



武汉大学学报(信息科学版)

Geomatics and Information Science of Wuhan University

ISSN 1671-8860, CN 42-1676/TN

《武汉大学学报(信息科学版)》网络首发论文

题目：一种基于车载图像的异常轨迹检测与预校正方法
作者：李伯钊，廖成，翁宝凤，蔡忠亮，韦瀚植
DOI：10.13203/j.whugis2024011610.13203/j.whugis20240116
收稿日期：2024-11-15
网络首发日期：2024-11-26
引用格式：李伯钊，廖成，翁宝凤，蔡忠亮，韦瀚植. 一种基于车载图像的异常轨迹检测与预校正方法[J/OL]. 武汉大学学报(信息科学版).
<https://doi.org/10.13203/j.whugis2024011610.13203/j.whugis20240116>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

DOI:10.13203/j.whugis20240116

引用格式:

李伯钊, 廖成, 翁宝凤, 等. 一种基于车载图像的异常轨迹检测与预校正方法[J]. 武汉大学学报(信息科学版), 2024, DOI:10.13203/J.whugis20240116 (LI Bozhao, LIAO Cheng, WENG Baofeng, et al. A Method for Abnormal Trajectory Detection and Pre-Correction Based on Vehicle-Borne Images[J]. Geomatics and Information Science of Wuhan University, 2024, DOI:10.13203/J.whugis20240116)

一种基于车载图像的异常轨迹检测与预校正方法

李伯钊¹, 廖成¹, 翁宝凤², 蔡忠亮^{1*}, 韦瀚植¹

1 武汉大学资源与环境科学学院, 湖北 武汉, 430079

2 浙江省测绘科学技术研究院, 浙江 杭州, 311100

摘要: 众包是实现高精地图实时更新的必要途径, 也是高精地图未来的应用形态。低成本众包设备使得众包轨迹数据普遍存在位置偏移和属性记录异常等情况, 进而影响高精地图众包更新的精度。地图匹配算法可以根据轨迹与道路之间的时空特征将存在位置偏移的轨迹点垂直匹配到车辆行驶的道路上, 但是平行于道路方向的较大位置偏移与异常的行驶角度仍会影响轨迹位置校正的精度。鉴于高精地图众包数据中的车载图像能够反映车辆的行驶环境与姿态变化, 本研究借助计算机视觉技术和隐马尔可夫模型构建了异常轨迹数据的检测与预校正方法, 以实现轨迹数据的异常角度校正和整体位置纠偏。本研究以武汉市为研究区域, 以30条带有车载图像的轨迹数据为研究对象, 通过综合实验验证了所提出的方法在提升众包轨迹数据质量方面的有效性, 并通过将预校正方法与地图匹配算法结合进一步证明了数据质量提升能够有效提升轨迹位置校正的精度, 为推动高精地图众包更新的应用落地提供了一定的技术支撑与方法参考。

关键词: 车载图像; 轨迹纠偏; 角度校正; 高精地图; 众包数据

A Method for Abnormal Trajectory Detection and Pre-Correction Based on Vehicle-Borne Images

LI Bozhao¹, LIAO Cheng¹, WENG Baofeng², CAI Zhongliang^{1*}, WEI Hanzhi¹

1 School of Resource and Environmental Sciences, Wuhan University, Wuhan 430079 China

2 Zhejiang Academy of Surveying and Mapping, Hangzhou 311100, China

收稿日期: 2024-11-15

项目资助: 国家自然科学基金(42301532); 中国博士后科学基金(2022M722442); 自然资源部数字制图与国土信息应用重点实验室开放研究基金资助项目(ZRZYBWD202409)

第一作者: 李伯钊, 博士, 副研究员, 主要从事高精地图众包更新等方面的研究。libozhao@whu.edu.cn

通讯作者: 蔡忠亮, 博士, 教授, 博士生导师。zcai@whu.edu.cn

Abstract: Objectives: Trajectory data obtained from low-cost crowdsourcing devices often suffer from overall positional offsets and abnormal attribute recordings, failing to meet the accuracy requirements for high-definition map updates. Given that onboard images in crowdsourcing data can capture changes in the driving environment and vehicle orientation, this paper aims to explore correction methods for overall trajectory position offsets and abnormal driving angles based on continuous onboard images. Our goal is to provide high-quality trajectory data that enhances the accuracy of subsequent position correction methods. **Methods:** This study first employs structure-from-motion technology to estimate the pose of the onboard camera, followed by the detection and correction of abnormal driving angles based on the estimated pose information. Next, the study identifies key trajectory points located at intersections and other critical locations using semantic information extracted from onboard images. The corrected angle values and hidden Markov model are then utilized to match these key trajectory points with nodes, enabling the detection and correction of overall trajectory position offsets. Finally, Wuhan city is selected as the research area, and 30 trajectory data accompanied by onboard images are used to validate the effectiveness of the proposed method. **Results:** Experimental results show that: (1) The difference between the estimated driving angle and the true driving angle of the vehicle is within 30° , meeting the accuracy requirements of map-matching algorithms. (2) The overall position correction accuracy of the trajectory is within 30 meters, with potential sub-meter accuracy at best. This performance is primarily influenced by the quality of the road network data, highlighting that the method relies on high-quality road network data to effectively address abnormal trajectory data with significant positional offsets. (3) High-quality trajectory data obtained after pre-correction can significantly enhance the accuracy of map-matching algorithms, resolving issues related to incorrect matches and relative positional deviations. **Conclusions:** The proposed innovative method effectively detects and corrects abnormal driving angles and overall trajectory offsets, significantly enhancing the quality of crowdsourced trajectory data. This improvement further aids in increasing the accuracy of trajectory position correction in map-matching algorithms. Additionally, it offers valuable technical support and methodological guidance for advancing the application of high-definition map crowdsourcing updates.

Key words: vehicle-borne images; trajectory position correction; abnormal angle correction; high-definition map; crowdsourcing data

高精地图是自动驾驶必不可少的基础设施之一^[1],是实现自动驾驶的必要条件,在辅助环境感知、精准定位与决策规划等任务中具有不可替代的关键作用^[2, 3]。众包是保障高精地图实现实时更新的必要途径,也是业内公认的高精地图生产和应用的未来形态^[4]。基础的众包数据通常由低成本 GPS 模块采集的车辆轨迹与车载相机采集的车载图像或车载视频构成。其中,轨迹数据能够确定车辆行驶的大致位置;而车载图像则可以在辅助车辆定位的基础上实现静态道路要素的提取与变化监测^[5]。将车载图像中提取的语义信息与位置信息相结合,即可确定识别的静态道路要素的大致位置,再通过与高精地图现有道路要素的匹配和融合,即可实现高精地图静态道路要素的缺失新增、冗余剔除和变化更新^[6]。

受车辆行驶环境以及 GPS 信号传输等多种因素的影响,轨迹数据普遍存在不同程度的位置抖动。为解决这一问题,地图匹配算法应运而生,作为一种轨迹数据的位置校正方法^[7],地图匹配算法能够根据轨迹与城市道路之间的距离、速度、角度差以及相邻轨迹点及其候选点之间的连通性等时空特征将存在位置偏移的轨迹点垂直匹配到最为可能的路段或节点上^[8]。

这一技术在在线地图导航和离线轨迹挖掘中扮演着关键角色^[9]，并以成为高精地图众包更新常用的基础算法之一。然而，不容忽视的是，质量参差不齐的低成本众包设备普遍存在信号不良或延滞以及设备未精确校准等问题^[10]，使得多路径效应、接收机内部噪声、通道延迟等误差无法消除^[11]，导致轨迹数据出现较为明显的整体位置偏移，并伴随着行驶方向等关键属性信息的异常突变。由于地图匹配算法无法校正平行于道路方向的位置偏移，且易受到轨迹点异常行驶角度的影响^[12]，从而可能将轨迹点匹配到错误的路段，甚至是与实际行驶方向相反的路段上，极大影响轨迹位置校正与高精地图众包更新的精度。

车载图像作为众包数据的重要组成部分，能够反映车辆的行驶环境与姿态变化^[13]，常用于车道线检测与提取^[14]、路标牌检测与识别^[15]、障碍物检测与识别^[16]、车辆检测与跟踪^[17]、测距定位与构图^[18]、动态目标检测与识别^[19]以及道路要素采集与更新^[20]等领域，部分研究证明了车载图像区分复杂道路场景的能力^[21]以及全景图像中的视觉道路特征用于轨迹定位的有效性^[22, 23]，但是利用单目车载图像实现轨迹数据的异常角度校正和整体位置纠偏尚存在研究空白。鉴于此，本研究提出一种基于车载图像的异常轨迹检测与预校正方法，主要创新在于：充分利用众包数据中的单目车载图像，构建异常轨迹检测与预校正方法，在异常行驶角度校正的基础之上实现轨迹整体位置纠偏，进而为后续的地图匹配算法提供高质量的轨迹数据，最终达到提升轨迹数据位置校正精度的目的。

1 异常轨迹检测与预校正方法

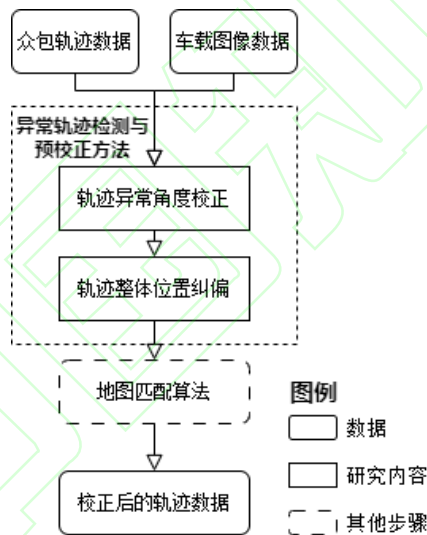


图 1 研究框架图

Figure 1. Research framework

本研究的整体框架如图 1 所示。异常轨迹校正与预校正方法包含轨迹异常角度校正和轨迹整体位置纠偏两个部分，预校正的主要目的是为地图匹配算法提供高质量的轨迹数据，以进一步提升地图匹配算法的轨迹位置校正精度。

1.1 轨迹异常角度校正方法

轨迹属性中的行驶方向是地图匹配算法筛选道路的关键特征之一。然而，受 GPS 模块与行车环境的影响，轨迹属性记录中常见行驶角度异常等情况，具体表现为两大显著问题：其一，GPS 信号暂时中断时，系统可能默认行驶方向角度为 0，导致方向信息缺失；其二，车辆快速切换车道或遭遇 GPS 信号延迟时，记录的行驶方向角度与实际道路数据之间出现显著夹角偏差。异常的车辆行驶角度会严重影响地图匹配算法的精度与效率，使得轨迹点被匹配到错误的路段甚至是行驶方向相反的路段上，相邻轨迹点之间的连通性无法保证，影响高精地图众包更新的精度。本研究将借助连续车载图像与单目视觉技术实现车载相机的位姿

估计，并借助每个轨迹点的视觉方向角，实现轨迹数据中异常行驶角度的检测与校正，进而为轨迹整体位置纠偏和地图匹配算法提供可靠的行驶方向角信息。

1.1.1 车载相机位姿估计

由于车载相机的摆放位置及姿态相对固定，因此由车载相机拍摄的连续车载图像能够反映了车辆的姿态变化。运动推断结构（Structure from Motion, SfM）是一种根据一组连续的二维图像进行三维场景重建的摄影测量成像技术，能够在 2D 图像三维重建的同时实现相机内、外参数的估计^[24]。

现阶段 SfM 算法根据实现方式的不同，分为增量式、全局式和混合式等不同类型^[25]。全局式 SfM 能够一次性处理全部图像并得出所有相机的姿态和场景点结构，并在所有图像位姿估计和三角化后执行一次光束平差法（Bundle Adjustment, BA），因此其效率较高、鲁棒性较差，更加适用于三维模型的建模^[26]；增量式 SfM 则以一对图像作为初始目标，在添加新图像的同时求解新图像的相机位姿，并且在执行三角化和 PnP（Perspective-n-Points）算法的同时执行局部 BA，因此其效率较低、鲁棒性较强^[27]；混合式 SfM 结合了全局式和增量式 SfM 算法的优势，在全局式 SfM 初步解算所有轨迹点的相机位姿之后，使用增量式 SfM 中的 BA 算法进行全局优化，以此确保最终结果的精准与稳健^[28]。考虑到车载图像之间的时空关系较为连续，与增量式 SfM 的过程相对一致，因此本研究采用抗噪性更强，执行效率相对较高的增量式 SfM 进行车载相机的位姿估计。

在本研究的上下文中，众包数据中的轨迹点与车载图像是一一对应的，且轨迹点的采样频率相对较高。然而，当车辆进行大角度转弯时，相邻车载图像之间的重叠度较低，匹配的特征点对也相对较少，进而会影响轨迹数据的位姿估计结果。为此，本研究创新性地提出以特征点匹配稀疏处为分割节点，将连续的轨迹数据智能划分为多个独立段进行处理。此举不仅有效提升了位姿估计的精确度，还显著优化了增量式 SfM 算法的执行效率，实现了效率与精度的双赢。车载图像增量式 SfM 算法流程图如图 2 所示。

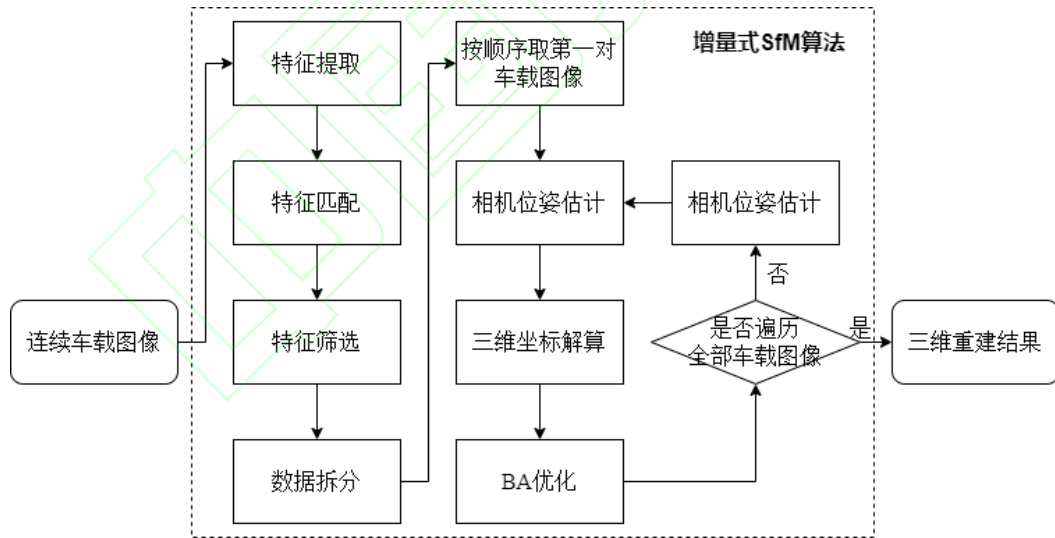


图 2. 车载图像增量式 SfM 算法流程图

Figure 2. Flowchart of incremental SfM algorithm for vehicle-borne images

具体而言，本研究首先采用方向梯度直方图算法（Histogram of Oriented Gradients, HOG），从每张车载图像中提取特征点，包括表示位置的关键点和描述关键点周围像素信息的描述子；随后采用随机 k-d 树算法计算两个描述子之间的相似性程度，将相邻车载图像之间的特征点进行匹配，并采用随机采样一致性（Random Sample Consensus, RANSAC）算法对错误匹配的特征点对进行筛选和剔除；如果一对车载图像之间所有特征点对的相似性程度较低，则从这两个车载图像之间的位置拆分数据集；然后取各数据集的第一对车载图像，采用对

极几何和八点法估计相机位姿，并采用三角测量方法解算特征点的三维坐标；最后依次添加其他车载图像来增长现有重建结果，分别采用 PnP 和三角测量方法求解相机位姿信息，解算特征点的三维坐标，并对解算的三维坐标点和估计的位姿信息进行 BA 优化，直到所有图像对解算完毕，即可得到三维重建的稀疏点云和车载相机在各轨迹点的位姿信息。在实操层面，本研究采用 OpenSfM 框架实现了连续车载图像的三维重建和车载相机的位姿估计。此外，前后轨迹点的经纬度信息将作为 OpenSfM 框架三维重建的地理参考，用于重建结果的全局移动与对齐，以此使重建的结果能够顾及 GPS 的绝对尺度。

1.1.2 异常行驶角度校正

相机位姿估计结果为相机外参矩阵 $[R, t]$ ，其中 t 为 3×1 的平移向量， R 为 3×3 的旋转矩阵，表示从世界坐标系转为相机坐标系的刚性变换。因此，根据旋转矩阵 R 即可求出相机在世界坐标系的方位角。将第一个轨迹点所在的位置定义为世界坐标系的原点，根据其角度即可确定世界坐标系的方向，再由递增式 SfM 算法得到每张图像旋转矩阵，进而求得每个轨迹点的视觉方向角。OpenSfM 默认使用的是罗德里格斯旋转向量，假设其求解的结果为：

$$R = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix} \quad (1)$$

则方位角可通过公式(2)得出：

$$\gamma = \text{mod} \left(\text{deg} \left(\arctan \frac{r_{13}}{r_{23}} \right) + 360, 360 \right) \quad (2)$$

其中， deg 为弧度转角度的函数， mod 为取余数的函数。

将视觉方向角与轨迹行驶角度进行对比，即可识别异常的行驶角度，随后即可借助视觉方向角来校正异常的行驶角度。需要注意的是，由于视觉方向角可能存在一定的精度偏差，因此无法完全由视觉方向角来取代车辆的行驶角度。故而本研究仅当识别到行驶角度存在明显异常之后，再尝试使用视觉方向角。

1.2 轨迹整体位置纠偏方法

低成本 GPS 模块，尤其是使用时间较长的低成本 GPS 模块，通常存在校准精度差等问题，加之 GPS 模块的信号接收可能存在延迟，使得众包轨迹数据中普遍存在整体位置偏移现象。由于地图匹配算法无法校正平行于道路方向的轨迹位置偏移，致使轨迹位置校正存在精度瓶颈，这也制约了依赖高精度轨迹数据的多样化应用场景的性能与可靠性。本研究将在轨迹异常行驶角度校正的基础之上，基于车载图像中蕴含的道路场景信息，进一步校正轨迹数据存在的整体位置偏移现象。轨迹整体位置纠偏的技术路线如图 3 所示。具体而言，本研究根据车载图像反映的道路场景语义信息，在轨迹数据中识别关键轨迹点，或基于现有轨迹点构建虚拟关键轨迹点，通过隐马尔可夫模型将关键轨迹点与城市道路节点进行匹配，并将所有轨迹点与匹配位置在经度与纬度上的偏移均值作为偏移因子，最后应用偏移因子到所有轨迹点，即可实现轨迹数据的整体位置纠偏。

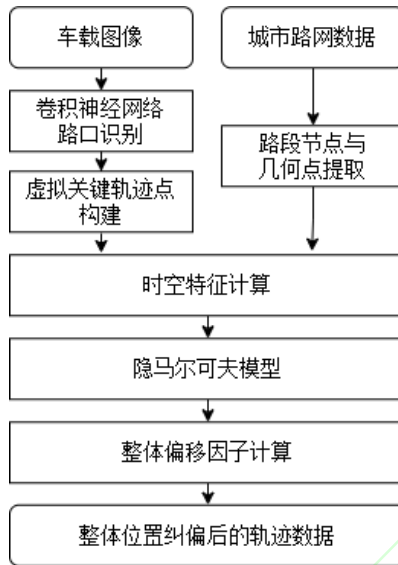


图 3. 轨迹整体位置纠偏技术路线图

Figure 3 Technology roadmap of trajectory overall position correction method

1. 2. 1 关键轨迹点提取

在关键轨迹点的识别与构建方面，本研究认为路网数据中能够辅助轨迹点实现精准定位的要素包括路口和多条道路的汇合口与分岔口，因此本研究将车载图像的道路场景语义信息分为路口、汇入口、分岔口与其他场景等 4 类，并利用卷积神经网络来实现车载图像的场景分类。

图像分类是计算机视觉领域里一个经典的监督学习问题。目前主流的卷积神经网络模型，如 VGG、ResNet 等，已被证明在道路场景分类等应用中的有效性^[21]。为了提高模型的鲁棒性，大规模的人工样本收集与精细标注，增加了训练数据集的构建成本。然而，迁移学习（Transfer Learning）则可以通过利用预训练模型来显著降低目标数据集的构建成本，同时降低模型的训练难度。值得注意的是，预训练过程中采用的数据集即便与目标任务不直接相关，其蕴含的通用视觉特征，如边缘、纹理、形状等，在新任务中依然能发挥关键作用。

微调（Fine Tuning）是一种常用的迁移学习方法^[29]，其实现过程包括以下 4 个步骤：首先在其他数据集上训练得到预训练模型；随后创建一个新的神经网络，即目标模型，复制预训练模型中除了全连接层以外的所有结构和参数到目标模型；接着根据当前任务场景设计目标模型的全连接层结构，并随机初始化全连接层的模型参数；最后在目标数据集上进行训练，以得到该任务场景的神经网络模型。

为了进行道路场景语义信息的提取，本研究采用在 ImageNet 数据集上训练好 VGG-16 和 ResNet-50 模型作为本研究的预训练模型，并在自主标注的道路场景分类数据集上进行模型微调，最终得到道路场景分类器。VGG-16 和 ResNet-50 模型的网络结构及微调示意如图 4 所示。

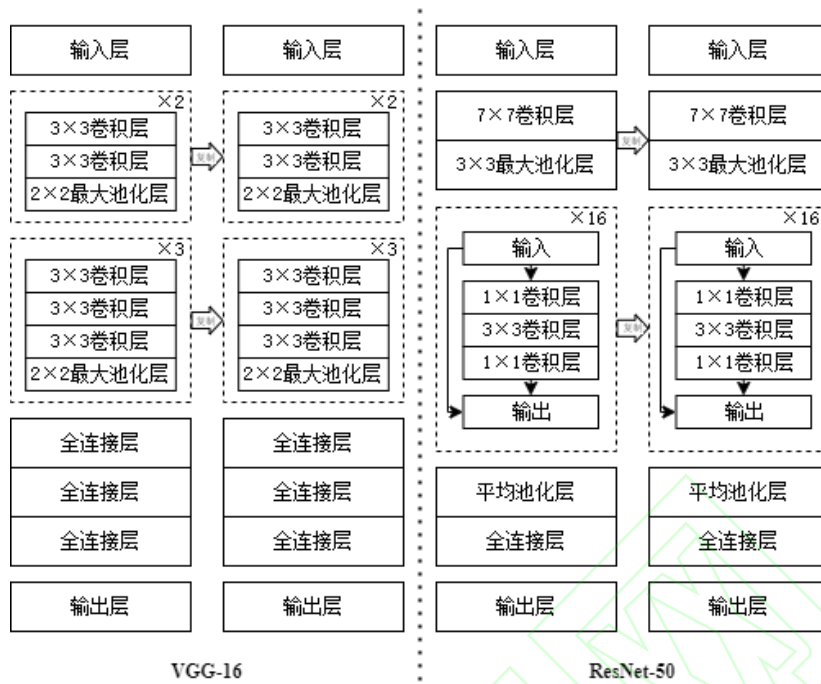


图 4. 常见卷积神经网络结构及微调示意图

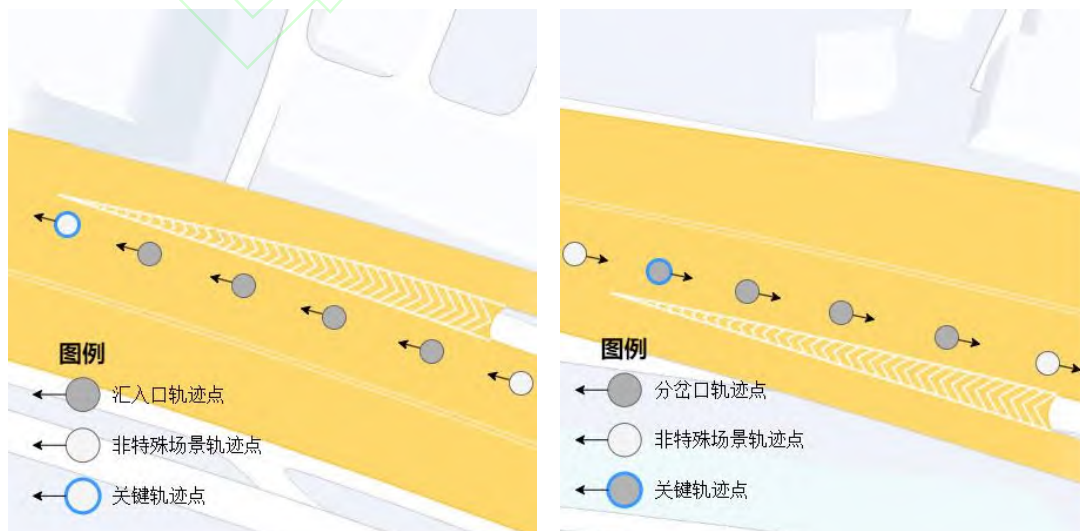
Figure 4. Structure and fine-tuning diagram of common convolutional neural network

由于现实道路场景中，车辆行驶在路口内或通过岔分和汇入口时是一个连续的过程，因此会有多个连续迹点的车载图像被分类为特定道路场景。为了在特定场景下仅保留唯一的迹点与路网节点进行匹配，本研究采用以下方式进行关键迹点提取：

(1) 如果连续迹点的道路场景被视为汇入口，则取连续迹点下一个被识别为其他场景的迹点作为关键迹点，如图 5 (a)所示；

(2) 如果连续迹点的道路场景被视为岔路口，则取连续迹点的第一个迹点作为关键迹点，如图 5 (b)所示；

(3) 如果连续迹点的道路场景被视为路口，则取驶入路口的首个迹点和驶出路口的首个迹点构建虚拟关键迹点。虚拟关键迹点为算法构建的用于与候选节点匹配的迹点锚点，如果出入路口的两个迹点的行驶方向接近，则取迹点对连线的中点作为虚拟关键迹点，如图 5 (d)所示；否则以这两个迹点以及其行驶方向分别构建直线，并取直线的交点作为该路口的虚拟关键迹点，如图 5 (c)所示。






图 5. 关键轨迹点提取示意图

Figure 5. Schematic diagram of key trajectory point extraction

在关键轨迹点提取之后，需要获取第一个进入该道路场景和第一个离开该道路场景的轨迹点的行驶角度，并将其分别作为驶入和驶出方向角记录在关键轨迹点中，用于在将关键轨迹点与路网节点匹配时，通过对比关键轨迹点的驶入和驶出方向以及候选节点连接道路的出入方向对候选节点进行初步筛选。在确定关键轨迹点的道路场景时，如果连续轨迹点中同时包含多个不同的道路场景，则以出现频率最高的道路场景为主；如果轨迹数据采样频率相对较高，且轨迹数据中存在不连续的轨迹点被识别为路口、汇入口、分岔口等道路场景时，那么这些轨迹点可以直接被算法忽略，以此来保证轨迹整体位置纠偏方法的精度。

1.2.2 整体位置纠偏

在关键轨迹点提取之后，通过将关键轨迹点按照顺序依次匹配到更为可能的道路节点上，再计算所有关键轨迹点的平均偏移量并赋予所有轨迹点，即可实现轨迹整体位置偏移的校正。轨迹整体位置纠偏方法的技术路线如图 6 所示，具体包括以下 6 个步骤：

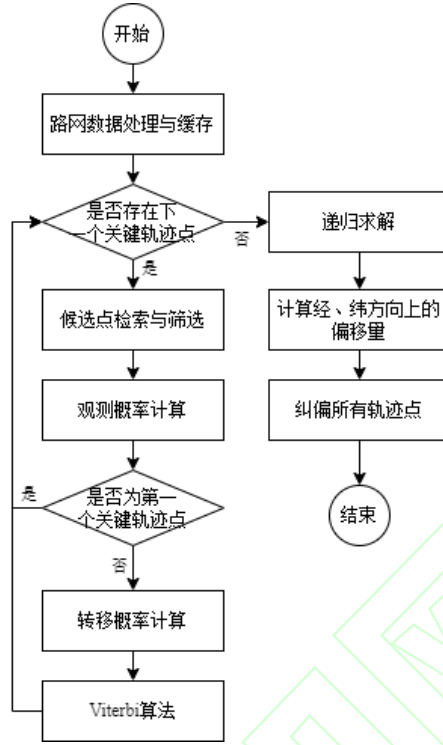


图 6. 关键轨迹点匹配技术路线图

Figure 6. Technology roadmap of key trajectory points mapping

(1) 从路网数据中提取节点数据，并提取与每个节点连接的路段数据，根据其行驶方向和坐标信息，计算节点每条入边和出边的方位角（双向路则将其同时视为入边和出边）。随后采用 R 树索引，缓存所有节点，以提高后续候选节点空间检索的效率。

(2) 依次遍历所有关键轨迹点。在每次计算过程中，以当前的关键轨迹点为圆心，以阈值 r 为半径，从 R 树索引中检索范围内的节点作为候选节点，并根据关键轨迹点的类型对候选节点进行初步筛选。其中，汇入口场景的关键轨迹点需要获取所有入度 $d_{in} \geq 2$ 且出度 $d_{out} \geq 1$ 的候选节点；分岔口场景的关键轨迹点则需要获取所有出度 $d_{out} \geq 2$ 且入度 $d_{in} \geq 1$ 的候选节点；路口的虚拟关键轨迹点仅需要保留度 $d_{out} + d_{in} \geq 3$ 的节点作为其候选节点。需要说明的是，候选节点的初筛并不是对节点所属的道路场景进行唯一分类，而是根据关键轨迹点所在的道路场景获取其附近所有满足筛选条件的候选节点，假设一个候选节点满足入度 $d_{in} \geq 2$ 且出度 $d_{out} \geq 2$ 的条件，则其可以作为附近所有汇入口场景和分岔口场景下关键轨迹点的候选节点。随后，根据关键轨迹点的驶入和驶出方向角以及候选点的入边和出边方向角对候选点进行再次筛选。路口场景中候选节点的筛选如公式(3)所示，汇入口和分岔口场景中的候选节点，则还分别需要额外考虑公式(4)和(5)的约束：

$$|a_{in} - a'_{in}| < a_t \text{ and } |a_{out} - a'_{out}| < a_t \quad (3)$$

$$|a_{in} - a'_{in2}| < a_{t2} \quad (4)$$

$$|a_{out} - a'_{out2}| < a_{t2} \quad (5)$$

其中 a_{in} 和 a_{out} 为关键轨迹点的驶入和驶出方向角， a'_{in} 和 a'_{out} 为候选节点中分别与关键轨迹点的入、出方向角最为接近的入边和出边的方向角， a'_{in2} 和 a'_{out2} 为候选节点中分别与关键轨迹点的入、出方向角第二接近的入边和出边的方向角， a_t 和 a_{t2} 分别为最接近和第二接近程度的角度阈值。

(3) 计算关键轨迹点与各候选节点之间的时空特征，以此定义隐马尔可夫模型的观测概率。

a. 计算关键轨迹点的驶入和驶出方向与候选点中方向角最为接近的入边和出边之间的角度差，以保证候选点与关键轨迹点的出入角度尽可能相似。参考相关研究成果^[12]，认为出、入的角度差均服从高斯（正态）分布：

$$F_a(c_t^i) = \frac{1}{\sqrt{2\pi}\sigma_a} e^{-\frac{(x_a - \mu_a)^2}{2\sigma_a^2}} \quad (6)$$

其中, x_a 为关键轨迹点 p_t 与候选点 c_t^i 之间出边或入边之间的角度差, μ_a 和 σ_a 分别为角度差的均值和方差。

b. 根据上述指标, 各候选点的观测概率定义为:

$$O(c_t^i) = F_a^{in}(c_t^i) * F_a^{out}(c_t^i) \quad (7)$$

(4) 计算当前关键轨迹点的各候选点与上一时刻关键轨迹点的各候选点之间的时空特征, 并以此定义隐马尔可夫模型的转移概率。如果当前处理的是整个轨迹的第一个关键轨迹点, 则可跳过此步骤。

a. 计算前后候选点之间的直线距离以及其对应的关键轨迹点之间的直线距离, 考虑两个距离之间的相似性, 以确保选择的相邻候选点对与关键轨迹点对之间的距离相似性。

$$F_s(c_{t-1}^s \rightarrow c_t^i) = \frac{\min(\text{dis}(p_{t-1}, p_t), \text{dis}(c_{t-1}^s, c_t^i))}{\max(\text{dis}(p_{t-1}, p_t), \text{dis}(c_{t-1}^s, c_t^i))} \quad (8)$$

其中, dis , \min 和 \max 分别为求欧式投影距离、取最小和取最大的函数。

b. 采用 A* 算法计算前后候选点之间的最短路径, 并在算法中考虑轨迹点之间的时间差, 当 A* 算法遍历的节点路径长度超过了车辆在这个时间内可能行驶的最大距离 (假设车辆在城市中的最大运行速度为 120km/h), 则直接认为最短路径求解失败, 以此确保候选点对之间的连通性, 并提高 A* 算法的求解效率。在转移概率中进一步考虑候选点之间的最短路径长度和关键轨迹点之间直线距离的相似性, 确保连通性越好的候选点对之间的转移概率越大。

$$F_p(c_{t-1}^s \rightarrow c_t^i) = \frac{\min(\text{dis}(p_{t-1}, p_t), \text{sp}(c_{t-1}^s, c_t^i))}{\max(\text{dis}(p_{t-1}, p_t), \text{sp}(c_{t-1}^s, c_t^i))} \quad (9)$$

其中, sp 为求解候选点之间最短路径长度的函数。

c. 根据 Viterbi 算法的思想, 每个候选点都会保存使其具有最高总概率的前一候选点, 因此每个候选点均可表示一条从第一个关键轨迹点到当前关键轨迹点的候选路径。为了确保所有关键轨迹点选择的候选点的相对方位尽可能一致, 可以分别计算当前候选路径中所有候选点与关键轨迹点之间经度与纬度差的方差, 并定义两个方差的概率计算公式如下:

$$F_c(c_{t-1}^s \rightarrow c_t^i) = e^{-k\sigma_c^2} \quad (10)$$

其中, σ_c^2 为经度或纬度差的方差, k 为缩放系数。

d. 根据上述三种指标, 相邻候选点之间的转移概率定义为:

$$T(c_{t-1}^s \rightarrow c_t^i) = F_s(c_{t-1}^s \rightarrow c_t^i) * F_p(c_{t-1}^s \rightarrow c_t^i) * F_c^x(c_{t-1}^s \rightarrow c_t^i) * F_c^y(c_{t-1}^s \rightarrow c_t^i) \quad (11)$$

(5) 按照轨迹中关键轨迹点的顺序, 在每个关键轨迹点中选择一个候选节点即可构成一条候选路径。在所有路径中找到一条概率最大的路径, 即为最终的匹配结果。任一候选路径的概率计算公式为:

$$F = O(c_1^{i_1}) * \prod_{t=2}^n T(c_{t-1}^{i_{t-1}} \rightarrow c_t^{i_t}) * O(c_t^{i_t}) \quad (12)$$

其中, n 为关键轨迹点的个数, i_t 为 t 时刻的关键轨迹点选择的第 i_t 个候选点。

由于本问题在隐马尔可夫模型中为预测问题, 因此可以借助 Viterbi 算法的动态规划思想来降低计算的复杂度, 即每个候选点仅记录一个使其具有最高整体概率的前一时刻候选点, 在所有关键轨迹点遍历完成之后, 从最后一个时刻中找到总体概率最大的一个候选节点, 通过不断递归其前一时刻的候选节点即可获取轨迹所有关键轨迹点的匹配结果。

(6) 根据各关键轨迹点与其匹配的候选节点，计算出经度和纬度方向上的平均偏移量，随后将所有轨迹点均加上该偏移量，即可完成轨迹整体位置偏移的校正工作。

2 实验与分析

2.1 研究区域与实验数据

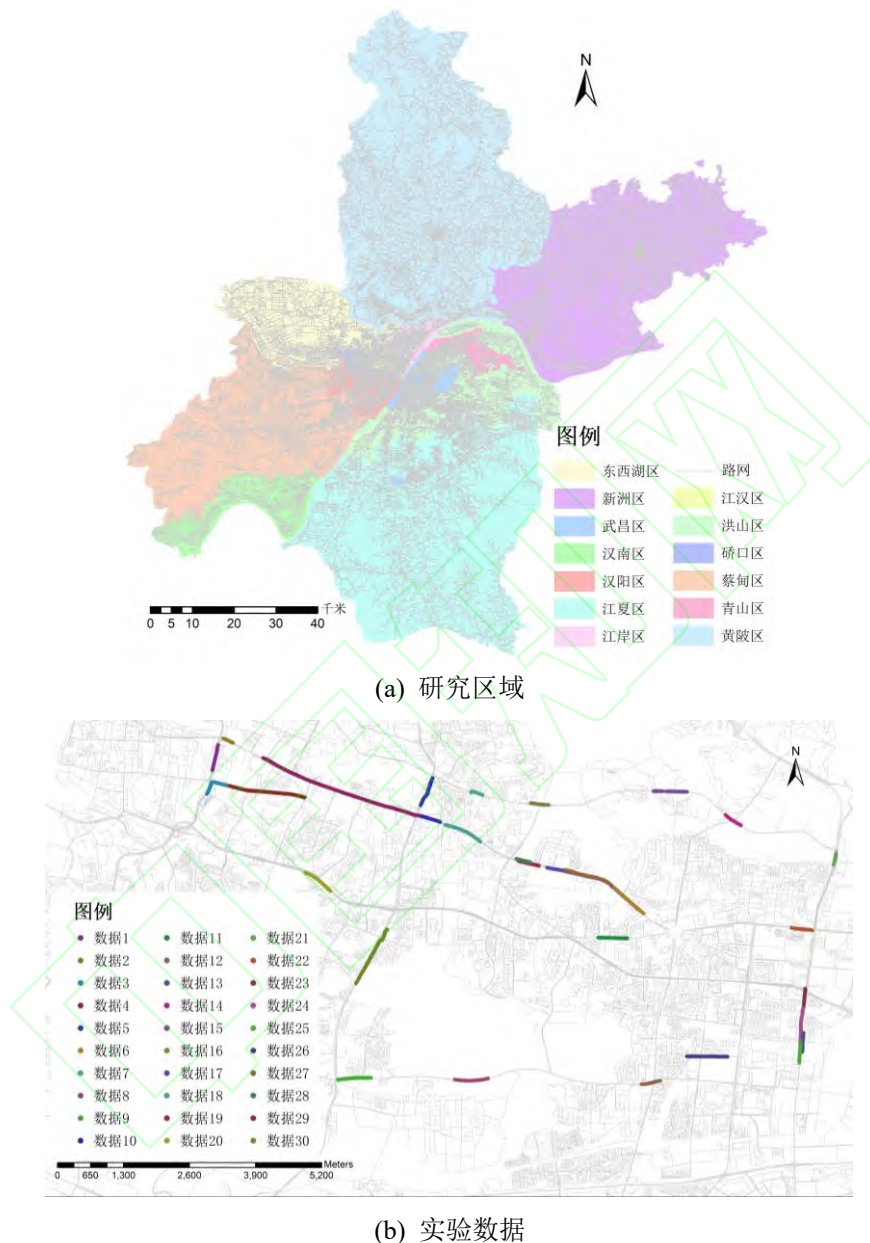


图 7. 研究区域与实验数据

Figure 7. Research area and experimental data

本研究以武汉市为研究区域，以更容易获取的导航路网数据作为轨迹整体位置纠偏实验的真值参考。相对于高精地图而言，导航路网的精度较差、特征点较少，但可以肯定的是，如果提出的方法在导航路网上可以获得较好的精度，那么其在高精地图上获得的精度只会更高。本研究采用导航路网进行实验验证，不仅可以方便实验的复现，且在真实应用场景中，能够避免直接将轨迹数据与高精地图进行匹配，以此提高轨迹位置校正的效率。

本研究使用的导航路网数据由当地导航公司提供，涵盖武汉 13 个区，共包含 351733 条道路，272150 个节点，研究区域如图 7(a)所示；众包数据为自主采集的 30 条带有车载图像的轨迹

数据, 轨迹点的行驶方向和轨迹的整体位置经过人工检查与校正, 众包数据的空间分布如图 7(b) 所示, 统计指标详见表 1。

表 1. 实验数据统计表

Table 1. Statistical table of experimental data

数据	记录数	里程	采样频率	数据	记录数	里程	采样频率	数据	记录数	里程	采样频率
Data1	38	591.37 米	1 秒	Data11	48	574.3 米	2 秒	Data21	30	280.54 米	2.5 秒
Data2	124	1404.77 米	1.5 秒	Data12	34	375.78 米	4.5 秒	Data22	36	410.84 米	1 秒
Data3	56	633.72 米	1 秒	Data13	37	434.01 米	1 秒	Data23	32	420.77 米	1 秒
Data4	156	1522.06 米	1.5 秒	Data14	35	389.84 米	3 秒	Data24	60	731.91 米	1.5 秒
Data5	63	674.17 米	1.5 秒	Data15	47	660.09 米	1.5 秒	Data25	38	457.67 米	1.5 秒
Data6	69	835.29 米	2 秒	Data16	37	347.2 米	1 秒	Data26	100	799.97 米	2 秒
Data7	42	265.87 米	1 秒	Data17	189	2095.15 米	1.5 秒	Data27	94	971.17 米	1.5 秒
Data8	36	660.16 米	1 秒	Data18	99	796.71 米	1 秒	Data28	35	277.02 米	1 秒
Data9	70	652.05 米	2 秒	Data19	42	412.38 米	1 秒	Data29	285	3346.66 米	1.5 秒
Data10	49	440.22 米	1.5 秒	Data20	48	655.53 米	1.5 秒	Data30	30	217.39 米	1 秒

2.2 异常角度校正

利用 OpenSfM 框架处理带有车载图像的轨迹数据, 当相邻车载图像之间的鲁棒特征点数量小于 50 组或鲁棒匹配点占有所有匹配点的比例小于 70% 时, 在当前位置将轨迹拆分为两条子轨迹; 设置用于匹配的两个图像之间的最大时间间隔为 4 个单位, 即每个图像只与其相邻的前后各 2 个图像进行特征点匹配, 以防止因场景相似而导致相隔较远的图像之间出现鲁棒的特征点对; 设置允许利用相机的相似性变换来补偿 GPS, 以避免 GPS 抖动对位姿估计结果的影响。此外, 本研究还通过配置参数 “locality bundle radius” 和 “bundle interval” 等参数来优化 OpenSfM 的性能。具体而言, bundle radius 设置为 1, 这意味着在添加新图像时, 只对新图像及其紧邻的图像进行 BA 优化; bundle interval 设置为 9999999, 表示在所有图像均添加完成之后再执行全局 BA 优化, 以此尽可能地提高 OpenSfM 的执行效率。将位姿估计结果与轨迹数据中记录的车辆行驶方向以及轨迹所在道路的行驶方向进行对比, 以验证众包数据中车载图像在行驶角度估计上的有效性, 实验结果如表 2 所示:

表 2. 行驶角度估计结果统计表

Table 2. Statistical table of driving angle estimation results

数据	与车辆行驶方向的角度差			与道路行驶方向的角度差			数据	与车辆行驶方向的角度差			与道路行驶方向的角度差		
	最大值	最小值	平均值	最大值	最小值	平均值		最大值	最小值	平均值	最大值	最小值	平均值
Data1	8.05	0.89	4.30	6.49	0.66	3.39	Data16	17.90	2.39	9.37	10.41	0.95	7.66
Data2	25.51	1.20	15.70	23.50	0.18	11.96	Data17	12.51	3.87	7.18	20.45	0.55	9.48
Data3	21.60	2.40	10.66	18.21	0.54	9.15	Data18	9.11	0.64	6.69	17.27	0.03	9.15
Data4	13.39	2.78	7.39	15.71	0.70	8.77	Data19	12.55	3.41	4.36	20.02	3.51	7.47
Data5	18.21	2.39	11.50	16.31	2.27	9.62	Data20	10.15	0.41	4.73	15.79	6.06	8.99
Data6	6.03	0.02	4.27	11.65	3.60	8.27	Data21	23.29	0.06	8.09	10.36	2.04	7.12
Data7	20.20	3.91	9.60	28.64	0.28	7.93	Data22	7.37	0.02	3.64	25.30	0.01	6.76
Data8	21.53	8.75	18.28	21.92	10.00	17.97	Data23	15.61	2.59	8.57	15.48	1.75	5.91
Data9	16.57	5.24	9.28	15.18	2.26	8.22	Data24	21.33	0.06	10.00	23.08	0.86	8.53
Data10	9.48	6.46	8.42	20.83	9.43	12.16	Data25	8.62	4.50	6.06	12.45	0.47	6.23
Data11	9.27	2.05	8.43	10.24	1.08	8.38	Data26	11.81	6.64	8.49	24.41	2.70	8.72
Data12	13.80	1.89	4.50	7.98	0.09	2.53	Data27	19.80	0.83	11.98	19.41	0.11	10.39
Data13	22.27	0.16	12.02	21.30	4.21	11.12	Data28	10.56	2.87	7.66	12.13	4.07	9.23
Data14	12.51	0.05	7.61	17.06	2.15	9.28	Data29	8.39	0.42	4.42	17.65	0.44	7.57
Data15	29.13	1.56	6.06	23.71	1.56	5.85	Data30	5.66	0.09	3.18	11.26	0.79	6.29

实验结果显示, 所有轨迹点的姿态估计值与车辆行驶方向以及道路行驶方向的角度差均小于 30° 。由于常见地图匹配算法通常将轨迹点和候选路段之间的角度差限定在 60° 以内, 以此获得较高的地图匹配精度^[12], 因此, 递增式 SfM 算法与车载图像能够用于识别并校正车辆异常的行驶方向。具体应用时, 可在角度估计值与车辆行驶方向的夹角超过 90° 时选择信任角度估计值。

普通的异常行驶角度检测方法, 通常采用相邻两个轨迹点之间的方位角作为前一个轨迹点

行驶角度的参考值。这种方法仅适用于轨迹采样频率相对较高的场景下，且容易受到 GPS 抖动的影响，相邻轨迹点之间如果出现与道路行驶方向完全相反的位置偏差，则会影响异常行驶角度检测的精度，无法满足实际应用的需求。普通异常行驶角度检测方法的实验结果如表 3 所示。

表 3. 普通异常行驶角度检测方法结果统计表

Table 3. Statistical table of ordinary abnormal driving angle detection method

数据	与车辆行驶方向的角度差			与道路行驶方向的角度差			数据	与车辆行驶方向的角度差			与道路行驶方向的角度差		
	最大值	最小值	平均值	最大值	最小值	平均值		最大值	最小值	平均值	最大值	最小值	平均值
Data1	149.60	0.00	14.33	149.96	0.03	10.97	Data16	178.50	0.00	4.08	174.04	0.00	3.46
Data2	61.40	0.00	3.56	86.53	0.01	3.47	Data17	40.10	0.00	8.70	43.56	0.00	10.04
Data3	15.20	0.00	2.28	66.42	0.01	3.07	Data18	40.10	0.00	3.55	42.66	0.01	2.82
Data4	120.10	0.00	4.08	120.23	0.01	5.90	Data19	27.30	0.00	4.03	44.96	0.06	5.24
Data5	58.80	0.00	2.49	132.39	0.06	3.57	Data20	27.10	0.00	1.41	31.94	0.00	1.43
Data6	20.20	0.00	2.37	22.43	0.00	2.73	Data21	68.30	0.00	3.03	77.76	0.00	3.08
Data7	125.70	0.00	3.23	124.91	0.00	4.48	Data22	40.54	0.05	5.65	40.83	0.09	6.26
Data8	27.50	0.00	3.57	30.31	0.00	2.59	Data23	19.19	0.00	2.79	38.93	0.00	3.20
Data9	9.00	0.00	3.86	29.62	0.12	4.46	Data24	79.38	0.00	4.16	71.97	0.00	4.83
Data10	87.10	0.00	4.99	82.57	0.01	7.03	Data25	172.24	0.00	4.09	171.56	0.00	4.16
Data11	32.00	0.00	3.92	74.39	0.00	4.82	Data26	43.75	0.00	5.14	57.43	0.00	7.00
Data12	89.20	0.00	3.55	82.21	0.00	3.92	Data27	83.65	0.00	3.74	71.25	0.00	4.46
Data13	75.20	0.00	6.73	96.20	0.04	5.69	Data28	71.06	0.00	4.50	179.43	0.00	5.08
Data14	106.00	0.00	7.93	107.28	0.00	8.20	Data29	75.01	0.03	4.19	82.35	0.01	3.92
Data15	175.30	0.00	8.79	174.22	0.01	10.97	Data30	90.60	0.00	2.83	89.49	0.00	3.36

2.3 整体位置纠偏

在道路场景识别实验中，用于道路场景分类的样本数据爬取自百度全景，通过截取车辆行驶方向的局部全景图片来模拟行车图像。本研究共计获取了 9484 张局部全景图片，通过人工标注构建了道路场景训练样本数据集。由于路口、汇入口、分岔口等场景的样本数量相对较少，因此本研究采用一定的图像增强方法对样本数据进行补充，数据集的统计结果以及采用的样本增强方法如表 4 所示。本研究将训练集与测试集的样本数量比例设为 4:1，且保证了测试集与训练集之间不同时包含由同一图片增强出来的两张不同的样本数据；此外，在样本数据增强时，本研究确保汇入口和分岔口的样本在随机裁剪、随机旋转和随机擦除时不会完全剔除能够区分道路场景的隔离带特征。

表 4. 道路场景样本数据及训练结果汇总表

Table 4. Summary table of road scenes sample data and training results

道路场景	样本数量	增强方法	训练集数量	测试集数量	VGG 查准率	VGG 查全率
路口	1727	随机裁剪 随机旋转	5000	1250	90.80%	97.12%
汇入口	360	随机水平翻转 随机擦除	5000	1250	96.58%	88.08%
分岔口	482	高斯滤波 颜色抖动	5000	1250	98.65%	87.60%
其他场景	6250	不增强	5000	1250	88.68%	99.13%

本研究选用 AutoGluon 框架进行图像分类任务训练，采用预训练好的 VGG-16 和 ResNet-50 模型为道路场景分类的骨干网络，在标注好的数据集上进行模型微调。实验结果表明，VGG-16 模型的分类精度为 93.14%；而 ResNet-50 模型的分类精度仅为 88.84%。因此，本研究最终选择表现更佳的 VGG-16 模型作为道路场景分类的卷积神经网络，各道路场景的查准率与查全率如表 4 所示。

利用训练好的模型识别车载图像的道路场景，随后根据道路场景识别结果从轨迹数据中提取关键轨迹点。选择关键轨迹点数量大于 1 的轨迹数据，对轨迹数据的经纬度坐标进行随机的整体位置偏移，利用偏移后的轨迹数据进行轨迹整体位置纠偏实验，验证随机生成的偏移量和求解的纠偏因子之间的误差，以此验证整体位置纠偏算法的效果。

本研究设置候选点的搜索半径 r 为 200 米，高于轨迹数据可能的整体偏移量；关键轨迹点提取时的角度阈值 α_t 和 α_{t2} 依据经验被分别设置为 30° 和 60° ；在计算时空特征的概率时，角度差的均值 μ_a 和方差 σ_a 依据相关论文的经验被分别设置为 0 和 30° ；在计算关键轨迹点与候选点之间经度或纬度差的方差时，缩放系数 k 依据经验被设置为 300。本研究提取了 10 条轨迹数据用于整体位置纠偏实验，轨迹数据在经度和纬度上的随机偏移距离均为 $[50, 100]$ 米，每条轨迹随机偏移 10 次，实验统计结果如表 5 所示。

表 5. 轨迹整体位置纠偏实验结果

Table 5. Experimental result of trajectory overall position offset

数据	关键轨迹点数量	纠偏后误差	数据	关键轨迹点数量	纠偏后误差
Data1	2	16.83 米	Data15	2	4.20 米
Data2	2	23.59 米	Data17	7	4.49 米
Data3	2	15.50 米	Data21	2	23.87 米
Data4	5	0.40 米	Data26	2	23.02 米
Data13	2	25.25 米	Data29	7	22.63 米

实验结果表明，所选数据在不同的随机偏移量下实验结果较为稳定，纠偏后的轨迹与原始轨迹之间的距离误差在 30 米之内。以数据 Data4 为例，轨迹整体位置纠偏结果如图 8 所示。由于本研究使用的导航路网数据精度有限，且部分道路数据与真实道路在空间位置上存在相对误差，因此本研究的纠偏误差仍存在下降空间；此外，道路场景连续识别异常与相似道路场景也可能对轨迹整体位置纠偏算法的精度造成影响，因此关键轨迹点的提取和匹配逻辑也存在优化空间。


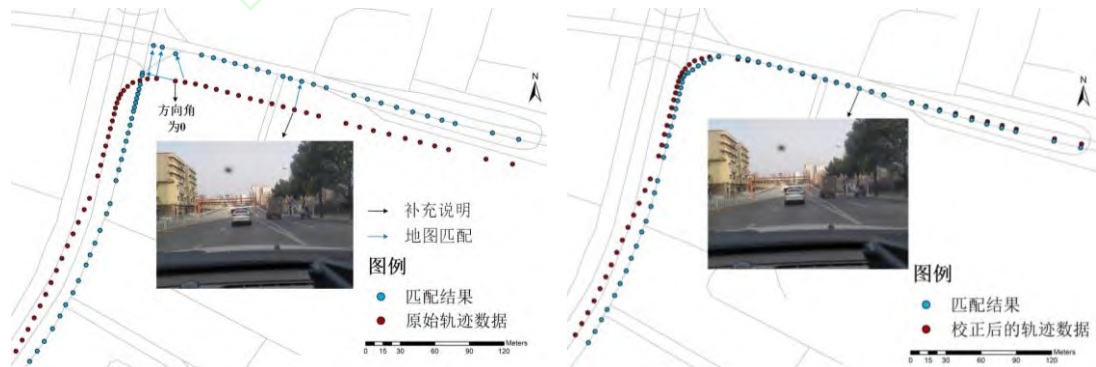


图 8. 轨迹整体位置纠偏实验效果图

Figure 8. Result of trajectory overall position correction experiment

2.4 地图匹配效果对比

最后，本研究以带有异常角度和整体偏移的真实众包轨迹数据为例，对比属性校正和轨迹整体位置纠偏前后的地图匹配效果差异。实验结果如图 9 所示，原始轨迹数据中存在方向角为 0 的异常轨迹点，导致一系列轨迹点出现了错误匹配的情况；同时，由于轨迹数据存在一定的整体位置偏移，导致地图匹配结果存在一定的位置偏差，图示的路口点匹配到了距离道路分岔口约 15 米的位置；经过异常属性校正和整体位置纠偏后的轨迹数据整体匹配结果明显好于未校正的数据，图示的路口点恰好匹配到了道路分岔口位置。地图匹配效果的对比一定程度上也反映了本研究提出方法的有效性。



(a) 未校正的原始众包数据与匹配结果

(b) 校正后的众包轨迹数据与匹配结果

图 9. 地图匹配效果对比图

Figure 9. Comparison of map-matching results

3 结语

由低成本众包设备采集的轨迹数据普遍存在行驶方向异常和整体位置偏移等问题,极大增加了轨迹位置校正的难度,进而影响高精地图众包更新的精度。针对这一问题,本研究提出了一种基于车载图像的异常轨迹检测与预校正方法,首先基于递增式 SfM 算法识别并校正了众包轨迹数据中的异常行驶角度值;随后基于高可信的轨迹行驶角度值,设计了基于隐马尔可夫模型的轨迹整体位置纠偏方法,实现了众包轨迹数据的整体位置纠偏;最后将预校正方法与地图匹配算法结合,验证了预校正方法在提升众包轨迹数据位置校正精度上的有效性。

由于本研究的实验场景有限,所提出方法仍存在优化空间,后续可从以下几个方面继续开展研究:

(1) 在异常角度检测与校正方面,本研究采集的实验数据未涉及道路拥堵场景,在动态目标较多且存在相对于当前车辆的位置移动时,可能会对轨迹异常角度检测与校正方法产生影响,本研究后续将进一步补充实验数据,并通过完善算法逻辑,提升轨迹异常角度检测与校正方法的精度和鲁棒性;

(2) 在轨迹整体位置纠偏方面,本研究后续可从车载图像语义及轨迹时空特征等方面提取更多的关键轨迹点识别特征,设计相应的候选轨迹点匹配策略以及错误关键轨迹点的容错逻辑,并通过补充更多属于不同道路场景的众包数据,以此来进一步提升轨迹整体位置纠偏方法的鲁棒性。

(3) 在方法的验证和应用方面,本研究后续将在高精地图数据中验证异常轨迹检测与预校正方法的有效性,并进一步尝试将本方法用于高精地图众包更新等应用场景当中,在实践中优化和完善预校正方法,以此提升方法的预校正质量和适用性。

参考文献

- [1] Zhang Pan, Liu Jingnan. A generalized data model of high definition maps[J]. *Acta Geodaetica et Cartographica Sinica*. 2021, 50(11): 1432-1446.
张攀, 刘经南. 通用化高精地图数据模型[J]. *测绘学报*. 2021, 50(11): 1432-1446.
- [2] Li Deren, Hong Yong, Wang Mi, et al. What can surveying and remote sensing do for intelligent driving?[J]. *Acta Geodaetica et Cartographica Sinica*. 2021, 50(11): 1421-1431.
李德仁, 洪勇, 王密, 等. 测绘遥感能为智能驾驶做什么?[J]. *测绘学报*. 2021, 50(11): 1421-1431.
- [3] Qi Ruyü, Yin Zhangcai, Gu Jiangyan, et al. Knowledge Graph Expression of High Definition Map[J]. *Geomatics and Information Science of Wuhan University*. 2024, 49(4): 651-661.
齐如煜, 尹章才, 顾江岩, 等. 高精地图的知识图谱表达[J]. *武汉大学学报(信息科学版)*. 2024, 49(4): 651-661.
- [4] Yang Zhenkai, Hua Yixin, Zi Lu, et al. Analysis of the development status and key technologies of high-precision map[J]. *Bulletin of Surveying and Mapping*. 2021(6): 54-60.
杨振凯, 华一新, 晷璐, 等. 浅析高精度地图发展现状及关键技术[J]. *测绘通报*. 2021(6): 54-60.
- [5] Report on the development of autonomous driving map and positioning technology industry[J]. *Intelligent connected vehicle*. 2019(3): 58-67.
自动驾驶地图与定位技术产业发展报告[J]. *智能网联汽车*. 2019(3): 58-67.
- [6] Liu Jianping, Zheng Yang, Zheng Wangxiao. Application and Update Solution of High Definition Map[J]. *Automobile Technology*. 2021, 46(12): 27-29.

- 刘建平, 郑阳, 郑望晓. 高精度地图的应用和更新方案[J]. 汽车实用技术. 2021, 46(12): 27-29.
- [7] Xie Jinyun, Tu Wei, Li Qingquan, et al. A Parallel Map-Matching Approach for Large Volume Floating Car Stream Data[J]. Geomatics and Information Science of Wuhan University. 2017, 42(5): 697-703.
- 谢金运, 涂伟, 李清泉, 等. 大规模浮动车流数据并行地图匹配方法[J]. 武汉大学学报(信息科学版). 2017, 42(5): 697-703.
- [8] Li B, Cai Z, Kang M, et al. A trajectory restoration algorithm for low-sampling-rate floating car data and complex urban road networks[J]. International Journal of Geographical Information Science. 2021, 35(4): 717-740.
- [9] Rehrl K, Grchenig S, Wimmer M. Optimization and Evaluation of a High-Performance Open-Source Map-Matching Implementation[C]. 2018.
- [10] Li Bijun, Guo Yuan, Zhou Jian, et al. Development and Prospects of High Definition Map for Intelligent Vehicle[J]. Geomatics and Information Science of Wuhan University. 2023: 1-18.
- 李必军, 郭圆, 周剑, 等. 智能驾驶高精地图发展与展望[J]. 武汉大学学报(信息科学版). 2023: 1-18.
- [11] Liu Tianxiong. What are the main sources of error in GPS? (Part 1)[J]. Satellite & Network. 2012(9): 58-63.
- 刘天雄. GPS主要误差源有哪些?(上)[J]. 卫星与网络. 2012(9): 58-63.
- [12] Li B, Cai Z, Kang M, et al. An improved hidden Markov model-based map matching algorithm considering candidate point grouping and trajectory connectivity[J]. Cartography and geographic information science. 2022, ahead-of-print(ahead-of-print): 1-20.
- [13] Hu Zhaozheng, Sun Yingmei, Li Yicheng. High definition map construction from pavement landmarks for multi-scale vehicle localization[J]. Journal of Harbin Institute of Technology. 2019, 51(9): 149-156.
- 胡钊政, 孙莹妹, 李祎承. 路面路标高精度地图构建与多尺度车辆定位[J]. 哈尔滨工业大学学报. 2019, 51(9): 149-156.
- [14] Neven D, De Brabandere B, Georgoulis S, et al. Towards End-to-End Lane Detection: an Instance Segmentation Approach[C]. Changshu, China: 2018.
- [15] Liu Y, Peng J, Xue J, et al. TSingNet: Scale-aware and context-rich feature learning for traffic sign detection and recognition in the wild[J]. Neurocomputing. 2021, 447: 10-22.
- [16] Lee, Taejae, Yi, et al. A Monocular Vision Sensor-Based Obstacle Detection Algorithm for Autonomous Robots[J]. Sensors. 2016, 16: 311.
- [17] Zhou Su, Zhi Xuelei, Lin Feibin, et al. Research on Vehicle Detection and Tracking Algorithm Based on Onboard Video Images[J]. Journal of Tongji University (Natural Science). 2019, 47(S1): 191-198.
- 周苏, 支雪磊, 林飞滨, 等. 基于车载视频图像的车辆检测与跟踪算法[J]. 同济大学学报(自然科学版). 2019, 47(S1): 191-198.
- [18] Mur-Artal R, Tardos J D. ORB-SLAM2: An Open-Source SLAM System for Monocular, Stereo, and RGB-D Cameras[J]. IEEE Transactions on Robotics. 2017, 33(5): 1255-1262.
- [19] Yang Z, Li J, Li H. Real-time Pedestrian and Vehicle Detection for Autonomous Driving[C]. Changshu, China: IEEE, 2018.
- [20] Zhang W, Liu H, Wu X, et al. Lane marking detection and classification with combined deep neural network for driver assistance[J]. Proceedings of the Institution of Mechanical Engineers, Part D. Journal of Automobile Engineering. 2019, 233(5).

- [21] Li B, Wang M, Cai Z, et al. VIS-MM: a novel map-matching algorithm with semantic fusion from vehicle-borne images[J]. *International journal of geographical information science*. 2023, 37(5): 1069-1098.
- [22] Zhou M, Chen X, Samano N, et al. Efficient Localisation Using Images and OpenStreetMaps[C]. Prague, Czech Republic: IEEE, 2021.
- [23] Samano N, Zhou M, Calway A. You Are Here: Geolocation by Embedding Maps and Images[C]. 2020.
- [24] Ullman S. The interpretation of structure from motion[J]. *Proceedings of the Royal Society of London. Series B. Biological Sciences*. 1979, 203(1153): 405-426.
- [25] Zhang Yanwen, Hu Kai, Wang Pengsheng. Review of 3D reconstruction algorithms[J]. *Journal of Nanjing University of Information Science & Technology*. 2020, 12(5): 591-602.
张彦雯, 胡凯, 王鹏盛. 三维重建算法研究综述[J]. *南京信息工程大学学报*. 2020, 12(5): 591-602.
- [26] Cui Z, Tan P. Global structure-from-motion by similarity averaging[Z]. Santiago, Chile: 2015864-872.
- [27] Tahri O, Boutat D, Mezouar Y. Brunovsky's Linear Form of Incremental Structure From Motion[J]. *IEEE Transactions on Robotics*. 2017, 33(6): 1491-1499.
- [28] Lin Musen. Optimization and Implementation of 3D Reconstruction Algorithm Based on Incremental SfM[D]. Wuhan University of Technology, 2020.
林木森. 基于增量式SfM的三维重建算法的优化及其实现[D]. 武汉理工大学, 2020.
- [29] Zhang A, Lipton Z C, Li M, et al. Dive into Deep Learning[M]. arXiv preprint arXiv:2106.11342, 2021.

网络首发:

标题: 一种基于车载图像的异常轨迹检测与预校正方法

作者: 李伯钊, 廖成, 翁宝凤, 蔡忠亮, 韦瀚植

收稿日期: 2024-11-15

DOI:10.13203/j.whugis20240116

引用格式:

李伯钊, 廖成, 翁宝凤, 等. 一种基于车载图像的异常轨迹检测与预校正方法[J]. *武汉大学学报(信息科学版)*, 2024, DOI:10.13203/J.whugis20240116 (LI Bozhao, LIAO Cheng, WENG Baofeng, et al. A Method for Abnormal Trajectory Detection and Pre-Correction Based on Vehicle-Borne Images[J]. *Geomatics and Information Science of Wuhan University*, 2024, DOI:10.13203/J.whugis20240116)