

## 1. はじめに

ポイントクラウドデータを入力とした深層学習による物体識別手法として、PointNet[1] が提案されている。PointNet は入力されるポイント数に依存せず物体識別ができる。しかし、PointNet は学習の際、各クラスに属するポイント数に偏りがあると、ポイント数の少ないクラスの識別精度が低下する問題がある。本研究では、各クラスの出現率に応じた重みを用いて学習することで、PointNet による三次元物体識別の精度向上を実現する。

## 2. PointNet

PointNet はポイントクラウドデータを入力とし、各ポイントのクラスを識別する手法である。図1にネットワーク構成を示す。 $n$  は入力ポイント数、 $k$  は出力クラス数を示す。また、 $t$  は入力チャンネル数を示しており、ポイントクラウドのみの場合は3、画像を合わせて入力する場合は6となる。PointNet は、畳み込み処理により局所的な特徴を抽出する。Max Pooling 処理により、各ポイントの特徴を集約し全体の特徴とする。そして、局所的な特徴と全体の特徴を結合した特徴に畳み込み処理を行うことにより識別を行う。しかし、PointNet には対象物体の構成ポイント数が少ないクラスの識別精度が低下する問題がある。

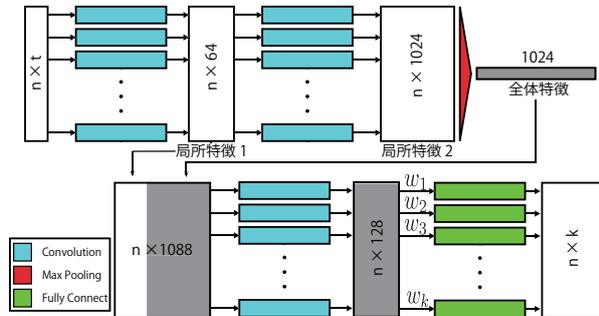


図1：PointNet による識別ネットワークの構造

## 3. 提案手法

各クラス出現率を考慮した学習を行うことで、出現率の少ないクラスの識別精度の高精度化を実現する。クラス  $k$  の重み  $w_k$  は式(1)のように求める。  $w_k$  を求める時、 $w_k$  が0または負の値になると学習できない。そこでパラメータ  $c$  を与えることで  $w_k > 0$  となるようにする。

$$w_k = \frac{1}{\log(c + \frac{N_k}{N})} \quad (1)$$

提案手法では2種類の重み付け手法によりクラス  $k$  の出現率を求める。

**重み付け手法1** 学習データの全ポイント数を  $N$ 、学習データのクラス  $k$  の全ポイント数を  $N_k$  として、出現率を求める。

**重み付け手法2** 1回の更新に用いるポイント数を  $N$ 、 $N$  内のクラス  $k$  のポイント数を  $N_k$  として、出現率を求める。PointNet の学習誤差  $E$  は、式(2)のように、教師データ  $y_k$  とクラス  $k$  の確率  $x_k$  との cross entropy 誤差から求め、各クラスに対して求めた重み  $w_k$  を乗算する。

$$E = - \sum_{k=1}^K y_k \log(x_k) w_k \quad (2)$$

## 4. 評価実験

各クラスの出現率を考慮した重み更新の効果を評価実験により検証する。

### 4.1. 実験概要

学習及び評価には、CG シミュレータで作成した30種類の走行シーンを含むデータセットを用いる。データセットは28,279フレームから構成されており、クラス数は13クラス(車, 乗り物, バス, バイク, 自転車, 歩行者, 子供,

建造物, ガードレール, 標識, 緑石, 壁, その他)である。また各フレームにポイントクラウドデータ, RGB 画像, 正解ラベルがある。本実験では、ポイントクラウドデータとRGB画像を学習に15,540フレーム、評価に12,739フレームを用いる。各クラスの出現率と重み付け手法1で算出した各クラスの重みを表1に示す。なお、重み付け手法2の重みは毎回更新されるので表記しない。評価方法は、各ポイントに対して評価を行い、各クラスの正答率を識別率とする。

表1：各クラスの出現率と各手法の重み

クラス	ポイント数	出現率	重み付け手法1
その他	22,340,970	35.10	7.65
車	1,610,796	2.53	92.14
乗り物	310,137	0.49	473.73
バス	254,552	0.4	576.92
バイク	61106	0.1	2399.67
自転車	46,403	0.07	3159.65
歩行者	69,607	0.11	2106.74
子供	9,971	0.02	14700.16
建造物	54,902	0.09	2670.70
標識	231,790	0.39	633.46
緑石	6,152,674	9.67	24.95
ガードレール	5,655,771	8.89	27.05
壁	26,853,188	42.19	6.54

## 4.2. 実験結果

従来手法と重み付け手法1及び2のクラス毎の識別率を図2に示す。従来手法と比べて、クラス平均精度は各手法で約13%向上した。特に重み付け手法1は、歩行者の識別精度が約18%向上した。重み付け手法2は、自転車の識別精度が約50%向上した。これにより、重み付けを行うことで、出現率の低いクラスに対する精度を向上することができた。また、出現率の高いクラスは、重み付けの影響をほとんど受けず同等の精度である。

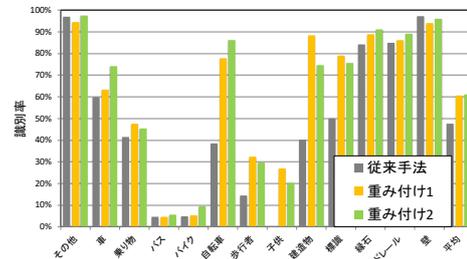


図2：各クラスの識別結果

自転車クラスのポイントクラウドの識別例を図3に示す。図3より、重み付け手法2のほうが重み付け手法1より正解ポイント数が増加していることが確認できる。

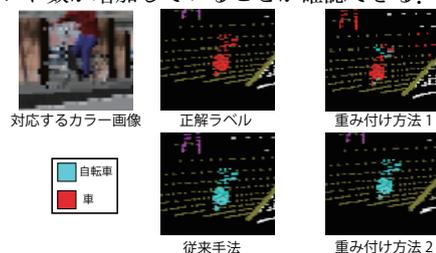


図3：自転車クラスのポイントクラウドの識別例

## 5. おわりに

本研究では、PointNetによる物体識別に、各クラスの出現率を考慮した学習を行うことで、ポイント数の少ないクラスの高精度化を実現した。今後は、さらなる識別精度の高精度化を目指す。

### 参考文献

- [1] Charles R. Qi, *et al.*, “PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation”, CVPR, pp. 652-660, 2017.