

Thinking of Point Cloud Registration from a Learning Perspective

西安交通大学 姚润昭

2024年8月1日

Outline

- 背景介绍
- 基于旋转等变网络的配准方法
- 结论与展望

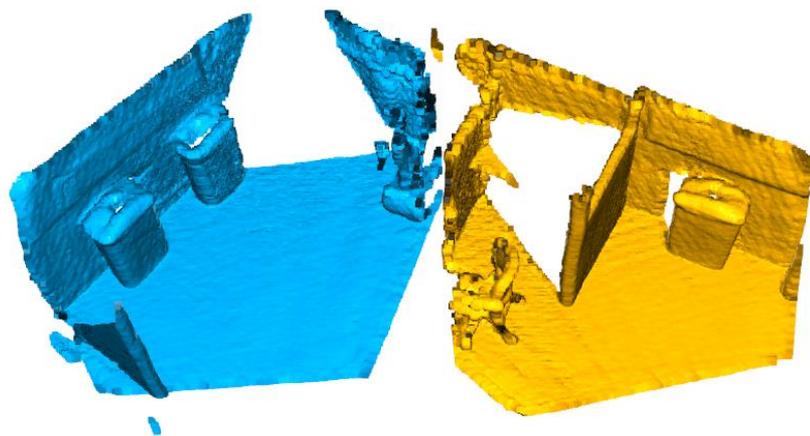
点云配准

□ 什么是点云配准?

原点云: $\mathbf{X} \in \mathbb{R}^{N_x \times 3}$

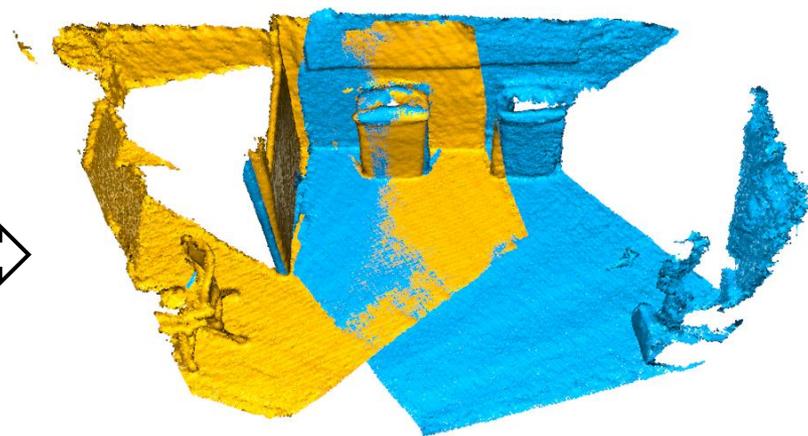
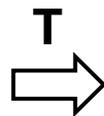
目标点云: $\mathbf{Y} \in \mathbb{R}^{N_y \times 3}$

$$\min_{\mathbf{T}, c(i) \in \{1, 2, \dots, N_y\}} \left(\sum_{i=1}^{N_x} \|\mathbf{T}(\mathbf{X}_i) - \mathbf{Y}_{c(i)}\|_2^2 \right)$$



原点云

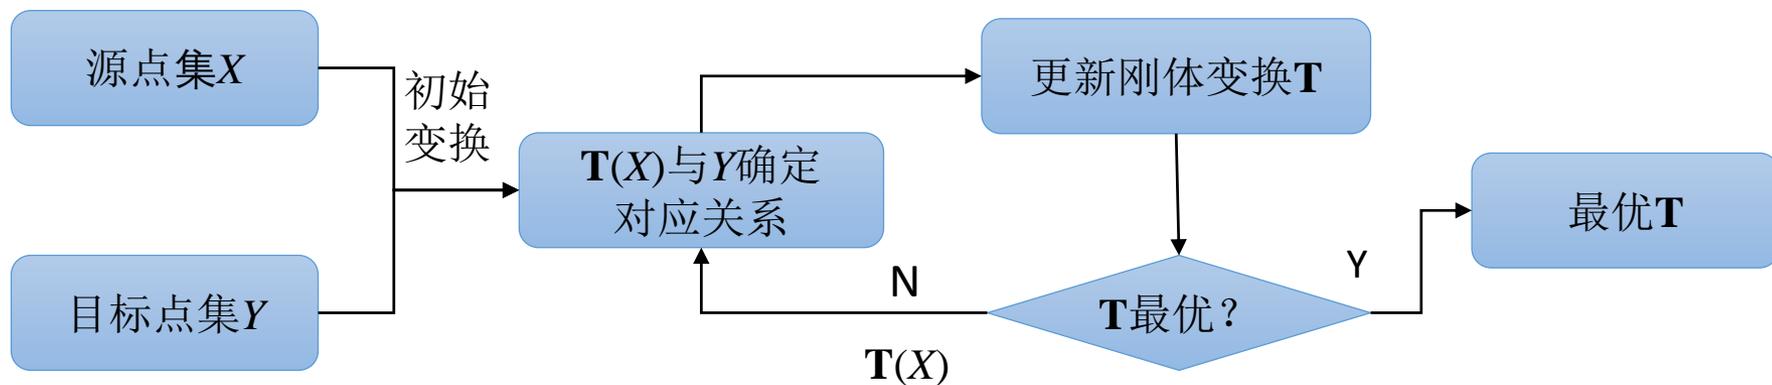
目标点云



配准结果

传统的点云配准方法

□ 迭代最近点算法 (ICP)



➤ 优点:

- 计算效率高
- 适用性较强

➤ 缺点

- 对初始位姿要求较高
- 对离群点较为敏感

➤ 其它方法: Point2PlaneICP、GICP、CPD、NDT

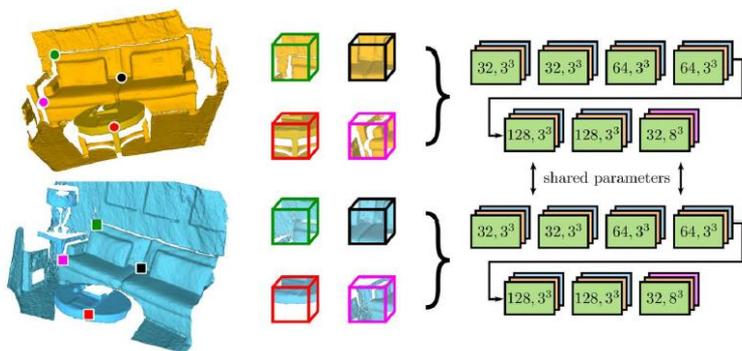


基于深度学习的配准方法

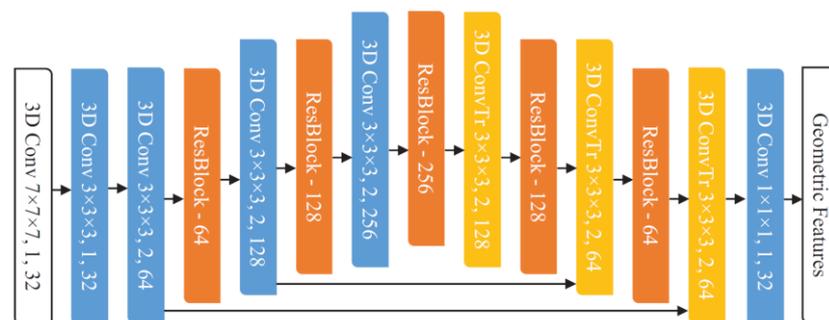
□ 一般流程图



➤ 特征提取:



基于Patch的方式 (PerfectMatch)



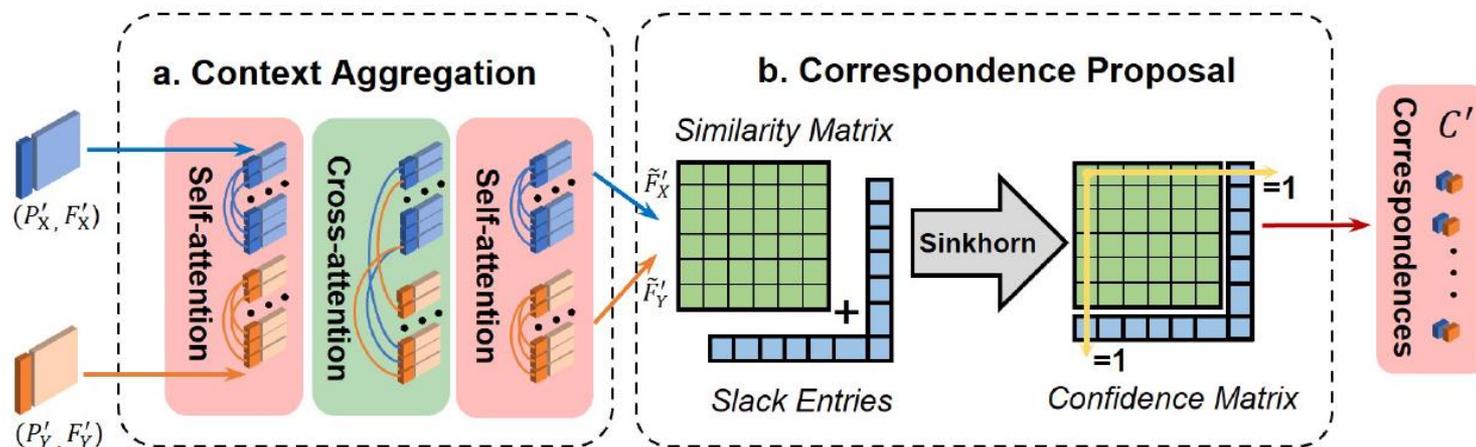
基于全卷积网络 (FCGF)

基于深度学习的配准方法

□ 一般流程图



➤ 对应关系估计:



特点：结合两幅点云中**特征的位置分布信息**来推理对应关系

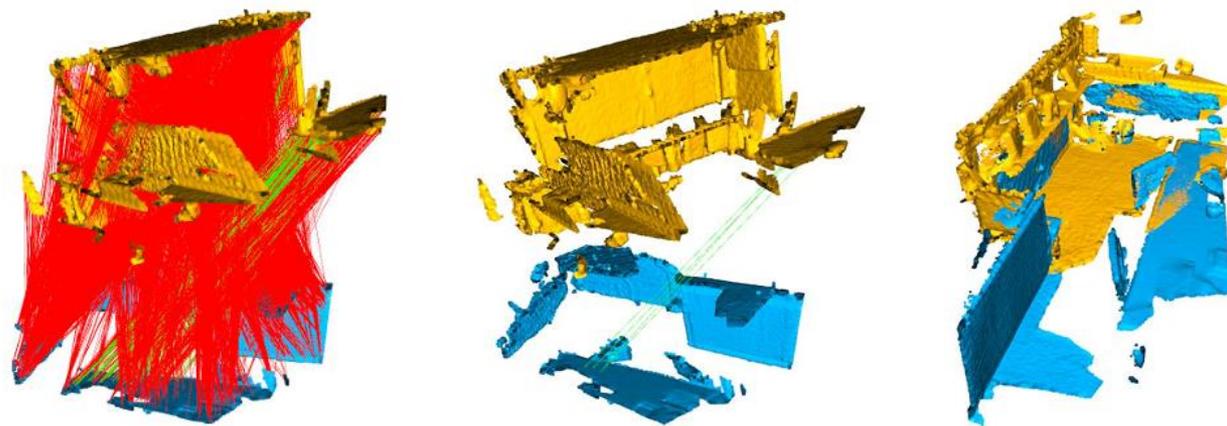
代表性工作：PREDATOR、CoFiNet、GeoTransformer、PEAL

基于深度学习的配准方法

□ 一般流程图



➤ 鲁棒位姿估计:



特点：通过分析对应关系的**空间一致性**来识别错误的对应关系

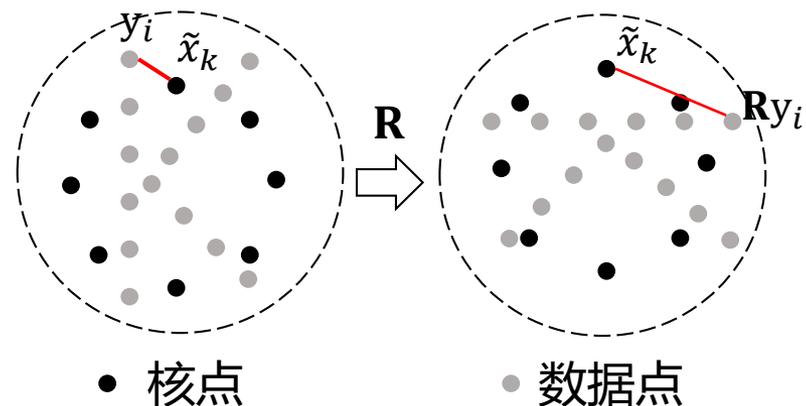
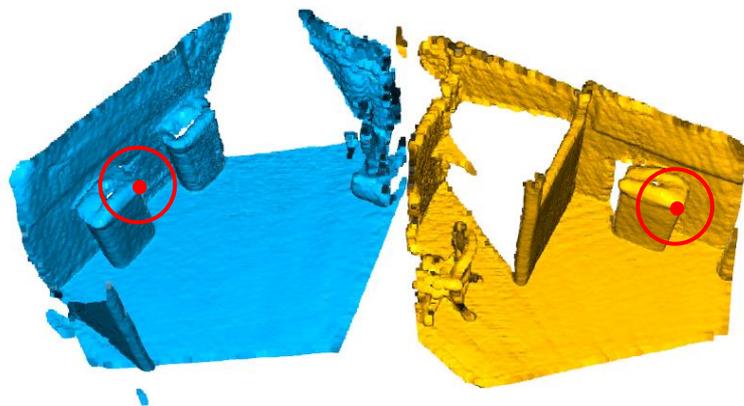
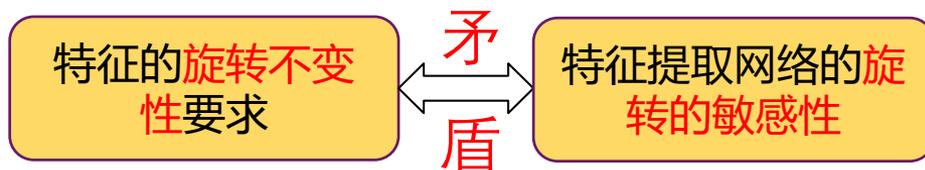
代表性工作：PointDSC、SC2-PCR、MAC、Hunter

Outline

- 背景介绍
- 基于旋转等变网络的配准方法
- 结论与展望

基于旋转等变网络的配准方法

□ 研究动机



$$g(y_i) = \sum_{k < K} h(y_i, \tilde{x}_k) W_k \quad h(y_i, \tilde{x}_k) = \max\left(0, 1 - \frac{\|y_i - \tilde{x}_k\|}{\sigma}\right)$$

希望特征描述子在点云不同位姿下是不变的

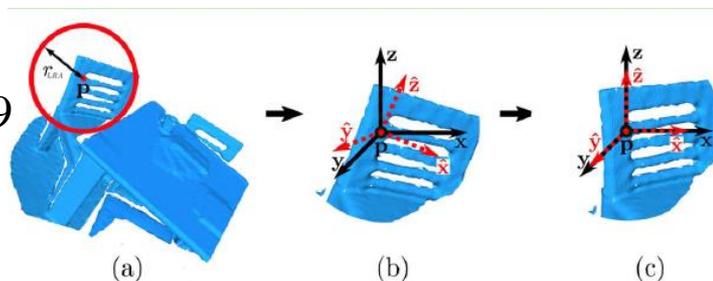
特征提取网络对点云的旋转是敏感的

基于旋转等变网络的配准方法

□ 研究动机

➤ 位姿归一化：利用Local Reference Frame 来对位姿进行归一化

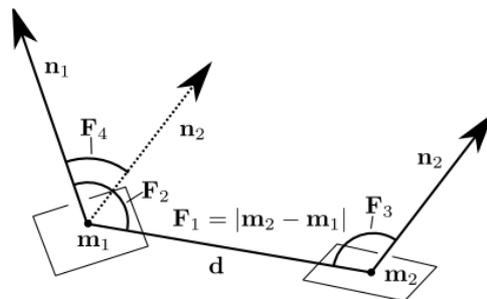
- LCGF, ICCV 2017
- PerfectMatch, CVPR 2019
- SpinNet, CVPR 2021



对部分重叠敏感

➤ 旋转不变的统计特征：Point Pair Features (PPF) 特征

- PPFNet, CVPR 2018
- PPFoldNet, ECCV 2018
- RoITR, CVPR 2023



信息损失

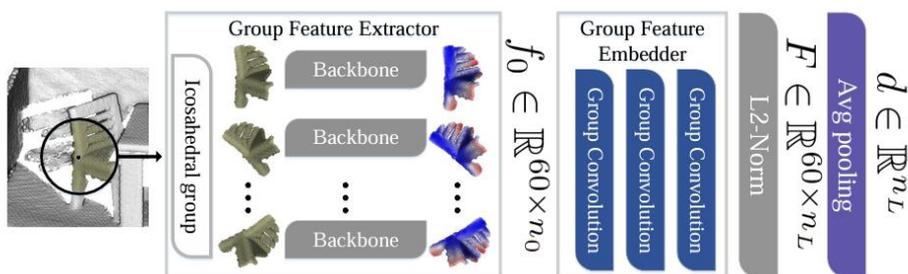
基于旋转等变网络的配准方法

研究动机

基于群理论：对SO(3)中的离散姿态进行穷举

- YOHO, ACM MM 2022
- RoReg, TPAMI 2023

计算复杂度高



全卷积网络：利用数据的旋转增强来训练网络的旋转不变性

- PREDATOR, CVPR 2021
 - CoFiNet, NIPS 2021;
 - GeoTransformer, CVPR 2022;
 - PEAL, CVPR 2023.
- 需要大量的训练样本
 - 对Unseen旋转敏感
 - 推理时计算效率高

基于旋转等变网络的配准方法

□ 研究动机

GeoTransformer (9.83MB) 在3DLoMatch数据集上的成功率

训练\测试	Without augmentation	With augmentation
Without augmentation	77.5	11.4 (↓66.1)
With augmentation	75.4	72.6 (↓2.8)

➤ PARE-Net: 采用高效的旋转等变/不变的点云卷积方法

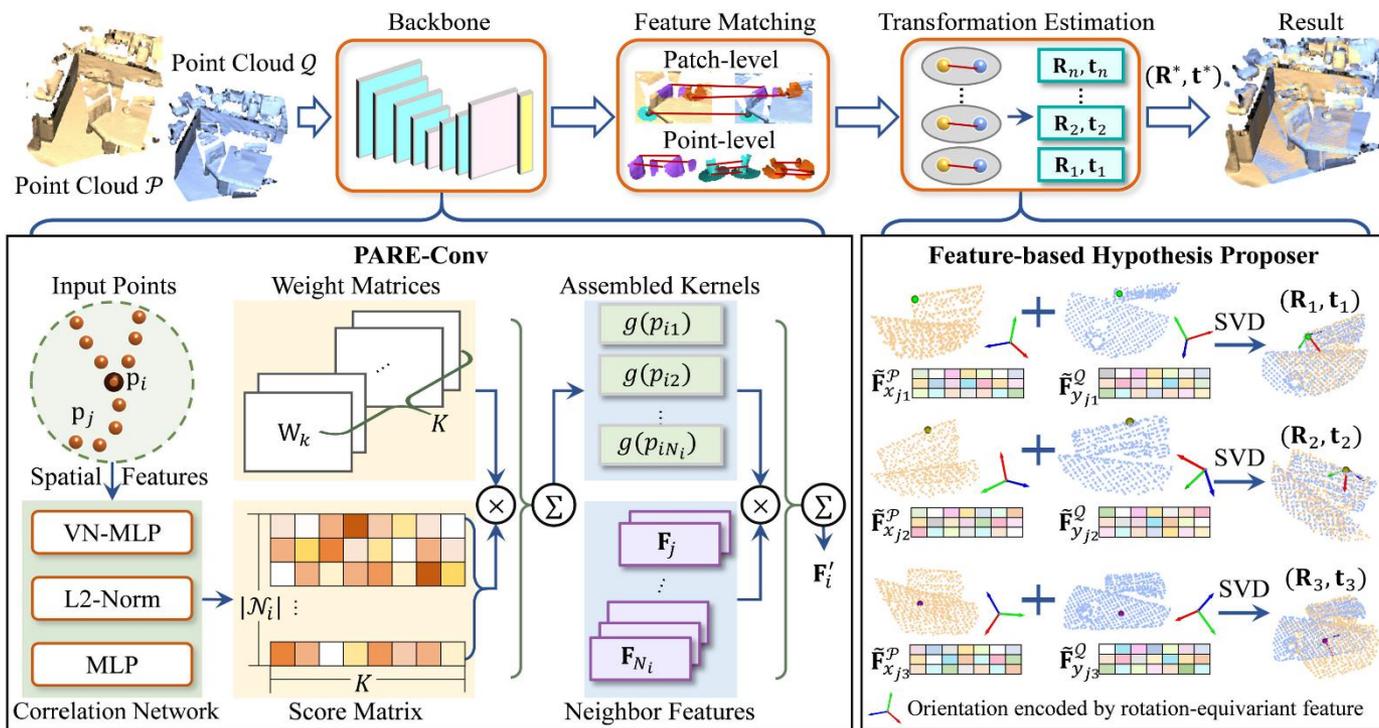
PARE-Net (3.84MB) 在3DLoMatch数据集上的成功率

训练\测试	Without augmentation	With augmentation
Without augmentation	77.9	77.8 (↓0.1)
With augmentation	81.3	81.8 (↑0.5)

优势：对旋转变换更加鲁棒、更加轻量化、描述能力更强

基于旋转等变网络的配准方法

配准流程图



➤ PARE-Conv: 位置感知的旋转等变卷积 $f(\mathbf{R} \circ \mathbf{X}) = \mathbf{R} \circ f(\mathbf{X})$

➤ 基于旋转等变特征的假设生成



基于旋转等变网络的配准方法

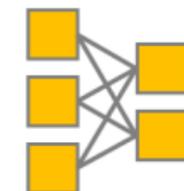
□ 位置感知的旋转等变卷积

➤ Vector Neurons (VN)

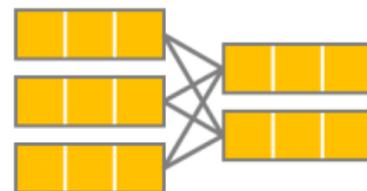
$$\mathbf{V}' = f_{\text{lin}}(\mathbf{V}; \mathbf{W}) = \mathbf{W}\mathbf{V} \in \mathbb{R}^{C' \times 3}$$

$$f_{\text{lin}}(\mathbf{V}R; \mathbf{W}) = \mathbf{W}\mathbf{V}R = f_{\text{lin}}(\mathbf{V}; \mathbf{W})R = \mathbf{V}'R$$

基于VN-MLP构建类似PointNet网络结构



(classical)
scalar neurons



vector neurons

缺点：不能有效地学习局部点云的位置分布信息

基于旋转等变网络的配准方法

位置感知的旋转等变卷积

➤ PARE-Conv

点云卷积

$$(\mathbf{F} * g)(\mathbf{p}_i) = \sum_{\mathbf{p}_j \in \mathcal{N}_i} g(\mathbf{p}_j - \mathbf{p}_i) \mathbf{F}_j$$

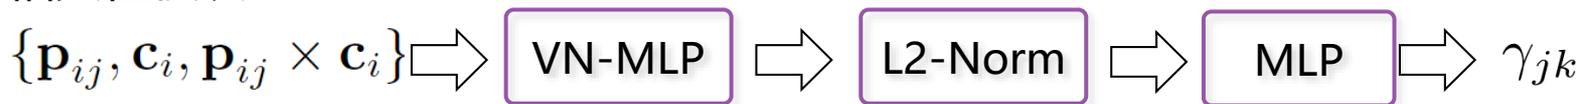
组装的卷积核

$$g(\mathbf{p}_{ij}) = \sum_{k=1}^K \text{softmax}(\gamma(\mathbf{p}_{ij}, k)) \mathbf{W}_k$$

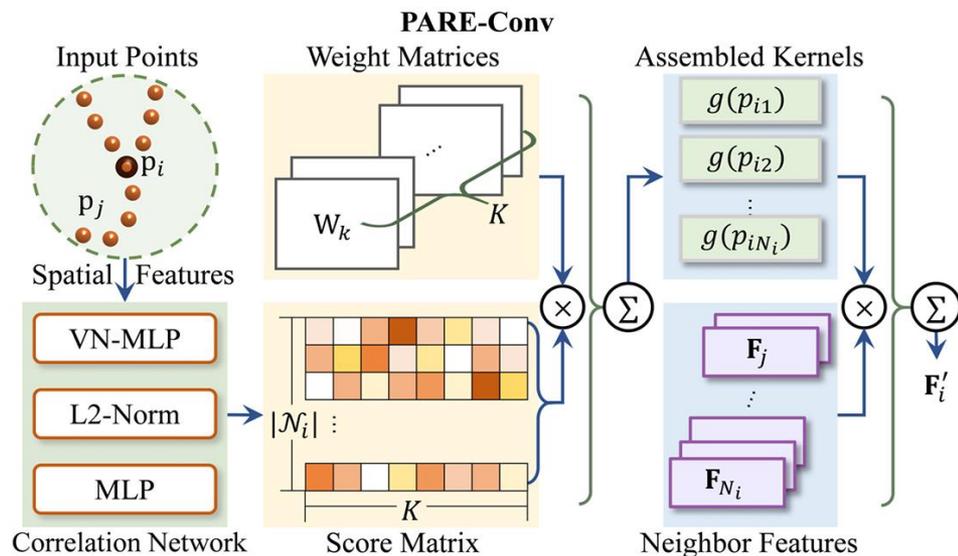
$$(\mathbf{F} * g)(\mathbf{p}_i) = \sum_{\mathbf{p}_j \in \mathcal{N}_i} \sum_k \gamma_{jk} \mathbf{W}_k \mathbf{F}_j$$

根据位置信息生成且满足旋转不变

相关性模块

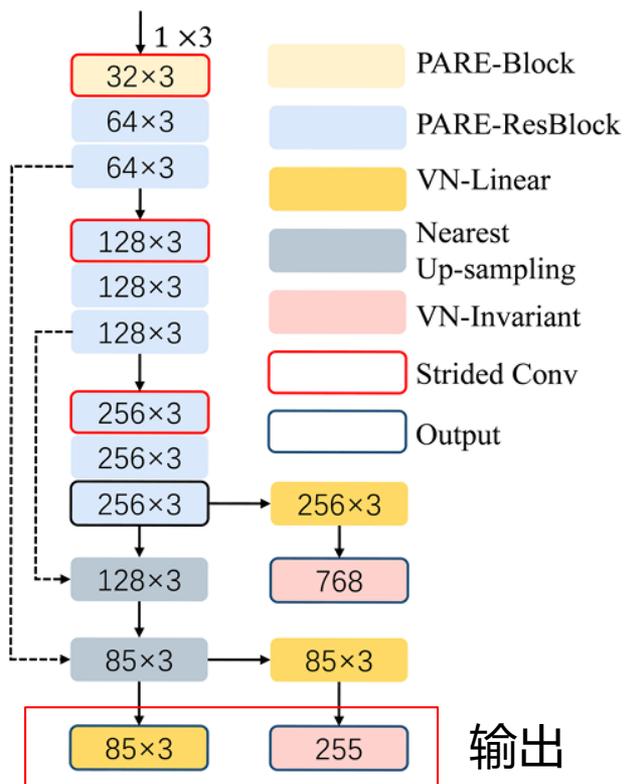


旋转等变位置信息 旋转等变特征 $C \times 3$ 旋转不变特征 C 旋转不变得分



基于旋转等变网络的配准方法

特征提取网络



Stage	3DMatch	KITTI
<i>Backbone</i>		
1	KPConv(1 → 64) ResBlock(64 → 128)	KPConv(1 → 64) ResBlock(64 → 128)
2	ResBlock(64 → 128, strided) ResBlock(128 → 256) ResBlock(256 → 256)	ResBlock(64 → 128, strided) ResBlock(128 → 256) ResBlock(256 → 256)
3	ResBlock(256 → 256, strided) ResBlock(256 → 512) ResBlock(512 → 512)	ResBlock(256 → 256, strided) ResBlock(256 → 512) ResBlock(512 → 512)
4	ResBlock(512 → 512, strided) ResBlock(512 → 1024) ResBlock(1024 → 1024)	ResBlock(512 → 512, strided) ResBlock(512 → 1024) ResBlock(1024 → 1024)
5	-	ResBlock(1024 → 1024, strided) ResBlock(1024 → 2048) ResBlock(2048 → 2048)
6	-	NearestUpsampling UnaryConv(3072 → 1024)
7	NearestUpsampling UnaryConv(1536 → 512)	NearestUpsampling UnaryConv(1536 → 512)
8	NearestUpsampling UnaryConv(768 → 256)	NearestUpsampling UnaryConv(768 → 256)

PARE-Net: 3层1.15MB (3DMatch)

3层1.46MB (KITTI)

GeoTransformer: 4层6.01MB(3DMatch)

5层24.3MB (KITTI)

基于旋转等变网络的配准方法

□ 基于等变特征的模型假设生成器

估计的对应关系

$$\mathcal{C} = \{(\tilde{\mathbf{p}}_{x_j}, \tilde{\mathbf{q}}_{y_j})\}$$

利用旋转等变特征估计旋转矩阵

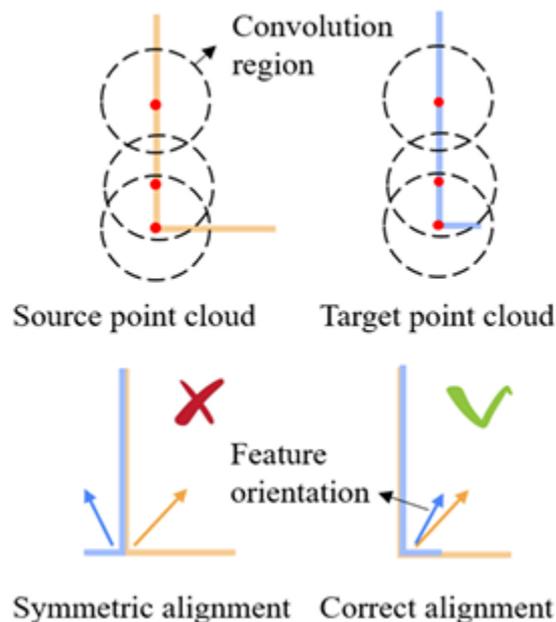
$$\tilde{\mathbf{R}}_j = \arg \min_{\mathbf{R}} \|\mathbf{R}(\tilde{\mathbf{F}}_{x_j}^{\mathcal{P}})^{\mathbf{T}} - (\tilde{\mathbf{F}}_{y_j}^{\mathcal{Q}})^{\mathbf{T}}\|_2^2$$

利用对应点估计平移矩阵

$$\tilde{\mathbf{t}}_j = \tilde{\mathbf{q}}_{y_j} - \tilde{\mathbf{R}}_j \tilde{\mathbf{p}}_{x_j}$$

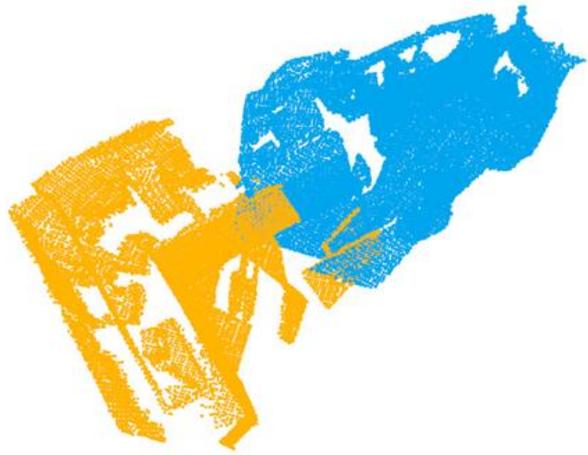
模型假设评估与选择

$$(\mathbf{R}^*, \mathbf{t}^*) = \arg \max_{\mathbf{R}_j, \tilde{\mathbf{t}}_j} \sum_{(\tilde{\mathbf{p}}_{x_j}, \tilde{\mathbf{q}}_{y_j}) \in \mathcal{C}} 1 \left(\|\tilde{\mathbf{R}}_j \tilde{\mathbf{p}}_{x_j} + \tilde{\mathbf{t}}_j - \tilde{\mathbf{q}}_{y_j}\|_2^2 < \tau_d \right),$$

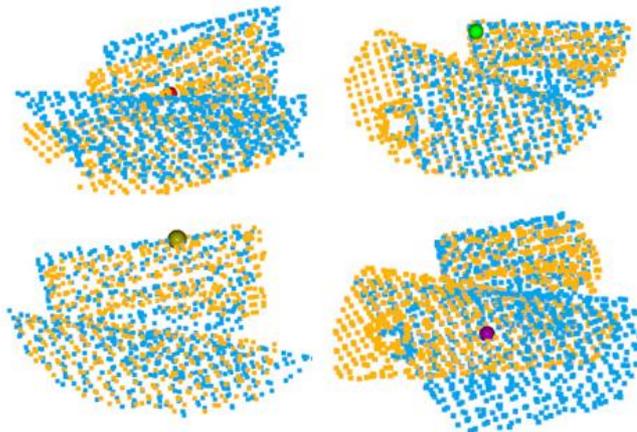


基于旋转等变网络的配准方法

□ 基于等变特征的模型假设生成器



(a) Ground-Truth Transformation



(b) Examples of hypotheses



(c) Estimated Transformation

基于旋转等变网络的配准方法

□ 损失函数

- 旋转等变特征的监督损失

$$\begin{aligned}\mathcal{L}_{r_i} = & \frac{1}{|\mathcal{C}_i^*| \cdot \tilde{d}} \sum_{(x_i, y_i) \in \mathcal{C}_i^*} \sum_{c=1}^{\tilde{d}} [\|\tilde{\mathbf{F}}_{x_i, c}^{\mathcal{P}} \mathbf{R}_{gt}^T - \tilde{\mathbf{F}}_{y_i, c}^{\mathcal{Q}}\|_2^2 - \alpha]_+ \\ & + \frac{1}{|\bar{\mathcal{C}}_i| \cdot \tilde{d}} \sum_{(x_i, y_i) \in \bar{\mathcal{C}}_i} \sum_{c=1}^{\tilde{d}} [\beta - \|\tilde{\mathbf{F}}_{x_i, c}^{\mathcal{P}} \mathbf{R}_{gt}^T - \tilde{\mathbf{F}}_{y_i, c}^{\mathcal{Q}}\|_2^2]_+, \end{aligned}$$

- 旋转不变特征的监督损失

基于旋转等变网络的配准方法

□ 室内数据集的实验结果

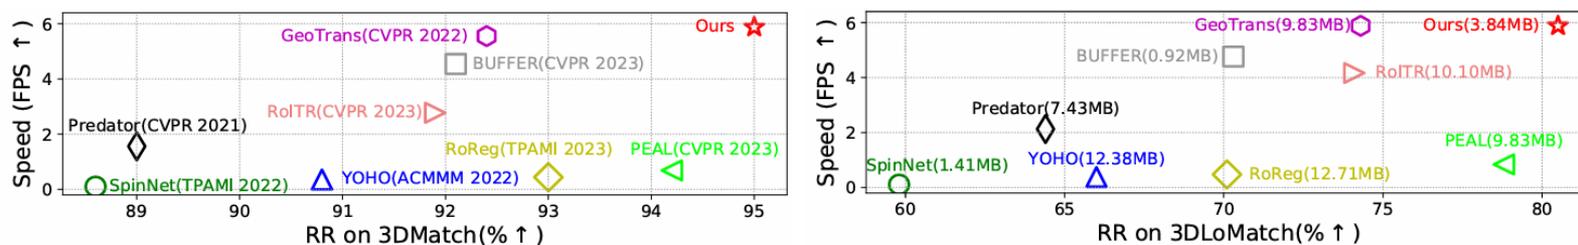


Fig. 1: Experimental results on 3DMatch and 3DLoMatch. Our method significantly outperforms state-of-the-art methods w.r.t. registration recall (RR) while maintaining fast speed and lightweight.

轻量化的网络、较高的运行效率、最高的配准成功率

基于旋转等变网络的配准方法

□ 3DMatch vs. Rotated 3DLoMatch

Method	Size (MB)	3DLoMatch			Rotated 3DLoMatch		
		RE ($^{\circ}$ ↓)	TE (cm ↓)	TR (% ↑)	RE ($^{\circ}$ ↓)	TE (cm ↓)	TR (% ↑)
FCGF [7]	8.76	4.84	12.87	39.6	4.74	13.39	24.5 ^{-15.1}
PREDATOR [15]	7.43	3.61	10.65	65.6	3.55	10.30	64.0 ^{-1.6}
GeoTrans [25]	9.83	2.91	<u>8.71</u>	75.4	2.94	8.85	72.6 ^{-2.8}
PEAL [36]	9.83	2.84	8.64	<u>81.2</u>	<u>2.86</u>	8.53	<u>78.7</u> ^{-2.5}
YOHO* [27]	12.38	3.54	10.34	66.6	3.61	10.16	67.1 ^{+0.5}
RoReg* [28]	12.71	3.01	9.26	71.3	3.03	9.28	71.0 ^{-0.3}
BUFFER* [1]	0.92	3.03	9.86	74.4	3.02	9.99	74.7 ^{+0.3}
RoITR* [35]	10.10	2.95	9.03	75.1	2.97	9.08	75.5 ^{+0.4}
Ours*	<u>3.84</u>	<u>2.87</u>	8.83	81.3	2.84	<u>8.71</u>	81.8 ^{+0.5}

良好的旋转鲁棒性、最高的配准成功率

基于旋转等变网络的配准方法

□ 室外数据集的实验结果

Table 3: Evaluation results on KITTI Odometry.

Method	Size	RE ($^{\circ}$)	TE (cm)	TR (%)	Time (s)
FCGF [7]	8.76	0.30	9.5	96.6	-
D3Feat [4]	14.08	0.30	7.2	99.8	-
Predator [15]	22.77	0.27	6.8	99.8	0.77
SpinNet [2]	1.41	0.47	9.9	99.1	16.24
CoFiNet [34]	5.48	0.41	8.2	99.8	0.59
GeoTrans [25]	25.50	0.23	6.2	99.8	0.26
BUFFER [1]	0.92	0.26	7.1	99.8	0.27
Ours	2.08	0.23	4.9	99.8	0.21

更高的配准精度

基于旋转等变网络的配准方法

消融实验结果

Table 4: Ablation experiments of our method.

Component Method		3DMatch			3DLoMatch		
		FMR (% \uparrow)	IR (% \uparrow)	RR (% \uparrow)	FMR (% \uparrow)	IR (% \uparrow)	RR (% \uparrow)
Backbone	VN (Node) [8]	98.6	71.0	93.4	87.8	41.4	76.6
	PARE-Conv (Node)	98.9	74.1	94.5 ^{+1.1}	88.3	44.0	78.8 ^{+2.2}
	VN (Edge) [8]	98.7	72.4	94.1	88.8	43.5	77.8
	PARE-Conv (Edge)	98.5	76.9	95.0 ^{+0.9}	88.1	47.5	80.5 ^{+2.7}
Pose Estimator	RANSAC	98.5	76.9	93.7	88.3	47.5	77.5
	LGR [25]	98.5	76.9	94.0 ^{+0.3}	88.3	47.5	78.9 ^{+1.4}
	Ours	98.5	76.9	95.0 ^{+1.3}	88.3	47.5	80.5 ^{+3.0}
Rotation Loss	Without	98.3	74.4	93.3	88.7	45.5	79.3
	L2	98.6	65.4	94.2 ^{+0.9}	85.9	35.0	75.4 ^{-3.9}
	Contrastive	98.5	76.9	95.0 ^{+1.7}	88.3	47.5	80.5 ^{+1.2}

基于旋转等变网络的配准方法

□ 泛化实验结果

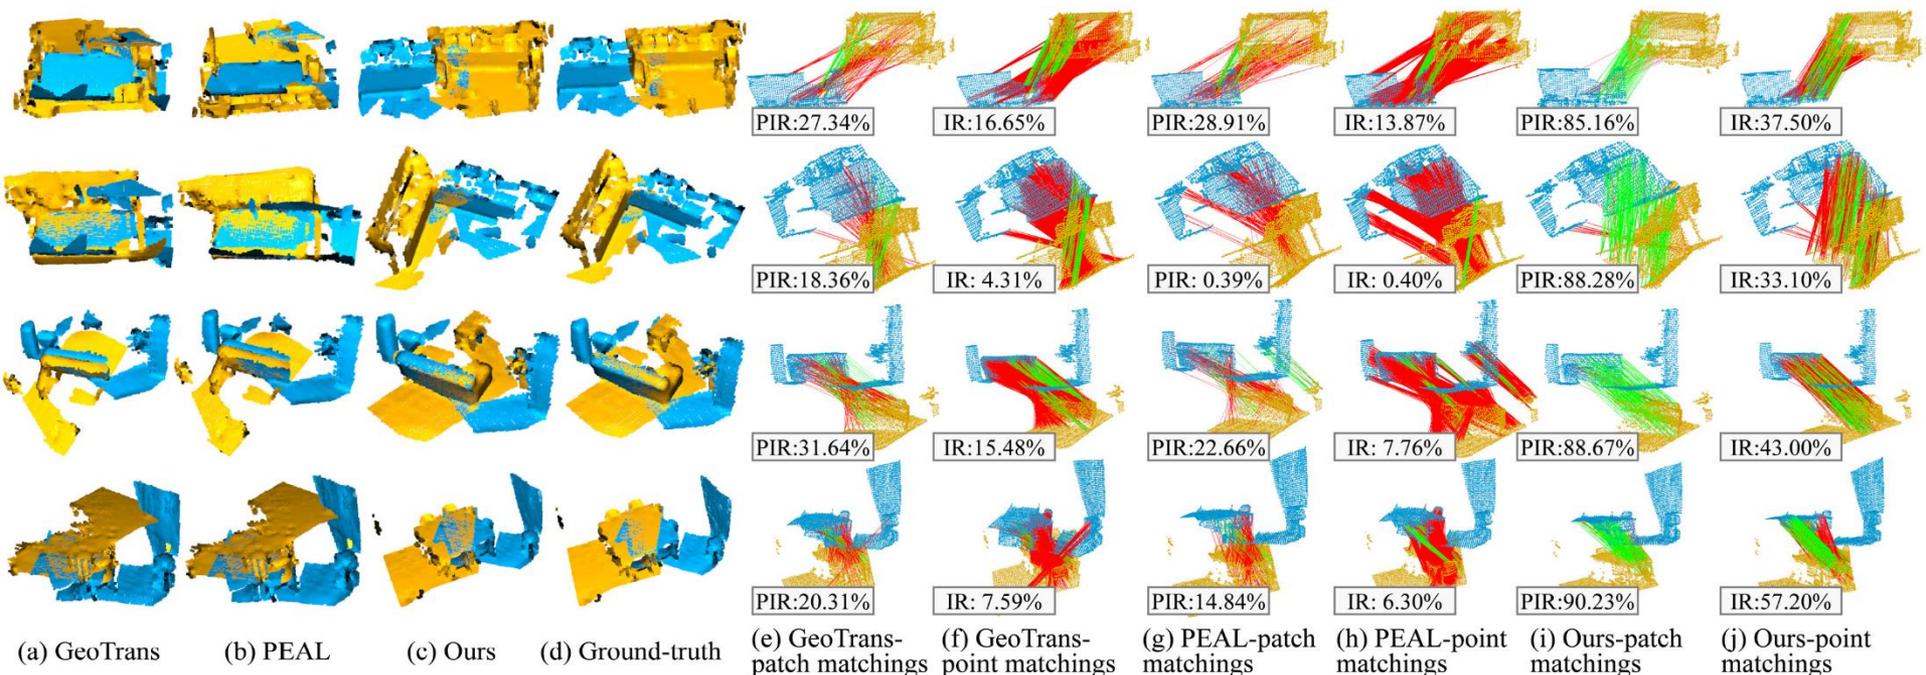
Table 12: Generalization results from 3DMatch to KITTI.

	RE ($^{\circ}$)	TE (m)	TR (%)
Coarse-to-fine Matching	0.79	0.26	70.8
Only Fine Matching	0.82	0.19	98.4

较好的泛化能力

基于旋转等变网络的配准方法

可视化结果



缓解对称配准的问题，更高的内点率

Outline

- 背景介绍
- 基于旋转等变网络的配准方法
- 结论与展望

结论与展望

□ 结论

点云配准任务在现有的实验设置上，实验结果已经趋近饱和。但在现实应用当中，**泛化能力更强**的配准模型仍需进一步研究。

□ 仍待研究的问题

➤ 配准结果的评价

Deep-PE: A Learning-Based Pose Evaluator for Point Cloud Registration. Arxiv 2024

➤ NeRF或者3D Gaussian Splatting的配准

GaussReg: Fast 3D Registration with Gaussian Splatting. ECCV 2024.

VF-NeRF: Viewshed Fields for Rigid NeRF Registration. ECCV 2024.

谢谢大家!

