

# 포인트 클라우드 복원 분포 균일도 향상을 위한 정량 지표 및 딥러닝 모델 학습 절차 개선

조항재, 전경구\*

인천대학교 임베디드시스템공학과

hangjae99@inu.ac.kr, \*kjun@inu.ac.kr

## Quantitative Metrics and Improved Deep Model Training Procedure for Enhancing the Uniformity of Point Cloud Completion

Hangjae Cho, Kyungkoo Jun\*

Embedded System Engineering, Inchoen National University

요 약

포인트 클라우드 완성(point cloud completion)은 불완전한 3차원 포인트 클라우드를 입력받아 전체 형상을 복원하는 문제로, 자율주행을 비롯한 다양한 응용 분야에서 활용된다. 이와 관련하여 딥러닝 모델들을 이용한 연구들이 성과를 내고 있으며, 모델들의 학습과 복원 정확도 평가에 포인트 클라우드 간 유사도를 측정하는 Chamfer Distance(CD)가 사용된다. 하지만, 포인트간 1:1 대응이 아닌, 중복 대응을 허용하는 CD는 복원된 포인트들의 분포가 고르지 못한 문제를 갖는다. 본 논문은 복원 분포 품질을 정량 평가할 수 있는 지표들과, 이들을 개선할 수 있는 학습 절차와 새로운 손실 함수 계산에 포함되는 포인트 선정 방법을 제안한다. 이 지표들은 CD 계산 과정에서 산출되는 포인트들의 대응 관계의 비율들로 정의된다. 기존 딥러닝 모델에 제안 절차와 손실 함수를 적용하여, 벤치마크 PCN 데이터셋의 형상 카테고리 일부를 대상으로 실험한 결과 시각적 품질 및 복원 포인트들의 분포 균일도에서 개선을 확인하였다.

### I. 서 론

Light Detection and Ranging (LiDAR) 센서를 이용해 얻은 포인트 클라우드 데이터는 원리적 한계와 환경적 요인, 하드웨어 제약으로 인해 일부가 누락된다. 이러한 소실 부분을 복원하는 문제를 포인트 클라우드 완성이라고 한다. 전체 모양 중 일부에 해당하는 포인트 클라우드(입력 포인트)를 받아 복원 형상(생성 포인트)을 만들어 내는 것을 목표로 한다. 최근 딥러닝 기반 모델 연구들 중, PCN<sup>[1]</sup>은 전체 형상을 먼저 복원한 뒤 세부를 보완하는 방식을 제안하였고, SnowflakeNet<sup>[2]</sup>은 transformer 구조를 도입해 지역적 세부를 확장하였다. CRA-PCN<sup>[3]</sup>은 해상도 간 특징을 통합하여 정밀도를 향상시켰고, PointSea<sup>[4]</sup>는 2D 이미지를 보조 입력으로 활용하여 성능을 개선하였다. 하지만 기존 모델들의 경우, 생성 포인트들의 위치가 입력 포인트에서 멀리 벗어나지 않는 경우가 많아, 누락 영역이 충분히 복원되지 않는 한계를 가진다.

이러한 한계의 주요 원인은 학습과 평가에 사용되는 손실함수에서 비롯된다. 가장 널리 사용되는 Chamfer Distance(CD)<sup>[5]</sup>는 수식 1과 같이 계산된다.

$$d_{cd}(S_1, S_2) = \sum_{x \in S_1} \min_{y \in S_2} \|x - y\|_2 + \sum_{y \in S_2} \min_{x \in S_1} \|x - y\|_2 \quad (1)$$

이때,  $S_1$ 과  $S_2$ 는 포인트 클라우드 집합이다. 모델이 예측한  $S_1$ 과 실제 정답  $S_2$  두 포인트 사이의 유클리디안 거리를 측정하기 때문에, CD가 작을수록 유사성이 높음을 의미한다. 이러한 CD는 대응 포인트간 1:1 관계를 보장하지 않기 때문에, 포인트 클라우드간 유사성 표현에 한계가 있다. 예를 들어, 그림 1은 한 개의 정답 포인트 클라우드에 대해 동일 CD값(=2.636)을 갖는 2개의 서로 다른 복원 포인트 클라우드이지만, 시각적 품질에서 차이가 있다.

이러한 CD의 한계를 개선하기 위해 DCD<sup>[6]</sup>, HyperCD<sup>[7]</sup>, InfoCD<sup>[8]</sup>등이 제안되어, 복원 유사도 향상에 기여했지만 앞서 지적한 문제, 즉 생성

포인트들이

누




그림 1. 같은 CD값(=2.636)을 갖는 서로 다른 2개의 복원된 포인트 클라우드. 좌측과 우측 포인트 클라우드는 제안하는 Qualitative CD, 즉 1:1, 1:n, 1:0 관계 비율에서 차이를 보인다.

략 영역에 고르게 분포하지 못하는 현상은 해결되지 않았다.

본 논문은 CD 계산에서 포인트들의 대응 관계 종류별 빈도수를 활용하여 포인트 클라우드 유사도를 분포 균일도 면에서 측정할 수 있는 지표를 제안한다. 또한 제안 지표를 개선할 수 있는 딥러닝 모델들의 학습 절차와 손실함수 적용 범위를 제시한다. 본 논문의 주요 기여는 다음과 같다.

- CD 한계를 보완하는 포인트 분포 균일도 지표 Qualitative CD 제안
- Qualitative CD 개선을 위한 모델 학습 절차와 손실 함수 적용 방안 제안
- 기존 딥러닝 모델에 제안 방법을 적용하여 성능 검증

### II. 본론

생성 포인트의 분포 품질 관련 평가지표인 Qualitative CD를 제안하고, 이를 고려한 딥러닝 모델 학습 및 손실 함수 적용 절차를 제안한다.




그림 2. 정답(a), 입력(b), 원본 모델의 결과(c), seed generator만 수정한 결과(d), seed generator와 손실 함수 모두 개선한 결과(e)이다. 우측으로 갈수록 누락 된 영역에 고루 분포하고, 정교함이 나타나는 것을 확인할 수 있다.

## 2.1 Qualitative CD

CD 계산 과정에서 포인트 들은 대응되는 포인트들의 개수에 따라 3가지 관계, 1:1, 1:n, 그리고 1:0 로 분류된다. 이들 관계에 속하는 포인트들의 비율은 복원된 포인트 클라우드로 정답 포인트 클라우드로의 유사도 품질과 관계가 있다. 예를 들어, 생성 포인트들이 고르게 분포하여 시각적 품질이 높은 경우는 1:1 비율이 가장 높은 경우이다. 반대로 1:0 관계의 비율이 높을수록 분포 균일도가 낮아진다. 따라서 본 논문에서는 이들 관계들의 빈도수 비율을 Qualitative CD로 정의하며, 그림 1에서와 같이, 시각적 품질 면에서 더 우수한 우측 포인트 클라우드는 1:1과 1:0 관계 비율에서 좌측과 차이가 있다. 따라서, 복원 포인트 클라우드로 시각적 품질을 높이기 위해서는 Qualitative CD를 개선하는 것이 필요하며, 다음에서 이를 위한 모델의 학습 절차와 손실 함수적용 범위 변경을 제안한다.

## 2.2 Qualitative CD를 고려한 딥러닝 모델 학습 절차

포인트 클라우드 완성에 사용되는 대부분의 딥러닝 모델들은 순차적으로 다음 3단계를 수행한다. 우선 입력 포인트로부터 특징을 추출하는 단계, 특징으로부터 저해상도 복원하는 seed generator 단계, 마지막으로 upsampling을 이용한 고해상도 복원 단계이다. Qualitative CD 측면에서 분석하면, seed generator에서 만들어지는 생성 포인트들이 누락 영역 복원에 활용되는 비율이 낮아 분포 균일도가 저하되는 문제가 발생한다.

이에 대해 딥러닝 모델 학습 절차에서 다음 2가지 개선을 제안한다. 첫째, seed generator의 Farthest Point Sampling(FPS)<sup>[9]</sup> 과정에서 입력 포인트를 먼저 일부 선택하고, 생성 포인트는 모두 포함시켜, 생성 포인트의 활용률을 높인다. 기존 절차에서는 생성 포인트의 평균 39%가 이 과정에서 소실되었다. 두 번째는 손실 함수 계산에 포함되는 포인트 선정 절차의 변경이다. 이전에는 입력 포인트까지 포함하여 손실 함수를 계산하였으나, 개선된 절차에서는 생성 포인트들만 대상으로 손실을 계산한다. 이를 통해 생성 포인트가 누락 영역 위주로 분포하는 효과를 가져온다.

## 2.3 성능 실험 및 결과 분석

제안한 학습 절차가 Qualitative CD에 미치는 영향 분석 실험을 다음과 같이 진행한다. 포인트 클라우드 완성 관련 SOTA 성능의 모델 중 하나인 CRA-PCN을 대상 모델로 하여, 벤치마크 PCN 데이터셋 중 분포 균일도를 시각적으로 쉽게 인지할 수 있는 비행기 카테고리들을 이용한다. 실험에서는 2가지 개선 절차 중 첫 번째만 적용한 경우와, 두 개 모두 적용한 경우를 비교한다. 표 1의 실험 결과에서 전자의 경우 성능 향상이 제한적이지만, 손실 함수까지 개선한 경우 CD 손실, 1:1 매칭 비율, Earth Mover's Distance(EMD)가 모두 향상되었고, 특히 1:0 매칭 비율이 감소하였다. 그림 2는 이러한 정량적 결과들의 차이를 포인트들의 분포 차이로 보여준다.

## III. 결론

본 연구는 포인트 클라우드 완성에 널리 쓰이는 CD의 한계를 분석하여, 포인트 분포 품질 관련한 지표와 이를 개선하는 학습 절차와 손실 함수 적용 방법을 제안하였다. 제안 방법을 적용한 딥러닝 모델 실험에서 제안 지표의 성능 향상이 있었으며, 시각적으로도 누락 영역 복원과 분포 균등성이 개선된 결과를 확인할 수 있었다.

모델	CD	예측에서 정답 매칭 비율			EMD
		1:1	1:n	1:0	
CRA-PCN (original)	3.74	8.44%	<b>45.35%</b>	46.18%	10.84
CRA-PCN (seed)	3.74	8.59%	46.27%	45.14%	10.04
CRA-PCN (seed+loss)	<b>3.70</b>	<b>9.09%</b>	46.53%	<b>44.38%</b>	<b>9.89</b>

표 1. 하나의 카테고리(비행기)를 학습하였을 때의 결과. 1:1 비율은 높을수록 좋고, 나머지는 낮을수록 좋다.

## ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-학·석사연계ICT핵심인재양성 지원을 받아 수행된 연구임 (IITP-2025-RS-2023-00260175)

## 참 고 문 헌

- [1] YUAN, Wentao, et al. Pcn: Point completion network. In: 2018 international conference on 3D vision (3DV). IEEE, 2018. p. 728-737.
- [2] Xiang, Peng, et al. "Snowflakenet: Point cloud completion by snowflake point deconvolution with skip-transformer." Proceedings of the IEEE/CVF international conference on computer vision. 2021.
- [3] Rong, Yi, et al. "Cra-pcn: Point cloud completion with intra-and inter-level cross-resolution transformers." Proceedings of the AAAI Conference on Artificial Intelligence. Vol. 38. No. 5. 2024.
- [4] Zhu, Zhe, et al. "PointSea: Point Cloud Completion via Self-structure Augmentation." International Journal of Computer Vision 133.7 (2025): 4770-4794.
- [5] Fan, Haoqiang, Hao Su, and Leonidas J. Guibas. "A point set generation network for 3d object reconstruction from a single image." Proceedings of the IEEE conference on computer vision and pattern recognition. 2017.
- [6] Wu, Tong, et al. "Density-aware chamfer distance as a comprehensive metric for point cloud completion." arXiv preprint arXiv:2111.12702(2021).
- [7] Lin, Fangzhou, et al. "Hyperbolic chamfer distance for point cloud completion." Proceedings of the IEEE/CVF international conference on computer vision. 2023.
- [8] Lin, Fangzhou, et al. "InfoCD: A contrastive chamfer distance loss for point cloud completion." Advances in Neural Information Processing Systems 36 (2023): 76960-76973.
- [9] Charles R Qi, Li Yi, Hao Su, and Leonidas J Guibas. PointNet++: Deep hierarchical feature learning on point sets in a metric space. In Advances in Neural Information Processing Systems (NeurIPS), pages 5099-5108, 2017.