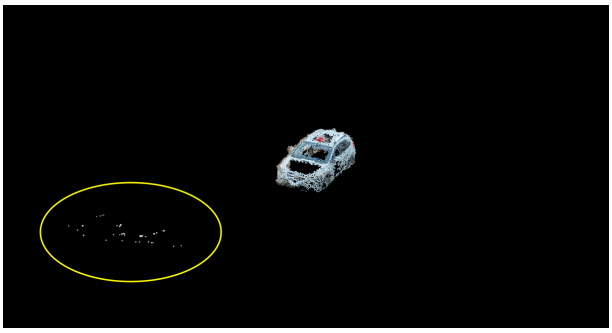

図 7　地表面上の自動車を捉えた点群から地表面を除去した結果

### 4.1　平地に立つ車両を捉えた点群

ここでは，平地に立つ車両に対して 3.2 節で述べた地表面除去のアルゴリズムを適用することで，その精度を評価する．点群の生成にあたり，大阪府豊能郡能勢町に所在するドローン飛行場において，グラウンド上に自動車を配置した上で，ドローンに搭載したカメラを用いてこれを撮影した．点群の生成に使用した画像は，撮影により得られた 14 枚の俯瞰画像（そのうちの 1 枚を図 5 に示す）である．これを統合して生成した点群を図 6 に示す．

これに対して，3.2 節で述べた地表面の除去のアルゴリズムを適用した結果を図 7 に示す．黄色で囲まれた領域（地表面上の積雪部分）は画像に特徴がなく，地表面として除去できなかったものの，ほとんどの地表面が除去されていることがわかる．

図 8 は，地表面の除去に加えて，3.3 節〜3.6 節で述べた，クラスタリングをはじめとする本手法の物体切り分け

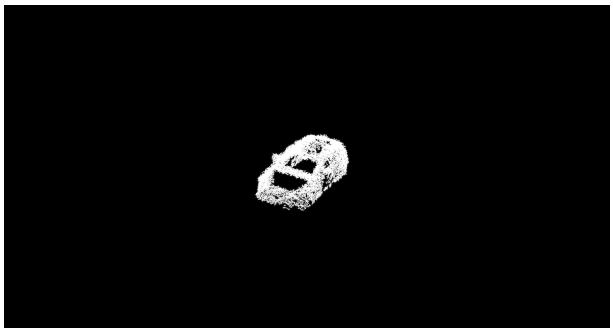

図 8　地表面上の自動車を捉えた点群に対して一連の手法を適用した結果

表 1　処理過程による点の個数とクラスタ数の推移

| | |
|---|---|
| 車を表す点群の $z$ 座標の範囲 | 153.7cm |
| 実際の車高 | 160.0cm |
| 差 | −6.3cm |

図 9　平地上の建造物を捉えた空撮写真の一つ

に関する処理を一通り加えた結果である．図 7 における残留物がフィルタリングの過程で除去されており，結果として車両のみが 1 つのクラスタとして出力されている．これより，本手法における地表面除去の処理の後に残留した点をその後の処理によっていくらか取り除けることを確認できた．

最後に，地表面除去の処理を施して得られた車両の高さと，実際の車高を比較した結果を表 1 に掲載した．ここで，前者の高さは，地表面の除去によって得られた点群の中で車両に相当する部分の $z$ 座標範囲を表す．両者の差は −6.3cm であり，これは実際の車高に対して 3.94% 程度の誤差である．

### 4.2　平地上の建造物を捉えた点群

点群の生成に使用した画像は，ドイツのミュンヘン郊外に佇む建造物を写した 36 枚の空撮写真（図 9）であり，[16] にて配布されている．生成された点群を図 10 に示した．

今回使用した点群は，国外を捉えたもので国土地理院が提供する数値標高モデルの対象範囲外である点，および現地の標高情報 [17] からは密度として不十分である 200m

© 2018 Information Processing Society of Japan

**図 10**　平地上の建造物を捉えた画像から生成した点群

**図 11**　平地上の建造物を捉えた点群から地表面を除去したもの

メッシュのものまでしか入手できない点から，ここでは提案手法における地表面除去のアルゴリズムを適用することができない．したがって，この例では，RANSAC による平面抽出アルゴリズムを用いて地表面を除去した点群（図 11）を入力として与え，3.3 節〜3.6 節で述べた処理を施した結果を検証する．

入力した点群に対して本手法を適用した結果を図 12 に示す．ここでは，本手法の適用前後の点群と，本手法における再統合処理前のクラスタリング状況を並べてこれらを比較している．図 12 の B に＊印を付加しているが，これは建造物の一部を表すクラスタであるものの，軒下であるために建造物の大部分を示すクラスタと連続しておらず，独立してクラスタリングされたものである．このようなクラスタは，水平面における重複の度合いに基づく再統合処理によって，同一の建造物を表す他のクラスタと統合されることになっているが，図 12 の C との比較によって，これらの再統合処理が正しく行われていることが観察される．また，同様に B と C の比較を通じて，小さな植え込みや車両などに起因する微小なクラスタが再統合処理後のフィルタリング処理によって除去されていることもわかる．

さらに，3.3 節〜3.6 節にて述べた各処理を経た時点における点群内の点の個数とクラスタ数（点のグループの個数）を表 2 に示す．再統合処理の前に行うフィルタリング処理について，処理の前後で点の個数は 345,409 から 344,994 に変化しており，約 0.12%の減少率に過ぎないものの，一方でクラスタ数は 171 から 121 まで減少し，約 29.2%の変化となっている．これにより，再統合処理前のフィルタリング処理によって点群の形状に大きな影響を与えることなく，再統合処理の付加に影響を及ぼすクラスタの個数を大きく削減できていることがわかる．

**表 2**　処理過程による点の個数とクラスタ数の推移

| | 点の個数 | クラスタ数 |
|---|---|---|
| 元の点群 | 345,755 | 1 |
| クラスタリング処理後 (3.3 節) | 345,409 | 171 |
| フィルタリング処理後 (3.4 節) | 344,994 | 121 |
| 再統合処理後 (3.5 節) | 344,994 | 92 |
| フィルタリング処理後 (3.6 節) | 316,347 | 14 |

最後に，点群内のクラスタと実際の物体との対応について確認する．図 13 では，点群内の各クラスタに番号を付与すると共に，対応する物体を右の空撮写真にて示している．図に示した通り，ほとんどのクラスタが実際の物体と一対一対応しているが，一部で正しく対応していない箇所が存在する．例えば，4 番と 5 番は異なるクラスタであるが共に同じ建造物を表している．この建造物は空撮範囲の境界近くに位置するために点群では建物の後ろ半分に相当する部分が切れており，低層階部分に相当するクラスタ（4 番）と，高層階部分に相当するクラスタ（5 番）の分布領域において水平面上における重なりが見られなかったのがその理由である．これより，本手法における再統合処理を確実に行うためには，与えられた点群について建造物の全体を正しく点群化できていることが重要であることがわかる．また，これとは逆に，クラスタとしては 1 番の中に含まれていた箇所（1 ＊番）が，実際には 1 番とは全く異なるものを表していた．これは，1 ＊番の最下にある草木が建造物の壁面近くを生い茂っている関係で建造物と連続する点群として捉えられたことに起因する．この草木が 1 番のクラスタの一部として扱われたことで，1 番の分布領域を表す凸包の範囲が広がり，周囲の草木も 1 番の一部として統合された．この結果は，異なる複数の物体が至近距離で隣接する場合において本手法を正確に適用することの難しさ，凸でない多角形状に点が分布しているときに生じる誤差の可能性を示唆している．

### 4.3　住宅地を捉えた点群

ここでは，点群の切り分けを災害直後の簡易的な被害調査に用いることを想定した評価を実施した．ただし，家屋の倒壊前後を実際に捉えた点群を入手することは困難であるため，代わりに 1/150 スケールの模型を用意し，これを人の手によって様々な角度から撮影した 23 枚の画像を用いて点群を生成した．そして，これに対して実寸スケールとなるよう適宜拡大処理を施している．地表面の除去について，模型を用いている点から標高情報が存在せず，よっ

© 2018 Information Processing Society of Japan

A 入力点群　　B 再統合処理に用いる点群　　C 出力点群

**図 12**　平地上の建造物を捉えた点群におけるクラスタリングの変化

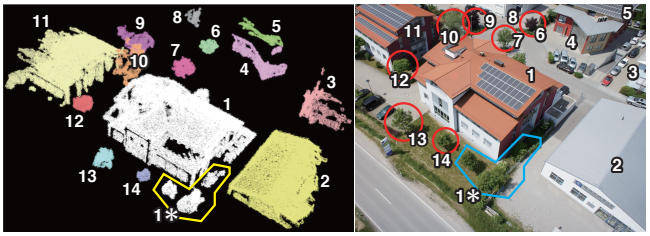

**図 13**　点群のクラスタと実際の物体との比較

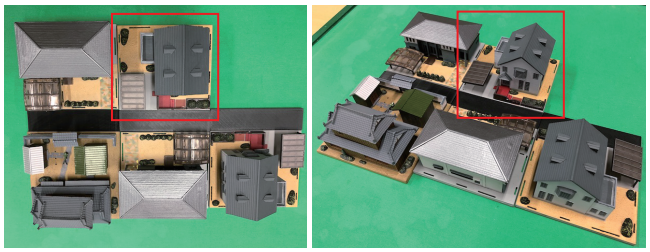

上部から俯瞰した図　　斜めから俯瞰した図

**図 14**　災害前の状況を模した住宅地の模型

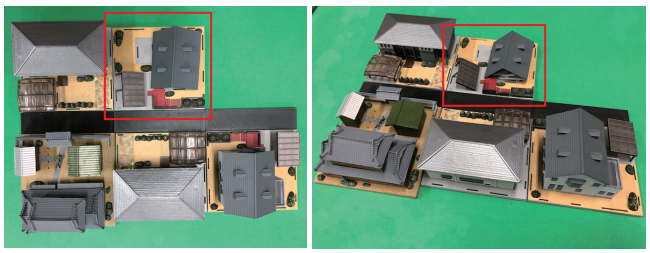

上部から俯瞰した図　　斜めから俯瞰した図

**図 15**　災害後の状況を模した住宅地の模型

て本手法における地表面除去のアルゴリズムを適用できないため，4.2 節における検証と同じく，RANSAC による平面抽出で地表面に相当する部分を除去したものを入力点群として与え，物体間の切り分けのアルゴリズムを確認することにする．被災前の状況を模したものの写真を図 14 に，被災後の写真を図 15 に示した．ここで，災害として地震の場合を想定し，図 14，図 15 において赤色で囲んだ右奥の戸建て住宅が屋根を残して倒壊したときの点群の変化を，被害を受けていない他の住宅と比較する．

まず，2 つの点群に対して，それぞれ本手法を適用した

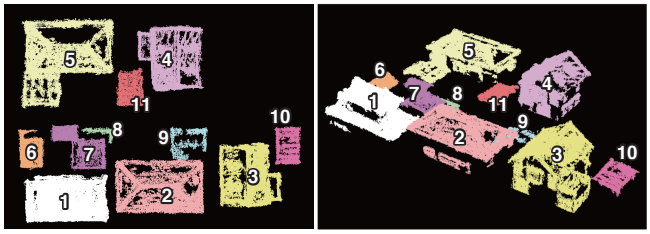

上部から俯瞰した図　　斜めから俯瞰した図

**図 16**　災害前の状況を模した点群に対する本手法適用の結果

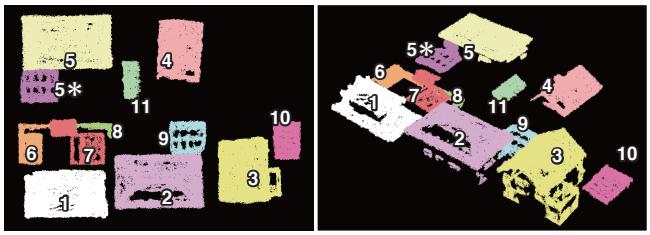

上部から俯瞰した図　　斜めから俯瞰した図

**図 17**　災害後の状況を模した点群に対する本手法適用の結果

結果を図 16，図 17 に示した．付与した番号は同じ図の左右で同一のクラスタを指しており，また図 16 と図 17 で同一の物体を指している．6 番において納屋と塀が，7 番において別の納屋と門構えが同一のクラスタにまとめられているが，これは 4.2 節における検証で生じた結果と同じく，両者の距離が近すぎるために両者を表す点が連続的に分布しているためである．災害前後における本手法の適用結果を比較すると，5 番の家屋においてカーポートの屋根が同化しているか否かの違いが生じた．

次に，家屋を表すクラスタの災害前後における比較を行う．前述した通り，4 番のクラスタに相当する家屋は，災害後において屋根部分が接地する全壊被害を被ったこととし，その他の家屋は災害前後において家屋の形状に変化がないとする．建物の高さは，クラスタの最低部と最高部における $z$ 座標の値の差から求めることができる．家屋を表す 1 番から 5 番までのクラスタについて，災害前および災害後の点群からそれぞれ導出される高さと，その変化量をまとめたものが表 3 である．ただし，5 番のクラスタについては，災害前の点群に合わせるため，災害後のクラスタ

© 2018 Information Processing Society of Japan

表 3　災害前後の点群から導出される家屋の高さの比較

| クラスタ番号 | 模型高の実寸換算値 | $z$ 座標範囲 (高さ) 災害前 | 災害後 | 変化率 |
|---|---|---|---|---|
| 1 | 9.00m | 8.43m | 8.35m | −0.95% |
| 2 | 6.75m | 6.15m | 6.36m | 3.41% |
| 3 | 8.55m | 7.89m | 8.02m | 1.65% |
| 4 | 8.55m(3.60m*2) | 8.11m | 3.36m | **−58.7%** |
| 5 | 6.75m | 6.13m | 6.10m | −0.49% |

において 5 番と 5 ＊番を統合した，カーポートを含む高低差で比較した．

実際の模型の高さから計算した実寸値と比べて，$z$ 座標の範囲が総じて 50cm 程度低く出ているのは，RANSAC のアルゴリズムでは，その原理から建築物の一部を地表面と見なして除去することがあるためである．また，一般的に同じ物体を捉えた画像から点群を生成した場合であっても，使用した画像やその組み合わせが異なる場合，点群の分布は多少異なるものになる．そのため，入力として与える点群に多少の違いが生じ，同じ物体であっても点群によって導出される高さに多少の変化が出る．実際に，4 番以外のクラスタは，災害前後で一切の変化が生じていないにも関わらず，最大でおよそ ±3.5%程度の変化が生じている．一方で，大きな損壊を被った 4 番のクラスタにおける高さの変化率は −58.7%におよび，他のクラスタとは一線を画す変化が数字に表れることが見て取れる．この比較を通じて，点群を切り分けてできた家屋のクラスタを見ることで，一定規模以上の被害を受けた家屋の存在を捉えられる可能性が示された．

### 4.4　森林とその中の建造物を捉えた点群

最後に，起伏のある地表面上における森林とその中に佇む建築物を捉えた空間を対象にして，画像から生成した点群を用いて本手法を適用した結果について確認する．点群の生成にあたり，4.1 節と同じく大阪府豊能郡能勢町におけるドローン飛行場の周囲をドローンに搭載したカメラを用いて撮影した．点群の生成に使用した画像は，撮影により得られた 49 枚の俯瞰画像（図 18）である．これを統合して生成した点群を図 19 に掲載した．

これに対して，3.2 節で述べた地表面除去のアルゴリズムを適用したのが図 20 である．図 18 から，空撮範囲は左から右にかけて下りの勾配があることが見て取れるが，そうした中でも正しく地表面を除去していることが判る．なお，図 20 の左端に残った点群は一見すると地表面の残留物のようであるが，これは図の左部に広がるグラウンドを囲む木々の一部である．

次に，物体間の切り分けのアルゴリズムの適用結果について検証する．図 21 は，本手法の一連のアルゴリズムを適用した結果である．まず，点群の中央部が木々に応じてあ

*2　災害における倒壊後の値

図 18　点群の対象物である森林と建造物

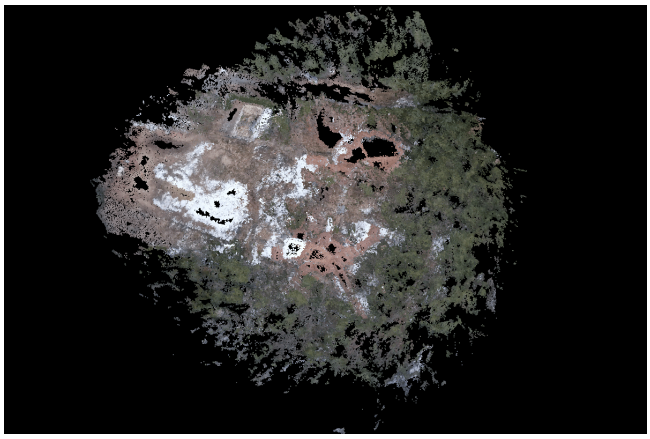

図 19　森林と建造物を捉えた画像から生成した点群

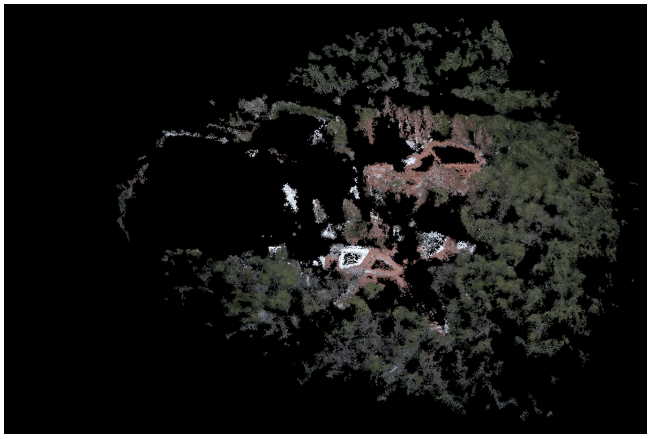

図 20　森林と建造物を捉えた点群から地表面を除去した結果

る程度切り分けされているのに対して，画像の外側にあった点の多くが消えていることが判る．これは，点群の中心部と外側で画像に捉えられた回数に違いが生じることで，点群の密度にも違いが生まれ，クラスタリングの閾値設定において中央部に適した値を設定した場合に，外側では密度の低さからクラスタと認められる点のグループが形成されなくなり，本手法の適用の過程で除外されてしまうからである．これより，比較的広域を捉えた場合は，必ずしも画像が捉えた全ての範囲を等しく利用できるわけでないことがわかる．

建物の切り分け結果について，図 18 の奥に映る建物を

© 2018 Information Processing Society of Japan

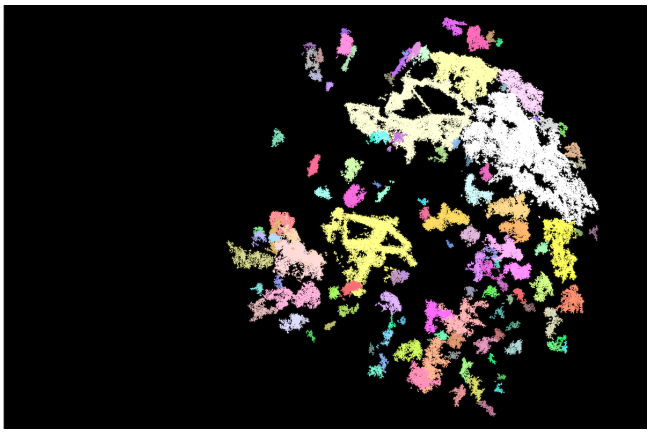

図 21　森林と建造物を捉えた点群に対して一連のアルゴリズムを適用した結果

図 22　建造物における実物と点群の比較

比較したものを図 22 に示す．おおよそ建物として識別できる形状をもっているが，画像の黄色で囲んだ部分をはじめ，建造物に隣接する木々が共に抽出されている．これは，4.2 節で述べた通り，点間の距離に基づくクラスタリングの限界であり，特に森林部では建造物に木々がもたれかかることが多々あるため，このような同化が頻繁に発生する．ちなみに，赤色で囲んだ部分は，隣の建物を結ぶ廊下の一部を表したものであり，誤抽出ではない．

木々の切り分け，建造物の切り分け共に，4.1〜4.3 節における検証と比べてその精度が低いのは，森林部は木々が複雑に入り組んでおり，本手法の前提となる物体間の空間的な分離が決して明確でないからである．しかし，クラスタの形状から目視における建造物と木々の最低限の識別は可能であり，木々の分布状況や建物の配置・サイズなどを捉える上で全てを手作業で行う場合と比べ，効率化に大きく寄与するといえる．特に，厳密な三次元形状を必要としない無線シミュレーションのモデル作成などの用途において，その実用可能性が十分期待できる．

## 5.　まとめと今後の課題

本研究では，ドローンなどが捉えた空撮画像から生成した三次元点群の活用に資する技術開発の一環として，生成した点群から地表面と外れ値としてのノイズを除去した点群に対して，点間距離に基づく物体の切り分けの手法を提案した．

提案手法は，5 つの処理過程に分けることができる．1 つ目は，点群からの地表面除去であり，国土交通省が提供する標高情報との照合によって起伏の大きさに関わらず地表面を除去する．2 つ目は，点群の距離に応じたクラスタリング処理であり，ユークリッドクラスター抽出法を用いることで点の集まりや集まり同士の距離を反映したクラスタリングを実施する．3 つ目は，ノイズの除去を目的としたフィルタリングで，クラスタの分布範囲について矩形で評価することで，物体とは無関係な点によって構成されたクラスタを大まかに取り除く．4 つ目は，同一の物体を表す複数のクラスタを統合するための処理であり，鉛直方向に分断された複数のクラスタについて水平面上における分布範囲の重なりを，点群の平面的な凸包の重複度合いから評価し，これに基づく条件を与えて統合を行う．この条件は，家屋の軒下をはじめとする空撮画像の死角において点分布が疎になることに起因する誤ったクラスタリングを補う役割を果たす．5 つ目は，出力結果の用途に応じたクラスタのフィルタリングである．クラスタの大きさを 2 つ目のフィルタリングと同様の方法で評価し，用途に適った物体のサイズ未満のクラスタを取り除いている．

提案手法の有効性を確かめるために，4 つの状況に対してそれぞれ異なる観点から評価した．まずは，平面上にある車両を捉えた点群を対象として，本手法における地表面除去のアルゴリズムの適用結果とその精度を確かめた．次に，空間的に余裕がある配置の建造物を捉えた点群を対象として，本手法を構成する各処理段階における点群の変化を観察した．ここで各処理がもたらす影響や効果を検証すると共に，各処理が抱える課題や限界について考察することができた．そして，複数の家屋が立ち並ぶ住宅地を模した模型に対して，クラスタリングの結果を比較した．これに加えて，災害による家屋の倒壊を想定した模型を用意し，両者を捉えた点群の比較を通じて，家屋の損壊が一定規模を上回る場合において，倒壊家屋に対応するクラスタの $z$ 座標範囲からこれを検知できることを確かめた．最後に，山岳部の森林と，そこ佇む建造物を捉えた点群を対象に，起伏のある状況下における地表面除去のアルゴリズムの適用結果を確かめ，また物体の切り分け精度が住宅地などと比べて低下するものの，手作業による切り分けを手間を軽減可能な精度を達成できた．

本手法は，物体間の距離が大きな場合において十分適用可能であるものの，例えば都市部などの建造物が密集する領域や，4.4 節で見受けられたような建造物に樹木などがもたれかかっている場合など，異なる物体が至近距離に配置されている時に誤抽出が生じることがある．また，同一の物体が水平方向に分断されてクラスタリングされた場合に再統合処理の適用が難しい場合がある．前者については，クラスタリング処理において点間距離以外の要素，例えば

© 2018 Information Processing Society of Japan

色や幾何的な要素を考慮に入れることを検討している．後者についても，再統合処理において，より多くの要素を考慮に入れることで一定の解決が見込めるが，入力として与える点群について，高精度かつ物体上の分布密度が高く安定している良質なものを選ぶことでも，一定の改善効果を期待することができる．

## 謝辞

本研究開発は総務省 SCOPE（受付番号 175001002）の委託を受けたものです．

### 参考文献

[1] 織田和夫：解説：Structure from Motion (SfM)　第一回　SfM の概要とバンドル調整，写真測量とリモートセンシング，Vol. 55, No. 3, pp. 206–209 (2016).
[2] Futuhal, A., Arifandi, D. R. and Didit, W.: Autonomous Detection and Tracking of an Object Autonomously Using Ar.drone Quadcopter, *Jurnal Ilmu Komputer dan Informasi* (2014).
[3] Chen, P., Dang, Y., Liang, R., Zhu, W. and He, X.: Real-Time Object Tracking on a Drone With Multi-Inertial Sensing Data, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 19, No. 1, pp. 131–139 (2018).
[4] 安岡里都，薗頭元春，飯山将晃：ドローン搭載カメラ画像を用いた物体認識，*ELCAS Journal* (2018).
[5] van Gemert, J. C., Verschoor, C. R., Mettes, P., Epema, K., Koh, L. P. and Wich, S.: Nature Conservation Drones for Automatic Localization and Counting of Animals, *Computer Vision - ECCV 2014 Workshops* (2015).
[6] Maria, G., Baccaglini, E., Brevi, D., Gavelli, M. and Scopigno, R.: A drone-based image processing system for car detection in a smart transport infrastructure, *2016 18th Mediterranean Electrotechnical Conference (MELECON)*, pp. 1–5 (2016).
[7] Fischler Martin A and Bolles Robert C: Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography, Technical report, SRI International (1980).
[8] R., S., R., W. and R., K.: Efficient RANSAC for Point - Cloud Shape Detection，*Computer Graphics Forum*, Vol. 26, No. 2, pp. 214–226 (2007).
[9] Zhang, K., Chen, S.-C., Whitman, D., Shyu, M.-L., Yan, J. and Zhang, C.: A progressive morphological filter for removing nonground measurements from airborne LIDAR data, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 41, No. 4, pp. 872–882 (2003).
[10] Golovinskiy, A. and Funkhouser, T.: Min-Cut Based Segmentation of Point Clouds, *Computer Vision Workshops (ICCV Workshops) 2009 IEEE 12th International Conference*, pp. 39–46 (2009).
[11] Niemeyer, J., Rottensteiner, F. and Soergel, U.: Classification of urban LiDAR data using conditional random field and random forests, *Joint Urban Remote Sensing Event 2013*, pp. 139–142 (2013).
[12] 国土地理院：基盤地図情報サイト. http://www.gsi.go.jp/kiban/.
[13] Rusu, R. B.: Semantic 3D Object Maps for Everyday Manipulation in Human Living Environments, PhD Thesis, Computer Science department, Technische Universitaet Muenchen, Germany (2009).
[14] OpenDroneMap: OpenDroneMap. http://opendronemap.org/.
[15] Point Cloud Library: PCL - Point Cloud Library (PCL). http://pointclouds.org/.
[16] Esri: Sample data - Drone2Map for ArcGIS Help. http://doc.arcgis.com/en/drone2map/get-started/sample-data.htm.
[17] Federal Agency for Cartography and Geodesy: Open Data - Free Data and Services of BKG. http://www.geodatenzentrum.de/geodaten/gdz?l=down_opendata.

© 2018 Information Processing Society of Japan