arXiv:2303.00616v1 [cs.RO] 1 Mar 2023

使用集成学习回归模型和一维全局池化进行数据表征的SLAM绝对轨迹误差预测

Islam Ali[1], Bingqing (Selina) Wan[2],和 Hong Zhang[3]

摘要——**同步定位与建图（SLAM）的鲁棒性和韧性是现代自主机器人系统的关键要求。实现鲁棒性和韧性的必要步骤之一，是使SLAM能够为其定位估计提供完整性度量，从而具备应对性能退化的内部容错机制。在本研究中，我们提出了一种基于原始传感器输入表征来预测SLAM定位误差的新方法。该方法采用在由表征后的原始传感器数据生成的一维全局池化特征上训练的随机森林回归模型。我们通过使用该模型预测ORB-SLAM3在三个不同数据集、四种不同运行模式下的性能，对其进行了验证，平均预测准确率最高达到94.7%。本文还研究了12种不同一维全局池化函数对回归质量的影响，并通过定量分析证明了一维全局平均池化的优越性。最后，本文研究了训练数据有限时的预测质量，并证明仅使用20 %的训练样本进行训练时，仍能保持良好的预测质量，这凸显了所提模型能够优化SLAM系统评估开销的能力。**

一、引言

同步定位与建图（SLAM）是现代机器人系统的一项基础构件，使其能够在构建所行进环境地图的同时估计自身位置 [1]。过去几十年来，SLAM研究在架构、准确性、需求和挑战等方面都取得了显著发展 [2]。SLAM面临的主要挑战之一，是系统在真实世界中部署时的鲁棒性与韧性 [3]。SLAM的鲁棒性是指系统在预定义条件下运行时能够提供可接受性能的能力。韧性则是指系统在预定义条件之外运行时，仍能收敛至可接受性能的能力；这也凸显了在SLAM中设置内部误差预测和容错机制的重要性，以确保有效实现这种收敛 [4]。因此，研究人员将注意力转向为SLAM处理流程中的某些模块 [5],或最终SLAM结果 [6]引入完整性指标。

绝对轨迹误差（*ATE*） [7] 被视为衡量SLAM系统定位准确性的事实标准，大多数最先进的解决方案（如 ORB-SLAM3 [8], 和 VINS-Mono [9],）都采用这一指标。因此，在线预测 SLAM绝对轨迹误差是实现鲁棒且具韧性的同步定位与建图的重要组成部分，因为它能为 SLAM系统提供用于评估自身估计结果完整性的内部指标，以便纠正估计误差、指导定位方案之间的切换，并提升部署时的机器人安全性。

本文提出一种新颖的方法，利用输入数据特征的一维全局池化以及基于集成学习的回归模型，预测同步定位与建图算法的绝对轨迹误差（绝对轨迹误差）。该方法的动机源于我们先前的工作 [4]中观察到并报告的高度相关性：一方面是多种算法的同步定位与建图性能，另一方面是不同同步定位与建图数据集上测得的表征指标。在本研究中，我们做出了多项设计决策，例如选择一维全局池化函数，以及生成足够多的回归训练样本。为确保这些选择恰当，我们对不同选项对最终准确性的影响进行了定量分析，并在本文中予以介绍。

本文其余部分安排如下。第二节简要回顾相关工作。第三节概述背景知识。第四节详细介绍我们提出的方法。第五节展示并讨论实验结果。最后，第六节总结本研究的结论。

II. 相关工作

预测和估计系统性能对于安全地使用机器人和自主系统至关重要，并且已在密切相关的学科中得到广泛研究。例如，INS/GPS 等导航系统使用统计模型来估计传感器测量值中的误差，并通过卡尔曼滤波器改进定位 [10] [11]。此外，已有研究提出了用于机器人定位的完整性度量，以最大限度地降低真实世界场景中的部署风险 [12]-[13]。尽管定位结果的完整性对于实现稳健且具韧性的感知与导航至关重要，但正如 [14] 所述，由于设计要求尚不明确，关于同步定位与建图定位结果完整性的研究仍然有限。

现有关于同步定位与建图完整性度量的文献主要聚焦于两个领域。第一个领域是预测整个同步定位与建图流程的总体性能。这种方法旨在评估整个同步定位与建图流程的完整性，并提供一个单一度量来

[1]Islam Ali 任职于加拿大埃德蒙顿 AB T6G 2R3 阿尔伯塔大学计算机科学系iaali@ualberta.ca[2]Bingqing (Selina) Wan 任职于多伦多 ON M5S 2E4 多伦多大学工程科学系 b.wan@mail.utoronto.ca[3]Hong Zhang 任职于加拿大埃德蒙顿 AB T6G 2R3 阿尔伯塔大学计算机科学系hzhang@ualberta.ca

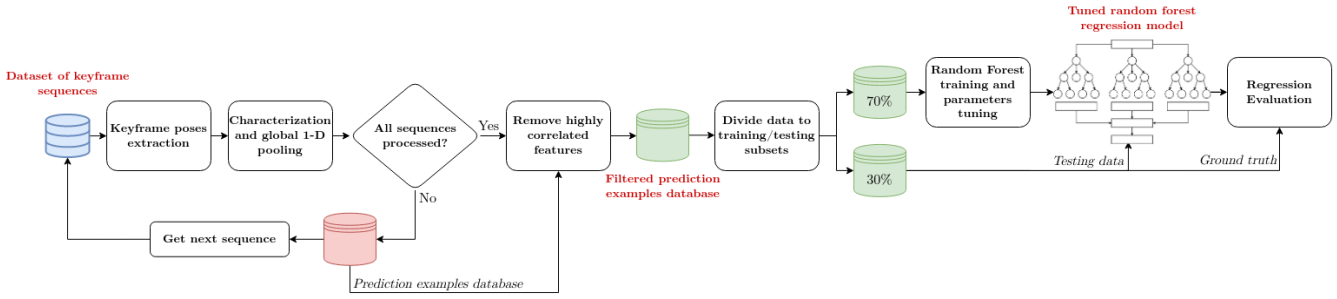

图 1：所提出的 ATE 预测方法框图

衡量同步定位与建图输出的完整性。例如，使用沃罗诺伊图对机器人的行进路径建模，以训练预测同步定位与建图性能的模型 [6]。训练数据采用 [15] 中概述的方法获取，该方法通过在选定环境中多次模拟同步定位与建图算法来生成训练样本。在 [16] 中也采用了相同的训练样本生成方法，训练多个单变量和多变量线性回归模型，以预测归一化相对平移误差和绝对轨迹误差。这两种方法有助于确定同步定位与建图的总体性能，但无法实现定位完整性的在线预测。这是因为它们依赖于机器人将要 traversed 的整段路径的总体描述，而不是增量式原始传感器数据（例如图像）。另一方面，其他方法旨在确定同步定位与建图中定位不确定性的上界，并在已知特征的空间分布时保证系统性能 [17]。

第二个研究方向是考察 SLAM 处理流程中特定组件的完整性。该方法旨在评估各个 SLAM 组件的完整性，并探讨如何利用对完整性度量的量化结果，恰当地纠正定位估计中可能出现的异常。例如，在 [5] 中，提出了一种基于学习的视觉回环检测完整性度量方法，以减少假阳性，并最终通过减少回环检测中的假阳性来提升同步定位与建图定位精度的整体表现。

我们的方法在设计和目标上都独具特色。我们将一系列关键帧测量值（例如图像和/或惯性测量值）作为输入，并对其进行表征，以生成与所遍历序列对应的表征矩阵。随后，我们对表征矩阵的各行应用一维全局池化函数，从而得到该序列的一维向量描述符。之后，将该描述符输入预测模型，以预测输入序列结束时的预期绝对轨迹误差。因此，该方法能够在线监测系统性能，并随时提供定位估计的完整性度量。这对于确保同步定位与建图系统的鲁棒性和韧性至关重要，尤其是在具有挑战性的环境或不确定条件下。

III. 背景

为本研究奠定基础，本节将探讨两个概念：一维全局池化和随机森林回归。我们将讨论这些技术的应用方式，并考察它们对所提出工作的适用性。

A. 一维全局池化

该技术在 [18] 中被提出，用于解决神经网络中过拟合的问题。其方法是使用全局池化函数（例如平均值、最小值、最大值等）对特征图的所有特征进行池化，将其空间维度缩减为单个值。从本质上说，这种缩减以抽象、描述性的特征取代了详细的特征图。研究证明，学习这些特征而非示例本身，有助于提升所学习模型的泛化能力 [19]。在本研究中，我们采用了这一技术，并考察 12 种不同全局池化函数对预测质量的影响。此外，我们还研究了将所有全局池化函数的结果串接成一个扩展特征向量的影响；该向量能为学习算法提供有关输入示例的更多抽象信息。

B. 随机森林回归

随机森林是一种集成学习技术，依托于装袋法 [20]：在自助采样阶段，使用输入特征的多个独立随机子样本训练多个决策树预测模型。自助采样是一种统计技术，通过从训练数据集中随机抽取子样本并允许有放回抽样 [21]，生成自助样本。对于随机森林中的每棵决策树，都会选取一个自助样本，并从可用的描述符特征中随机选取一个子集进行训练。随后，通过平均法（回归）或多数投票（分类）[22]，汇总所有决策树的结果。由于决策树之间相互独立且相关性较低，预测误差不会累积或传播，因此预测误差更低。随机森林提供了一种平衡准确性与泛化能力的方法，并已证明优于其他竞争方法。例如，研究证明，在表格结构化数据上，随机森林的表现优于神经网络[23]；与提升算法 [24]相比，它也能更好地处理过拟合问题。

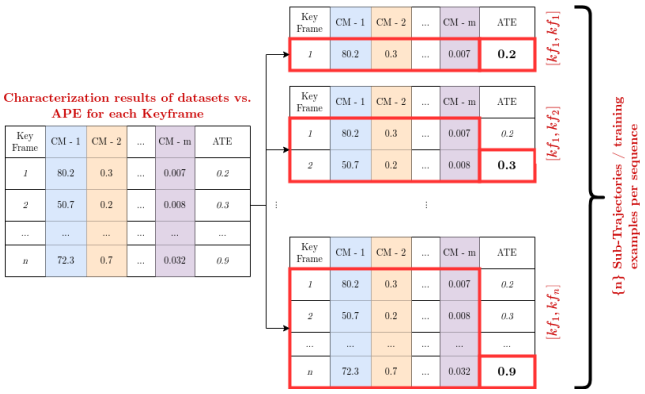

图2：基于子轨迹数据及其对应的绝对轨迹误差提取训练样本

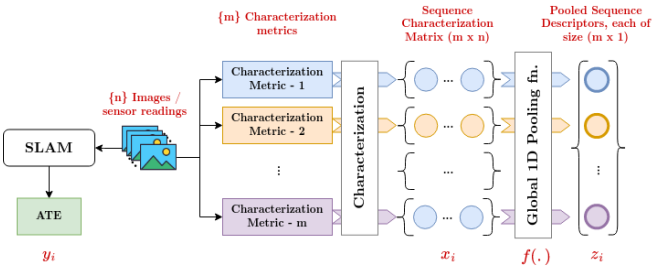

图3：使用输入子序列表征和一维全局池化生成特征向量

IV. 方法

本节介绍所提出的用于预测同步定位与建图中绝对轨迹误差的方法，并概述本研究所采用的设计选择。图1展示了所提出的流程管线，并说明系统的不同组件如何相互作用。该图以可视化方式呈现了所提方法中的数据流和处理过程。

给定一个包含 $\mathcal{D}$ 个 N 序列的数据集，定义如下：

$$\mathcal{D} = \{(\mathbf{x_i}, y_i), i = 1, ..., N\} \tag{1}$$

其中，$\mathbf{x_i}$ 是一个大小为$(m \times n)$的表征矩阵，对输入序列中的 n 个测量值（例如图像/惯性测量值）应用 m 个表征指标后得到；y_i 是一个标量，对应于该轨迹的绝对轨迹误差。

通过应用一维全局池化函数 $f(.)$，每个表征矩阵$\mathbf{x_i}$都会转换为一个大小为$(m \times 1)$的一维向量$\mathbf{z_i}$，如下所示：

$$\mathbf{z_i} = f(\mathbf{x_i}) \tag{2}$$

因此，变换后的数据集 $\mathcal{D}'$ 定义如下：

$$\mathcal{D}' = \{(\mathbf{z_i}, y_i), i = 1, ..., N\} \tag{3}$$

我们旨在学习一个模型，以便在给定变换后的数据集 $\mathcal{D}'$中一个未见过的一维向量$\mathbf{z_i}$ 的情况下，预测SLAM绝对轨迹误差$\hat{}y_i$ 。

A. 数据样本生成

为了生成绝对轨迹误差预测模型的训练样本，我们在多个数据集中所有可用的序列上运行同步定位与建图算法。对于每个运行序列，我们计算多个子序列，这些子序列对应于同步定位与建图算法选取的关键帧。因此，我们利用子轨迹 [7] 的概念来增加训练样本的数量。

给定一个大小为 $\mathcal{K}$ 个关键帧的输入序列，我们可以提取 $\mathcal{K}$ 个样本，其中每个样本都是由处于包含范围 $[(kf)_1, (kf)_k]$ 内的关键帧 (kf) 构成的子序列，其中 $k = \{1, 2...\mathcal{K}\}$。计算每条子轨迹对应的绝对轨迹误差，并将其与每条轨迹关联起来，以构建一个训练样本。图 2 详细展示了该过程，并展示了训练样本的提取及绝对轨迹误差关联的具体过程。用于模型训练和测试的子轨迹，是从以特定运行模式运行的数据集中的可用数据序列依次生成的。可用数据的训练集和测试集划分不进行随机化，这意味着训练和测试使用的是从同一数据集的不同序列中生成的子序列。

B. 序列表征与一维全局池化

我们将生成的每个子序列视为由图像/传感器读数组成的独立序列。我们应用 [4] 中介绍的表征框架，其中包含一系列表征指标（例如测量亮度、对比度等），为序列中的每幅图像/每个传感器读数生成一个表征向量。如图3所示，表征过程会生成一个大小为$(m \times n)$的二维矩阵，其中每一行代表一个表征指标的结果，每一列代表一个输入子序列。由于序列大小各异，生成的二维矩阵维度并不相同。因此，为了降低维度并提供统一的特征向量用于训练，我们对二维矩阵应用一维全局池化函数，生成大小统一为$(m \times 1)$的一维向量。具体而言，使用池化函数将表征矩阵中的每一行缩减为单个标量值。在本研究中，我们采用12种不同池化函数中的一种，包括统计池化函数（例如均值、最小值、最大值等）和多样性池化函数（例如熵、辛普森多样性指数及其变体）。为了向预测模型提供更具描述性的特征，我们还将所有一维全局池化特征拼接成一个特征向量，研究其对预测质量的影响，并将其性能与使用单个一维全局池化函数的情况进行比较。

C. 移除高度相关特征

独立输入特征之间存在共线性是回归中的一个潜在问题，可能导致数值不稳定的结果 [25]。为检测高度相关的特征，我们计算每个特征与所有其他可用特征之间的皮尔逊相关系数（PMCC） [26]。随后，将高度相关的特征进行分组，其中组内任意两个特征之间的皮尔逊相关系数均

表 I：随机森林中的调优超参数及其对应范围

超参数	范围
树估计器数量	[10, 1000]
分裂所需的最小样本数	{2,5,10}
叶节点所需的最小样本数	{1,2,4}
用于分裂的最大特征数	{无、平方根、对数2}
树可生长到的最大深度	[10,100]
用于构建树的自助采样	{是、否}

高于95%的阈值。然后，从每个组中仅选择一个特征，用于回归模型的训练，以确保训练所得回归模型的预测稳定性。

D. 随机森林回归模型

针对每个测试用例，使用 70 % 的可用数据样本训练并调优随机森林回归模型。随后，使用其余未见过的 30 % 数据对模型进行测试，以确定其性能。我们采用 scikit-learn 库提供的随机森林回归实现 [27]，因为它效率高且易于使用。它还提供了多个可调超参数，以优化模型性能。

调优随机森林的超参数对于实现最佳预测性能至关重要。为此，我们在表 I 所列的超参数多维空间中进行随机网格搜索，并采用交叉验证。事实证明，这种方法能够高效地选出最佳超参数，同时保持合理的复杂度和执行时间 [28]。

E. 性能评估

为定量评估我们方法的回归质量，我们采用了四种不同的指标，其定义如下。

1) 决定系数（R^2）

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(\hat{y_i} - y_i)^2}{\sum_{i=0}^{n}(y_i - \bar{y_i})^2} \tag{4}$$

2) 平均绝对百分比误差（$MAPE$）

$$MAPE = \frac{100\%}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y_i}}{y_i}\right| \tag{5}$$

3) 平均绝对误差（MAE）

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y_i}| \tag{6}$$

4) 均方根误差（$RMSE$）

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(y_i - \hat{y_i})^2}{n}} \tag{7}$$

其中，y 为ATE真实值，$\hat{}y$ 为预测ATE，n 为测试样本数。

这些指标在允许范围和所反映的性能质量方面各不相同。综合来看，它们能够清晰地反映性能，并抑制任何单一指标可能出现的极端情况或异常。

表 II：各数据集在不同运行模式下可用的子轨迹数量。

		可用子轨迹数			
数据集	# 序列	M	S	M-I	S-I
KITTI	22	11799	23201	-	-
EuRoC-MAV	11	3348	1956	3043	1484
TUM-VI	28	2049	1161	4230	1924

* M、S、M-I 和 S-I 分别指单目、双目、单目惯性和双目惯性。

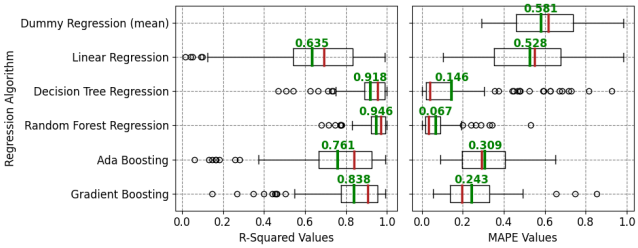

图 4：不同回归模型的绝对轨迹误差预测定量对比

V. 实验结果与讨论

本节介绍并讨论我们的实验设置及相关实验结果。如第 IV 节所述，我们在三个不同的数据集上以四种不同的运行模式运行 ORB-SLAM3 [8]，共得到 10 个测试用例，如表 II 所示。对于每个测试用例，我们分别考察 12 种不同的一维池化函数，对随机森林进行训练和调优，并评估模型性能。此外，我们还研究了减少训练数据量对 ATE 预测质量的影响，以展示在可用于训练的数据有限时，我们提出的预测模型仍能保持相对良好的性能。

实验结果表明，所提出的方法能够以最高达 94.7% 的准确性预测 SLAM绝对轨迹误差，这直接证明了该方法的有效性、将表征指标用作数据描述符的合理性，以及为 SLAM绝对轨迹误差预测任务选择一维全局池化函数的恰当性。

A. 训练数据生成

为了生成用于训练绝对轨迹误差预测模型的样本，我们在三个不同数据集（KITTI [29]、EuRoC-MAV[30]，和 TUM-VI [31]）中的所有可用序列上运行了 ORB-SLAM3 [8]。我们应用所提出的数据样本生成流程，大幅增加了可用于训练、测试和验证的样本数量。该方法应用于 ORB-SLAM3 [8] 的四种不同模式，即单目、单目惯性、双目和双目惯性，共产生 10 种不同的测试用例。表 II 列出了为每种测试用例生成的训练样本数量。

B. 回归算法的选择

为了验证我们对回归算法的选择，我们考察了多种著名的回归模型

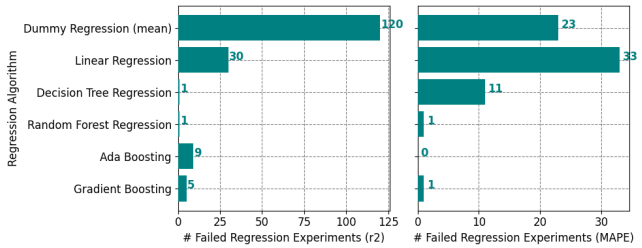

图 5：不同回归模型的失效率统计

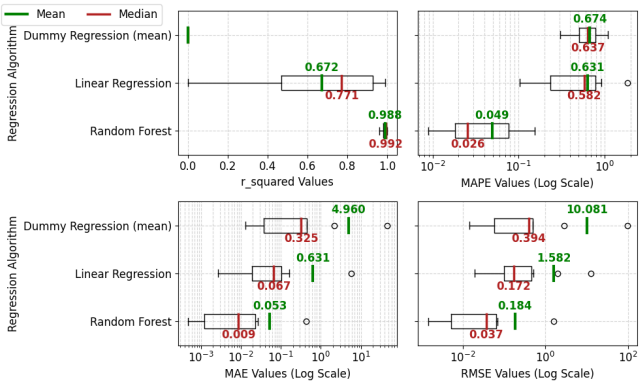

图 6：随机森林回归模型与选定基线模型的性能比较

并使用 [27] 中提供的默认超参数值。这些算法包括：取输入特征平均值的虚拟回归、线性回归、决策树、随机森林、Ada提升和梯度提升。评估采用 R^2 和 $MAPE$ 指标，以便比较不同测试用例，因为无论预测变量的值和取值范围如何，这些指标都能提供绝对的性能度量。如图 4 所示，随机森林优于其他回归算法，其 R^2 值最高，$MAPE$ 值也最低。此外，将 Ada提升和梯度提升的表现与随机森林进行比较时，我们可以清楚地观察到提升算法的过拟合问题 [24] 。另一项实验旨在确定算法能否对给定的测试用例执行回归。为此，我们将 R^2 和 $MAPE$ 的超范围概念用作回归失败的判据，如下所示：$R^4 \in [0,1]$ 和 $MAPE \in [0,1]$。如图 5 所示，与其他算法相比，随机森林在两项指标下的回归失败次数最少。事实上，我们发现，随机森林出现失败的情况是在 TUM-VI 上以双目模式测试 ORB-SLAM3 时发生的，这是由于训练样本不足。不过，经过进一步调优，我们也能够对这些测试用例执行回归。

C. 与基线的性能比较

机器学习中的标准做法是将回归结果与基线模型进行比较，以证明学习过程的完整性 [32]。因此，我们将

表 III：对于所有测试用例，比较使用轨迹 20 % 处的绝对轨迹误差作为预测器来预测整个轨迹的绝对轨迹误差，与使用 20 % 的可用数据训练的本文所提随机森林方法

	基线		随机森林	
模式 - 数据集	R^2	$MAPE$	R^2	$MAPE$
M-EuroC	0.1557	0.3683	0.9973	0.0106
M-KITTI	0.7621	0.3710	0.9992	0.0079
M-TUMVI	0.9036	0.2503	0.9663	0.1246
MI-EuroC	-0.0637	0.2909	0.9888	0.0199
MI-TUMVI	0.8571	0.2539	0.9835	0.1221
S-EuroC	0.9899	0.2699	0.9993	0.0125
S-KITTI	0.9559	0.1627	0.9999	0.0013
S-TUMVI	0.6202	0.1904	0.8458	0.0359
SI-EuroC	0.6864	0.1954	0.9900	0.0189
SI-TUMVI	0.9381	0.1681	0.9723	0.1979
Mean	**0.6805**	**0.2521**	**0.9743**	**0.0552**

随机森林模型的结果与两个不同的基线进行比较。第一个是简单的虚拟回归模型，该模型使用输入特征的均值作为回归输出。第二个是采用默认超参数设置的线性回归模型。

如图6所示，在所有考察的性能指标方面，随机森林模型均优于两个基线模型，这直接表明了在当前任务中使用我们模型的价值。

D. 训练数据有限对绝对轨迹误差预测的影响

不出所料，减少可用于训练的数据会降低绝对轨迹误差预测的质量。然而，数据量有限时，预计质量会降低多少？此外，我们旨在证明，通过使用数据集的一小部分进行训练，并预测数据集其余部分的结果，所提出的方法可以减少同步定位与建图的评估工作量。

在本实验中，鉴于一维全局平均池化相较于其他池化函数表现更优，我们将池化函数固定为一维全局平均池化。我们将每个测试用例的训练数据比例从 10% 调整到 90%，并测量四项回归质量指标。

如图8所示，随着训练数据的增加，预测质量通常会提高。观察 R^2和 $MAPE$指标可知，仅使用每个测试用例中 20% 的数据进行训练，我们也能准确预测绝对轨迹误差。在这种情况下，R^2 的降幅平均仅为 6.51%。另一方面，$MAPE$也仅下降了 4.7%。此外，我们还可以看到，使用少于 20% 的数据进行训练会导致结果不可靠，这一点可由 R^2 指标超出范围的数值体现出来。这项实验直接表明，我们能够减少

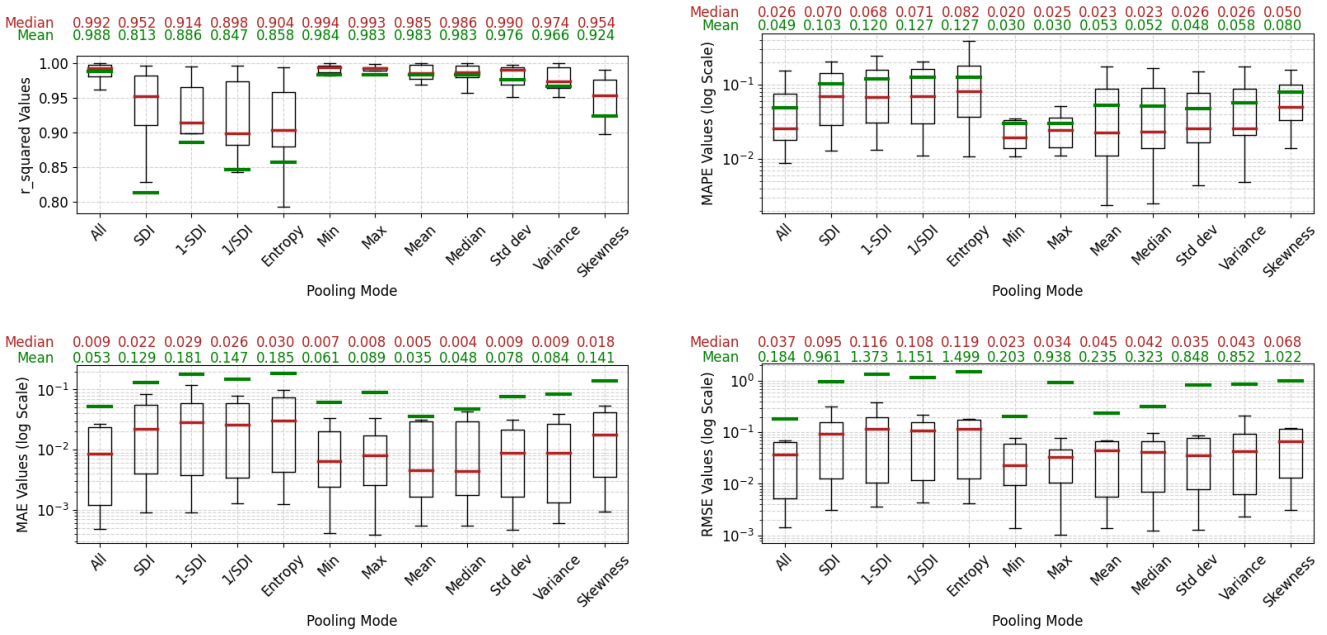

图 7：在使用 70% 的数据进行训练后，不同一维全局池化函数的回归质量比较

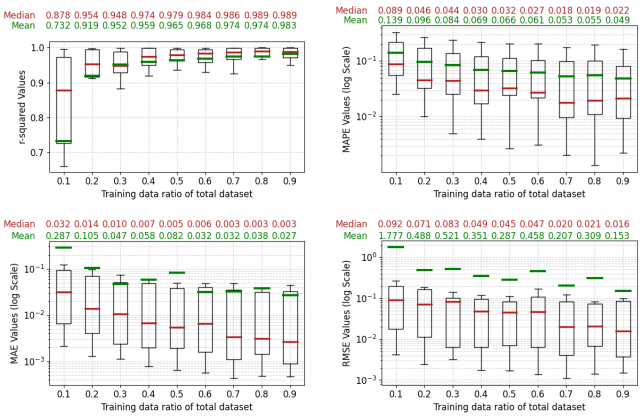

图 8：使用一维全局平均池化时，减少训练数据量对 ATE 预测质量的影响

同步定位与建图的评估工作量 80%，同时仍能对绝对轨迹误差预测质量保持较高的信心。

鉴于 ATE 误差的性质及其随时间的演变方式，我们希望将仅使用 20% 数据进行训练的模型，与遍历给定数据样本 20% 后观测到的 ATE 进行比较。该实验突显了训练预测模型以预测 ATE 的必要性，因为在轨迹过程中观测到的 ATE 与轨迹末端的 ATE 并不相关。为此，我们计算了轨迹 20% 处的 ATE 与轨迹末端 ATE 之间的 R^2 和 $MAPE$。随后，我们将所得结果与预测模型的结果进行比较。如表 III 所示，可以观察到，预测模型优于基线（20% 处的 ATE），并且能够以更高的置信水平提供更准确的结果。

E. 一维全局池化函数的评估

我们所提出解决方案的另一个主要组成部分是对训练序列进行一维全局池化。如第 IV 节所述，我们考察了 12 种不同的池化函数，其中 11 种属于统计指标或多样性指标，最后一种是将所有这些函数的结果进行拼接。

为了比较这些函数对回归质量的影响，我们使用每种池化函数重复所有测试用例，并对性能进行评估和比较。图 7 展示了各项指标的比较结果，并突出了每种池化函数在所有测试用例上的均值和中位数性能。在该图中，箱线图中的每个箱体由 10 个数据点构成，每个数据点对应表 II 中列出的一个测试用例。对于每个测试用例，使用 70% 的数据进行训练，并使用剩余的 30% 进行测试。

可以观察到，池化函数的拼接版本与最小值和均值一维全局池化函数的性能相近。然而，综合考虑所有评估指标，均值/平均值一维全局函数表现得更加均衡且稳定。

因此，图9展示了我们所考察的10个测试用例中，使用一维全局平均池化和随机森林得到的预测ATE与实际ATE之间的比较。此外，图10展示了这10个测试用例中每个测试样本绝对误差百分比的核密度估计（KDE）。可以看出，我们能够预测ATE，其平均误差为实际ATE的6%至7%；在所考察的10个测试用例中，有7个用例的最佳表现是平均误差低于实际ATE值的5%。

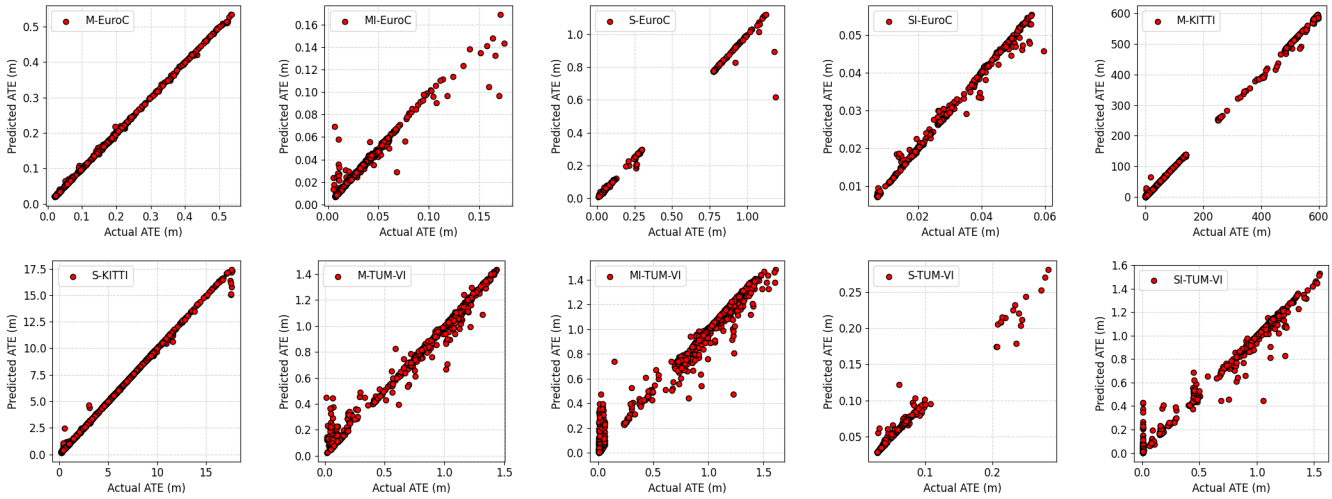

图 9：在使用 70% 的数据进行训练后，采用一维全局平均池化和随机森林对所有评估测试用例得到的实际绝对轨迹误差与预测绝对轨迹误差

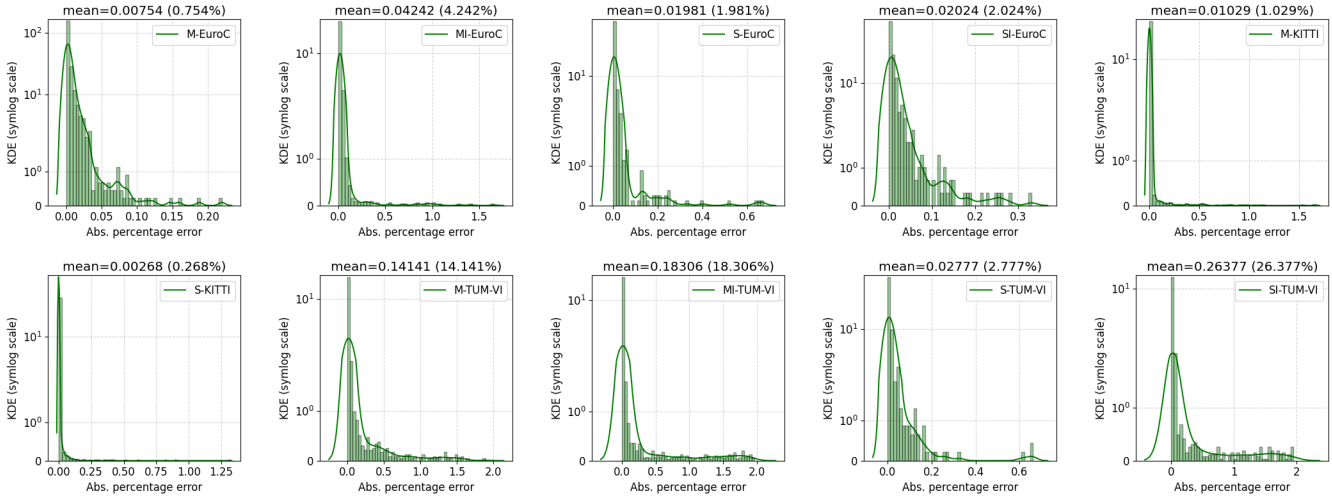

图 10：在使用 70% 的数据进行训练后，采用一维全局平均池化和随机森林对所有测试用例得到的绝对误差百分比

VI. 结论

本文将SLAM性能预测问题视为实现SLAM鲁棒性和韧性的一项基本要求。研究首先简要回顾了与该主题相关的文献，并为所提出的算法奠定基础。随后，我们介绍了利用集成学习技术和输入数据表征结果的一维全局池化来预测SLAM绝对轨迹误差的方法。我们首先将该方法与多种回归模型进行比较，以验证选择随机森林作为回归模型的合理性。随后，我们使用12种不同的一维全局池化函数，在10种不同的测试用例上对该方法进行测试，共进行了120项不同的实验。实验结果表明，与我们选定的基线相比，使用随机森林具有优越性，并证明了预测在所考察的测试用例中，使用经表征并池化的特征进行 ORB-SLAM3 绝对轨迹误差预测，平均准确率最高可达 94.7%。本文还评估了选择特定池化函数对绝对轨迹误差回归质量的影响。结果表明，串联多个池化函数带来的收益非常有限。研究还证明，采用一维全局平均池化能够在所有已测量的性能指标之间取得良好平衡。此外，本文研究了减少训练数据量对绝对轨迹误差预测质量的影响，结果显示，仅使用 20% 的可用数据进行训练，平均绝对百分比误差仍可达到 90.4%，与使用 90% 的可用数据训练相比，性能仅下降 4.7%。最后，研究指出，所用的表征结果适合作为数据序列描述符。

参考文献

[1] J. Aulinas、Y. Petillot、J. Salvi 和 X. Llad´o，“同步定位与建图问题：综述”，人工智能研究与开发，第 363–371 页，2008年。[2] C. Cadena、L. Carlone、H. Carrillo、Y. Latif、D. Scaramuzza、J. Neira、I. Reid 和 J. J. Leonard，“同步定位与建图的过去、现在与未来：迈向鲁棒感知时代”，*IEEE*机器人学汇刊，第 32 卷，第 6 期，第 1309–1332 页，2016年。[3] A. Prorok、M. Malencia、L. Carlone、G. S. Sukhatme、B. M. Sadler 和 V. Kumar，“超越鲁棒性：韧性多机器人系统方法分类”，*arXiv* 预印本 *arXiv:2109.12343*，2021年。[4] I. Ali 和 H. Zhang，“我们是否已准备好实现鲁棒且具韧性的同步定位与建图？同步定位与建图数据集定量表征框架”，载于*2022*年*IEEE/RSJ*智能机器人与系统国际会议（*IROS*），2022年，第 2810–2816 页。[5] H. Carson、J. J. Ford 和 M. Milford，“预测以改进：用于评估视觉定位性能的完整性度量”，*IEEE*机器人与自动化快报，第 7 卷，第 4 期，第 9627–9634 页，2022年。[6] M. Luperto、V. Castelli 和 F. Amigoni，“预测同步定位与建图算法的性能”，*arXiv* 预印本 *arXiv:2109.02329*，2021年。[7] Z. Zhang 和 D. Scaramuzza，“视觉（惯性）里程计定量轨迹评估教程”，载于*2018*年*IEEE/RSJ*智能机器人与系统国际会议（*IROS*）。IEEE，2018年，第 7244–7251 页。[8] C. Campos、R. Elvira、J. J. G. Rodr´ıguez、J. M. Montiel 和 J. D. Tard´os，“ORB-SLAM3：一种用于视觉、视觉惯性和多地图同步定位与建图的高精度开源库”，*IEEE*机器人学汇刊，第 37 卷，第 6 期，第 1874–1890 页，2021年。[9] T. Qin、P. Li 和 S. Shen，“VINS-Mono：一种鲁棒且通用的单目视觉惯性状态估计器”，*IEEE*机器人学汇刊，第 34 卷，第 4 期，第 1004–1020 页，2018年。[10] S. Sukkarieh、E. M. Nebot 和 H. F. Durrant-Whyte，“为自主地面车辆应用实现惯性导航系统/全球定位系统导航回路的完整性保障”，载于论文集：*1998*年*IEEE*机器人与自动化国际会议（目录号 *98CH36146*），第 4 卷。IEEE，1998年，第 3437–3442 页。[11] A. Noureldin、T. B. Karamat、M. D. Eberts 和 A. El-Shafie，“提升基于MEMS的惯性导航系统/全球定位系统集成在低成本导航应用中的性能”，*IEEE*车辆技术汇刊，第 58 卷，第 3 期，第 1077–1096 页，2008年。[12] G. D. Arana、O. A. Hafez、M. Joerger 和 M. Spenko，“移动机器人定位安全的递归完整性监测”，载于*2019*年机器人与自动化国际会议（*ICRA*）。IEEE，2019年，第 305–311 页。[13] O. A. Hafez、G. D. Arana、M. Joerger 和 M. Spenko，“量化机器人定位安全：一种用于固定滞后平滑的完整性监测新方法”，*IEEE*机器人与自动化快报，第 5 卷，第 2 期，第 3182–3189 页，2020年。[14] Y. D. Yasuda、L. E. G. Martins 和 F. A. Cappabianco，“移动机器人的自主视觉导航：系统性文献综述”，*ACM*计算综述（*CSUR*），第 53 卷，第 1 期，第 1–34 页，2020年。[15] F. Amigoni、V. Castelli 和 M. Luperto，“通过自动评估同步定位与建图算法提高实验的可重复性”，载于*2018*年*IEEE/RSJ*智能机器人与系统国际会议（IROS）。IEEE，2018年，第7237–7243页。[16] E. Piazza、P. U. Lima和M. Matteucci，《机器人学中的性能模型：以SLAM为例》，*IEEE*机器人与自动化快报，第7卷，第2期，第4646–4653页，2022年。[17] A. I. Mourikis和S. I. Roumeliotis，《预测协同同步定位与地图构建（c-slam）的性能》，《国际机器人研究杂志》，第25卷，第12期，第1273–1286页，2006年。[18] M. Lin、Q. Chen和S. Yan，《网络中的网络》，*arXiv* 预印本 *arXiv:1312.4400*，2013年。[19] I. Goodfellow、Y. Bengio和A. Courville，《深度学习（自适应计算与机器学习丛书）》，2016年。[20] C. D. Sutton，《分类与回归树、装袋法和提升法》，《统计学手册》，第24卷，第303–329页，2005年。[21] B. Efron，《自助法：重新审视刀切法》。施普林格，1992年。[22] L. Breiman，《随机森林》，机器学习，第45卷，第1期，第5–32页，2001年。[23] L. Grinsztajn、E. Oyallon和G. Varoquaux，《为什么基于树的模型在典型表格数据上仍优于深度学习？》，载于第三十六届神经信息处理系统大会数据集与基准赛道，2022年。[24] D. Opitz和R. Maclin，《流行集成方法：一项实证研究》，《人工智能研究杂志》，第11卷，198，1999年，第169页。[25] J. I. Daoud，《多重共线性与回归分析》，载于《物理学杂志：会议系列》，第949卷，第1期。IOP出版社，2017年，第012009页。[26] J. Benesty、J. Chen、Y. Huang和I. Cohen，《皮尔逊相关系数》，载于《语音处理中的噪声抑制》。施普林格，2009年，第1–4页。[27] F. Pedregosa、G. Varoquaux、A. Gramfort、V. Michel、B. Thirion、O. Grisel、M. Blondel、P. Prettenhofer、R. Weiss、V. Dubourg、等，《Scikit-learn：Python机器学习》，《机器学习研究杂志》，第12卷，第2825–2830页，2011年。[28] P. Probst、M. N. Wright和A.-L. Boulesteix，《随机森林的超参数与调参策略》，《*Wiley*跨学科评论：数据挖掘与知识发现》，第9卷，第3期，第e1301页，2019年。[29] A. Geiger、P. Lenz和R. Urtasun，《我们准备好迎接自动驾驶了吗？KITTI视觉基准套件》，载于*2012*年*IEEE*计算机视觉与模式识别会议。IEEE，2012年，第3354–3361页。[30] M. Burri、J. Nikolic、P. Gohl、T. Schneider、J. Rehder、S. Omari、M. W. Achtelik和R. Siegwart，《EuRoC微型飞行器数据集》，《国际机器人研究杂志》，第35卷，第10期，第1157–1163页，2016年。[31] D. Schubert、T. Goll、N. Demmel、V. Usenko、J. St¨uckler和D. Cre- mers，《用于评估视觉惯性里程计的TUM VI基准》，载于*2018*年*IEEE/RSJ*智能机器人与系统国际会议（IROS）。IEEE，2018年，第1680–1687页。[32] R. Bhagwat、M. Abdolahnejad和M. Moocarme，《使用*Keras*进行深度学习应用：以*Keras*的简洁性解决复杂的现实问题》。Packt出版社有限公司，2019年。