arXiv:2301.04860v1 [cs.CV] 12 Jan 2023

点云的保边隐式曲面表示

Xiaogang Wang、Yuhang Cheng、Liang Wang、Jiangbo Lu，*IEEE* 高级会员、Kai Xu，*IEEE* 高级会员、Guoqiang Xiao

摘要——近年来，直接从原始数据学习隐式曲面已成为一种极具吸引力的三维重建表示方法，这得益于其出色的性能。然而，随着原始数据质量下降，隐式函数往往会导致不理想的重建结果。为此，我们提出了一种新颖的保边隐式曲面重建方法，主要由可微拉普拉斯正则项和动态边缘采样策略组成。其中，可微拉普拉斯正则项能够有效缓解点云质量下降造成的隐式曲面不平滑问题；同时，为了减少隐式曲面边缘区域的过度平滑，我们提出了一种动态边缘提取策略，对点云尖锐边缘附近进行采样，从而有效避免拉普拉斯正则项对所有区域进行平滑。最后，我们将二者与一个简单的正则化项结合，实现稳健的隐式曲面重建。与最先进方法相比，实验结果表明，我们的方法显著提升了三维重建结果的质量。此外，我们通过多项实验证明，该方法可便捷且有效地应用于若干点云分析任务，包括点云边缘特征提取、法线估计等。

索引词—隐式曲面表示、微分拉普拉斯正则项、动态边缘采样、点云、几何建模、形状分析。

1 引言

近年来，隐式神经表示（INRs）在三维重建领域取得了长足进展 [1]–[8]。与点云 [9]、体素 [10]，[11] 和网格 [12]–[15]，等传统显式表示不同，隐式神经表示主要通过神经网络表示曲面函数，能够提供更高的质量、灵活性和保真度，避免离散化误差，并显著减少存储高质量结果所需的空间。

然而，这些方法大多需要真实数据作为监督 [1]–[3]，因此难以很好地泛化到与训练样本差异较大的未见形状。近期，一些方法 [16]–[20] 被提出，可直接从原始数据（点云、三角形面片集合、无定向网格等）重建隐式神经表示。与数据驱动方法相比，直接从原始数据构建隐式神经表示显然更具吸引力。一般来说，这类方法的核心思想是施加显式/隐式正则性约束，以降低对数据集的依赖。SAL [18]提出了一种针对原始数据中给定无符号距离函数的无符号回归损失，可生成隐式函数的有符号解。具体而言，从原始数据（例如点云、真实扫描网格等）出发，隐式神经表示以自监督方式进行学习，仅依靠原始输入数据，通过最小化无符号回归损失即可可靠地完成训练。随后，SALD [17]，作为 SAL [18] 的推广版本被提出，通过在 SAL 上加入显式梯度约束，可获得更高质量的重建结果

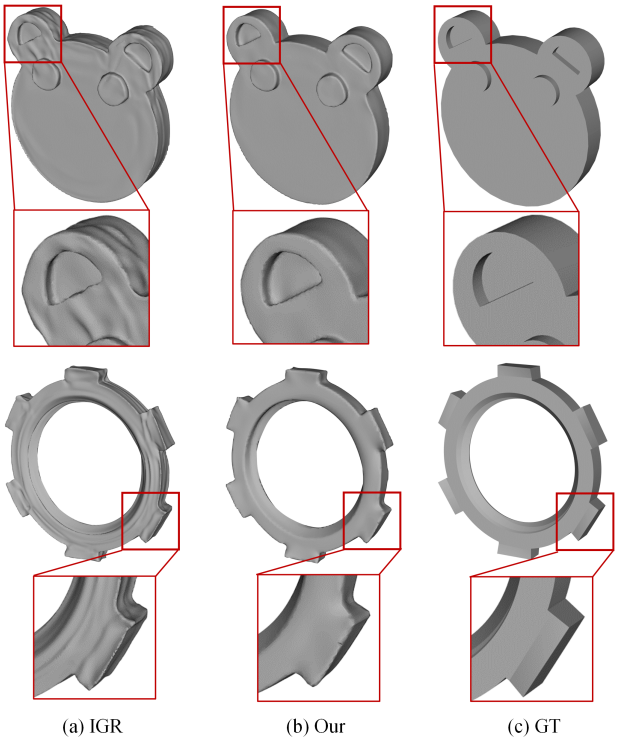

图 1：边缘保持微分拉普拉斯正则项的效果。(b) 是将边缘保持微分拉普拉斯正则项融入先进方法 IGR [19] 后的优化结果。(a) 和 (c) 分别是 IGR 和真实值的结果。

• *Xiaogang Wang*、*Yuhang Cheng*、*Liang Wang* 和 *Guoqiang Xiao* 就职于中国西南大学计算机与信息科学学院。

• *Jiangbo Lu* 就职于思谋科技有限公司。
• *Kai Xu* 就职于中国国防科技大学。

Gropp 等人 [19] 提出了一种新颖的隐式几何正则化（IGR）方法，可直接从原始数据中学习隐式神经表示，并取得了令人惊喜的结果。与 SAL [18]和 SALD [17], 不同，IGR 仅依赖隐式正则化约束，无需无符号距离函数。更具体地说，IGR 提出了一种隐式几何正则化，其本质是求解一个特定的 Eikonal 边值问题，该问题将空间梯度的范数约束为几乎处处等于1。然而，当无法获得法向信息且输入点数量不够密集时，上述算法往往会导致不理想的重建结果（见图1(a)）。

我们观察到，重建结果不尽如人意的主要原因在于，隐式函数需要尽可能拟合输入点云，而点云中的噪声信息往往会导致隐式曲面非常不平滑。换言之，这一现象的主要原因是重建曲面的局部区域中法线不一致。因此，一个直观的想法是尽可能保持曲面的局部法线一致；与此同时，需要注意的是，并非所有区域都应受到法向一致性的约束，例如，曲面中通常存在明显的尖锐边缘（如图1所示）。在重建过程中，我们希望这部分区域不会被过度平滑。因此，对于隐式曲面表示而言，保留边缘的局部法向一致性更为准确。

鉴于上述问题，可以直观地将其视为一个标准的拉普拉斯最小化问题；与此同时，我们还可以利用拉普拉斯算子有效识别边缘区域，这种方法在许多图像处理任务中都取得了良好效果。因此，换言之，我们可以设计一种直观的拉普拉斯正则化，从而有效提升重建结果的质量。

然而，在这项任务中，我们所考虑的原始数据类型是点云数据，而差分法无法直接用于近似高阶导数，主要原因在于，点云数据不像网格或图像那样具有明确的拓扑关系。如果采用类似 K近邻 的算法，搜索得到的最近邻点无法保证正确的拓扑结构（如图 3 所示），尤其是在点云不稠密且无法获得法线时，这种错误的最近邻结果很容易导致反优化结果（如图 4(a) 所示）。

近年来，人们对隐式神经表示的可微优化日益关注，这种方法能够在学习框架中将微分性质用作监督信号 [3], [19], [21]–[25]。可微隐式神经表示的优势在于，它可以直接求解输入信号的高阶导数，而非采用离散化近似，从而显著提升优化性能并拓展应用范围。得益于隐式神经表示在解析意义上的可微性质，我们可以轻松设计可微拉普拉斯正则项。同时，可微拉普拉斯正则项也能轻松、直观地融入隐式神经曲面表示中（如图1所示）。我们展示了该方法能显著提升三维重建的质量。同时，为了便于进行定性和定量比较，除非另有说明，本文所有实验结果均通过将其融入 IGR [19] 获得。我们通过一系列消融实验仔细评估了其性能。同时，我们通过若干实验证明，我们的方法可以方便且有效地应用于一些点云分析任务，包括点云边缘特征提取、法线估计等。

总而言之，我们作出以下贡献：在本文中，我们利用隐式神经表示的无限可微性，提出了一种新颖的保边隐式曲面重建方法，该方法主要由可微拉普拉斯正则项和动态边缘采样策略组成。1）其中，可微拉普拉斯正则项能够有效缓解由点云质量下降所导致的隐式曲面不平滑问题；2）同时，为了减少隐式曲面在边缘区域的过度平滑，我们提出了一种动态边缘提取策略，用于在点云尖锐边缘附近进行采样，从而有效避免拉普拉斯正则项对所有区域进行平滑。

2 相关工作

2.1 基于数据驱动的隐式曲面重建

近年来，得益于机器学习技术的进步，从原始数据进行三维曲面重建取得了显著进展 [1]–[8]。早期研究 [26]–[28]大多针对特定任务采用预定义的几何先验（如局部线性和平滑性）。这些几何先验通常编码了原始数据的统计特性，并以便于优化的形式进行设计，例如泊松方程 [28], [29], 径向基函数 [26], 移动最小二乘法 [27]。近来，隐式神经表示凭借其简洁性和出色性能，在几何重建 [1]–[3], [6], [7], [16], [30]–[34]及对象表示 [3], [23], [35]–[45] 方面取得了显著进展。这类方法通过多层感知机（MLP）学习近似的隐式函数。与传统的连续表示和离散表示（网格、点云和体素）相比，隐式神经表示具有诸多潜在优势，能够在避免离散化误差的同时提供更高的建模质量、灵活性和保真度，并节省存储空间。然而，这些方法大多需要真实数据作为监督 [1]–[3], ，因此难以很好地泛化到与训练样本差异较大的未见形状。

此外，还有一些混合式方法 [46]–[50], 将数据驱动先验与优化策略相结合，能够达到最先进的性能。然而，上述方法还需要额外的真实数据作为监督，这严重限制了它们的适用性。

2.2 无符号隐式曲面重建

近年来，有一些方法 [17]–[20] 被提出，用于直接从原始数据重建隐式神经表示。与大规模数据驱动方法相比，直接从原始数据构建隐式神经表示显然更具吸引力。这些方法无需将大量训练数据的真实值有符号距离表示作为监督。SAL [18] 针对原始数据的给定无符号距离函数引入了一种符号无关回归损失，该函数是无符号距离函数的有符号版本。同时，通过适当初始化隐式解码器网络，使其只能利用无符号距离函数生成隐式函数的有符号解，从而避免使用曲面法线。随后，SALD [17], 作为 SAL [18]的推广版本

被提出。该方法在 SAL 的基础上加入显式梯度约束，从而获得质量更高的重建结果。与此类似，本文的方法也使用隐式神经表示，直接从原始数据估计水平集函数。主要区别在于，我们提出的正则化项直接基于可微隐式优化，并不显式地对零水平集施加某些正则化约束。当无法获取法向信息且输入点云数量不够密集时，隐式神经表示往往会导致不理想的重建结果。

2.3 可微隐式神经表示

与一般的隐式神经表示相比，可微隐式神经表示的优势在于能够直接利用微分几何的各种性质，而非采用离散化近似，因此在许多优化问题中可以获得更稳定的解。近年来，人们对隐式神经表示的可微优化日益关注，并将微分性质作为学习框架中的监督信号 [3], [19], [21], [21]–[25]。一般的数值优化通常采用微分几何的离散近似，例如，常用有限差分法来增强空间中相邻采样点之间的平滑性。但得益于隐式神经表示可解析求导的特性，可微隐式神经表示能够直接利用微分几何中的许多性质，例如梯度 [19], [21], [23], 、曲率 [24], 以及偏微分方程的解 [22], [25]。近期，Gropp 等人 [19]提出利用可微隐式神经表示直接从原始数据重建曲面。具体而言，他们提出了一种隐式正则化约束，其本质是求解一个特定的程函方程边值问题，该问题约束空间梯度的范数在几乎所有位置都为1 。类似地，Sitzmann等人 [21] 提出使用可微的周期激活函数，以完全可微的方式表示有符号距离场。然而，这两项工作 [19], [21]在无法获得法向信息且输入点数量不够密集时，往往会导致不理想的重建结果。本文同样基于隐式神经表示的可微性，对直接从输入点云估计的隐式水平集函数进行优化。具体而言，我们设计了一种隐式可微拉普拉斯正则项，有效缓解了隐式神经函数直接拟合输入点云所导致的不理想重建结果问题。

3 方法

我们提出一种可微拉普拉斯正则项，可直接从输入点云中学习神经隐式表示，无需法向监督。请注意，我们的微分拉普拉斯正则项可以应用于任意隐式神经表示，例如 IGR [19], SAL [18],SALD [17]。除非另有说明，本文均将其应用于 IGR。IGR 使用神经网络的水平集表示三维形状（第 3.1 节）。具体而言，IGR 提出了一种隐式几何正则化，其本质是求解特定的 Eikonal 边值问题，约束空间梯度的范数几乎处处为 1。然而，当无法获得法向信息且输入点的数量不够密集时，IGR 往往会导致

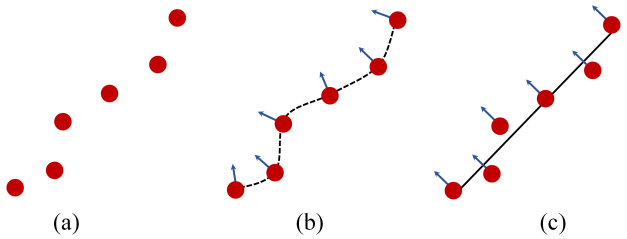

图 2：局部法线一致性的示意图 cy.

不理想的重建结果（见图1(a)）。我们观察到，重建结果不理想的主要原因是隐式函数需要尽可能贴合输入点云，而点云中的噪声信息往往会导致隐式曲面非常不光滑。

为解决这一问题，我们利用隐式神经表示在解析意义上可微的特性，提出一种微分拉普拉斯正则项，可有效缓解重建结果不理想的问题（第 3.2 节）。同时，为减少三维形状边缘区域（如人造形状）的过度平滑，我们引入动态边缘提取策略（第 3.2 节），在输入点云的尖锐边缘附近采样，从而有效避免拉普拉斯正则项平滑所有区域，在保留边缘的同时提升重建结果的质量。

3.1 背景

神经隐式表示是一个近似有符号距离函数的连续函数。三维形状的底层曲面由该函数的零水平集隐式表示，

$$f_\theta(x) = 0, \forall x \in X. \tag{1}$$

其中 θ 表示待学习的参数， X 表示输入点云集合。通常，我们使用多层感知机（MLP）对该函数进行参数化。同时，为了便于利用隐式神经表示在解析意义上可微的特性（如梯度等），近期研究[19], [21] 通常以非线性可微激活函数替代常用的 ReLU激活函数，从而将多层感知机转化为连续且无限可微的函数。

在 IGR 中，训练通过最小化损失函数来完成，该损失函数促使 f 在 X上趋于零:

$$L_{vanish} = \frac{1}{N(X)} \sum_{x \in X} |f_\theta(x)| \tag{2}$$

其中， $N(X)$ 是点集 X的数量， $|\bullet|$ 表示绝对值。如果输入点云包含法向信息$\mathbf{n_{gt}}(\mathbf{x})$，则相应的损失函数可以设计为使预测法向（即隐式函数的可微梯度 $\nabla f_\theta(x)$ ）尽可能接近真实法向$\mathbf{n_{gt}}(\mathbf{x})$:

$$L_{normal} = \frac{1}{N(X)} \sum_{x \in X} ||\nabla f_\theta(x) - \mathbf{n_{gt}}(\mathbf{x})||_2 \tag{3}$$

除了上述两个直观的拟合损失项外，基于 Eikonal偏微分方程的 IGR[19] 还引入了一个额外的损失函数（Eikonal损失），这相当于求解

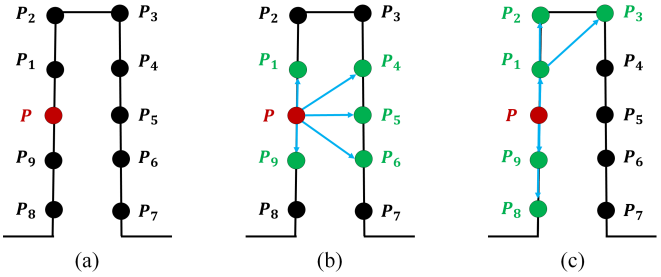

图3：几何结构(a)的非拓扑保持(b)与拓扑保持(c)两种不同最近邻的示意图。

特定程函方程的边值问题，该方程约束空间梯度的范数 $\nabla f_\theta(x)$ 几乎处处为1：

$$L_{eikonal} = \frac{1}{N(X)} \sum_{x \in X} (||\nabla f_\theta(x)||_2 - 1)^2 \tag{4}$$

请注意，在我们的方法中，我们不将法向信息作为监督，因此后续所有实验中都不考虑 L_{normal} 项。更具体地说，我们的方法建立在上述两项 L_{vanish} 和 $L_{eikonal}$之上。

3.2 可微拉普拉斯正则化

邻域法线一致性。当输入点数据足够多时，基于上述两项（L_{vanish} 和 $L_{eikonal}$）可以生成高质量结果；然而，当无法获得法向信息且输入点数量不够密集时，往往会导致重建结果不尽如人意（见图1(a)）。

我们观察到，重建结果不尽如人意的主要原因是，隐式函数需要尽可能拟合输入点云，而点云中的噪声信息往往会导致隐式曲面非常不平滑。更具体地说，优化结果无法保证生成高质量的重建结果，这直观地表现为重建结果的法线可能在邻域内不一致。

从另一个角度来看，众所周知，三维形状通常是分片光滑的，也就是说，平坦曲面比高频结构更常见 [51]。为此，我们通过鼓励重建结果具有几何光滑性，将这一先验融入隐式神经函数。因此，一个直观的解决方案是约束重建结果邻域法线的一致性（如图 2 所示）：

$$L_{neibor} = \sum_{x \in X} \sum_{x_i \in nei(x)} ||\nabla f_\theta(x) - \nabla f_\theta(x_i)||_2 \tag{5}$$

其中 $nei(x)$ 表示点 x的邻域点集。

然而，本文考虑的原始数据类型是点云数据，它不像网格或体素那样具有明确的拓扑结构。如果使用类似 K近邻的算法，搜索到的最近邻点无法保证保持正确的拓扑结构，尤其是在点云较稀疏且没有法线的情况下。如图 3(b) 所示，在保持拓扑结构的前提下，点 P_4、P_5 和 P_6 并不符合 $N = 5$ 的最近邻结果，而正确的最近邻点集合

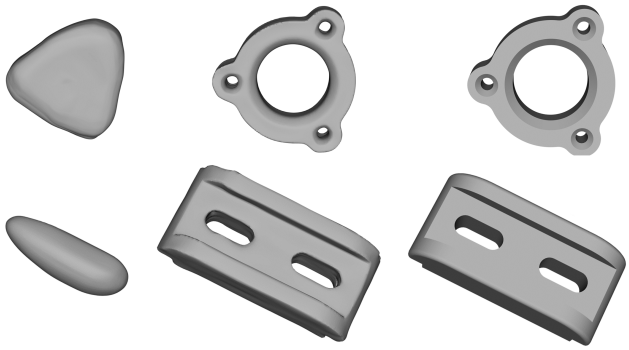

(a) *KNN=9* (b) Our (c) GT

图 4： L_{neibor} (a) 与 $L_{laplacian}$ (b) 的比较。

应为 $\{P_1, P_2, P_3, P_8, P_9\}$。此外，在实践中很难为该参数 nei（x） 确定一个合理的取值。如图 4 所示，我们很容易看出重建结果有误，这主要是由上述原因造成的。

可微拉普拉斯正则项。事实上，上述约束 L_{neibor} 主要用于约束局部域中的法向一致性，可以很容易地将其解释为离散拉普拉斯算子。拉普拉斯算子 $\triangle f$ 是 n维欧几里得空间中的二阶微分算子，定义为梯度（∇f）的散度（$\nabla \cdot f$）。得益于隐式神经表示的无限可微性，我们可以设计一种简单而有效的可微拉普拉斯正则项：

$$L_{laplacian} = \sum_{x \in X} \triangle f_\theta(x)^2 \tag{6}$$

其中 $\triangle f_\theta(x)$ 表示点 x 的可微拉普拉斯算子。

如图4(b)所示，与基于最近邻法向一致性的显式正则化约束 L_{neibor} 相比，可微拉普拉斯正则项无需引入超参数最近邻 N，即可获得更稳定的结果。

3.3 动态边缘采样

然而，尽管可微拉普拉斯正则项约束了法向一致性，却也带来了一个新问题：它对所有三维区域都施加了同等的约束，即使是尖锐边缘区域也是如此，如图6所示。众所周知，复杂三维形状通常由多个分片光滑曲面构成，这些曲面在交界处可能不可微，也更容易形成尖锐边缘。因此，从本质上说，复杂三维形状（带有尖锐边缘的分片光滑模型）无法由隐式函数精确表示，因为它在尖锐边缘处显然不可微。因此，如果强行用隐式函数表示，尤其是在仅使用不含法向信息的稀疏点集作为监督时，就很容易在尖锐边缘处形成过度平滑重建（如图6所示）。

最直观的解决方案是分别对每个分片光滑曲面进行隐式表示，但在实践中很难实现，因为这首先需要对输入点集进行分割，而在无监督条件下很难准确完成这一任务。

因此，我们提出一种新颖的 *dynamic edge sampling*策略，以便在训练

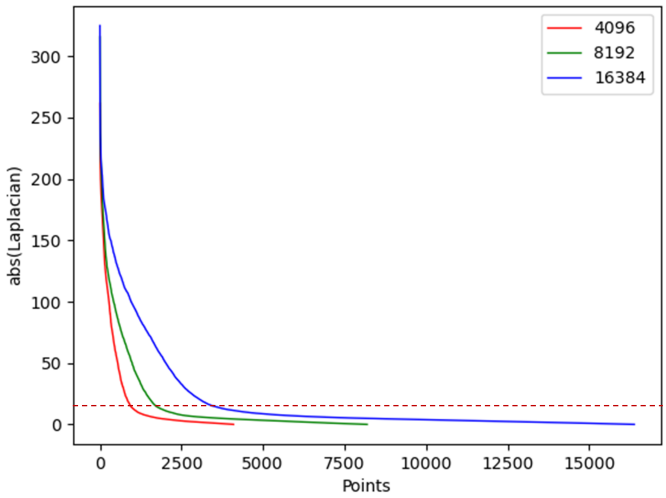

图 5：拉普拉斯算子 $|\triangle f_\theta(x)|$ 和边缘阈值 τ 选择的统计数据。

过程中有效提取尖锐边缘区域。理论上，剩余区域不仅满足可微性，还符合正法向一致性约束，从而能有效避免拉普拉斯正则化器对所有区域（包括边缘区域）进行无差别平滑。

具体而言，对于输入点集中的每个点 p，我们可以根据其可微拉普拉斯算子 $\triangle f_\theta(x)$快速判断它是否为边缘点。本质上，拉普拉斯主要用于描述梯度的变化率，常用于图像处理中的边缘检测。从微分几何的角度来看，它用于描述空间位置法向的变化率。因此，点的拉普拉斯值越大，该点属于边缘点的可能性就越高。我们对拉普拉斯 $|\triangle f_\theta(x)| < \tau$进行阈值处理，以获得相应的非边缘点集 X'。根据统计结果（如图 5 所示），我们在所有实验中将参数 $\tau = 20$ 设为固定值。此操作在每次迭代的反向传播之前执行，因此我们将其称为 $dynamic\ edgesampling$。

$$L_{laplacian} = \sum_{x \in X'} \triangle f_\theta(x)^2 \tag{7}$$

其中，X' 表示输入点云X的非边缘子集。最后，我们优化总损失函数：

$$L_{total} = L_{vanish} + \lambda_1 L_{eikonal} + \lambda_2 L_{laplacian} \tag{8}$$

其中，在所有实验中，我们将 $\lambda_1 = 0.1$ 和 $\lambda_2 = 0.001$ 设为固定值。

4 细节、结果与评估

4.1 实现细节

数据准备。为了便于在重建、边缘提取和法线估计等多项任务上对我们的方法进行定量评估，我们从 ABC 数据集 [52], 中选取了 100 个几何拓扑丰富的三维形状，构建评估数据集（见图 8）。该数据集包含超过1百万个标准三维 CAD 模型，以及多种类型的标准 CAD 格式文件。除了三维几何和法线信息之外，上文提到的几何边缘信息并未直接提供给我们。为此，我们开发了一种工具，

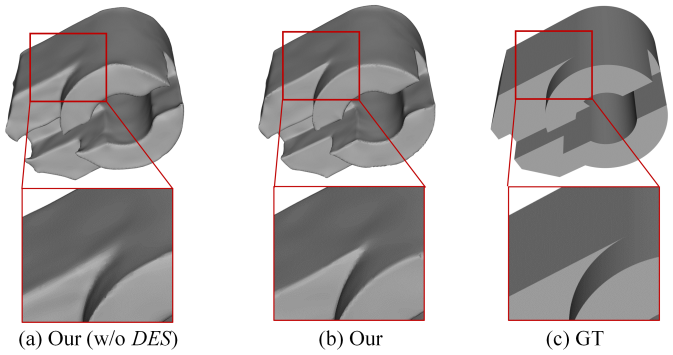

(a) Our (w/o *DES*) (b) Our (c) GT

图 6：有（b）和无 $Dynamic\ EdgeSampling$ （DES）（a）的对比。

该工具能够针对每个三维形状，快速、轻松地从多个 CAD 文件中提取几何边缘信息，从而充分满足我们的方法进行多任务定量评估的需求。

点采样。对于每个模型，我们通过均匀点采样将其采样为包含 16，384 个点的点云。同时，为了模拟真实点云中的噪声，我们为每个采样点添加均值为 $\mu = 0$ 、标准差为 $\delta = 0.005$ 的高斯噪声。除非另有说明，在所有实验中，每种情况下网络均在含噪数据上训练。我们定义了若干用于评估点云多任务准确性的指标，以支持对所提方法进行定量评估；详情见以下小节。

4.2 指标

在我们的实验中，我们同时进行了定性评估和定量评估。我们通过消融实验（第4.6节），以及与最先进的三维重建方法（第4.3节）、边缘检测方法（第4.4节）和法线估计方法（第4.5节）的比较来评估我们的方法。对于三维重建结果的定量评估，我们使用了由 [19]引入的双向Chamfer d_C和Hausdorff距离 d_H。对于法线估计的评估，我们使用预测法线与真实值法线之间的角度 d_{angle} 作为指标。为了评估边缘检测，我们测量预测结果与真实值之间的 $precision/recall$ 和IoU；而为了评估重建边缘的几何精度，我们采用了由 [1] 引入的边缘Chamfer距离（ECD）。

4.3 重建

与 IGR 的比较 [19]。为了与 IGR 进行公平比较，我们的网络架构与IGR [19]保持一致。在所有实验中，我们采用 IGR 中指定的默认训练流程来训练网络，但不在训练中使用法向信息，并将迭代次数设置为10000。在整个实验过程中，我们将损失参数（见公式（8））设置为 $\lambda_2 = 0.1$ 和 $\lambda_3 = 0.001$。定性和定量实验结果如表1所示，图7中也可以看到，我们的方法性能显著更好。

与最先进方法 SAL 的比较 [18]和 SALD [17]。除了 IGR [19], ，我们的方法还与两种基于原始数据的最先进符号无关学习方法 SAL [18] 和 SALD [17],进行了比较。表1（第1行和第2行）所示的结果不如我们的方法。如图7所示，结果表明

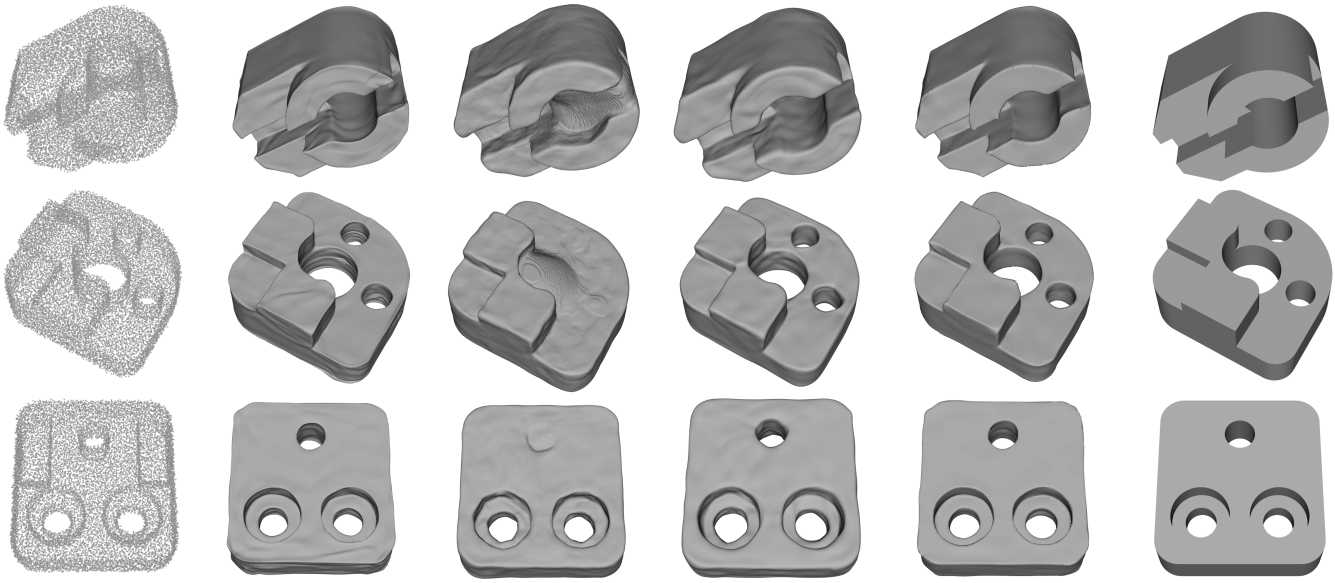

(a) Input (b) IGR (c) SAL (d) SALD (e) Our (f) GT

图7：与最先进方法 IGR [19], SAL [18] 和 SALD [17的定性比较].

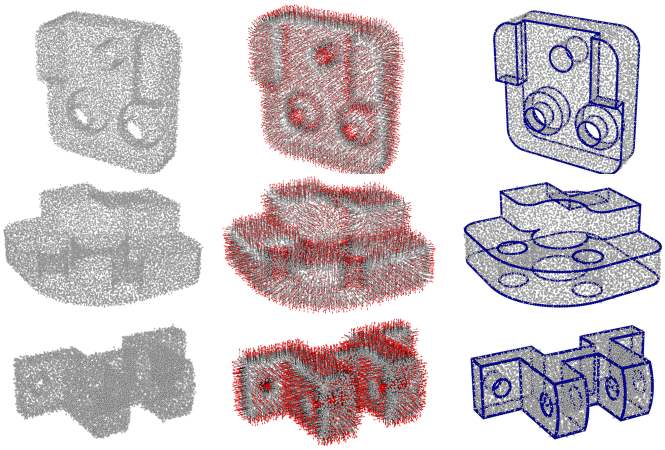

(a) Point cloud (b) Normal (c) Edge

图8：多任务评估数据集概览。

	d_C		d_H	
	Mean	*Median*	*Mean*	*Median*
SAL [18]	0.019	0.016	0.094	0.050
SALD [17]	0.016	0.015	0.053	0.042
IGR [19]	0.028	0.011	0.111	0.034
我们的（$L_{laplace}$）	0.017	0.009	0.068	0.026
我们的（$L_{laplace} + DES$）	**0.007**	**0.007**	**0.021**	**0.021**

表1：我们的方法与消融实验的定量比较与 IGR [19], SAL [18] 和 SALD 的比较 [17] 在多任务评估数据集上。

我们的方法具有显著优势，这是因为微分拉普拉斯正则项能够有效缓解重建结果不理想的问题。

4.4 边缘识别

具体而言，对于输入点集中的每个点 p，我们可以根据其可微拉普拉斯算子 $\triangle f_\theta(x)$ 快速判断它是否为边缘点。本质上，拉普拉斯算子主要用于描述梯度的变化率，常用于图像处理中的边缘检测。从微分几何的角度来看，它用于描述空间位置法向的变化率。因此，点的拉普拉斯算子值越大，该点为边缘点的可能性就越大。我们对拉普拉斯算子 $|\triangle f_\theta(x)| > \tau$ 进行阈值处理，以获得相应的非边缘点集 X_{edge}。在所有实验中，我们将参数设为$\tau = 20$，如图10所示。

除 IGR [19], 外，我们还选择了两种具有代表性的经典非学习方法：Voronoi 协方差测度（VCM） [53], 和边缘感知重采样（EAR） [54], ，因为它们都已应用于知名 CGAL库 的点集处理流程中。如表 4 所示，我们的方法全面优于这些经典方法。这主要是因为我们采用每个采样点的可微拉普拉斯算子作为度量，它可以近似隐式曲面表示中的平均曲率。需要注意的是，目前已有大量基于数据驱动的高质量边缘检测方法。我们在此没有将这些方法作为参考，主要是因为我们采用的是自监督学习方法。

4.5 法线估计

本质上，采用 softplus 激活函数的隐式表示多层感知机（MLP）表示了一个可微的有符号距离函数 $d = f_\theta(x)$。根据微分几何的性质，隐式曲面上每个点的梯度算子 $f_\theta(x) = 0$可视为该点的法向量 x。因此，训练完成后，对于输入点云中的每个点，我们可以直接计算可微函数 $f_\theta(x)$ 在当前点 x处的梯度算子 $\nabla f_\theta(x)$ ，也就是该点的法向量 x。实验结果见表1。对比结果表明，我们的方法性能显著更优；这一点可由以下事实直接量化： d_{angle} 大于我们方法所报告的数值。

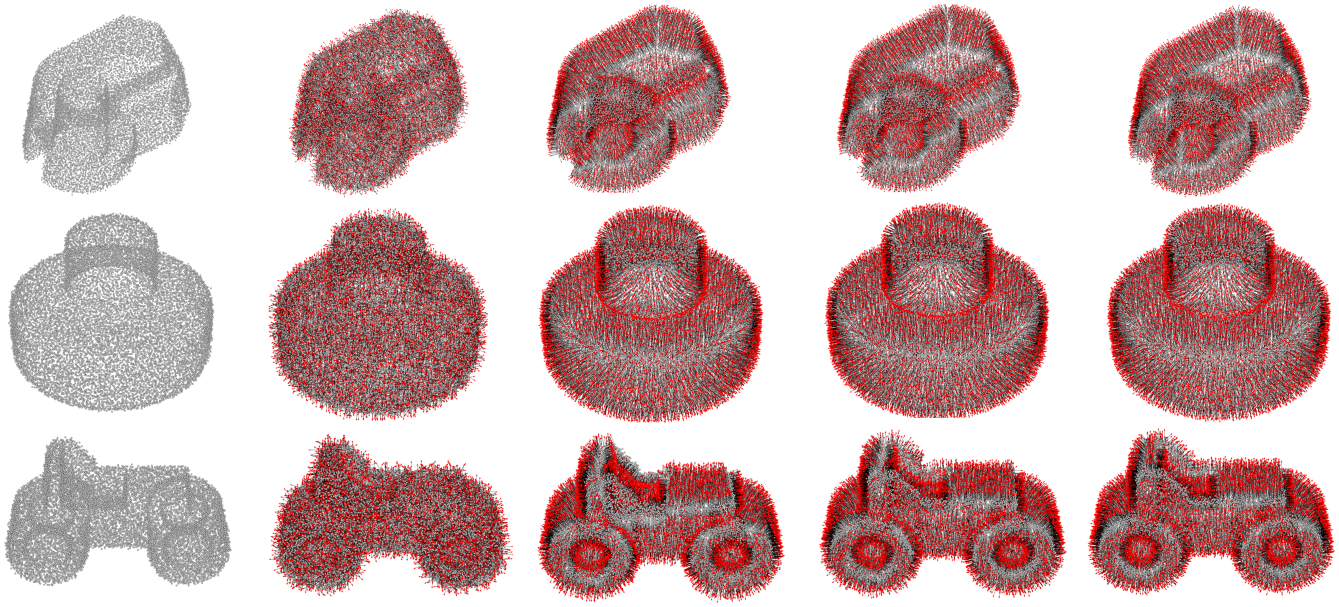

(a) Input (b) IGR (c) $+L_{laplacian}$ (d) $+L_{laplacian}+DES$ (e) GT

图 9：微分拉普拉斯正则项的法线估计可视化（c）和 *dynamic edge sampling* 策略（d）。

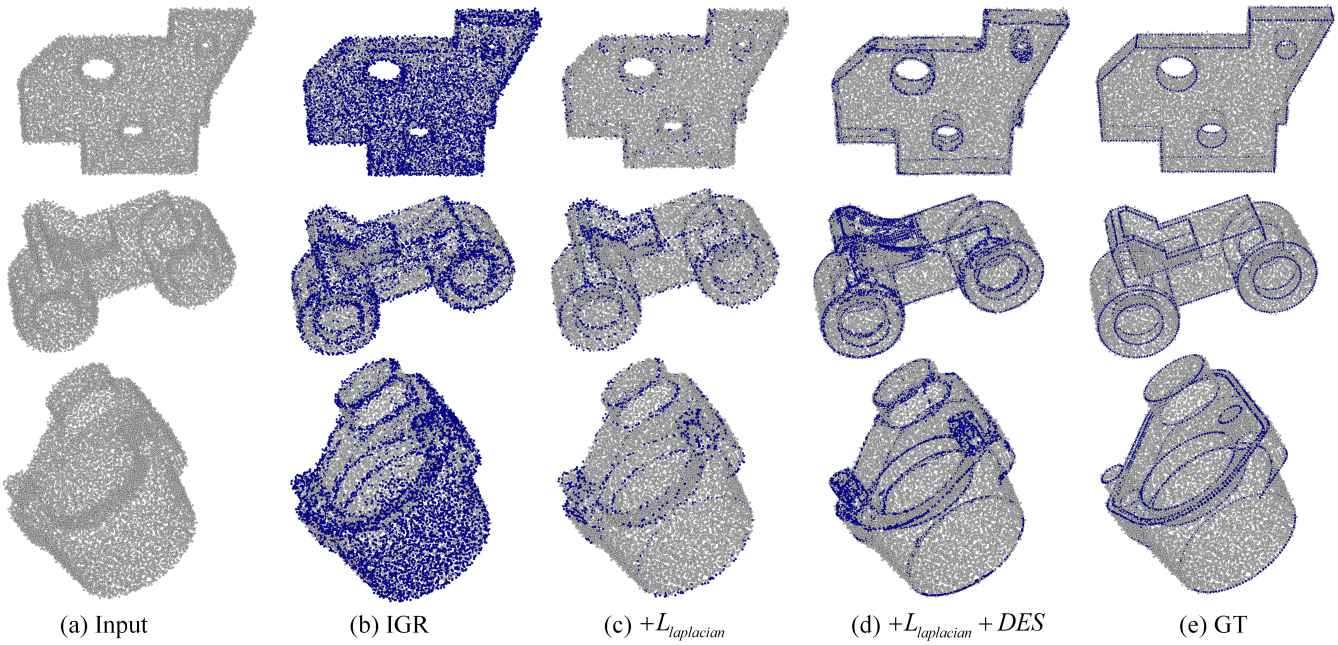

(a) Input (b) IGR (c) $+L_{laplacian}$ (d) $+L_{laplacian}+DES$ (e) GT

图 10：微分拉普拉斯正则项的边缘识别（c）和 *dynamic edge sampling* 策略（d）。

	d_C		d_H	
	Mean	*Median*	*Mean*	*Median*
$X = 0.010$	0.0102	0.0108	0.0509	0.0543
$X = 0.005$	0.0069	0.0069	0.0206	0.0209
$X = 0.000$	0.0055	0.0057	0.0148	0.0153
$D = 4,096$	0.0075	0.0075	0.0350	0.0328
$D = 8,192$	0.0071	0.0072	0.0352	0.0269
$D = 16,384$	0.0069	0.0069	0.0206	0.0209

表 2：不同噪声 X 和采样密度 D下的算法性能。

4.6 参数和网络分析

噪声的影响。我们通过提高噪声水平对拉普拉斯正则项进行压力测试。具体而言，我们随机添加高斯噪声其均值为 0，方差为 X。我们将噪声添加到三维形状曲面上的每个采样点，并测试了$X = \{0, 0.005, 0.01, 0.02\}$的四个取值。在每种情况下，均使用加噪数据训练隐式神经表面。表 2 展示了定量结果。我们可以看到，即使在含噪数据上训练，拉普拉斯正则项仍能胜过这些最先进方法 [17]–[19]，即使它们是在含有0.005噪声的点云上进行测试。

密度的影响。我们还在密度降低的点云上训练了我们的方法。具体而言，对于每个三维形状，我们采样了不同数量的点 D，以验证我们的网络能否处理更稀疏的点云，其中 $D =$

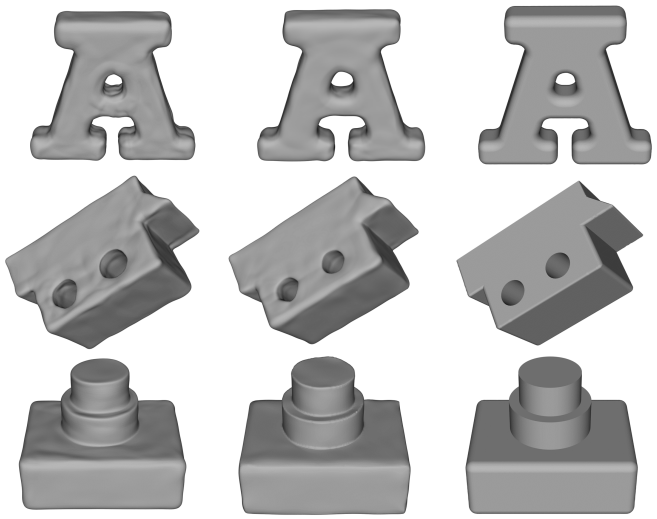

(a) SALD (b) $+L_{laplacian} + DES$ (c) GT

图 11：边缘保持微分拉普拉斯正则项的效果。(b) 为将边缘保持微分拉普拉斯正则项纳入最先进方法 SALD [17] 后的优化结果。(a) 和 (c) 分别为 SALD 和真实值的结果。

	d_C	d_H	d_{angle}
IGR [19]	0.028	0.111	0.514
我们的方法 ($+L_{laplacian}$)	0.017	0.068	0.274
我们的方法 ($+L_{laplacian} + DES$)	**0.009**	**0.036**	**0.133**

表 3：消融实验——我们评估了方法在包含/不包含组件 $L_{laplacian}$ 和$dynamic\ edge\ sampling$ (DES)时的定量性能。

$\{4,096, 8,192, 16,384\}$。（表 2 中的结果呈现出与前述压力测试相似的趋势。也就是说，在更稀疏的点云上训练时，我们的网络仍然优于这些最先进的方法 [17]–[19]，即使这些方法是在全分辨率（16,384 个点）的数据上测试或训练的。

效果 $L_{laplacian}$。为了评估损失函数$L_{laplacian}$的有效性，我们将其融入另一种最先进的方法 SALD [17]，。定性结果如图11所示。可以发现，与原始算法相比，加入拉普拉斯后，重建质量得到了有效提升。这主要是因为可微拉普拉斯正则项能够有效改善不理想的重建结果。

动态边缘采样。 我们评估了 $dynamicedge\ sampling$ 策略对重建质量的影响。我们对 $dynamic\ edge\ sampling$进行了实验，同时保持其他所有参数不变。从表1、图7和图12中可以看出，与最先进的方法（表1（第1、3行））以及不使用 $dynamic\ edgesampling$的基线方法相比，我们能够有效提升尖锐边缘处的建模质量。这主要归功于 $dynamic\ edge\ sampling$策略：在输入点云的尖锐边缘附近采样，从而有效避免正则项对所有区域进行平滑。

	ECD	IoU	精确率	召回率
VCM [53]	0.0017	0.1925	0.2238	0.5998
EAR [54]	0.0071	0.1146	0.2399	0.1933
IGR [19]	0.0063	0.0880	0.0958	0.5620
Our	**0.0015**	**0.2375**	**0.2665**	**0.6934**

表4：最先进的边缘识别技术比较——VCM [53], EAR [54],和 IGR [19]。

5 结论与局限性

我们提出了一种直接从输入点云中构建、无需法向监督的神经隐式表示微分拉普拉斯正则项。具体而言，我们利用隐式神经表示的无限可微性，提出一种可微拉普拉斯正则项，从而有效缓解重建结果不理想的问题。同时，我们提出一种 $dynamic\ edge\ sampling$ 策略，在输入点云的尖锐边缘附近进行采样，从而有效避免拉普拉斯正则项对所有区域进行平滑，进而在保留边缘的同时有效提升重建结果的质量。此外，可微拉普拉斯正则项能够轻松、直观地融入隐式神经曲面表示。我们通过一系列消融实验仔细评估了其生成质量，结果表明，我们的方法显著提升了三维重建的质量。除了三维重建之外，我们的方法还可便捷地应用于其他点云分析任务，包括边缘提取和法线估计等。

局限性。我们的方法存在一些局限性，也指出了未来研究的方向。图13展示了一些具有代表性的失败案例。首先，我们的方法在重建超薄几何结构时容易出现问题，这可能是因为点云数据含有噪声，导致几何结构被完全破坏。其次，我们的方法可能会忽略极其精细的结构，从而导致重建结果不正确。

致谢

我们感谢匿名审稿人提出的宝贵意见。本研究部分受到国家自然科学基金（62102328）和中央高校基本科研业务费专项资金（SWU120076）的资助。

参考文献

[1] Z. Chen 和 H. Zhang，《用于生成式形状建模的隐式场学习》，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2019年，第5939–5948页。[2] L. Mescheder、M. Oechsle、M. Niemeyer、S. Nowozin 和 A. Geiger，《占据网络：在函数空间中学习三维重建》，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2019年，第4460–4470页。[3] J. J. Park、P. Florence、J. Straub、R. Newcombe 和 S. Lovegrove，《DeepSDF：学习用于形状表示的连续有符号距离函数》，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2019年，第165–174页。[4] J. Chibane、T. Alldieck 和 G. Pons-Moll，《特征空间中的隐式函数：用于三维形状重建与补全》，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2020年，第6970–6981页。[5] P. Erler、P. Guerrero、S. Ohrhallinger、N. J. Mitra 和 M. Wimmer，《Points2Surf：从点云学习隐式曲面》，载于欧洲计算机视觉会议。Springer，2020年，第108–124页。

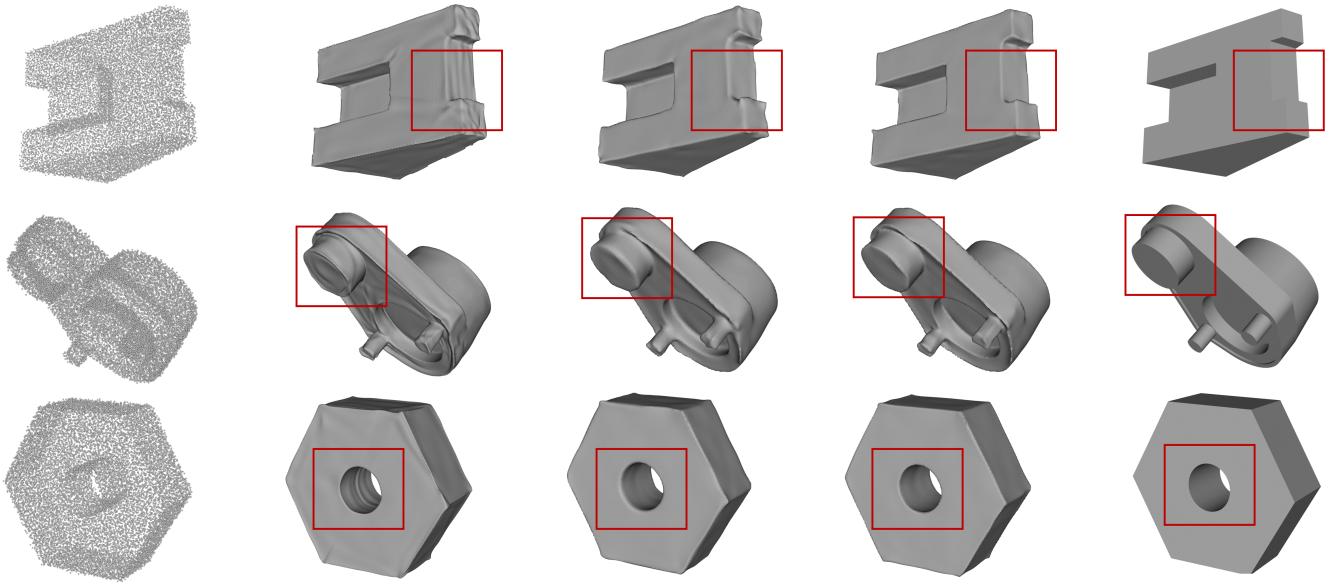

图 12：可视化 微分拉普拉斯正则项 (c) 和 *dynamic edge sampling* 策略 (d) 的示例).

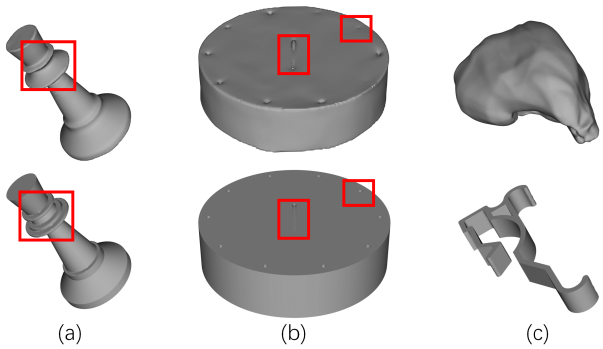

图 13：失败案例。

[6] S. Peng、M. Niemeyer、L. Mescheder、M. Pollefeys 和 A. Geiger，《卷积占据网络》，载于欧洲计算机视觉会议。Springer，2020年，第523–540页。[7] S. Saito、Z. Huang、R. Natsume、S. Morishima、A. Kanazawa 和 H. Li，《PIFu：用于高分辨率着装人体数字化的像素对齐隐式函数》，载于*IEEE/CVF*国际计算机视觉会议，2019年，第2304–2314页。[8] Q. Xu、W. Wang、D. Ceylan、R. Mech 和 U. Neumann，《DISN：用于高质量单视图三维重建的深度隐式表面网络》，神经信息处理系统进展，第32卷，2019年。[9] H. Fan、H. Su 和 L. J. Guibas，《点集生成网络：从单张图像重建三维物体》，载于*IEEE*计算机视觉与模式识别会议论文集，2017年，第605–613页。[10] C. B. Choy、D. Xu、J. Gwak、K. Chen 和 S. Savarese，《3D-R2N2：单视图与多视图三维物体重建的统一方法》，载于欧洲计算机视觉会议。Springer，2016年，第628–644页。[11] J. Wu、C. Zhang、T. Xue、B. Freeman 和 J. Tenenbaum，《通过三维生成对抗建模学习物体形状的概率潜在空间》，神经信息处理系统进展，第29卷，2016年。[12] T. Groueix、M. Fisher、V. Kim、B. Russell 和 M. Aubry，《AtlasNet：一种学习三维表面生成的纸浆塑形方法。arXiv 2018》，*arXiv*预印本 *arXiv:1802.05384*，1802。[13] H. Kato、Y. Ushiku 和 T. Harada，《神经三维网格渲染器》，载于*IEEE*计算机视觉与模式识别会议论文集，2018年，第3907–3916页。[14] J. Tang、X. Han、J. Pan、K. Jia 和 X. Tong，《一种骨架桥接深度用于从单张 RGB 图像生成具有复杂拓扑的网格的学习方法”，载于第*28*届计算机视觉与模式识别会议论文集，2019年，第4541–4550页。[15] J. Tang、X. Han、M. Tan、X. Tong 和 K. Jia，“Skeletonnet：一种拓扑保持方法，用于学习从 RGB 图像重建物体表面的网格”，*IEEE*模式分析与机器智能汇刊，2021年。[16] M. Atzmon、N. Haim、L. Yariv、O. Israelov、H. Maron 和 Y. Lipman，“控制神经水平集”，神经信息处理系统进展，第32卷，2019年。[17] M. Atzmon 和 Y. Lipman，“SALD：利用导数进行符号无关学习”，*arXiv*预印本 *arXiv:2006.05400*，2020年。[18] ——，“SAL：从原始数据进行形状的符号无关学习”，2020年，第2565–2574页。[19]A. Gropp、L. Yariv、N. Haim、M. Atzmon 和 Y. Lipman，“用于形状学习的隐式几何正则化”，*arXiv*预印本 *arXiv:2002.10099*，2020年。[20] W. Zhao、J. Lei、Y. Wen、J. Zhang 和 K. Jia，“基于符号无关隐式学习的表面自相似性，用于形状建模及从原始点云进行重建”，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2021年，第10 256–10 265页。[21] V. Sitzmann、J. Martel、A. Bergman、D. Lindell 和 G. Wetzstein，“采用周期激活函数的隐式神经表示”，神经信息处理系统进展，第33卷，第7462–7473页，2020年。[22] H. Chen、R. Wu、E. Grinspun、C. Zheng 和 P. Y. Chen，“用于时变偏微分方程的隐式神经空间表示”，*arXiv*预印本 *arXiv:2210.00124*，2022年。[23] L. Yariv、J. Gu、Y. Kasten 和 Y. Lipman，“神经隐式曲面的体渲染”，神经信息处理系统进展，第34卷，第4805–4815页，2021年。[24] T. Ehret、R. Mar´ı 和 G. Facciolo，“NeRF，来认识一下微分几何！”，*arXiv*预印本 *arXiv:2206.14938*，2022年。[25] J. Zehnder、Y. Li、S. Coros 和 B. Thomaszewski，“Ntopo：使用隐式神经表示进行无网格拓扑优化”，神经信息处理系统进展，第34卷，10 381，2021年，10 368页。–。[26] J. C. Carr、R. K. Beatson、J. B. Cherrie、T. J. Mitchell、W. R. Fright、B. C. McCallum 和 T. R. Evans，“利用径向基函数重建和表示三维物体”，载于第*28*届计算机图形学与交互技术年会论文集，2001年，第67–76页。[27] M. Alexa、J. Behr、D. Cohen-Or、S. Fleishman、D. Levin 和 C. T. Silva，“点集曲面的计算与渲染”，*IEEE*可视化与计算机图形学汇刊，第9卷，第1期，第3–15页，2003年。[28] M. Kazhdan、M. Bolitho 和 H. Hoppe，“泊松曲面重建

”，载于第四届 *Eurographics* 几何处理研讨会论文集，第7卷，2006年。[29] M. Kazhdan 和 H. Hoppe，“屏蔽泊松曲面重建”，*ACM*图形学汇刊（*ToG*），第32卷，第3期，第1–13页，2013年。[30] K. Genova、F. Cole、D. Vlasic、A. Sarna、W. T. Freeman 和 T. Funkhouser，“利用结构化隐式函数学习形状模板”，载于*IEEE/CVF*国际计算机视觉会议论文集，2019年，第7154–7164页。[31] M. Niemeyer、L. Mescheder、M. Oechsle 和 A. Geiger，“Occupancy Flow：通过学习粒子动力学进行4D重建”，载于*IEEE/CVF*国际计算机视觉会议论文集，2019年，第5379–5389页。[32] M. Oechsle、S. Peng 和 A. Geiger，“UniSurf：统一神经隐式曲面与辐射场以进行多视图重建”，载于*IEEE/CVF*国际计算机视觉会议论文集，2021年，第5589–5599页。[33] M. Tancik、P. Srinivasan、B. Mildenhall、S. Fridovich-Keil、N. Raghavan、U. Singhal、R. Ramamoorthi、J. Barron 和 R. Ng，“傅里叶特征使网络能够在低维域中学习高频函数”，神经信息处理系统进展，第33卷，第7537–7547页，2020年。[34] P. Wang、L. Liu、Y. Liu、C. Theobalt、T. Komura 和 W. Wang，“NeuS：通过体渲染学习用于多视图重建的神经隐式曲面”，*arXiv*预印本 *arXiv:2106.10689*，2021 年。[35] V. Sitzmann 、 M. Zollh¨ofer 和 G. Wetzstein，“场景表示网络：连续的三维结构感知神经场景表示”，神经信息处理系统进展，第32卷，2019年。[36] A. Bergman、P. Kellnhofer 和 G. Wetzstein，“利用元学习快速训练神经光场表示”，神经信息处理系统进展，第34卷，第172–186页，2021年。[37] J. Chibane、A. Bansal、V. Lazova 和 G. Pons-Moll，“立体辐射场（SRF）：学习新场景稀疏视图的视图合成”，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2021年，第7911–7920页。[38] C. Gao、Y. Shih、W.-S. Lai、C.-K. Liang 和 J.-B. Huang，“基于单张图像的人像神经辐射场”，*arXiv*预印本 *arXiv:2012 05903*，2020年。。[39] Y. Jiang、D. Ji、Z. Han 和 M. Zwicker，“SDFDiff：用于三维形状优化的有符号距离场可微渲染”，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2020年，第1251–1261页。[40] P. Kellnhofer、L. C. Jebe、A. Jones、R. Spicer、K. Pulli 和 G. Wetzstein，“神经光场渲染”，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2021年，第4287–4297页。[41] L. Liu、J. Gu、K. Zaw Lin、T.-S. Chua 和 C. Theobalt，“神经稀疏体素场”，神经信息处理系统进展，第33卷，第15 651–15 663页，2020年。[49] M. Yang、Y. Wen、W. Chen、Y. Chen 和 K. Jia，“用于三维形状建模与重建的深度优化先验”，载于论文集

[42] R. Martin-Brualla、N. Radwan、M. S. Sajjadi、J. T. Barron、A. Doso- vitskiy 和 D. Duckworth，“野外神经辐射场：面向无约束照片集合的神经辐射场”，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2021年，第 7210–7219 页。[43] B. Mildenhall、P. P. Srinivasan、M. Tancik、J. T. Barron、R. Ramamoorthi 和 R. Ng，“NeRF：将场景表示为用于视图合成的神经辐射场”，*arXiv* 预印本 *arXiv:2003.08934*，2020年。[44] M. Niemeyer、L. Mescheder、M. Oechsle 和 A. Geiger，“可微体渲染：无需三维监督学习隐式三维表示”，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2020年，第 3504–3515 页。[45] L. Yariv、Y. Kasten、D. Moran、M. Galun、M. Atzmon、B. Ronen 和 Y. Lipman，“通过解耦几何与外观进行多视图神经表面重建”，神经信息处理系统进展，第 33 卷，第 2492–2502 页，2020年。[46] C. Jiang、A. Sud、A. Makadia、J. Huang、M. Nießner、T. Funkhouser 等，“三维场景的局部隐式网格表示”，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2020年，第 6001–6010 页。[47] E. Tretschk、A. Tewari、V. Golyanik、M. Zollh¨ofer、C. Stoll 和 C. Theobalt，“Patchnets：基于图块的可泛化深度隐式三维形状表示”，载于欧洲计算机视觉会议。Springer，2020年，第 293–309 页。[48] R. Chabra、J. E. Lenssen、E. Ilg、T. Schmidt、J. Straub、S. Lovegrove 和 R. Newcombe，“深度局部形状：学习用于精细三维重建的局部有符号距离函数先验”，载于欧洲计算机视觉会议。Springer，2020年，第 608–625 页。*IEEE/CVF*计算机视觉与模式识别会议，2021年，第 3269–3278 页。[50] J. Tang、J. Lei、D. Xu、F. Ma、K. Jia 和 L. Zhang，“Sa-convonet：卷积占据网络的符号无关优化”，载于*IEEE/CVF*国际计算机视觉会议论文集，2021年，第 6504–6513 页。[51] J. Huang、A. B. Lee 和 D. Mumford，“距离图像统计”，载于*IEEE*计算机视觉与模式识别会议论文集。*CVPR 2000*（目录号*PR00662*），第 1 卷。IEEE，2000年，第 324–331 页。[52] S. Koch、A. Matveev、Z. Jiang、F. Williams、A. Artemov、E. Burnaev、M. Alexa、D. Zorin 和 D. Panozzo，“ABC：用于几何深度学习的大型 CAD 模型数据集”，载于*IEEE*计算机视觉与模式识别会议（*CVPR*），2019年6月。[53] Q. M´erigot、M. Ovsjanikov 和 L. J. Guibas，“基于沃罗诺伊图的点云曲率与特征估计”，*IEEE*可视化与计算机图形学汇刊，第 17 卷，第 6 期，第 743–756 页，2010年。[54] H. Huang、S. Wu、M. Gong、D. Cohen-Or、U. Ascher 和 H. Zhang，“边缘感知点集重采样”，*ACM*图形学汇刊（*TOG*），第 32 卷，第 1 期，第 1–12 页，2013年。