

令和 5 年 6 月 2 日現在

機関番号：14701

研究種目：基盤研究(C)（一般）

研究期間：2020～2022

課題番号：20K04399

研究課題名（和文）3D LIDARからの複数物体点群データの自動補間システムの構築とその応用

研究課題名（英文）Development and Application of an Automatic Complementation System for Multiple Object Point Cloud Data from 3D LIDAR

研究代表者

中村 恭之（Nakamura, Takayuki）

和歌山大学・システム工学部・教授

研究者番号：50291969

交付決定額（研究期間全体）：（直接経費） 3,300,000円

研究成果の概要（和文）：本研究では、空間的計算量を抑えつつ周囲環境を計測して得られた大規模な3次元点群データに対して補完処理を行う深層学習ネットワークと、入力点群の隙間を適切に補完できたかを表す3次元点群データの補完のための新たな評価指標を考案した。また、その評価指標を損失関数の一部に用いて考案した深層学習ネットワークを学習させて、適切に点群を生成できることを実験的に示した。考案した手法の有効性を示すために、自動運転車のための実環境の3次元点群データセットとして有名なSemanticKITTIデータセットやSemanticPOSSデータセットを用いて検証実験を行い、その有効性を示した。

研究成果の学術的意義や社会的意義

最近の自動運転車などに多く用いられているLiDARセンサで取得された3次元点群データは、疎かつ偏在しているため、本来の構造を正確に捉えることができないことがある。この問題を解決するために、本研究では、疎に分布している、または、一部が欠損したような3次元点群データを、密かつ一様に分布する3次元点群のデータに変換する手法を開発した。本研究課題で扱ったような大規模な3次元点群データを対象とした手法は、我々の知る限りこれまでに存在しない。また、開発した手法により、本来の構造を正確に捉えた3次元点群データを生成することが可能になり、その結果として自動運転車の安全性を向上することに寄与することができる。

研究成果の概要（英文）：In this study, we developed a deep learning network that performs completion processing for large-scale 3D point cloud data obtained by measuring the surrounding environment while minimizing spatial computational complexity, and a new evaluation index for completion of 3D point cloud data that indicates whether the gaps in the input point clouds are appropriately filled (completed). We also experimentally showed that the new evaluation index can be used as part of the loss function to train the deep learning network so that it can generate point clouds appropriately. To demonstrate the effectiveness of the proposed method, validation experiments were conducted using the well-known SemanticKITTI and SemanticPOSS datasets, which are real-world 3D point cloud datasets for self-driving cars.

研究分野：知能ロボット

キーワード：3次元点群データ補完 深層学習

1. 研究開始当初の背景

3D LIDAR(Light Detection and Ranging の略)センサは、自律型移動ロボットや自動運転車などのシステムに、近年多用されており、欠かすことのできない存在になっている。3D LiDAR は、周囲にレーザー光を照射することで 3 次元点群データを取得し、周囲の物体の状況を捉えるセンサである。しかし、3 次元点群データは疎かつ偏在しているため、本来の構造を正確に捉えることができないという問題がある。この問題を解決するためには、疎に分布している、または、一部が欠損したような 3 次元点群データを何らかの方法で、密かつ一様に分布する 3 次元点群のデータに変換する必要がある、このような技術が求められている。

これまでも、このような課題を解決する手法として、Point Cloud Upsampling Adversarial Network(PU-GAN)[1]を代表として、深層学習法を用いて 3 次元点群データを補完する様々な手法が開発されてきた。しかし、一つの物体を計測した小規模な 3 次元点群データを対象とした研究例が多く、空間的計算量の問題により、ある周辺環境を表すような大規模な 3 次元点群データを対象とした研究例は少ない。

また 3 次元点群データの補完の評価指標として、主に Chamfer Distance が用いられてきた。この評価指標は 2 つの点群間の距離を算出できるため、学習時の損失関数として用いられることが多い。しかし、この評価指標を用いても、入力点群の隙間を適切埋めているか、補完した点が入力点群と密接してしまっているかといった点群の配置の状況が反映されないという問題がある。

2. 研究の目的

上述したこれまでの研究例における課題を解決するために、本研究では、空間的計算量を抑えつつ、3 次元点群データに対して補完処理を行う深層学習ネットワーク、および、入力点群の隙間を適切に埋める(補完)することができたかを表すような 3 次元点群データの補完のための新たな評価指標を考案すること、新たな評価指標を損失関数の一部に用いることで、適切に点群を生成できるように、考案した深層学習ネットワークを学習させることが可能になることを実験的に示すことを、研究目的とする。

3. 研究の方法

3.1 考案した深層学習ニューラルネットワーク



図 1 考案した深層学習ニューラルネットワーク

本研究では、図 1 に示す深層学習ニューラルネットワークを提案する。このニューラルネットワークは敵対的生成ネットワーク(GAN: Generative Adversarial Networks)の構造を有している。生成器は PU-GAN[1] と RandLA-Net[2]を統合したような U-Net 型の構造になっている。このような構造によって、空間的計算量を削減しつつ、点群内の局所領域ごとの特徴量抽出を行い、その特徴量を基に補完したような点群を形成することが可能となる。識別器においても同様の特徴量抽出処理を行い、最終的に 0 から 1 の値を出力して生成された点群の真偽判定を行っている。このニューラルネットの学習方法については、自動運転車のための実環境の 3 次元点群データセットとして有名な SemanticKITTI データセットに含まれる 3 次元点群からランダムに点を選択し、入力点群 P と補完した点群に相当する教師点群 Q に分け P を生成器に入力する。これにより、生成器は P を補完する点群 Q を新たに生成し、P と Q が結合された点群を出力す

る．識別器には Q か Q' を入力し，真であるか偽であるかを識別するように学習させる．考案したニューラルネットの現在の実装では，生成器が入力点群を 2 倍に増やすような構造になっている．

3.2 考案した評価指標




図2 生成点の判定のために設定する領域

本研究では，図2に示すように，補完のために生成された点が入力点を中心としたLiDARセンサの分解能を反映して決められる一定の領域内に存在しているかどうかを判定し，領域内に存在する生成点の割合を補完の評価指標として用いることを考案した．

また，この評価指標によって計算した値と， Q と Q' との Chamfer Distance $CD(Q, Q')$ と識別器の出力値 $D(Q')$ を加算したものの損失関数として用いて，適切に点群を生成できるように考案した深層学習ネットワークを学習させることも考案した．考案した損失関数 L_G は，以下のものである．

$$L_G = \alpha CD(Q, Q') + (D(Q') - 1)^2 - \log\left(\frac{N_{in}}{N_Q} + \delta\right)$$

ここで， N_Q は，補完の対象となった点の総数， N_{in} は，生成点群の中で補完点と判定された点の個数を表している． δ は，対数の無限大発散を防ぐための定数値を表している．検証実験においては， $\alpha = 100$ ， $\delta = 1e-10$ と設定した．


4. 研究成果

考案した深層学習ニューラルネットワーク（以下DNNと呼ぶ）とPU-GANについて比較実験を行った．考案したDNNとPU-GANを同じ実験条件で実験を行うと，PU-GANの場合，計算量の多さが影響し，メモリ容量が不足し，処理が続けられないという結果となった．そのため，PU-GANの実験では，メモリ容量の不足が発生しない点の数（9000個）に削減して学習を行った．一方，考案したDNNでは，入力点数を60000個にして実験を行った．10エポック学習させたモデルに学習時と同じサイズの100個のテスト用データを入力し，点群が作られるまで処理時間，そして生成点群と教師点群とのChamfer Distance (CD)をそれぞれ測定し，その平均値を算出した．その結果を表1に示す．


表1 PU-GANと考案したDNNの比較結果

手法	入力する点数	平均CD値	平均処理時間[s]
PU-GAN	9000	0.02	0.254
考案したDNN	60000	0.001	0.036

また，生成された点群の例を図3に表す．図内で緑で色付けされているのが入力点群，白で色付けされているのが生成点群である．これらの結果から，考案したDNNは，PU-GANよりもサイズの大きい点群の処理が可能であり，点群生成処理の時間を短縮し，元の点群の形状に沿って点群を生成できることが確認できた．



(a) PU-GAN の結果



(b) 考案した DNN の結果

図 3 生成点群の比較結果

本研究では、様々な物体が含まれる周辺環境を表す大規模な 3 次元点群データを補完するため、U-Net 型生成器を用いた敵対的生成ネットワーク (GAN) と、Mechanical scanning タイプの LiDAR で取得された点群を補完した結果の善し悪しを評価するための評価指標を考案した。また、その評価指標による結果を生成器の損失関数の一部として組み込み、学習実験を行った。

考案した GAN の構造により、特徴量抽出における空間的計算量を削減し、比較的規模の大きな 3 次元点群の補完について学習させることができ、学習済みの生成器が入力した実際の点群の形状に沿って点群を生成できることが確認できた。

そして、提案した評価指標により、生成された点群の配置を詳細に調べることが可能となった。この補完精度の評価を行った結果、提案した GAN の生成器は、密接点や遠方点ばかりを生成せず、点群内の隙間を適切に埋めていることが確認できた。また、対数を用いて計算した値を生成器の損失関数に組み込むことにより、学習の収束を速くすることや、汎化性能の向上に繋がった。

[参考文献 1] Ruihui Li, Xianzhi Li, Chi-Wing Fu, Daniel Cohen-Or, Pheng-Ann Heng. PU-GAN: a Point Cloud Upsampling Adversarial Network, Proc. of ICCV, 2019.

[参考文献 2] Qingyong Hu, Bo Yang, Linhai Xie, Stefano Rosa, Yulan Guo, Zhi-hua Wang, Niki Trgoni, Andrew Markham "RandLA-Net: Efficient Semantic Segmentation of Large-Scale Point Clouds" Proc. of CVPR 2020.

5. 主な発表論文等

〔雑誌論文〕 計0件

〔学会発表〕 計1件（うち招待講演 0件 / うち国際学会 0件）

1. 発表者名 和田拓真, 中村恭之
2. 発表標題 U-Net 型生成器を持つ敵対的生成ネットワークを用いた 周辺環境の 3 次元点群データ補完法
3. 学会等名 第28回ロボティクスシンポジウム予稿集, 1A3, pp.5 - 8, 2023.
4. 発表年 2023年

〔図書〕 計0件

〔産業財産権〕

〔その他〕

代表者のこれまでの研究 https://www.wakayama-u.ac.jp/~ntakayuk/research-j.html
--

6. 研究組織

氏名 (ローマ字氏名) (研究者番号)	所属研究機関・部局・職 (機関番号)	備考
---------------------------	-----------------------	----

7. 科研費を使用して開催した国際研究集会

〔国際研究集会〕 計0件

8. 本研究に関連して実施した国際共同研究の実施状況

共同研究相手国	相手方研究機関
---------	---------