arXiv:2302.04488v1 [cs.RO] 9 Feb 2023

PredRecon：一种预测增强规划框架，用于快速、高质量的自主空中重建

Chen Feng[2], Haojia Li[2], Fei Gao[3,4],Boyu Zhou[1], †和 Shaojie Shen[2]

摘要——面向高质量三维模型的三维重建自主无人机路径规划，已在各类应用中得到广泛研究。然而，现有大多数工作采用先探索后利用、基于先验或基于探索的策略，表现出反复飞行、效率低下和自主性不足等问题。本文提出 **PredRecon**，这是一种预测增强规划框架，可自主生成实现高质量三维重建的路径。我们的灵感来自人类能够根据局部观测大致推断完整的结构。因此，我们设计了一个表面预测模块（**SPM**），根据当前的部分重建预测目标的大致完整表面。随后，通过在线体积映射生成尚待无人机观测的未覆盖表面。最后，分层规划器为三维重建规划运动：依次寻找高效的全局覆盖路径，规划局部路径以最大限度提升多视图立体视觉（**MVS**）的性能，并生成平滑轨迹以采集图像-位姿对。我们在真实感模拟器中进行了基准测试，验证了 **PredRecon** 相较于经典方法和最先进的方法的性能。开源代码已发布于 **https://github.com/HKUST-Aerial-Robotics/PredRecon**。

一、引言

近年来，高质量三维重建已成为多个应用领域的热门课题，包括文物数字化、增强现实/虚拟现实和结构检测。凭借高度的灵活性，无人驾驶航空器（**无人机**）非常适合用于对目标区域进行快速、精准且完整的三维重建。为了有效提升重建质量和效率，构建自主空中重建路径规划框架至关重要。

现有的重建规划研究 [1]–[7] 在重建目标区域时效率不尽如人意。首先，许多以往的方法 [1]–[4] 采用先探索后利用 策略，需要执行两条扫描航迹，或者依赖粗略的先验模型来获取重建路径。这些策略存在若干缺点：1）两条扫描航迹会降低任务完成效率。2）由于需要输入先验模型，任务无法完全自动化。3）由于规划仅基于粗略模型或先验模型，无法根据实际观测实时调整飞行路径，因此无法保证目标区域细节的准确性和完整性。近期，在线

[1]中山大学人工智能学院，中国珠海。[2]香港科技大学电子与计算机工程系，中国香港。[3]浙江大学网络系统与控制研究所，工业控制技术国家重点实验室，中国杭州。[4]浙江大学湖州研究院，中国湖州。{cfengag, hlied, eeshaojie}@ust.hk, fgaoaa@zju.edu.cn, zhouby23@mail.sysu.edu.cn

† 通讯作者

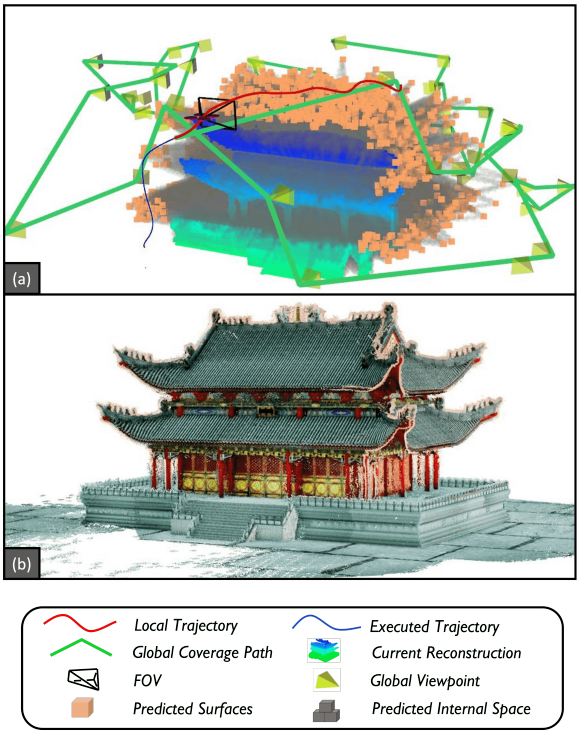


图1。（a）所提出框架在执行三维重建轨迹期间的结果示意图；（b）所提出框架生成的上述目标的三维重建结果。

已有研究提出了需要单条扫描航迹且不依赖先验模型的规划方法 [5]–[7], ，部分解决了上述问题。然而，由于目标区域事先未知，且大量时间花在探索未知区域上，其效率仍不尽如人意。此外，其中一些方法的计算时间长得难以接受，通常会导致不理想的走走停停行为，甚至需要与外部高性能计算机通信。

为解决上述问题，我们提出了**PredRecon**，一种预测增强规划框架，可在单次飞行中高效重建未知环境中目标区域的高质量三维模型。我们的方法受到这样一个事实的启发：人类能够根据自身知识和经验，基于局部观测合理推断不完整结构。推断出的结构或表面有助于生成更具针对性的视点，从而能够更高效地规划覆盖整个目标的全局覆盖路径，避免将大量时间浪费在探索未知空间上。受此启发，我们引入了一种基于学习的表面预测模块（**SPM**），该模块根据当前的局部重建预测目标的粗略完整表面

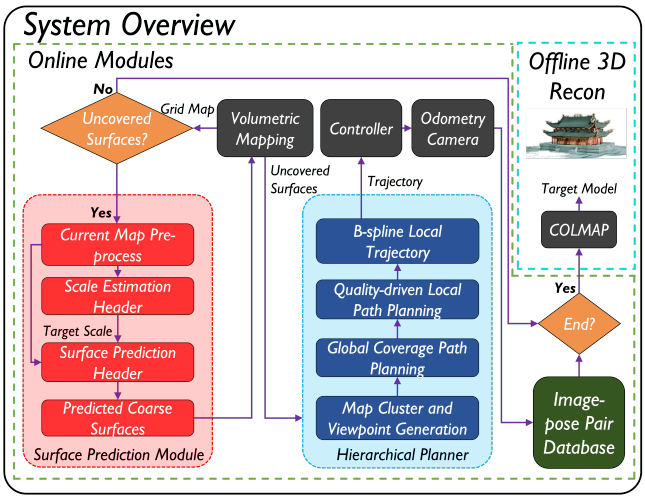


图 2. 所提出的用于三维重建的预测增强路径规划框架概览。

。随后，在线体积映射从预测结果和当前重建中提取不完整观测表面，作为尚未覆盖的部分。接着，分层规划器以由粗到细 的方式生成用于重建未覆盖表面的运动。首先，它会寻找一条高效的全局路径以实现全面覆盖。其次，在全局路径的引导下，生成一段从当前位姿到下一视点（NBV）的局部路径段，同时优化对多视图立体视觉性能至关重要的因素。然后，生成可执行的局部轨迹，以获取目标的图像—位姿对。使用COLMAP [8]–[10]处理采集到的数据集，以进行稠密三维重建。

我们在真实仿真中将所提出的方法与经典方法和最先进的方法 进行了比较。结果表明，我们的方法在基准场景中具有更高的效率和更好的重建质量。此外，基准实验表明，我们的方法具有更高的自主性水平，并且能够在典型的机载计算机上实现实时规划。本文的贡献总结如下：

1) 一种表面预测模块（SPM），可根据部分重建信息直接推断完整的目标表面，并促进对目标的高效全局覆盖，避免在额外探索上浪费大量时间。

2) 一种基于 SPM 的分层规划器，可实时充分考虑多视图立体视觉相关因素和全局覆盖，从而实现更高的重建质量和效率。

3) 验证**PredRecon**性能的基准测试比较。我们已公开实现的源代码。

II. 相关工作

A. 表面预测与补全

表面预测与补全一直是三维重建中的重要课题。现有工作大致可分为基于几何的方法和基于学习的方法。

基于几何的方法通过几何启发式方法，根据部分输入数据预测整个表面。一些经典研究 [11]–[14]利用不完整的局部孔洞，通过平滑插值生成完整的表面模型。这些方法假设可以直接根据几何输入结构推断整个表面。因此，在大部分飞行时间内，它们的表现并不理想。

基于学习的方法以通过表面体素化获取的点云作为输入。它们 [15]–[18] 直接利用隐式参数化模型（深度神经网络）输出完整的表面模型，因此能够更好地适应复杂情况。我们的 SPM 属于这一类别。然而，大多数现有方法都存在精度不稳定的问题，主要受归一化影响。因此，需要额外的检测器来预测目标模型的尺度和中心。此外，许多方法采用三维卷积神经网络以获得更高精度，但复杂的架构会导致推理时间变慢。

基于这一方法， [15],我们的 SPM 直接使用地图点云作为输入，无需额外的检测器进行归一化，即可实现端到端 表面预测。此外，我们优化了网络架构，采用更轻量的结构，同时获得更高的性能（第 VI-C 节）。

B. 空中重建路径规划

为实现高效、高质量的三维重建，多年来，研究人员一直深入研究视点路径规划：该方法在最大限度提升重建质量的同时，尽可能减少视点数量。其根本问题在于如何建立视点选择与质量之间的联系。一些方法 [2, 19, 20] 将视点信息增益（定义为粗略模型的覆盖范围）作为规划目标。此外，其他研究[1, 21]为每个表面划分一个覆盖半球，确保所选视点能从不同视角方向扫描整个表面。

基于MVS的方法 [5, 7, 22, 23] 会考虑MVS因素来确定最优视点，以改善深度估计，本文也采用了这种做法。[5, 7]将问题表述为信息路径规划问题，而 [22, 23] 则采用基于可重建性启发式规则的选择策略。这些方法都考虑了立体匹配和三角测量因素。

本文以基于 MVS 的相关工作为基础构建分层规划器，同时对 MVS 启发式代价进行了更精简的表述。此外，该规划器充分利用 SPM 的结果生成路径，从而实现高重建效率和高质量。

III. 系统概述

图2展示了所提出流程的概览，该流程由在线模块和离线模块组成。在线子系统由SPM（第IV节）、在线体积映射（第IV-C节）和分层规划器（第V节）组成。SPM根据当前局部地图（第IV节）预测整个目标模型表面的尺度和点云。随后，在线体积映射利用SPM结果提取剩余的未覆盖表面（第IV-C节）。之后，分层规划器负责寻找全局路径并生成局部轨迹，以最大化全局覆盖效率和MVS性能。无人机通过里程计和机载相机采集图像-位姿对（第V节）。

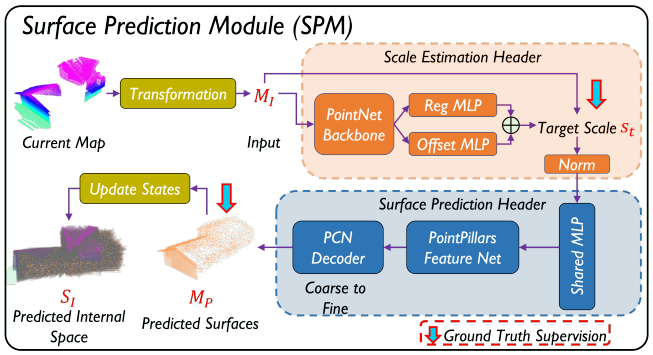


图 3. 所提出的 SPM 的整体架构（第 IV 节）。

如果映射未发现未覆盖表面，在线子系统将结束飞行。随后，使用离线COLMAP处理图像-位姿对数据库，以获取目标的三维重建模型。

IV. 表面预测模块

如图 3 所示，SPM 能够在完全未知的环境中，根据局部地图预测目标的完整表面。表面预测有效减少了冗余飞行，因为无需额外花费时间探索未知环境。此外，它有助于生成数量更少且足以观测目标的视点，从而降低后续规划器的复杂度。

A. 数据预处理

SPM 的输入是当前局部地图（第 IV-C 节）的下采样点云 M_C，其数量固定为 N_C。不同于以往工作 [15]–[17]，，我们直接通过局部变换 T_p 处理每个点 $p_i \in M_C$，如下所示：

$$T_p(p_i, C_C) = p_i - C_C, \tag{1}$$

其中，C_C 是 M_C 的质心。随后，每个变换后的点都存储在 M_I 中，并发送至预测网络。

B. 预测网络结构

与以往的点云补全工作[15]–[17，24]，相比，我们的预测网络采用端到端方式，无需额外的检测器进行归一化。此外，在网络实现中不使用三维卷积操作，满足实时和轻量化要求。该网络由两个头组成，即尺度估计头和表面预测头。

为便于后续进行表面预测，我们引入尺度估计头，用于预测目标的粗略尺度。输入 M_I 表示为一个 $N_C \times 3$矩阵，其中包含每个点的 3D 坐标（x、y、z）。具体而言，我们采用 PointNet [25] 作为骨干网络，利用其置换不变性和高效的全局特征提取能力。随后设置两个多层感知机（MLP）作为输出分支。回归多层感知机直接输出一个向量（x_s、y_s、z_s），表示三个轴上的尺度。为进一步提高尺度估计精度，我们对局部特征图进行特殊处理：将 PointNet 后的局部特征图输入偏移多层感知机，以获得相应的偏移量（Δx_s、Δy_s、Δz_s）。因此，目标尺度 s_t 可表示为：

$$s_t = max(x_s + \Delta x_s, y_s + \Delta y_s, z_s + \Delta z_s). \tag{2}$$

在训练阶段，我们使用Huber损失监督各个轴上的尺度估计。最后，通过将输入点云 M_I 缩小 s_t倍来进行归一化。

表面预测头负责根据归一化的M_I生成目标的完整表面。我们使用共享多层感知机对归一化 M_I 中的每个点进行编码，将其映射为特征图 F。随后，在 F 上执行PointPillars特征网络 [26]，将其作为编码器，通过伪图像操作以较低的计算成本聚合不同区域的几何信息。此外，PointPillars适用于该问题，因为我们希望网络具备空间感知能力，从而扩展或补全不同区域中的部分表面。与PCN[15]，类似，我们还采用由粗到细的解码器，以生成用于全局与局部几何学习的预测结果。精细预测 Y_{fine} 和粗略预测 Y_{coarse} 均包含 N_C 个点。对于损失函数，使用置换不变的倒角距离来监督网络输出与其真实值 Y_{gt}之间的差异，如下所示：

$$cd(X,Y) = \frac{1}{|X|}\sum_{x\in X} \underset{y\in Y}{min}\, ||x-y||_2^2 + \frac{1}{|Y|}\sum_{y\in Y} \underset{x\in X}{min}\, ||x-y||_2^2 \tag{3}$$

$$\mathcal{L} = cd(Y_{coarse}, Y_{gt}) + cd(Y_{fine}, Y_{gt}). \tag{4}$$

随后，将 M_I 和逆归一化后的 Y_{fine} 拼接为一个 $2N_C \times 3$ 矩阵，作为预测表面 M_P。为确定正确的视点采样空间，我们采用*GHPR* [27] 处理 M_P，以获得内部空间 S_I，该空间是生成视点时的禁入区域。

C. 预测体积映射

为了在线评估目标的重建部分，我们参考 [28] 构建体积地图，为 SPM 提供局部观测。我们将从两个或更多不同视点观测到的表面定义为完整观测表面。SPM 推理完成后，体积地图构建从预测结果中提取这些不完整的观测表面，作为分层规划器的目标未覆盖区域。

V. 分层规划器

针对未覆盖表面，路径规划可表述为生成路径，以高效、完整地覆盖目标的未覆盖表面。为实现这一目标，所提出的规划器采用分层规划范式，分为两个步骤：全局覆盖路径规划（第 V-A 节），以及用于数据采集和轨迹生成的质量驱动的局部路径规划（第 V-B 节）。

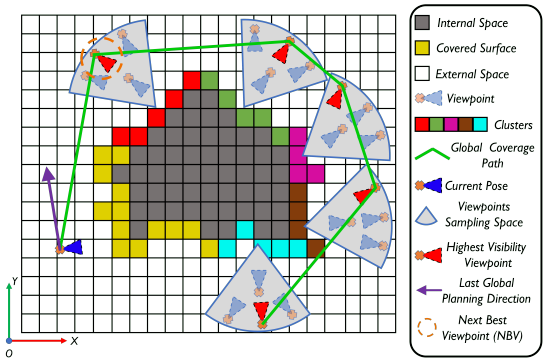


图 4. 全局覆盖路径规划：（1）对未覆盖表面进行聚类。（2）通过双重采样生成视点。（3）由 ATSP 求解器给出全局覆盖路径。（第 V-A 节）

A. 全局覆盖路径规划

此规划阶段旨在输出高效的视点全局访问序列，以覆盖未覆盖表面，如图 4 所示。首先，基于欧几里得距离和法向量对未覆盖表面进行聚类，以提取待访问的 N_G 个簇。然后，与 [5]，类似，我们采用双重采样方法生成*4-DoF* 视点：从每个簇的中心沿其法向方向，在各自的扇形圆柱体内采样一组覆盖视点，如图 4 所示。最后，我们选择每个簇中表面可见率最高的视点作为 $V_G = \{v_g^1, v_g^2, ..., v_g^{N_G}\}$，其中 $v_g^i = (\mathbf{P}_g^i,\ \theta_g^i)$ 表示位置和偏航角。视点的表面可见率定义如下：

$$r(v,s) = \frac{\mathcal{N}(v)}{\mathcal{N}(s)}, \tag{5}$$

其中，v 表示视点，s 表示观测到的表面，$\mathcal{N}(v)$ 表示从 v可见的 s 中的可见点数量，而 $\mathcal{N}(s)$ 表示 s中的点数。

为了找到从当前位姿出发并经过每个视点的最短路径，我们将该问题建模为非对称旅行商问题（ATSP） [29]。通过设计合适的代价矩阵 Υ_G，即可使用已有的成熟算法求解 ATSP。因此，我们给出两个视点之间的代价 c_g（v_g^i，v_g^j），该代价考虑了路径长度和偏航角变化，如下所示：

$$c_g(v_g^i, v_g^j) = \frac{L(\mathbf{P}_g^i, \mathbf{P}_g^j)}{v_{max}} + \frac{min(||\theta_g^i - \theta_g^j||_1, 2\pi - ||\theta_g^i - \theta_g^j||_1)}{\omega}, \tag{6}$$

其中，L（$\mathbf{P}_g^i$，$\mathbf{P}_g^j$）表示在自由空间中通过 A^* 算法搜索得到的$\mathbf{P}_g^i$ 与$\mathbf{P}_g^j$之间的路径长度，v_{max} 和 ω 分别表示最大速度和偏航角的角变化率。

有时，存在多条代价相近的全局覆盖路径，导致路径优化结果不稳定，进而造成飞行方向不一致、效率低下。因此，生成稳定的解时必须充分考虑全局一致性。我们将上一次的全局规划方向定义为（从上一次当前位置 $\mathbf{P}_{cur}^{last}$ 到上一次的下一最佳视点 $\mathbf{P}_{nbv}^{last}$的向量） d_g^{last}，并引入全局一致性代价 $c_{GC}(v_g^i)$，定义如下：

$$d_g^{last} = \frac{\mathbf{P}_{nbv}^{last} - \mathbf{P}_{cur}^{last}}{||\mathbf{P}_{nbv}^{last} - \mathbf{P}_{cur}^{last}||_2}, \tag{7}$$

$$c_{GC}(v_g^i) = arccos\frac{\mathbf{P}_g^i - \mathbf{P}_{cur}^{now}}{||\mathbf{P}_g^i - \mathbf{P}_{cur}^{now}||_2} \cdot d_g^{last}. \tag{8}$$

然后，我们可以给出带有视点索引集 $\zeta = \{1, 2, ..., N_G\}$ 的 Υ_G 完整形式：

$$\Upsilon_G(k,h) = \begin{cases} 0, & k == h \, or \, h = 0 \\ c_g(v_g^k, v_g^h), & k, h \in \zeta \\ [\beta_1 c_g(v_g^k, v_g^h) + & k == 0 \, and \, h \in \zeta \\ \beta_2 c_{GC}(v_g^h)], & \end{cases} \tag{9}$$

因此，通过利用 Υ_G 求解上述非对称旅行商问题，我们可以找到一条高效的全局覆盖路径，从当前位姿出发访问所有未覆盖表面。

B. 质量驱动的局部路径规划

全局规划主要关注对目标进行快速且完整的覆盖。为进一步提高重建质量，局部规划会对从当前位姿到下一最佳视点的分段路径进行优化，并充分考虑多视图立体视觉相关因素，如图 5 所示。

与全局规划不同，局部分段所覆盖的簇会进一步细分为更小的簇，而局部规划中的视点采样空间由两个相邻簇决定，如图 5 所示。局部视点集表示为 $V_L = \{VP_1$ 的形式：$\{v_l^{1,1}, v_l^{1,2}, ..., v_l^{1,n}\}$，$.....VP_i$：$\{v_l^{i,1}, v_l^{i,2}, ..., v_l^{i,k}, ...\}\}$，簇表示为 $\mathcal{C}_L = \{cls_1, cls_2, ..., cls_j, ...\}$。

许多先前研究 [9, 30, 31]充分证明，高质量的 MVS 重建取决于以下因素，包括可见性 $\mathcal{S}_{vis}$、相对距离 $\mathcal{S}_{dis}$ 和三角化角度 $\mathcal{S}_{ang}$，如式 10、11、12、13 所示。为了优化局部路径的 MVS 性能，我们将 MVS 结构分解为若干基本三角化单元，每个单元由局部路径中相邻的两个视点及其共同可见的簇表面定义。此外，该路径的 MVS 性能可以视为该路径中所有三角化单元的重建质量 Q 之和。于是，三角化单元的 Q可写为：

$$Q(v_1, v_2, s) = \mathcal{S}_{vis} \cdot \mathcal{S}_{dis} \cdot \mathcal{S}_{ang}, \tag{10}$$

其中，簇表面 s 位于两个视点 v_1 和 v_2下。

$\mathcal{S}_{vis}$ 是两个视点的可见率（$r \in [0,1]$）得分，如下所示：

$$\mathcal{S}_{vis}(v_1, v_2, s) = \frac{r(v_1, s) + r(v_1, s)}{2}. \tag{11}$$

设 dis_1 和 dis_2 分别为两个视点到表面质心的距离。我们希望 $\mathcal{S}_{dis}$ 接近 1，以便两个视点图像具有相似的分辨率，从而更好地进行深度估计。公式如下：

$$\mathcal{S}_{dis}(v_1, v_2, s) = \frac{min(dis_1, dis_2)}{max(dis_1, dis_2)}. \tag{12}$$

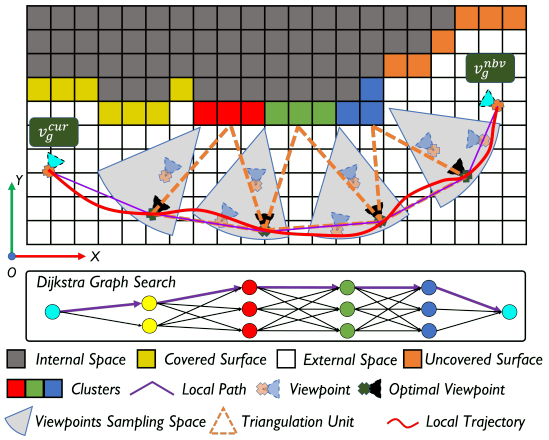


图 5. 基于图搜索的质量驱动局部路径规划。通过充分考虑多视图立体视觉相关因素，生成一条以重建质量为驱动的局部路径及其对应的轨迹。（第 V-B 节）

$\mathcal{S}_{ang}$ 衡量三角化性能，包括精度和可匹配性。设 ϵ 为 vec_1 与 vec_2 之间的夹角。ε_1 是 s 的法向量 $\mathcal{N}_s$ 与 vec_1 之间的夹角，而 ε_2 是 vec_2 对应的夹角。因此， $\mathcal{S}_{ang}$ 可写为:

$$\begin{aligned} vec_h &= \mathcal{C}_s - v_h, \\ \mathcal{S}_{ang}(v_1, v_2, s) &= exp(-(\frac{\epsilon - \epsilon_d + \varepsilon_1 - \varepsilon_2}{\kappa})^2), \end{aligned} \tag{13}$$

其中， $\mathcal{C}_s$ 是 s的质心， ϵ_d 是期望的三角化角度， κ是用于保证数值稳定性的小常数。

因此，我们可以将多视图立体视觉启发式代价 c_{MVS}和包含运动代价的总成本 c_l 表示为:

$$c_{MVS}(v_1, v_2, s) = \frac{1}{Q(v_1, v_2, s)}, \tag{14}$$

$$c_l(v_1, v_2, s) = \alpha_1 c_{MVS}(v_1, v_2, s) + (1-\alpha_1) c_g(v_1, v_2). \tag{15}$$

假设总共有 N_L 个簇，则 V_l的数量应为 $N_L + 1$ ，以满足 N_L 定义的三角化单元。为优化局部路径的质量驱动代价 c_l ，我们将其表述为一个图搜索问题。随后，采用迪杰斯特拉算法搜索使所提出代价最小的最优局部路径 $\mathcal{P}_L = \{v_l^{1,i_1}, v_l^{2,i_2}, ..., v_l^{N_L+1,i_{N_L+1}}\}$:

$$min \sum_{k=1}^{N_L} c_l(v_l^{k,i_k}, v_l^{k+1,i_{k+1}}, cls_k). \tag{16}$$

最后，通过利用 [32], ，我们将局部路径$\mathcal{P}_L$ 转换为一条安全、平滑、满足动力学可行性且时间最短的B样条局部轨迹，同时考虑多视图立体视觉性能，从而有效采集图像-位姿对。

VI. 实验

A. 实现细节

为了训练我们的 SPM，我们使用合成 CAD 模型集 Houses3K [33] 创建包含部分和完整点云的建造场景数据集。此外，我们还在虚幻引擎（UE4[1]）中收集了其他类型的建造模型。具体而言，我们利用 Blender[2] 生成部分点云

[1]https://www.unrealengine.com/en-US/ [2] https://www.blender.org/

表 I 两种场景下的路径规划与三维重建结果。

	方法	先验模型	Path 长度 (m)	Time (s)	召回率 (%)	精确率 (%)	F值 (%)
Palace	Plan3D [2]	✗	375.5	507.7	74.48	82.57	78.32
	CAPP [1]	✓	243.6	322.6	69.21	85.86	76.64
	FUEL [6]	✗	371.1	469.8	40.31	38.38	39.32
	Ours	✗	**213.1**	**252.7**	**74.67**	**86.45**	**80.13**
Village House	Plan3D [2]	✗	239.3	310.6	64.28	72.86	68.30
	CAPP [1]	✓	193.4	242.3	80.30	**84.60**	82.40
	FUEL [6]	✗	405.1	506.8	44.35	36.46	40.02
	Ours	✗	**153.2**	**184.6**	**84.54**	83.13	**83.83**

其中包含来自不同建造类别的 12900 个模型。此外，我们在数据预处理阶段设置了 $N_C = 8192$ 。关于训练细节，SPM 在单张 NVIDIA RTX 3070Ti 上训练 200 轮，耗时 13 小时。训练时我们选择 Adam [34] 优化器，初始学习率为 1e-4，批量大小为 16，并在训练至 150 轮时将学习率衰减至 1e-5。

在分层规划中，我们在式（9）中设置 $\beta_1 = 1.0$ 和 $\beta_2 = 5.0$, 在式（13）中设置 $\epsilon_d = 22.5°$ 和 $\kappa = 0.2$ ，并在式（15）中设置 $\alpha_1 = 0.8$ 。在全局覆盖路径规划中，通过 Lin-Kernighan-Helsgaun 启发式求解器 [35]求解非对称旅行商问题。

在所有实验中，均使用几何控制器 [36] 对（x， y， z， θ）轨迹进行跟踪控制。SPM 在 NVIDIA RTX 3070 Ti 上运行（GPU内存使用量： ~**1GB**），其他模块则在 Intel Core i9-10900K 中央处理器上运行。

B. 基准比较

我们在 UE4 中的逼真仿真器 AirSim 中开展仿真实验，并在两个纹理丰富的场景中进行基准测试：宫殿 （$15 \times 25 \times 14m^3$）和乡村房屋（$14 \times 11 \times 12m^3$）。我们将所提方法与三种方法进行比较：Plan3D [2] （先探索后利用）、CAPP [1]（基于先验）和 FUEL [6]（基于探索）。Plan3D [2]和 CAPP [1],均没有开源代码，因此我们使用自行实现的版本。我们采用搭载前视摄像头的无人机作为实验平台，其视场角为 $[80°, 60°]$ ，图像分辨率为 1280×720px。在两个场景中，我们限制 $v_{max} = 0.85m/s$ 和$\omega = 0.5rad/s$。Plan3D [2] 首先执行预定义飞行以获取粗略模型，然后使用我们的规划器生成全局路径。CAPP [1] 也根据输入的先验模型，通过我们的规划器生成全局覆盖路径。至于 FUEL [6], ，它会在包含目标的未知环境中探索，同时采集目标的图像-位姿对。每种方法采集的数据均通过 COLMAP 处理，以获得重建的三维模型。

我们通过两项指标评估它们的性能：效率（路径长度和时间）以及重建质量（*F*值）。平均比较结果列于表 I 和图 6 中。与其他方法相比，我们的方法耗时更短、路径长度也更短，这主要是因为在 SPM 预测的支持下，我们的规划器能够生成效率更高的全局覆盖路径，并且

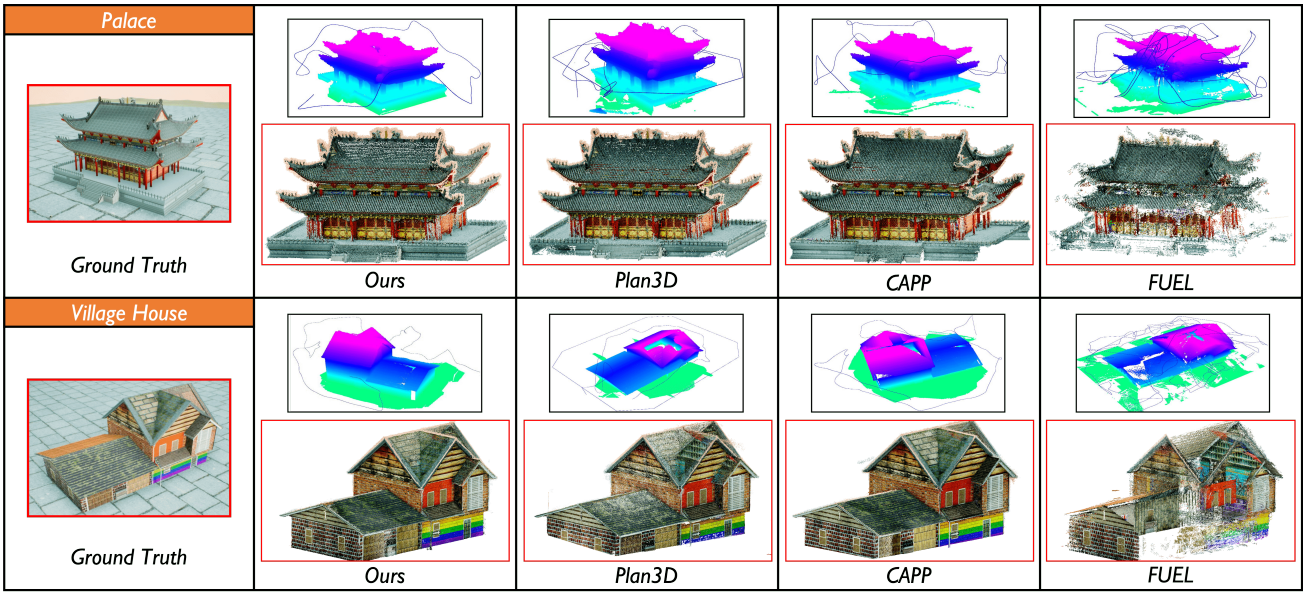


图6. 所提方法、Plan3D [2], CAPP [1] 和 FUEL [6] 在两个场景（宫殿和乡村房屋）中的基准比较（重建的三维模型、体积地图及已执行轨迹）。

表II 各模块的计算时间。

	SPM	全局规划	局部规划	轨迹 Opt.	总计计算
时间（ms）	~26.8	~93.5	~0.5	~3.7	~124.7

表III 点云补全性能比较。

方法	#参数(M)	L1倒角距离 (1e-3m)	L2倒角距离 (1e-4m)	F值 (%)
我们的 SPM	**28.20**	**13.6404/ 9.4461**	**14.7100 /3.9368**	**52.6050 / 68.6693**
PCN [15]	28.91	15.5221/10.4897	18.3987/ 4.7431	50.1210/65.7207

支持 SPM 预测。对于重建质量，我们参考 [37] 中的评估流程和指标。首先，我们对重建模型与真实值进行点云配准。随后，以 $0.05m$ 的体素尺寸对两个点云进行均匀重采样，并通过 $Precision$ 和 $Recall$ 进行比较。$Precision$ 表示与真实值中的某个点距离较近的重建点所占的百分比，而 $Recall$ 则定义为与重建点距离较近的真实值点所占的百分比。我们将两点之间的距离小于 $0.1m$ 视为距离较近。随后，$F\text{-}score$ 表示为 $F-score = \frac{2(Precision \times Recall)}{Precision+Recall}$。图 6 和表 I 展示了四种方法在两种场景下重建模型的重建质量。显然，所提出的方法取得了更高的 $Precision$、$Recall$ 和 F值，这主要是因为我们的局部规划旨在优化 MVS性能，并且每当预测和地图更新时，我们的方法都会实时重新规划路径，以获取完整的细节。尽管在乡村房屋 场景中，我们的 $Precision$ 略低于 CAPP [1]，但我们的方法无需先验模型。

如表II所示，所提出的系统约需 $100ms$ 完成一次规划，因此能够满足真实无人机机载计算机进行实时规划所需的频率。

C. SPM预测性能

与点云补全任务相比，我们系统中的表面预测更为困难，因为没有提供精确的尺度和中心用于归一化。然而，在倒角距离和 F值 指标下，即使没有预先给定尺度和中心，我们的 SPM 仍优于 PCN [15] 在上述任务中使用生成数据（第 VI-A 节）（左图）和 ShapeNet 数据集（右图）时的表现，如表 III 所示。就重建表面而言，PCN [15] 生成的表面比 SPM 生成的粗略预测结果更平滑。

VII. 结论

本文提出了一种预测增强规划框架，利用自主单次轨迹实现高效、高质量的三维重建。所提出的 SPM 根据局部地图预测完整表面，为路径规划器提供全局信息。基于 SPM，分层规划器以序列方式规划三维重建所需的运动。该规划器寻找高效的全局覆盖路径，优化由重建质量驱动的局部路径，以提升 MVS性能，并生成相应的平滑局部轨迹。通过引入 SPM 并考虑多视图立体视觉相关因素，该方法显著提高了重建效率和质量。在真实仿真中的具有挑战性的基准测试表明，与现有的经典方法和**最先进的** 方法相比，*PredRecon* 表现出更强的能力。

我们方法的局限在于真实世界测试不足，以及 SPM 的泛化能力和鲁棒性有限。未来，我们计划进一步优化 SPM 架构，以改进数据表示，并开展更具挑战性的真实世界测试。

参考文献

[1] H. Zhang、Y. Yao、K. Xie、C.-W. Fu、H. Zhang 和 H. Huang，《面向三维城市场景重建的连续空中路径规划》，ACM图形学汇刊，第 40 卷，第 6 期，第 225–1 页，2021 年。[2] B. Hepp、M. Nießner 和 O. Hilliges，《Plan3D：面向空中多视图立体重建的视点与轨迹优化》，ACM图形学汇刊（TOG），第 38 卷，第 1 期，第 1–17 页，2018 年。[3] Q. Kuang、J. Wu、J. Pan 和 B. Zhou，《面向自主城市场景重建的实时无人机路径规划》，载于 2020 年 IEEE机器人与自动化国际会议（ICRA）。IEEE，2020 年，第 1156–1162 页。[4] X. Zhou、K. Xie、K. Huang、Y. Liu、Y. Zhou、M. Gong 和 H. Huang，《用于高效城市场景重建的异地空中路径规划》，ACM图形学汇刊（TOG），第 39 卷，第 6 期，第 1–16 页，2020 年。[5] S. Song、D. Kim 和 S. Choi，《通过在线多视图立体视觉进行视点路径规划，以实现大型结构的三维建模》，IEEE机器人学汇刊，第 38 卷，第 1 期，第 372–390 页，2021 年。[6] B. Zhou、Y. Zhang、X. Chen 和 S. Shen，《FUEL：利用增量式前沿结构和分层规划进行快速无人机探索》，IEEE机器人与自动化快报，第 6 卷，第 2 期，第 779–786 页，2021 年。[7] S. Song、D. Kim 和 S. Jo，《通过在线多视图立体视觉实现主动三维建模》，载于 2020 年 IEEE机器人与自动化国际会议（ICRA）。IEEE，2020 年，第 5284–5291 页。[8] J. L. Sch¨onberger 和 J.-M. Frahm，《重新审视运动恢复结构》，载于计算机视觉与模式识别会议（CVPR），2016 年。[9] J. L. Sch¨onberger、E. Zheng、M. Pollefeys 和 J.-M. Frahm，《面向非结构化多视图立体视觉的逐像素视图选择》，载于欧洲计算机视觉会议（ECCV），2016 年。[10] J. L. Sch¨onberger、T. Price、T. Sattler、J.-M. Frahm 和 M. Pollefeys，《一种用于图像检索中快速空间验证的投票与验证策略》，载于亚洲计算机视觉会议（ACCV），2016 年。[11] 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。[12] J. Davis、S. R. Marschner、M. Garr 和 M. Levoy，《利用体扩散填充复杂表面中的孔洞》，载于《论文集：第一届国际三维数据处理、可视化与传输研讨会》。IEEE，2002 年，第 428–441 页。[13] M. Berger、A. Tagliasacchi、L. Seversky、P. Alliez、J. Levine、A. Sharf 和 C. Silva，《点云曲面重建的最新进展》，《Eurographics 2014——前沿技术报告》，第 1 卷，第 1 期，第 161–185 页，2014 年。[14] W. Zhao、S. Gao 和 H. Lin，《一种适用于三角网格的鲁棒孔洞填充算法》，《The Visual Computer》，第 23 卷，997，2007 年 12，987 期，第 – 页。[15] W. Yuan、T. Khot、D. Held、C. Mertz 和 M. Hebert，《PCN：点云补全网络》，载于 2018 年国际三维视觉会议（3DV）。IEEE，2018 年，第 728–737 页。[16] H. Xie、H. Yao、S. Zhou、J. Mao、S. Zhang 和 W. Sun，《GRNet：用于稠密点云补全的网格化残差网络》，载于欧洲计算机视觉会议。Springer，2020 年，第 365–381 页。[17] L. Pan、X. Chen、Z. Cai、J. Zhang、H. Zhao、S. Yi 和 Z. Liu，《变分关系点云补全网络》，载于 IEEE/CVF 计算机视觉与模式识别会议论文集，2021 年，第 8524–8533 页。[18] J. Shi、L. Xu、P. Li、X. Chen 和 S. Shen，《具有位姿扰动的时序点云补全》，IEEE机器人与自动化快报，第 7 卷，第 2 期，第 4165–4172 页，2022 年。[19] A. Hornung、B. Zeng 和 L. Kobbelt，《用于改进多视图立体视觉的图像选择》，载于 2008 年 IEEE计算机视觉与模式识别会议。IEEE，2008 年，第 1–8 页。[20] P.-P. V´azquez、M. Feixas、M. Sbert 和 W. Heidrich，《利用视点熵进行自动视点选择及其在基于图像的建模中的应用》，载于《Computer Graphics Forum》，第 22 卷，第 4 期。Wiley Online Library，2003 年，第 689–700 页。[21] M. Roberts、D. Dey、A. Truong、S. Sinha、S. Shah、A. Kapoor、P. Han- rahan 和 N. Joshi，《面向空中三维扫描的次模轨迹优化》，载于 IEEE国际计算机视觉会议论文集，2017 年，第 5324–5333 页。[22] N. Smith、N. Moehrle、M. Goesele 和 W. Heidrich，《面向城市场景重建的空中路径规划：一种连续优化方法与基准测试》，2018 年。

[23] C. Peng 和 V. Isler，“用于航空三维重建的自适应视点规划”，载于*2019*年国际机器人与自动化会议（*ICRA*）。IEEE，2019年，第2981–2987页。[24] Z. Huang、Y. Yu、J. Xu、F. Ni 和 X. Le，“PF-Net：用于三维点云补全的点分形网络”，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2020年，第7662–7670页。[25] C. R. Qi、H. Su、K. Mo 和 L. J. Guibas，“PointNet：用于三维分类和分割的点集深度学习”，载于*IEEE*计算机视觉与模式识别会议论文集，2017年，第652–660页。[26] A. H. Lang、S. Vora、H. Caesar、L. Zhou、J. Yang 和 O. Beijbom，“PointPillars：用于点云目标检测的快速编码器”，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2019年，第12 697–12 705页。[27] S. Katz 和 A. Tal，“关于点云的可见性”，载于*IEEE*国际计算机视觉会议论文集，2015年，第1350–1358页。[28] L. Han、F. Gao、B. Zhou 和 S. Shen，“FIESTA：用于空中机器人在线运动规划的快速增量式欧氏距离场”，*arXiv*预印本 *arXiv:1903.02144*，2019年。[29] Z. Meng、H. Qin、Z. Chen、X. Chen、H. Sun、F. Lin 和 M. H. Ang，“用于三维未知环境探索和结构重建的两阶段优化下一视点规划框架”，*IEEE*机器人与自动化快报，第2卷，第3期，第1680–1687页，2017年。[30] O. Mendes、S. Hadfield、N. Pugeault 和 R. Bowden，“最佳下一立体视图：将最佳下一视点优化扩展至协作传感器”，2016年。[31] O. Mendez、S. Hadfield、N. Pugeault 和 R. Bowden，“通过风景路线实现三维重建：优化移动摄像机拍摄的重建结果”，载于*IEEE*国际计算机视觉会议论文集，2017年，第4677–4685页。[32] B. Zhou、F. Gao、L. Wang、C. Liu 和 S. Shen，“面向快速自主飞行的鲁棒高效四旋翼轨迹生成”，*IEEE*机器人与自动化快报，第4卷，第4期，第3529–3536页，2019年。[33] D. Peralta、J. Casimiro、A. M. Nilles、J. A. Aguilar、R. Atienza 和 R. Cajote，“用于三维重建的最佳下一视点策略”，*arXiv*预印本 *arXiv:2008.12664*，2020年。[34] D. P. Kingma 和 J. Ba，“Adam：一种随机优化方法”，*arXiv*预印本 *arXiv:1412.6980*，2014年。[35] K. Helsgaun，“林–克尼汉旅行商启发式算法的有效实现”，《欧洲运筹学杂志》，第126卷，第1期，第106–130页，2000年。[36] T. Lee、M. Leoky 和 N. H. McClamroch，“四旋翼无人机在 SE(3*2010 49*2010, 5420 5425) 上的几何跟踪控制”，载于决策与控制（*CDC*），第 *IEEE* 届会议，第 – 页。[37] A. Knapitsch、J. Park、Q.-Y. Zhou 和 V. Koltun，“Tanks and Temples：大规模场景重建基准测试”，*ACM*图形学汇刊（*ToG*），第36卷，第4期，第1–13页，2017年。