

自律施工の実現に向けた環境認識基盤の開発と検証

清水建設(株) 正会員 ○大山 春太郎
清水建設(株) 正会員 鈴木 正憲
清水建設(株) 正会員 山本 真哉
清水建設(株) 宮下 裕貴
清水建設(株) 正会員 大貫 奈々美

1. 背景

建設産業では少子高齢化に伴う生産労働人口の減少が大きな課題となっており、建設機械オペレータをはじめとする建設産業の担い手不足や現場における生産性の向上といった課題に直面している。その課題に対し、当社は建設現場への ICT 施工の導入や BIM/CIM の活用等のデジタル技術の導入を推進し、施工を中心とした業務効率化に努めている。その中でブルドーザによる自律施工の実現に向けて、必須となる現場環境認識アルゴリズムの構築を昨年より実施[1]しており、本稿ではより精度が向上した現場環境認識アルゴリズムについて報告する。

2. 現場環境認識アルゴリズムの概要

現場環境認識アルゴリズムの概要を図-1 に示す。構築した現場環境認識アルゴリズムの物体検知・分類モデルは、カメラ画像と LiDAR による点群データを使用したモデルとなっており、本取り組みにおいては、このモデルを LD-CC(LiDAR-Detection-Camera-Classification)と呼称している。LD-CC モデルはまず LiDAR によって取得した 3D 点群データにより物体（オブジェクト）を検知し、検知したオブジェクトを含んだ領域を区切ることによって 3D バウンディングボックスを作成する。次に、あらかじめ実施している LiDAR から取得する 3D 点群データとカメラから取得するカメラ画像の対応付け（キャリブレーションデータ）から、3D バウンディングボックスをカメラ画像上における 2D バウンディングボックスへと変換し、その後変換した 2D バウンディングボックスで区切った領域内のカメラ画像によりオブジェクトの分類を行う。

一般的なカメラ画像による物体検知モデル (Scaled Yolov4[2], FasterRCNN[3]) では画像から検知・分類が実施できたオブジェクトのみを認識することが出来るが、本モデルは最初のオブジェクトの検知に LiDAR からの 3D 点群データを使用しており、LiDAR の特性により 3D 点群データの取得が難しいオブジェクトや環境もあるが、一般的なカメラ画像による物体検知モデルでは検知が難しいオブジェクトに対しても確実な検知が実現できる。また 2D バウンディングボックスにより抜き出したカメラ画像に対し分類を行うことから背景等の影響を最小限にすることでより精度の高い分類が出来る。




図-1 現場環境認識アルゴリズム概要

キーワード 物体認識, 点群, 画像

連絡先 〒104-8370 東京都中央区京橋 2-16-1 清水建設株式会社 土木技術本部 TEL : 070-2792-0663

2. 検証方法

2. 1 評価用データセット作成

本研究では昨年より現場環境認識アルゴリズムの構築を実施しており、その中で取得した検証用データセットに対し、本アルゴリズムの評価用データセットとして変更した内容を表-1 にまとめる。

一般的なカメラ画像による物体検知モデルと LD-CC はオブジェクトの検知手法が異なるため、可能な限り同条件での性能比較を行うために昨年実施した現場環境認識アルゴリズム検証データセットに対し、カメラ画像と同時に取得している LiDAR からの 3D 点群データによりオブジェクトの距離、及び高さの情報を追加した。また昨年度構築したアルゴリズムにおいてはオブジェクトを 13 個に分類していたが、データ数の確保を目的として異なるエリアで取得したデータセットを活用するために分類を 3 個に統合した。さらに検証データセット内でデータが破損・不十分なデータについてフィルタリングを実施した。

表-1 評価用データセット変更内容

評価用データセット	- LiDAR からのデータを用いて各オブジェクトの計測機器からの距離と高さを推定し追加 - 分類の統合(13 分類 ⇒ 3 分類：人物・車両・その他) - データの手動フィルタリング ① LiDAR フレームが破損したデータ ② 時間同期が不十分なデータ
-----------	---

2. 2 検証比較 (IoU 法)

2.1 で作成したデータセットを用いて IoU (Intersection over Union) 法で LD-CC と Faster RCNN、Scaled YOLOv4 との比較評価を実施した。IoU 法は図-2 で示すように 2 つのバウンディングボックス間の重なる範囲を評価する指標であり、予測されたオブジェクトが実際のオブジェクトとどの程度一致しているかを示す。IoU の値によって、検出アルゴリズムの精度と再現率を定量化することができ、IoU スコアが高いほど、予測の精度が高いと言える。




図-2 IoU (Intersection over Union) 法の定義

2. 3 検証評価 (Visual Inspection 法)

LD-CC では近接したオブジェクトを一つの塊として検知・分類するため、図-3 の例で示すように検知・分類結果として予測 BOX 内に正解オブジェクトを含むことは本アルゴリズムの動作としては想定通りだが、IoU 法での評価の際には偽陽性 (False-Positive)、偽陰性 (False-Negative) が多く評価される。そのため LiDAR で検出したバウンディングボックスを基にした検知・分類を評価するために表-2 で示す Visual Inspection 法を用いて評価を実施した。




図-3 IoU による比較例

予測	有効	予測されたバウンディングボックスが1つ以上のオブジェクトを含む
	無効	予測されたバウンディングボックスにオブジェクトが含まれない
検知	有効	正解のバウンディングボックスに対し、少なくとも一つのバウンディングボックス
	無効	正解のバウンディングボックスに対し、対応するバウンディングボックス無し
分類	有効	予測されたクラスが対応する正解クラスと一致する
	無効	予測されたクラスが対応する正解クラスと一致しない

表-2 Visual Inspection 法

3. 検証結果

2.2 の検証結果を図-4、図-5 に示す。検証は分類したものが実際に正しかったことを示す指標である適合率 (Precision)、実際の分類に対し正しく分類できたことを示す指標である再現率 (Recall)、それらを組み合わせた F 値 (F1-Score) を算出し、主として F 値での比較評価を行った。

図-4 では分類対象ごとの指標を比較しており、LD-CC は人物 (Person) や車両 (Vehicle) に対しては他の比較対象よりも F 値が高いが、その他 (Other) では F 値が低い。これは LD-CC の特徴として比較対象よりも多くのオブジェクトを検知することが出来ているが、検知したオブジェクトが今回のアルゴリズムの分類対象外となっているオブジェクトが多くあり、そのため適合率、再現率が低くなり、結果として F 値も低くなっていると考えられる。

図-5 では各評価指標の平均値を比較しており、F 値(Micro Average, Macro Average, Weighted Average)において比較対象が概ね 0.3～0.4 程度であることに對し、LD-CC は 0.4～0.5 と優位であることが確認できた。

IoU 0.5		Faster RCNN	Scaled YOLOv4	LD-CC
Person	Precision	0.33	0.44	0.63
	Recall	0.16	0.22	0.53
	F1-Score	0.22	0.30	0.58
Vehicle	Precision	0.53	0.26	0.80
	Recall	0.41	0.34	0.65
	F1-Score	0.46	0.29	0.72
Other	Precision	0.86	0.77	0.26
	Recall	0.18	0.37	0.19
	F1-Score	0.30	0.49	0.22

図-4 検証結果 (2.2-1)

IoU 0.5		Faster RCNN	Scaled YOLOv4	LD-CC
Precision	Micro Average	0.58	0.42	0.52
	Macro Average	0.57	0.49	0.56
	Weighted Average	0.68	0.53	0.51
Recall	Micro Average	0.27	0.34	0.41
	Macro Average	0.25	0.31	0.46
	Weighted Average	0.27	0.34	0.41
F1-Score	Micro Average	0.37	0.38	0.46
	Macro Average	0.33	0.36	0.50
	Weighted Average	0.36	0.39	0.45

図-5 検証結果 (2.2-2)

2.3 の検証結果を図-6 に示す。図-6 より Visual Inspection 法において各クラス分類の F 値が 0.7～0.9 程度、平均 F 値が 0.8 程度のモデルであることが確認できた。

Visual Inspection	Precision	Recall	F1-score
Person	0.87	0.80	0.83
Vehicle	0.98	0.84	0.90
Other	0.86	0.60	0.71
Micro Average	0.91	0.71	0.80
Macro Average	0.90	0.75	0.81
Weighted Average	0.91	0.72	0.80

図 6 検証結果 (2.3)

4. 結言

本報告ではカメラ画像と LiDAR による点群データを使用した物体検知・分類アルゴリズム (LD-CC) を構築し、その性能を IoU 法による比較評価、及び LiDAR によるオブジェクト検出を基にした物体検知・分類に対する評価手法 (Visual Inspection 法) により評価を行った。検証結果として IoU 法では比較対象の F 値がおおよそ 0.3~0.4 であったのに対し、LD-CC は F 値が 0.4~0.5 と比較対象に対し優位であることが確認でき、Visual Inspection 法では 0.8 程度の F 値でオブジェクトを認識できることが確認できた。

今後は構築したアルゴリズムの精度向上と、それらを実装した自律施工建機システムの構築を進めて現場実証を行うことを目指す。

参考文献

- [1] 大貫奈々未, 山本真哉, 宮下裕貴: 自動施工に向けた点群データによる環境認識基盤システムの検討, 土木学会第 79 回年次学術講演会, VI-62, 2024
- [2] Alexey Bochkovskiy, Chien-Yao Wang, and Hong-Yuan Mark Liao. 2020. YOLOv4: Optimal speed and accuracy of object detection. In arXiv: <https://arxiv.org/abs/2004.10934>
- [3] Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun. 2015. Faster-rcnn: Towards real-time object detection with region proposal networks. In arXiv: <https://arxiv.org/abs/1506.01497>