

修士論文概要書

Master's Thesis Summary

Date of submission: 01/27/2025 (MM/DD/YYYY)

専攻名 (専門分野) Department	情報理工・ 情報通信専攻	氏 名 Name	小野蒼平	指 導 教 員 Advisor	渡辺裕 印 Seal
研究指導名 Research guidance	オーディオビジュ アル情報処理研究	学籍番号 Student ID number	CD 5123F026-9		
研究題目 Title	色と形状の相関を利用した点群分類における代表点選択 Point Sampling in Point Cloud Classification Using Color and Shape Correlation				

1. まえがき

近年、三次元情報を扱う技術はさまざまな分野で注目を集めており、三次元点群を利用したデータ解析が重要性を増している。点群は物体の形状を点の集合で表現するデータ形式である。膨大な情報を効率的に取得できる点が注目されているが、各点が規則的な構造を持たない非構造的データであるため、近傍点間の関係を捉えて局所特徴を効果的に学習することが難しく、深層学習を用いた解析には工夫が必要である。

点群を特定のカテゴリに分類するタスクである点群分類は、三次元データ解析の基盤であり、その有効性を高めることが重要な課題である。深層学習を用いた点群分類の従来の代表的なモデルとして、PointNet++[1] が挙げられる。PointNet++はPointNet[2]を改良したモデルであり、局所特徴の学習が可能である。PointNet++では、座標情報(x, y, z)を用いて学習が行われ、色情報(RGB)は活用されていない。点群分類では同じカテゴリに属するオブジェクトでも色にバリエーションがあり、色情報を学習において有効に活用することが難しい。しかし、物体の形状と色には相関が存在する場合があります。この相関を活用することで分類精度の向上が期待できる。そこで本研究では、PointNet++の処理工程の一つである代表点選択において色情報を利用する手法を提案する。

2. PointNet++

PointNet++は、点群データを入力して分類やセグメンテーションを行うモデルである。PointNetの課題を克服するために提案されたモデルであり、局所特徴の学習を可能にした。PointNetを階層的に適用した構造であり、代表点選択(サンプリング)を行う Sampling layer, 近傍点のグループ化を行う Grouping layer, 局所特徴量を計算して代表点に集約する PointNet layer で構成される。これらの処理を二段階で行うことで、局所的小および大域的な特徴量の学習を実現する。Sampling layer では、サンプリング手法に Farthest Point Sampling (FPS) [3] が用いられる。FPS はすでに選択された点から最も遠い点を順次選択する手法であり、点群全体にわたって均一に分布する代表点を効率的に選択できる。しかし、均一な代表点選択が常に分類精度の向上につながるとは限らない。

3. 提案手法

本研究では代表点選択において座標情報に加えて色情報を利用する新しいサンプリング手法を提案する。この手法を、PointNet++の2回のSampling layerのうち、1回目を置き換える形で適用する。モデル全体の概要を図1に示す。

物体の形状と色には相関が存在する場合があります。ため、色情報を活用することで、局所の特徴量を効果的に捉える代表点を選択できると考えられる。そこで、図2に示すサンプリング手法を提案する。




図 1. 提案手法を適用した PointNet++の概要




図 2. 色情報を利用した代表点選択

- ① 点群の色情報をもとに各点を色ごとに分け、グループ化を行う
- ② グループ化された各色の点群に対して FPS を適用し、代表点を選択する
- ③ 色ごとの代表点セットを統合し、最終的な代表点セットとして採用する

提案する代表点選択手法によって、より効果的に局所的特徴量を取得できると期待される。また、②で選択する色ごとの代表点の個数比の決定方法として、色ごとの点の個数比を維持する方法 (Ours1) と、平方根比を用いる方法 (Ours2) を提案する。Ours2 は、大小関係を維持しつつ点の数が少ない色を強調する。点の数が少ない色は、引き出しの取手など物体の特徴となる部分にある場合が多く、その部分から多く代表点を選択することで局所的特徴量をより効果的に捉えることが期待される。

4. 実験

本研究では、実験のために ModelNet10[4] を 3D モデリングツールで着色したデータセットを作成した。実験時間を短縮するため、10 クラスのうち正解率が低い傾向にある desk, dresser, night_stand, sofa, table の 5 クラスを選定した。各クラスでトレーニングデータ 70 種類、テストデータ 30 種類の計 500 種類の点群データを着色した。

Ours1, Ours2 と、従来手法である PointNet++ と 3 通りの手法でトレーニングを実施した。5 種類のクラスに対し、予測と実際のクラスが一致するかどうかを調べ、Instance Accuracy を算出した。Instance Accuracy の算出方法は式(1)で表される。

$$\text{Instance Accuracy} = \frac{\text{total hits}}{\text{total predicts}} \quad (1)$$

テストは 10 回行い、Instance Accuracy の平均値を評価指標とする。実験結果を表 1, 表 2 に示す。

表 1 より、Ours1 および Ours2 は、いずれも従来手法である PointNet++ を上回る分類精度を示し、特に Ours2 が最も高い分類精度を達成した。この結果から、色情報を利用することで効果的な代表点選択が可能であることが分かる。また、Ours2 の方がより高い分類精度を示していることから、点数が少ない色を強調する手段の有効性が確認された。

表 1. 各手法の分類精度の比較

Method	Accuracy (%)
PointNet++	82.9
Ours1	86.8
Ours2	87.1

表 2. 各手法のクラスごとの分類精度(%)の比較

Method	desk	dresser	night_stand	sofa	table
PointNet++	91.3	78.3	76.7	100	68.0
Ours1	90.0	77.3	86.0	95.7	85.0
Ours2	90.3	94.7	69.0	100	81.3

一方、表 2 に示す結果から、クラス単位では Ours2 の分類精度が他の手法に劣るものも確認された。この結果から、点の数が少ない色を強調する手段の有効性はクラスによって異なることが分かる。Ours2 は意図的に点が密である部分と疎である部分を作り出す手法であるため、重要な情報が欠落するリスクもある。そのため、点の数が少ない色を強調したことが逆効果となって分類精度が低下する場合もあり、有効性がクラスによって異なるという結果になったと考えられる。

5. むすび

本研究では、PointNet++ の処理工程の一つである代表点選択において色情報を利用する手法を提案した。提案手法により、色と形状の相関を利用して局所特徴をより効果的に学習する。実験において提案手法の有効性を示した。また、点の数が少ない色を強調する方法を提案し有効性を示したが、欠点も存在しクラスによって有効性に差が生じた。今後は、データセットのクラス数を増やして実験を行い、考察を深める必要がある。

参考文献

- [1] C.R. Qi, L. Yi, H. Su, and L.J. Guibas, "PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space," International Conference on Neural Information Processing Systems (NIPS'17), pp.5105-5114, Dec. 2017.
- [2] C.R. Qi, H. Su, K. Mo, and L.J. Guibas, "PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation," 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.652-660, Jul. 2017.
- [3] Y. Eldar, M. Lindenbaum, M. Porat, and Y.Y. Zeevi, "The farthest point strategy for progressive image sampling," IEEE Transactions on Image Processing, vol.6, no.9, pp.1305-1315, Sep.1997.
- [4] Z. Wu, S. Song, A. Khosla, F. Yu, L. Zhang, X. Tang, and J. Xiao, "3D ShapeNets: A Deep Representation for Volumetric Shapes," In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.1912-1920, Jun. 2015.

2024 年度

早稲田大学大学院 基幹理工学研究科 情報理工・情報通信専攻 修士論文

色と形状の相関を利用した点群分類における代表点選択

Point Sampling in Point Cloud Classification Using Color and Shape
Correlation

小野 蒼平
(5123F026-9)

提出日：2025 年 1 月 27 日

指導教員：渡辺 裕 教授

研究指導名：オーディオビジュアル情報処理研究

目次

第1章	序論.....	1
1.1	研究背景	1
1.2	関連研究と問題点	1
1.3	本論文の構成	2
第2章	関連研究.....	3
2.1	まえがき	3
2.2	PointNet.....	3
2.2.1	T-net.....	3
2.2.2	Max Pooling.....	4
2.3	PointNet++	4
2.3.1	Sampling layer	4
2.3.2	Grouping layer	5
2.3.3	PointNet layer.....	5
2.4	PointNet#.....	5
2.5	むすび	5
第3章	提案手法.....	6
3.1	まえがき	6
3.2	提案手法	6
3.2.1	概要	7
3.2.2	色情報を利用した代表点選択	7
3.3	むすび	9
第4章	実験.....	10
4.1	まえがき	10
4.2	データセット	10
4.3	評価方法	12
4.4	実験結果	13
4.5	考察	13
4.6	むすび	14
第5章	結論.....	15

5.1 結論	15
5.2 今後の課題	15
謝辞	16
参考文献	17
図一覧	18
表一覧	19
研究業績	20

第1章 序論

1.1 研究背景

近年, 産業のデジタル化が進展し, 様々な分野で三次元データの需要が拡大している. 例えば, 自動運転技術では LiDAR センサーによる高精度な三次元環境認識が利用されている[1]. また, 建築や土木分野では, Building Information Modeling (BIM) [2] の普及により, 建築物やインフラの設計から維持管理まで一貫して三次元データを活用する動きが進んでいる. さらに, 都市開発においても, 航空機やドローンから取得される LiDAR データを基に, 効率的な土地利用計画や環境評価が行われている[3].

特に, 3次元データの一つである点群は, 環境や物体に関する膨大な情報を効率的に取得できるデータ形式として注目されている. 点群はセンサーやスキャナーによって大量の位置情報を収集することが可能であり, 広範囲の環境を記録できる. さらに, RGB センサーやカメラを併用することで, 色情報を含む点群を取得することも可能である. このような点群データを活用する上で, 点群分類は基盤となるタスクの一つである. 点群分類とは, 各点にラベルを付与することで, 環境中の物体や地形を識別する作業を指す. 自動運転においては道路や歩行者, 車両などを正確に識別するために使用され, 建築分野では建物の部材を分類して設計や施工に活用されるなど, 点群分類は多様な分野でのデータ解析や応用の基盤となるタスクであり, その重要性は極めて高い.

1.2 関連研究と問題点

点群とは, 三次元空間上の物体を点 (x, y, z) の集合で表現するデータ形式であり, 三次元座標のほかに色情報 (R, G, B) や法線情報を持つものもある. 点群のクラス分類とは, 与えられた点群データがどのカテゴリに属するかを推定するタスクである. 画像と異なり, 点群は点の順序や位置が不規則に配置されている. この非構造的な性質のため, 従来の畳み込みニューラルネットワーク (CNN) を直接適用することが困難であることが課題になる.

深層学習を用いた点群分類の代表的なモデルとして, PointNet[4] やその発展型である PointNet++[5] が挙げられる. PointNet は, 点群をそのままのデータ形式で入力できるクラス分類モデルである. Spatial Transformer Networks (STN) [6] を T-Net として導入し, 入力点群を剛体変換することによって物体の回転と並進を正規化する. このネットワークによって点の順序や位置に依存しない出力を得られるようになる. また, 対称関数である Max Pooling を用いることで, 順不同の性質に対応する. しかし, PointNet には近傍点群の情報を取り込めないという問題がある.

PointNet++は, PointNet の課題を克服するために提案されたネットワークである. 入力点群から代表点を選択し, その点から半径 r 内にある点を一つの Point Set として PointNet 処理を行い, 特徴量を得る. この処理を繰り返すことで, 局所的な特徴を学習できる. 代表点選択ではサンプリング手法に Farthest Point Sampling (FPS) [7] が用いられる. FPS によって点群全体にわたって均一に分布する代表点を効率的に選択できる. しかし, 代表点を均一に選択することが常に分類精度の向上につながるとは限らない.

これらの関連研究では, 主に座標情報 (x, y, z) を用いて学習が行われ, 色情報 (RGB) は活用されていない. 点群分類では同じカテゴリに属するオブジェクトでも色にバリエーションがあり, 色情報を学習において有効に活用することが難しい. しかし, 物体の形状と色には相関が存在する場合があります, この相関を活用することで分類精度の向上が期待できる. そこで本研究では, PointNet++の代表点選択において座標情報に加えて色情報を利用する手法を提案する. さらに, 色情報を持つ点群分類データセットを使用した評価実験を通じて点群分類の精度改善を示す.

1.3 本論文の構成

以下に本論文の構成を示す.

第1章 本章であり, 本研究の背景および目的について述べる.

第2章 関連研究および本研究で用いるサンプリング手法について述べる.

第3章 本研究の比較条件について述べる.

第4章 評価実験と, その結果について述べる.

第5章 結論と今後の課題について述べる.

第2章 関連研究

2.1 まえがき

本章では，従来の点群分類手法である PointNet および PointNet++について述べる．また，PointNet++に色情報を付加した関連研究として PointNet# [8] について述べる．

2.2 PointNet

PointNet は点群データを入力して分類やセグメンテーションを行うネットワークである．前章で述べたように，点群は非構造化データであるため学習することが困難であり，従来の研究ではボクセルや画像などに変換して入力するものが大半であった．それに対して，PointNet は従来の変換を必要とせずに学習が可能であり，点群データをその形式のまま入力して使用できるという特徴がある．




図 2.1 PointNet のアーキテクチャ (Classification)

図 2.1 のように，入力情報は点群の座標データである．出力は，分類クラスごとの正解率である．

以下，特に重要な構成要素である T-Net と Max Pooling 関数について説明を行う．

2.2.1 T-net

T-net は，一般的に Spatial Transformer Networks (STN) として知られる技術に基づくニューラルネットワークである．三次元点群を入力として受け取り，出力としてアフィン行列を生成する．出力されたアフィン行列をアフィン変換として入力点群に適用することで，移動や回転に対応する．

2.2.2 Max Pooling

Max Pooling は入力要素のうち最大の要素を出力する関数である。対称関数であるため、入力要素の順序の影響を受けず同じ結果が出力される。PointNet は、ネットワークの最終層で Max Pooling を用いることで点群の順不同の性質に対応する。

2.3 PointNet++

PointNet++は、PointNet の著者らによって提案された新たなモデルである。PointNet と同様にクラス分類およびセグメンテーションを行うことが可能であり、PointNet では取り入れることのできなかった局所構造の特徴を取り入れた。PointNet++は、図 2.2 で示すように PointNet を階層的に適用したネットワーク構造であり、代表点選択（サンプリング）を行う Sampling layer, 近傍点のグループ化（グルーピング）を行う Grouping layer, 局所特徴量を計算する PointNet layer で構成される。これらの処理を二段階で行うことで、局所的および大域的な特徴量の学習を実現する。




図 2.2 PointNet++ のアーキテクチャ (Classification)

以下にそれぞれの層についての説明を行う。

2.3.1 Sampling layer

三次元点群を入力すると、指定された個数の代表点にダウンサンプリングされて出力される。ダウンサンプリングとは、情報量を失わないようにデータ数を減らす手法であり、通常は計算量の削減のためにデータ入力時に行われる。しかし、今回は計算量削減の目的ではなく、点のグループを形成するための代表点を選定するために用いられる。サンプリングに使用される手法は、Farthest Point Sampling (FPS) である。この手法では、まずランダムに 1 点を選択し、以降はすでに選択された点から最も遠い点を順次選択することを、指定の個数に達するまで繰り返す。このように選択することで、代表点が点群全体にわたって均一に分布するように選ばれる。FPS はデータ数の削減方法として優れた手法であるが、局所特徴を得る目的での代表点選択として常

に最適な手法であるは限らない。

2.3.2 Grouping layer

三次元点群とその代表点の情報を入力すると、それぞれの代表点における近傍点のグループが出力される。グルーピングには radius-Nearest Neighbor (rNN) [9] が使用されており、サンプリングされた点を中心とした半径 r の球の内部にある点がグループ化される。グループに含まれる点の数には指定があり、球の内部に点が多すぎる場合は、近い順に指定数まで選ばれる。一方で、点が足りない場合には、最も近い点を繰り返し追加して指定数を満たす。

2.3.3 PointNet layer

Grouping layer で出力されたグループを入力すると、各グループの局所的な幾何学的特徴が出力される。まず、各グループ内の点を、対応する代表点を原点とする相対座標に変換する。次に、各グループに対して PointNet を適用し、局所的な特徴を学習する。学習された特徴量は各グループの代表点に集約され、代表点がその特徴量を保持する状態となる。

2.4 PointNet#

PointNet++を基に、点群と色情報を同時に学習するよう拡張された点群分類モデルである。入力を六次元 (x, y, z, R, G, B) に拡張し、点群の位置情報と色情報に対して異なる処理を施す構造を持つ。六次元の入力は座標情報 (x, y, z) と色情報 (R, G, B) に分割され、座標情報を基に PointNet++と同様に Sampling と Grouping が行われる。色情報は、各点の特徴量として保持され、その後の処理で利用される。以降の処理は基本的に PointNet++に準じるが、2 回目以降の PointNet 処理においては座標情報の追加を行わない。これは、座標情報と色情報の重みが均一にする工夫である。

評価実験では、分類に座標情報と色情報の双方の学習が必要となる独自のデータセットが使用された。実験の結果、座標情報と色情報を同時に学習できることが示された。

なお、同著者によって、時系列情報を付加した点群データの学習が可能な拡張版[10]も提案された。

2.5 むすび

本章では、従来の点群分類手法である PointNet および PointNet++のクラス分類について述べた。また、関連研究として PointNet++を拡張したモデルである PointNet#について述べた。

第3章 提案手法

3.1 まえがき

本章では，PointNet++の代表点選択において色情報を利用する手法を提案する．

3.2 提案手法

前述したように，点群分類では，同じカテゴリに属するオブジェクトであっても色にバリエーションが存在するため，色情報を学習において有効に活用することが難しい．第4章で述べる本研究の評価実験は，色にバリエーションのあるデータセットを用いて実施した．図3.1は，実験のために用意したデータセットの一つであり，deskクラスに属するデータである．このデータセットには，白や黒など別の色のdeskのデータも含まれている．また，他のクラスにも図3.1と同じ色のデータが存在する．後述する実験と同じ条件下で，色情報を特徴量として直接利用するPointNet# や，色情報を座標情報と同列に扱い学習に活用する手法を適用して実験したが，PointNet++と比較しても精度の向上は確認されなかった．そこで，本研究では，色情報を直接学習に使用せず，座標情報による学習を補助する形で活用する次の手法を提案する．



図 3.1 着色した ModelNet のデータ (desk_0068.off)

3.2.1 概要

本研究では代表点選択において座標情報に加えて色情報を利用する新しいサンプリング手法を提案する．この手法を，PointNet++の2回の Sampling layer のうち，1回目を置き換える形で適用する．モデル全体の概要を図 3.2 に示す．




図 3.2 提案手法を適用した PointNet++の概要

3.2.2 色情報を利用した代表点選択

PointNet++の代表点選択は，重要な処理工程である．適切な代表点を選択することで，点群の局所的特徴量を効果的に取得することが可能となる．従来手法では，代表点選択に Farthest Point Sampling (FPS) が適用されており，代表点が点群全体にわたって均一に分布するように選ばれる．しかし，均一な代表点選択が常に最適であるとは限らず，物体の特徴的な部分を強調して代表点を選択することでより効果的に局所的特徴量を取得できると期待される．そこで，本研究では点群の色情報に着目する．物体の形状と色には相関が存在する場合があります，この相関を活用することで，より効果的な代表点選択が可能となり，分類精度の向上が期待される．例えば，図 3.1 では，desk を table と区別する際に重要な引き出しの取手部分が黒くなっており，全体では表面積の割合が小さい色が物体の形状において重要な特徴となる．このような特徴が欠落しないように，図 3.3 に示す手法を提案する．




図 3.3 色情報を利用した代表点選択

① 点群の色情報をもとに各点を色ごとに分け，グループ化を行う

点群の色情報を図 3.4 のように各チャンネル (R, G, B) をそれぞれ 2 段階に量子化し，各点を八つの色に区分する．さらに，閾値を設定して，点の数が極端に少ない色や，点が存在しない色を除外し，残った色ごとにグループを構成する．




図 3.4 色情報の量子化

② グループ化された各色の点群に対して FPS を適用し，代表点を選択する

グループ化された各色の点群に対して FPS を適用し，それぞれの代表点を選択する．各色に割り当てる代表点の数は，色ごとの点の数の比に基づいて決定される．本研究では，代表点の数の決定方法として二通りの方法を提案する．一つ目は，各色の点の数の比をそのまま維持する方法で，これを Ours1 とする．二つ目は，平方根比を用いる方法で，これを Ours2 とする．Ours2 は，平方根比を用いることで，図 3.5 のように比の大小関係を維持しつつ点の数が少ない色を強調する．点の数が少ない色は，図 3.1 の黒色の部分のように引き出しの取手など物体の特徴となる部分にある場合が多く，その部分から多く代表点を選択することで局所的特徴量をより効果的に捉えることが期待される．




図 3.5 点の数が少ない色を強調した代表点選択

- ③ 色ごとに選択した代表点セットを統合し，最終的な代表点セットとして採用する
色ごとに選択した代表点セットをすべて合わせたものを最終的な代表点セットとして採用し，**Sampling layer** の出力とする．

以上のサンプリング手法を 1 回目の **Sampling layer** に適用する．本研究では，1 回目の代表点選択で十分に色情報を考慮した分布が得られると判断し，2 回目の **Sampling layer** には適用しない．これにより，処理量の増加を最小限に抑えている．

3.3 むすび

PointNet++の代表点選択において色情報を利用する提案手法について述べた．提案手法では，色ごとに代表点を選択することで物体の重要な部分を強調し，局所特徴を効率的に学習して分類精度を向上する．

第4章 実験

4.1 まえがき

本章では、提案手法の有効性を評価するために行った実験の概要、結果、考察について述べる。実験では、提案手法による点群分類の結果を PointNet++ の結果と比較し、提案手法の分類精度を検証する。

4.2 データセット

本研究では、実験のために ModelNet10 [11] を 3D モデリングツールで着色したデータセットを作成した。ModelNet は、一般公開されている CAD データのデータセットであり、トレーニング用データとテスト用データに分けられている。このデータセットは色無しのメッシュデータとして提供されており、これを着色して点群に変換した後、正規化処理を行った。また、実験時間を短縮するため、ModelNet10 の 10 クラスのうち正解率が低い傾向にある 5 クラスを選定し、各クラスでトレーニングデータ 70 種類、テストデータ 30 種類の計 500 種類の色付き点群データを作成した。選定した 5 クラスのカテゴリを表 4.1 に示す。また、着色したデータの例を図 4.1, 図 4.2, 図 4.3, 図 4.4 に示す。

表 4.1 選定した 5 クラス

Class	Number of test data
desk	30
dresser	30
night_stand	30
sofa	30
table	30



図 4.1 dresser の例 (dresser_0064)



図 4.2 night_stand の例 (night_stand_0069)




図 4.3 sofa の例 (sofa_0034)




図 4.4 table の例 (sofa_0021)

4.3 評価方法

5 種類のクラスに対し，予測と実際のクラスが一致するかどうかを調べ，Instance Accuracy を算出した．Instance Accuracy の算出方法は式(4.1)で表される．テストは 10 回 行い，Instance Accuracy の平均値を評価指標とした．

$$\text{Instance Accuracy} = \frac{\text{total hits}}{\text{total predicts}} \quad (4.1)$$

4.4 実験結果

従来手法である PointNet++ と提案手法を用いて、4.2 で述べたデータセットを用いたトレーニングおよびテストを実施した。学習の Epoch 数は 200 に設定した。また、3.2.2 で述べた色分けにおける閾値は 10 に設定した。本研究では、提案手法は Ours1, Ours2 のそれぞれを用いて検証を行った。実験結果を表 2 に示す。

表 4.2 各手法の分類精度の比較

Method	Accuracy (%)
PointNet++	82.9
Ours1	86.8
Ours2	87.1

クラスごとの分類精度を表 4.3 に示す。

表 4.3 各手法のクラスごとの分類精度(%)の比較

Method	desk	dresser	night_stand	sofa	table
PointNet++	91.3	78.3	76.7	100	68.0
Ours1	90.0	77.3	86.0	95.7	85.0
Ours2	90.3	94.7	69.0	100	81.3

4.5 考察

表 4.2 より、Ours1 および Ours2 は、いずれも従来手法である PointNet++ を上回る分類精度を示し、特に Ours2 が最も高い分類精度を達成した。この結果から、色情報を利用することで物体の特徴を効果的に捉える代表点を選択できることが示された。また、Ours2 の方がより高い分類精度を示したことから、点の数が少ない色を強調する手段の有効性が確認された。

一方、表 4.3 に示す結果から、クラス単位では Ours2 の分類精度が他の手法に劣るものも確認された。この結果から、点の数が少ない色を強調する手段の有効性はクラスによって異なることが分かる。dresser に対して Ours2 が高い分類精度を示したのは、引き出しの取手が強調されたことで重要な特徴を捉えられたためであると考察される。一方で、Ours2 は意図的に点が密である部分と疎である部分を作り出す手法であるため、重要な情報が欠落するリスクもある。そのため、点の数が少ない色を強調したことが逆効果となって分類精度が低下する場合もあり、有効性がクラスによって異なるという結果になったと考えられる。

4.6 むすび

本章では，提案手法の有効性を評価するために行った実験のデータセット，実験方法，結果，考察について述べた．色情報を持つ点群分類データセットを作成し，従来手法と二通りの提案手法のそれぞれで学習，評価を行った．実験結果から，提案手法の有効性が確認できた．

第5章 結論

5.1 結論

本研究では、PointNet++点群分類ネットワークである PointNet++の代表点選択の処理工程において色情報を利用する手法を提案した。提案手法の特徴は、点群の色情報を元に点をグループ化し、色ごとに代表点を選択する点にあり、この手法により物体の重要な部分を効果的に反映した代表点分布を生成できる。さらに、色ごとの代表点の選択において点数の少ない色を強調する方法を導入し、分類精度の向上を図った。

実験では、点数の少ない色を強調する方法を導入した提案手法が他手法と比較して最も高い分類精度を示した。この結果から、色情報を用いた代表点選択が有効であり、特に物体の重要な部分を反映する工夫が精度向上に寄与することが示された。また、色情報を効果的に活用することで、座標情報のみを用いる従来の点群処理手法では解決が困難であった課題に対し、新たな解決策を提供できる可能性が実験結果から示唆された。

5.2 今後の課題

点数の少ない色を強調する方法の有効性が示されたが、平方根比以外の比の取り方についても考察する余地がある。例えば、立方根比を利用すれば少数をさらに強調でき、対数比を利用すれば強調を抑えることができる。これらの方法についても今後検討していきたい。

また、本研究で用いたデータセットにはいくつかの課題点が存在する。まず、使用したクラス数が限られており、各クラスの特性に関する十分な考察が困難であった。今後、さらに多くのクラスのデータを用意することで、各クラスの特性をより深く検討できると考えられる。また、本研究では ModelNet10 を手動で着色したデータセットを使用した。実際のカメラやセンサーを用いて実物から取得した点群を利用することで、より実用的なデータを取得できる可能性がある。現実世界に近いデータを利用することで、提案手法の汎用性や有効性をさらに検証できる可能性がある。

謝辞

本論文の執筆に際して、丁寧なご指導をしてくださり、快適な研究環境を与えてくださった渡辺裕教授に感謝いたします。

毎週のチームゼミ活動において、研究の方向性に関して丁寧なアドバイスを下さった早稲田大学情報通信研究センター招聘研究員の原潤一博士に感謝いたします。

研究室における温かい環境を提供してくださり、本論文の執筆においても丁寧なアドバイスを下さった渡辺研究室の皆様に感謝いたします。

最後に、私をここまで育ててくださり、常に心を支えてくださり、生活を支えてくださっている家族に感謝いたします。

参考文献

- [1] E. Marti, M. A. de Miguel, F. Garcia and J. Perez, “A Review of LiDAR Sensor Technologies for Perception in Automated Driving,” in IEEE Intelligent Transportation Systems Magazine, vol. 11, no. 4, pp. 94-108, Sep. 2019.
- [2] L. Pinti, R. Codinhoto, S. Bonelli, “A Review of Building Information Modelling (BIM) for Facility Management (FM): Implementation in Public Organisations,” Applied Sciences, 12, 1540, Jan. 2022.
- [3] R. Wang, J. Peethambaran and D. Chen, “LiDAR Point Clouds to 3-D Urban Models: A Review,” in IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 11, no. 2, pp. 606-627, Feb. 2018.
- [4] C.R. Qi, H. Su, K. Mo, and L.J. Guibas, “PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation”, 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.652-660, Jul. 2017.
- [5] C.R. Qi, L. Yi, H. Su, and L.J. Guibas, “PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space,” International Conference on Neural Information Processing Systems (NIPS'17), pp.5105-5114, Dec. 2017.
- [6] M. Jaderberg, K. Simonyan, and A. Zisserman, “Spatial Transformer Networks,” International Conference on Neural Information Processing Systems (NIPS;15), pp.2017-2025, Dec. 2015.
- [7] Y. Eldar, M. Lindenbaum, M. Porat, and Y.Y. Zeevi, “The Farthest Point Strategy for Progressive Image Sampling,” IEEE Transactions on Image Processing, vol.6, no.9, pp.1305-1315, Sep. 1997.
- [8] 河合継, 黒田唯矢, 眞嶋啓介 : “PointNet#: 色情報を付与した 3 次元点群の分類” , 情報処理学会研究報告, Vol. 2019-IFAT-135, No. 1, pp. 1-6, 2019
- [9] Jon L. Bentley, “A Survey of Techniques for Fixed Radius Near Neighbor Searching,” Stanford Linear Accelerator Center, Technical Report, SLAC-186; STAN-CS-75-513, Aug. 1975.
- [10] 石塚唯矢, 河合継, 眞嶋啓介 : “PointNet#:色情報と時系列情報を付与した 3 次元点群の分類” , 情報処理学会研究報告, Vol. 2019-CG-175, No. 3, pp. 1-7, 2019
- [11] Z. Wu, S. Song, A. Khosla, F. Yu, L. Zhang, X. Tang, and J. Xiao, “3D ShapeNets: A Deep Representation for Volumetric Shapes,” In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.1912-1920, Jun. 2015.

図一覧

図 2.1	PointNet のアーキテクチャ (Classification)	3
図 2.2	PointNet++ のアーキテクチャ (Classification).....	4
図 3.1	着色した ModelNet のデータ (desk_0068.off)	6
図 3.2	提案手法を適用した PointNet++の概要	7
図 3.3	色情報を利用した代表点選択	7
図 3.4	色情報の量子化.....	8
図 3.5	点の数が少ない色を強調した代表点選択	8
図 4.1	dresser の例 (dresser_0064)	11
図 4.2	night_stand の例 (night_stand_0069)	11
図 4.3	sofa の例 (sofa_0034)	12
図 4.4	table の例 (sofa_0021)	12

表一覧

表 4.1	選定した 5 クラス	10
表 4.2	各手法の分類精度の比較	13
表 4.3	各手法のクラスごとの分類精度(%)の比較	13

研究業績

[1] 小野蒼平, 渡辺裕, “色情報を用いた点群分類における代表点選択,” 2025 年 電子情報通信学会総合大会, D-12, Mar. 2025.