

无人车辆室内外无缝定位的区域识别方法

杨秀建, 杨义兴, 张生斌

(昆明理工大学 交通工程学院, 昆明 650500)

摘要: 针对无人车辆室内外无缝定位过程中难以准确判定车辆所处区域的问题, 提出了一种无人车辆室内外无缝定位的区域识别方法。首先, 设计基于粒子群优化的支持向量机 (PSO-SVM) 与隐马尔可夫模型 (HMM) 的联合预测模型, 并利用传感器获取环境特征数据作为模型输入, 得到区域识别结果; 然后, 引入三种环境模型描述车辆所处环境, 根据区域识别结果选择相应的量测信息; 最后, 利用区域切换概率更新交互式多模型算法 (IMM) 中三个环境子模型的切换概率, 从而提高无人车辆的室内外无缝定位环境区域识别的准确性和定位精度。实车实验结果表明, 联合识别方法在区域识别中的准确性为 98.09%, 相较于单独使用 PSO-SVM 或 HMM 分别提升了 2.13% 和 9.53%。进一步实验表明, 与传统的联邦卡尔曼滤波算法 (FKF) 以及 IMM 算法相比, 采用所提区域识别方法的平均定位精度分别提高了 43.75% 和 22.30%。

关键词: 无人车辆; 区域识别; 多源融合; 交互多模型算法; 室内外无缝定位

中图分类号: U666.1

文献标志码: A

A regional recognition method for seamless indoor-outdoor localization of unmanned vehicles

YANG Xiujian, YANG Yixing, ZHANG Shengbin

(Faculty of Transportation Engineering, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: To address the challenge of accurately determining the environmental region of unmanned vehicles during seamless indoor-outdoor positioning, a regional recognition method for seamless indoor-outdoor localization is proposed. Firstly, a joint prediction model integrating particle swarm optimization-support vector machine (PSO-SVM) and hidden Markov model (HMM) is designed. Environmental feature data acquired by sensors serve as model inputs to generate regional recognition results. Secondly, three environmental models are introduced to describe the vehicle's operational environment, with corresponding measurement information selected based on the regional recognition outcomes. Finally, the regional transition probabilities are utilized to update the switching probabilities of the three environmental sub-models in the interactive multiple model (IMM) algorithm, thereby enhancing the accuracy of environmental region recognition and positioning precision for seamless indoor-outdoor navigation. The results of real-vehicle experiment show that the proposed joint recognition method achieves an accuracy of 98.09% in region recognition, representing improvements of 2.13% and 9.53% compared to using PSO-SVM or HMM alone. Further experiments indicate that the proposed seamless positioning method enhances the average positioning accuracy by 43.75% and 22.30% compared to the traditional federated Kalman filter (FKF) algorithm and IMM algorithm, respectively.

Key words: unmanned vehicles; regional recognition; multi-source fusion; interactive multiple model algorithm; seamless indoor-outdoor positioning

收稿日期: 2024-11-14; **修回日期:** 2025-08-20

基金项目: 云南省基础研究计划项目 (202501AS070115); 云南省重大科技专项计划 (202402AE090009)。

作者简介: 杨秀建 (1980—), 男, 教授, 博士生导师, 从事车辆动力学控制、智能车辆技术研究。

通讯作者: 张生斌 (1981—), 男, 讲师, 博士, 从事车辆测试技术研究。

近年来,无人驾驶技术迅猛发展,其中,高精度的车辆定位是无人驾驶规划环节的关键所在^[1]。在城市复杂场景下,全球导航卫星系统(Global Navigation Satellite System, GNSS)易受建筑物干扰,从而导致信号衰减,造成定位性能显著下降,甚至无法提供定位服务^[2]。此外,在 GNSS 信号受阻情况下,仅依靠车辆搭载的单一传感器难以实现精准定位^[3]。惯性导航系统(Inertial Navigation System, INS)可以提供相对姿态、速度以及位置估计,通过 GNSS/INS 组合导航系统可以有效弥补 GNSS 短期失效的问题,提升整体室外定位精度^[4-6]。然而,在室内环境下,GNSS/INS 组合导航系统的定位能力有限,因此将超宽带(Ultra Wide Band, UWB)与 GNSS 和惯性测量单元(Inertial Measurement Unit, IMU)结合,形成 GNSS/IMU/UWB 定位系统^[7],可以有效解决室内外过渡区域及室内区域定位问题,实现无人车辆在城市复杂环境无缝定位。

室内外无缝定位技术利用不同的定位算法和传感器组合,旨在满足多种情况下对高精度定位的要求^[8]。为了应对这一具有挑战性的任务, Tao Feng 等人^[9]提出了 CrowdLOC-S 框架,该框架通过综合运用众包 WiFi 指纹、GNSS 和低成本传感器,结合扩展卡尔曼滤波(Extended Kalman Filter, EKF)多源融合模型,实现了稳健的室内外无缝定位,但其整体框架的实现相对复杂,涉及多种技术和算法,难以在实际应用中进行优化和平衡。Xingxing Li 等人^[10]提出了一种紧密耦合的 PPP/INS/UWB 集成系统,该系统通过融合多种测量值,并采用 UWB 两步加权模型和运动约束,实现了高精度的室内外无缝定位,并且采用 UWB 信号辅助识别室内外区域(Indoor-Outdoor, IO),但由于 UWB 通讯范围有限,尤其是当其受到非视距(Non Line of Sight, NLOS)干扰时,通信范围会迅速减少,无法作为室内外环境区分的准确依据。张威奕等人^[11]引入无迹卡尔曼滤波来改进 GPS/蜂窝网无缝定位算法,以克服现有算法的不足,提高其定位精度和鲁棒性。Linghan Yao 等人^[12]则提出了一种基于联邦滤波的定位算法,以解决现有研究中处理非视距误差和粗差方面的局限性,从而提高室内外无缝定位的精度和可靠性。张容阁^[13]通过比较交互式多模型算法(Interacting Multiple Model, IMM)与联邦卡尔曼滤波算法(Federated Kalman Filter, FKF)在噪声和模型不匹配条件下的精度测试结果,验证了在室内外无缝定位中 IMM 算法的优势。

上述研究人员在室内外定位算法方面取得了重要进展,但要构建高鲁棒性的室内外无缝定位系统,还需解决运动区域的准确识别问题^[9]。针对此问题,王

琳^[14]利用 GNSS 特征信息结合 K 近邻算法,将运动区域划分为室外与室内场景,验证了场景识别的可行性,但是仅依靠单一的 K 近邻算法并不足以准确的进行区域识别。Li M 等人^[15]通过隐马尔可夫模型(Hidden Markov Model, HMM),结合光接收器、蜂窝网络和磁力计,开发了 I-O 识别算法,实验中达到了 90%以上的识别准确率,但是光信号并非总是可用,并且只通过光探测器难以明确区分室外和半室外环境。Zhu Y, Luo H 等人^[16]基于接收到 GNSS 信号的空间几何分布,提出了一种针对室内外过渡快速 IO 检测方法,但未涉及室内或室外环境内更细致的定位或状态检测。

综合以上研究,本文提出了一种粒子群优化支持向量机(Particle Swarm Optimization-Support Vector Machine, PSO-SVM)算法,旨在提升无人车辆的定位精度。将车辆运动区域划分为室外区域模型(Outdoor Region, ODR)、室内外过渡区域模型(Indoor-Outdoor Transition Region, I-OTR)与室内区域模型(Indoor Region, IDR)三类,使用低成本 GNSS(Low-Cost GNSS, LC-GNSS)/IMU/UWB 构建室内外无缝定位框架,通过 PSO-SVM 与 HMM 相结合对车辆运动区域进行环境识别,并根据识别结果选择相应量测作为 IMM 算法输入。同时,根据区域识别结果更新子模型切换概率,提升定位精度。最后通过实车实验对本文所述方法进行评价验证。

1 无缝定位算法框架

如图 1 所示,本文提出的无缝定位框架核心包含区域识别算法与多模型融合策略两部分。其中环境识别模块采用 PSO-SVM 与 HMM 结合的策略,以 LC-GNSS 的可见卫星数与信噪比均值作为输入,并通过粒子群算法(Particle Swarm Optimization, PSO)对 SVM 的惩罚参数与核函数参数进行寻优,实现对三类区域的初步识别。考虑到整体定位的时序性,利用 HMM 对运动区域进行动态识别,并通过维特比算法(Viterbi Algorithm, VA)找到隐藏状态序列。最后,将两种识别结果加权融合,得到最终的联合识别结果,同时将 HMM 过程中得到的区域转移概率输入至后续的 IMM 步骤中,优化 IMM 的子模型切换概率。在多模型融合策略中定义三种融合子模型为 EKF-ODR、EKF-I-OTR 以及 EKF-IDR 对车辆定位进行描述,使用 EKF 作为子模型滤波器,并根据前序得出的区域识别结果与区域转移概率调整 IMM 算法中子模型量测信息以及子模型切换概率;最后,将三种子模型输入至 IMM 算法中进行加权融合,输出最终预测的车辆定位结果。

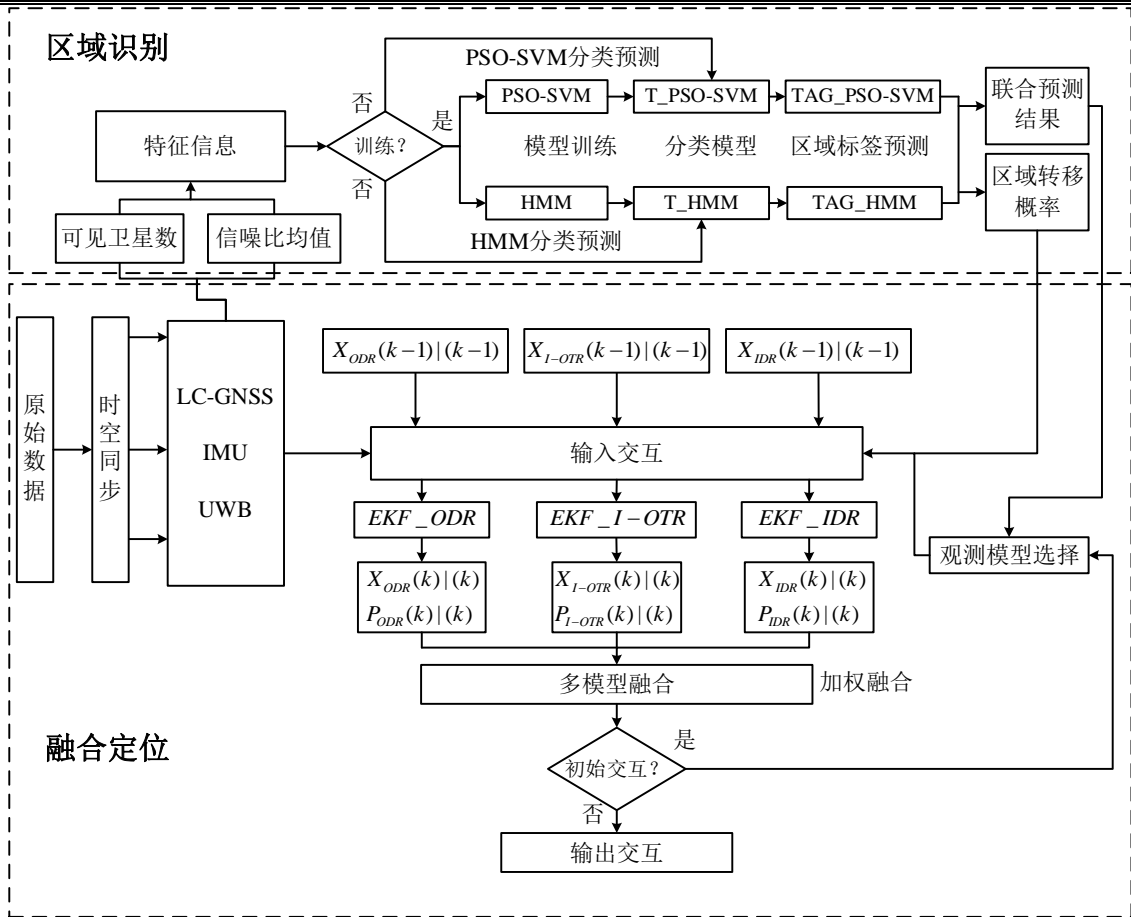


图 1 基于区域识别的室内外无缝定位架构

Fig.1 Indoor-outdoor seamless localization architecture based on region recognition

2 算法流程

2.1 基于粒子群优化的支持向量机分类预测

支持向量机 (Support Vector Machine, SVM) 最初由 Vapnik 等人于 20 世纪 90 年代提出^[17], 如图 2 所示 SVM 本身针对的是二分类问题, 但在本文中分类目标为多分类, 使用一对余类法 (One Versus Rest, OVR)^[18] 将多分类问题拆解为 k 个二分类问题进行聚类。




图 2 SVM 二分类

Fig.2 SVM binary classification

将 LC-GNSS 的总可见卫星数 (Total Number of Visible Satellites, TNVS) 与信噪比均值 (Mean Signal-

to-Noise Ratio, Mean SNR) 作为特征值样本 x_i , 设定包含 n 个训练样本的训练数据集为:

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (1)$$

其中, $x_i \in R^m$ 表示 m 阶的特征向量 (在本文中 $m=2$), $y_i \in \{1, 2, 3\}$ 是对应的区域类别标签, 其中 $y_i=1$ 代表室外区域, $y_i=2$ 代表室内外过渡区域, $y_i=3$ 代表室内区域。由于本文所针对的分类对象共有三类, 因此, 对于第 k 个分类器, 将属于第 k 个分类器的样本定义为正类, 其余样本定义为负类。则重新定义第 k 个分类器的标签为:

$$y_i^{(k)} = \begin{cases} 1 & y_i = k \\ -1 & y_i \neq k \end{cases} \quad (2)$$

对于第 k 个 SVM 分类器, 模型训练目标是找到超平面 $(\omega^{(k)})^T x + b^{(k)} = 0$ 使得超平面到两类样本点的间隔最大化, 对于任意样本点 $(x_i, y_i^{(k)})$ 到超平面的距离可以表示为:

$$d_i^{(k)} = \frac{|\omega^{(k)T} \cdot x_i + b^{(k)}|}{\|\omega^{(k)}\|} \quad (3)$$

式(3)中 $\omega^{(k)}$ 表示在第 k 个 SVM 分类器中超平面的法向量, $b^{(k)}$ 代表截距, 间隔表示为: $2/\|\omega^{(k)}\|$, 则

需要优化的目标函数表示为:

$$\Phi_k(\omega^{(k)}, b^{(k)}, \xi^{(k)}) = \min_{\omega^{(k)}, b^{(k)}, \xi^{(k)}} \frac{1}{2} \|\omega^{(k)}\|^2 + C \sum_{i=1}^n \xi_i^{(k)} \quad (4)$$

$$s.t. \quad y_i^{(k)} (\omega^{(k)T} x + b^{(k)}) \geq 1 - \xi_i^{(k)}, i = 1, 2, \dots, n$$

其中, $C > 0$ 是惩罚参数, 用于控制对错误分类的惩罚程度。 $\xi_i^{(k)} \geq 0$ 是松弛变量, 用于处理样本线性不可分的情况。

引入拉格朗日乘子 $\alpha_i^{(k)}$, 构造拉格朗日函数:

$$L(\omega^{(k)}, b^{(k)}, \xi^{(k)}, \alpha^{(k)}) = \frac{1}{2} \|\omega^{(k)}\|^2 + \frac{1}{2} C \sum_{i=1}^n (\xi_i^{(k)})^2 - \sum_{i=1}^n \alpha_i^{(k)} [y_i^{(k)} (\omega^{(k)T} x_i + b^{(k)}) - 1 + \xi_i^{(k)}] \quad (5)$$

对优化目标求偏导并令其为零, 得:

$$\omega^{(k)} = \sum_{i=1}^n \alpha_i^{(k)} y_i^{(k)} x_i \quad (6)$$

$$\sum_{i=1}^n \alpha_i^{(k)} y_i^{(k)} = 0 \quad (7)$$

$$\alpha_i^{(k)} = C \xi_i^{(k)} \quad (8)$$

$$y_i^{(k)} (\omega^{(k)T} x_i + b^{(k)}) - 1 + \xi_i^{(k)} = 0 \quad (9)$$

将式(6)~式(9)的结果与式(5)联立得到对偶问题的解:

$$L_d(\alpha^{(k)}) = \sum_{i=1}^n a_i^{(k)} - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i^{(k)} a_j^{(k)} y_i^{(k)} y_j^{(k)} x_i^T x_j \quad (10)$$

$$s.t. \quad 0 \leq a_i^{(k)} \leq C, \quad \sum_{i=1}^n \alpha_i^{(k)} y_i^{(k)} = 0, i = 1, 2, \dots, n$$

求解上述对偶问题, 得到最优的 $\alpha^{(k)*}$, 进而得到 $\omega^{(k)}$ 和 $b^{(k)}$ 。

对于待测样本 x , 分别计算 $k = 1, 2, 3$ 时的决策函数值:

$$f_k(x) = (\omega^{(k)})^T x + b^{(k)} \quad (11)$$

由于进行分类训练时, 数据不一定是线性可分的, 因此需要引入核参数将训练集数据映射至高维空间中, 则式(10)更新为:

$$L_d(\alpha^{(k)}) = \sum_{i=1}^n a_i^{(k)} - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i^{(k)} a_j^{(k)} y_i^{(k)} y_j^{(k)} K(\varphi(x_i), \varphi(x_j)) \quad (12)$$

其中, $\varphi(x_i)$ 为样本 x_i 在高维空间中的映射, $K(\varphi(x_i), \varphi(x_j))$ 为 SVM 的核函数。

在 PSO 算法中, 引入核参数 γ 与惩罚因子 C 作为粒子的位置向量 $x = (C, \gamma)$ 进行优化, 从而获得最优参数估计, 其中, $\gamma > 0, C > 0$ 。

待测样本分类为使 $f_k(x)$ 的值为最大的类别, 并将最终分类结果定义为:

$$V^* = \{v_1^*, v_2^*, \dots, v_i^*, \dots, v_n^*\}, \quad v_i^* \in \{1, 2, 3\} \quad (13)$$

2.2 隐马尔可夫分类预测

从时域角度分析, 无人车辆在室内外运动是一个连续的过程。当前所处的环境区域与前一时刻的状态有关, 而与先前位置无关, 并且会直接影响下一时刻的状态。与此同时, 在室内外区域判断过程中, 我们只能获取到 LC-GNSS 源的特征数据, 而无法直接观测到无人车辆所处的环境区域状态。进一步地, LC-GNSS 源的特征数据仅与当前所处的环境有关。因此, 本文建立了基于室内外区域识别的隐马尔可夫模型 $\lambda = (S, O, A, B, \pi)$, HMM 过程如图 3 所示。

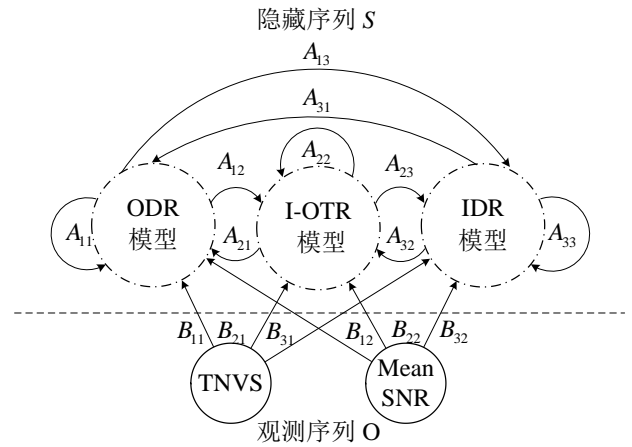


图 3 HMM 过程

Fig.3 Hidden Markov model process

其中 S 表示区域状态集合, 其具体取值如表 1 所示, 包含了三种区域状态与三类区域标签。

表 1 区域状态集合

Tab.1 Set of region states

S	状态列表	区域标签
室外区域	s_1	1
室内外过渡区域	s_2	2
室内区域	s_3	3

在构建的 HMM 模型中, $O = \{o_1, o_2\}$ 表示由 TNVS 与 Mean SNR 构成的观测向量; $A = [a_{ij}]$ 表示从状态 s_i 到状态 s_j 的概率, 其中 $a_{ij} = P(q_{t+1} = s_j | q_t = s_i)$, 对于任意的 $i, j \in \{1, 2, 3\}$ 满足 $\sum_{j=1}^3 a_{ij} = 1$; $B = [b_i(o_t)]$ 表示在隐藏状态为 s_j 时观测到序列 o_t 的概率, 其中 $b_j(o_t) = P(o_t | q_t = s_j)$; $\pi = \{\pi_i\}$ 表示初始时刻处于状态 s_i 的概率, 其中 $\pi_i = P(q_1 = s_i)$ 。

HMM 模型训练目标是通过给定的观测序列 O 及其对应的状态序列 S , 估计 HMM 的 A 、 B 、 π 的最佳参数。其中,

$$O = \{o_1, o_2\} \quad (14)$$

$$S = \{s_1, s_2, \dots, s_i, \dots, s_n\}, \quad s_i \in \{1, 2, 3\} \quad (15)$$

本文所涉及的问题属于 HMM 解码问题,通过 VA 找到测试集最有可能的隐藏状态序列为:

$$q_t^* = \psi_{t+1}(q_{t+1}^*) \quad (16)$$

其中, $\psi_t(i)$ 代表路径回溯指针。通过式(16)得到测试集的隐藏状态序列为:

$$H^* = \{s_1^*, s_2^*, \dots, s_i^*, \dots, s_n^*\}, \quad s_i^* \in \{1, 2, 3\} \quad (17)$$

2.3 联合分类预测

单一的分类预测结果在不同环境区域内的精度并非最优,因此对 PSO-SVM 的分类结果与 HMM 的分类结果进行联合预测,并使用联合预测的结果作为最终的分类结果。

设验证集有 N 个样本,真实类别标签为:

$$Y = \{y_1, y_2, \dots, y_i, \dots, y_n\}, \quad y_i \in \{1, 2, 3\} \quad (18)$$

则 PSO-SVM 对验证集的分类结果为:

$$\hat{Y}_S = \{\hat{y}_{s1}, \hat{y}_{s2}, \dots, \hat{y}_{si}, \dots, \hat{y}_{sn}\}, \quad \hat{y}_{si} \in \{1, 2, 3\} \quad (19)$$

HMM 对验证集的分类结果为:

$$\hat{Y}_H = \{\hat{y}_{h1}, \hat{y}_{h2}, \dots, \hat{y}_{hi}, \dots, \hat{y}_{hn}\}, \quad \hat{y}_{hi} \in \{1, 2, 3\} \quad (20)$$

在区域 k 中定义 N_k 为 Y 中类别为 k 的总真实样本数, $N_{s,k}$ 为 PSO-SVM 正确分类的样本个数, $N_{h,k}$ 为 HMM 正确分类的样本个数, $P_{S,K}$ 代表 PSO-SVM 的分类精度, $P_{H,K}$ 代表 HMM 的分类精度,则:

$$N_{s,k} = \sum_{i=1}^N I(y_{si} = k | y_i = k) \quad (21)$$

$$P_{S,K} = \frac{N_{s,k}}{N_k} \quad (22)$$

$$N_{h,k} = \sum_{i=1}^N I(y_{hi} = k | y_i = k) \quad (23)$$

$$P_{H,K} = \frac{N_{h,k}}{N_k} \quad (24)$$

总精确度记为:

$$P_K = P_{S,K} + P_{H,K} \quad (25)$$

在联合分类预测中,定义 $\omega_{k,i}^{(s)}$ 与 $\omega_{k,j}^{(h)}$ 分别表示在区域 k 中, PSO-SVM 的分类预测结果为 i , HMM 分类预测结果为 j 时($i, j \in \{1, 2, 3\}$)两种分类器的权重系数,其中 PSO-SVM 权重系数表示为:

$$P_{0j}(k-1|k-1) = \sum_{i=1}^r \mathbf{u}_{ij}(k-1|k-1) \cdot \left\{ \mathbf{P}_i(k-1|k-1) + \left[\hat{\mathbf{X}}_i(k-1|k-1) - \hat{\mathbf{X}}_{0j}(k-1|k-1) \right] \cdot \left[\hat{\mathbf{X}}_i(k-1|k-1) - \hat{\mathbf{X}}_{0j}(k-1|k-1) \right]^T \right\} \quad (35)$$

其中, $\hat{\mathbf{X}}_i(k-1|k-1)$ 和 $\mathbf{P}_i(k-1|k-1)$ 分别为模型 i 的状态预测和协方差。

根据式(28)得到联合分类的区域识别结果,设区域转移矩阵为 $C_T = [c_{ij}]_{3 \times 3}$,其中 c_{ij} 表示从区域 q_i^* 转移

$$\omega_{k,i}^{(s)} = \frac{P_{S,K}}{P_K} \quad (26)$$

同理, HMM 权重系数表示为:

$$\omega_{k,j}^{(h)} = \frac{P_{H,K}}{P_K} \quad (27)$$

最终输出的联合分类结果记为:

$$T_c = \omega_{k,i}^{(s)} H^* + \omega_{k,j}^{(h)} V^* \quad (28)$$

2.4 模型转移概率更新

本文将车辆的运动过程分为了室外区域、室内外过渡区域以及室内区域三种,对应有 ODR、I-OTR 以及 IDR 三种模型,即存在三个状态转移方程。利用 IMM 将三种模型估计出的结果加权融合从而得到车辆的预测轨迹,其中,第 j 个模型表示的目标状态方程为:

$$\mathbf{X}_j(k) = f(\mathbf{X}(k-1), \mathbf{W}(k-1)) \quad (29)$$

量测方程为:

$$\mathbf{Z}_j(k-1) = h(\mathbf{X}(k-1), \mathbf{V}(k-1)) \quad (30)$$

式(30)中, $f(\bullet)$ 和 $h(\bullet)$ 分别表示 $k-1$ 时刻的非线性状态方程函数和量测方程函数; $\mathbf{W}(k-1)$ 和 $\mathbf{V}(k-1)$ 分别表示 $k-1$ 时刻的状态噪声和量测噪声。

在 IMM 算法中模型转移概率矩阵定义为:

$$P = [p_{ij}]_{3 \times 3}, \quad i, j \in \{1, 2, 3\} \quad (31)$$

其中 p_{ij} 表示目标由子模型 i 切换至子模型 j 的概率。区域模型的预测概率为:

$$\bar{C}_j = \sum_{i=1}^r p_{ij} \mathbf{u}_i(k-1) \quad (32)$$

其中, $\mathbf{u}_i(k-1)$ 表示在 $t-1$ 时刻可能为区域模型 i 的概率且 $r=3$ 。

模型 i 到模型 j 的混合概率:

$$\mathbf{u}_{ij}(k-1|k-1) = p_{ij} \mathbf{u}_i(k-1) / \bar{C}_j \quad (33)$$

模型 j 的混合状态估计和协方差估计:

$$\hat{\mathbf{X}}_{0j}(k-1|k-1) = \sum_{i=1}^r \hat{\mathbf{X}}_i(k-1|k-1) \mathbf{u}_{ij}(k-1|k-1) \quad (34)$$

模型 j 的协方差估计:

到区域 q_j^* 的转移次数:若 $T_{c,t}^* = q_i^*$ 且 $T_{c,t+1}^* = q_j^*$, 则 $c_{ij} = c_{ij} + 1$, 其中, $T_{c,t}^*$ 表示 t 时刻对应的分类标签。

设 $N_i = \sum_{j=1}^3 c_{ij}$ 表示从区域 q_i^* 出发的总转移次数,区域

切换概率矩阵表示为:

$$M = \frac{C_T}{N_i} = [m_{ij}]_{3 \times 3}, \quad i, j \in \{1, 2, 3\} \quad (36)$$

其中 m_{ij} 表示为:

$$m_{ij} = \frac{c_{ij}}{N_i} \quad (37)$$

由式(31)与式(36)联立更新模型转移概率 P_m :

$$P_m = \omega_p P + \omega_m M = [p_{m,ij}]_{3 \times 3} \quad (38)$$

其中, ω_p 与 ω_m 分别表示区域切换概率的权重系数与模型转移概率的权重系数。

因此, 式(32)、式(33)更新为:

$$\begin{cases} \bar{C}_{m,j} = \sum_{i=1}^r p_{m,ij} \mathbf{u}_i(k-1) \\ \mathbf{u}_{m,ij}(k-1|k-1) = p_{m,ij} \mathbf{u}_i(k-1) / \bar{C}_{m,j} \end{cases} \quad (39)$$

将更新后的结果与量测 Z_j 一同输入 IMM 算法的后续步骤中, 得到最终的交互结果。

3 实验结果分析

本文通过图 4 所示无人车辆实验平台, 对提出的室内外无缝定位方法进行了系统分析和评价。评价指标包括区域识别准确度以及采样点误差均值。本实验平台基于 Ubuntu 20.04 和 ROS Noetic 系统环境, 配备了由北京星宇达公司研制的 XW-GI 类 GNSS 接收机, 用于输出 RTK 真实轨迹。LC-GNSS 产品则采用移远通信的 LC29H-E 系列 GNSS 模块。UWB 定位基站及标签使用了 DecaWave 公司研制的 DW1000 定位芯片。



图 4 无人车辆实验平台

Fig.4 Experimental platform of unmanned vehicle

本文在室外区域以及室内外过渡区域中使用千寻公司提供的 RTK 轨迹作为真实路径, 在室内区域中使用预先规定好的路径作为真实路径。通过中海达 ZTS-420 系列彩屏全站仪对 UWB 基站进行位置标定, UWB 定位标签布置于车辆的几何中心, LC-GNSS 接

收机则布置于车辆几何中心的两侧。

选择包含室内外环境的典型实验场地如图 5 所示, 红色实线表示室外及室内外过渡区域的无人车辆真实运动路径, 蓝色虚线表示室内区域的无人车辆真实运动路径, 蓝色圆表示起点, 红色圆表示终点。建立 X 轴方向指向车辆运动方向的右向, Y 轴方向指向车辆运动方向前向的运动坐标系, 将 LC-GNSS、UWB 以及 IMU 数据转换到该基准坐标系下, 描述无人车辆的室内外无缝定位过程。



图 5 真实实验场景

Fig.5 Real experimental scene

3.1 区域识别实验

图 6 展示了本文所建立的 PSO-SVM 分类预测模型、HMM 分类预测模型以及联合分类预测模型的区域分类结果, 其中标签 1 代表室外区域、标签 2 代表室内外过渡区域, 标签 3 则代表室内区域。区域识别结果显示, 在实验车辆的实际行驶轨迹中, 室外区域占比为 34.3%, 室内外过渡区域占比为 19.1%, 室内区域占比为 46.6%。

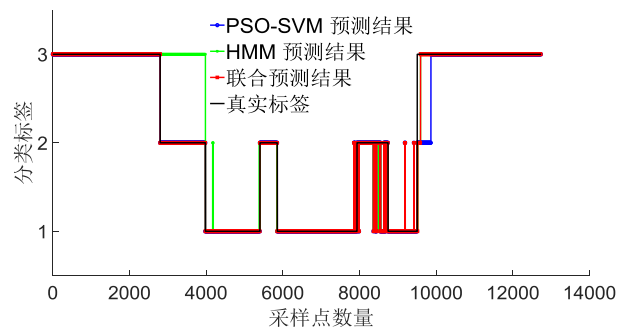


图 6 区域识别结果

Fig.6 Region recognition results

从图 6 中可以看出, HMM 在由室外出发向其他区域转移时的预测结果准确度更高, 但是由室内出发向半室外区域转移时会出现预测偏差。因为 HMM 模型在处理时序数据时能够有效捕捉到室内外环境变化的动态特征, 但是由于从室内环境向室外环境转移过

程中,传感器特征信号源变化更新不及时,并且 HMM 依赖于前序时间下的环境特征,这导致了从室内环境出发时 HMM 预测的滞后性; PSO-SVM 在室外及室内外过渡区域的预测准确度更高,但是从室内外过渡环境向室内转移过程中会出现预测偏差。因为 PSO 优化算法能够有效提升 SVM 的参数选择,从而在环境边界区域提供更精确的分类结果,但是从半室外环境转移至室内环境的边界训练样本不充分,导致了边界模糊性,通过增加准确的训练样本可以有效降低 PSO-SVM 的分类误差;联合分类预测结合了两种方法的优点,在时间维度保留 HMM 的状态转移先验以抑制传感器噪声的短期干扰,在空间维度集成 PSO-SVM 的实时分类结果以修正状态转移矩阵的累积偏差,使得识别结果更贴合真实环境标签,并且该模型在不同区域中表现均衡,能够综合处理室内外环境变化时的区域分类问题,为无人车辆提供贴合真实环境标签的区域识别结果,有效支撑多场景无缝定位系统的环境决策。

三种区域预测模型的准确度如表 2 所示,对比真实标签, PSO-SVM 的总体分类准确率为 95.96%, HMM 的总体分类精度为 88.56%,而联合预测的总体分类精度可以达到 98.09%,可看出本文所建立联合分类模型的分类准确度明显优于单一分类模型,能够更有效地利用多种分类方法的优势,提高整体区域性能。

表 2 三种区域分类精度对比

Tab.2 Comparison of classification accuracies for three regions

分类方式	准确度	分类方式	准确度
PSO-SVM	95.96%	联合分类	98.09%
HMM	88.56%	-	-

3.2 单一模型实验分析

图 7 展示了在本文实验场地中,实验车辆从室内




图 7 单一模型与本文算法的定位轨迹

Fig.7 Positioning trajectories of the single-model and the proposed algorithm

出发沿真实运动轨迹回到室内过程中本文所提算法与单一传感器、单一定位模型的定位轨迹对比。从图中可以看出, LC-GNSS 在室内环境下无法执行定位,但随着实验车辆向室外运动, LC-GNSS 逐渐恢复定位功能,定位误差逐渐减小;当实验车辆运动至室外边界并开始向室内环境转移时, LC-GNSS 的误差逐渐增大,当实验车辆完全进入室内环境后, LC-GNSS 信号丢失,无法继续提供定位功能。UWB 在室内环境中可以提供有效的定位信息,但随着实验车辆由室内向室外运动, UWB 的误差逐渐增大;当实验车辆离开室内环境边界时, UWB 受到严重的 NLOS 干扰,使其定位误差迅速增加,当实验车辆完全行驶至室外环境并且离开 UWB 基站通讯范围后, UWB 基站无法接收到标签信号,导致其在室外区域中无法执行定位功能;随着实验车辆由室外向室内运动, UWB 的定位能力逐步恢复。

ODR 定位模型依靠 LC-GNSS 提供量测, IMU 提供状态,并通过 EKF 耦合。当 LC-GNSS 无法提供定位信息时,依靠 IMU 推算定位轨迹,提升定位精度。I-OTR 定位模型依靠 LC-GNSS 与 UWB 同时提供量测, IMU 提供状态信息,并通过 EKF 滤波耦合。由于 LC-GNSS 与 UWB 表现出相反的定位特性,在两者同时输出定位信息时根据权重信息动态选择量测,可以有效提升整体定位精度,尤其是在室内外过渡区域中, EKF-I-OTR 表现出了较好的定位效果。IDR 与 EKF-ODR 效果类似,当 UWB 无法提供定位信息时,通过 IMU 推算定位轨迹,提升定位精度。本文算法相较于单一传感器与单一定位模型,均表现出了更优秀的定位能力,尤其是在室内外过渡区域中输出的定位结果更贴合真实运动轨迹,表明了本文所提算法在无人车辆完整室内外运动过程中的优越性。

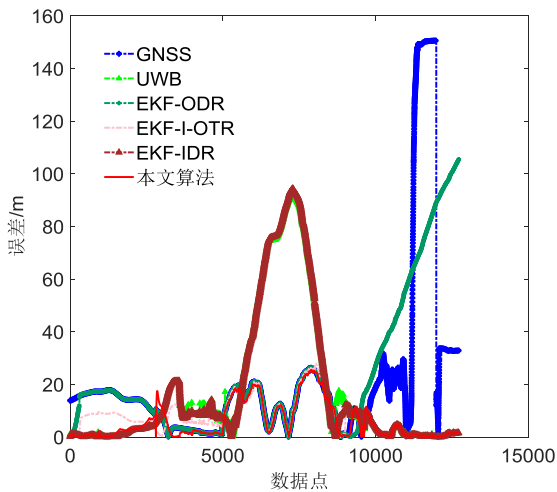
表 3 则展示了实验车辆采用不同定位方案的定位误差均值。从表 3 中可以看出,本文所提算法相比于单一传感器、单一定位模型的整体定位精度显著提升。具体而言,本文算法的整体定位平均误差最小,特别是在室内外过渡区域,本文算法的定位误差对比单一传感器分别减小了 0.8 m 和 2.19 m,定位精度分别提升了 46.78%和 70.65%;对比单一定位模型 (ODR、I-OTR、IDR),定位误差分别减小了 0.79 m、0.25 m 以及 2.18 m,定位精度分别提升了 46.47%、21.56%以及 70.55%。此外,相较于其他定位方案,本文算法的总体误差仅为 1.08 m,相较于 I-OTR 模型减小了 0.33 m,定位精度提升了 23.4%,在本次实验中本文算法实现了全面的定位精度提升。

表 3 单一模型的定位误差均值

Tab.3 Mean localization errors of the single-model

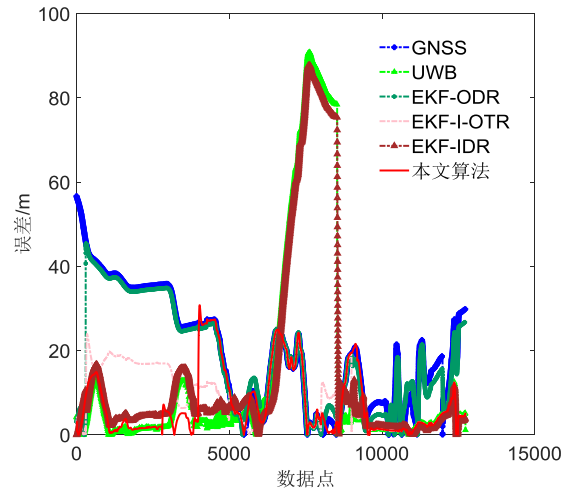
误差均值	室外/m	室内外过渡/m	室内/m	总体/m
GNSS	1.94	1.71	6.63	4.16
UWB	5.88	3.10	0.54	2.85
ODR	1.90	1.70	5.9	3.74
I-OTR	1.66	1.16	1.32	1.41
IDR	5.79	3.09	0.44	2.82
本文算法	1.94	0.91	0.53	1.08

图 8 展示了本文方法与单一传感器、单一定位模型在不同方向上的误差变化曲线。可以看出,本文方法通过实时环境特征感知与多模型协同优化,有效抑制了定位误差在多维度的累积,尤其在室内外过渡区域的复杂场景中表现出更强的鲁棒性。实验结果从定量角度验证了所提方法通过多模态信息融合与模型互补策略,在无人车辆全场景无缝定位中实现了定位精度与可靠性的显著提升,为复杂环境下的高精度定位系统设计提供了重要的理论与实验支撑。



(a) 单一模型 X 轴方向误差变化曲线

(a) X-axis error variation curves of the single-model



(b) 单一模型 Y 轴方向误差变化曲线

(b) Y-axis error variation curves of the single-model

图 8 单一模型误差变化曲线

Fig.8 Error variation curves of the single-model

3.3 无缝定位方法实验分析

图 9 展示了在本文实验场地中,实验车辆从室内出发沿真实运动轨迹回到室内过程中,本文所提算法与传统 IMM 算法以及 FKF 算法的定位轨迹比较。从图中可以看出,在室内外过渡区域,IMM 算法相较于 FKF 在定位轨迹贴合度上表现更优。这一差异的核心机制在于,IMM 算法通过马尔可夫转移概率矩阵实现对动态环境和模型不确定性的自适应建模,而 FKF 算法依赖主滤波器预设阈值进行融合权重分配,其静态权重策略无法有效利用过渡区域的特征先验信息,导致子模型切换存在滞后性,进而影响定位精度。本文方法相较于传统 IMM 算法与 FKF 方法定位效果显著提升,其核心原因在于本文算法对实验车辆预先进行了区域识别,明确了车辆运动的区域边界,在实验车辆行驶至对应区域时可以正确选择子模型量测,其次,本文算法优化了子模型切换概率,增强了算法对非结构化场景的动态适应能力,使得本文算法在过渡区域的定位轨迹与真实运动路径吻合度更高,验证了所提方法在复杂环境下的鲁棒性和精确性。

表 4 展示了在不同区域中,实验车辆采用不同定位方案时的定位误差均值。从表 4 中可以看出,本文所提出的算法相比于 FKF 和 IMM 算法的整体定位精度均有显著提升。具体而言,本文算法的整体定位精度为 1.08 m,相较于 FKF 与 IMM,定位误差分别减小了 0.84 m 和 0.31 m,整体定位精度分别提升了 43.75%和 22.30%,从量化指标中可以有效反映出本文算法在无缝定位过程中的优越性。




图 9 同类型无缝定位算法定位轨迹

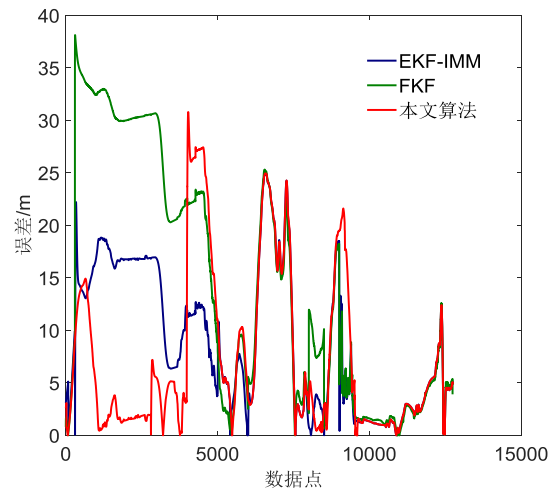
Fig.9 Positioning trajectories of same-type seamless positioning algorithms

表 4 同类型无缝定位算法定位误差均值 (单位: 米)

Tab.4 Mean positioning error of same-type seamless positioning algorithms (Unit: m)

误差均值	室外	室内外过渡	室内	总体
FKF	1.79	1.52	2.18	1.92
IMM	1.66	1.04	1.33	1.39
本文算法	1.94	0.91	0.53	1.08

图 10 展示了 FKF 和 IMM 算法以及本文算法在 X 和 Y 方向上的误差变化曲线, 通过对比可见, 本文算法在全方向定位过程中展现出显著优势, 其误差曲线波动幅度始终低于对比算法, 且在动态场景中保持更小的偏差范围, 呈现更优的收敛特性。有效验证了其在多维度定位任务中相较于传统无缝定位方案的鲁棒性与精确性提升。



(b) 同类型无缝定位算法 Y 轴方向误差变化曲线
(b) Y-axis error variation curves of Same-Type Seamless Positioning Algorithms

图 10 同类型无缝定位算法误差变化曲线


Fig.10 Error variation curves of Same-Type Seamless Positioning Algorithms

表 5 呈现了实验车辆在不同区域采用各类定位方案时, 在既定坐标系 X 轴方向上的均方根误差 (RMSE)。

表 5 同类型无缝定位算法 X 轴方向均方根误差 (单位: 米)

Tab.5 Root mean square errors (RMSE) in the X-axis of same-type seamless positioning algorithms (Unit: m)

均方根误差	室外	室内外过渡	室内	总体
FKF	1.22	1.29	0.83	1.05
IMM	1.24	1.22	0.53	0.91
本文算法	1.23	1.36	0.26	0.80



(a) 同类型无缝定位算法 X 轴方向误差变化曲线
(a) X-axis error variation curves of same-type seamless positioning algorithms

由表 5 可见, 本文提出的算法相较于 FKF 与 IMM 算法, 在整体定位精度上实现了显著提升。具体而言, 所提算法在 X 轴方向的整体 RMSE 为 0.80 m, 较 FKF

算法降低 0.25 m、精度提升 23.80%，较 IMM 算法降低 0.11 m、精度提升 12.09%。

表 6 呈现了实验车辆在不同区域采用各类定位方案时，在既定坐标系 Y 轴方向上的均方根误差 (RMSE)。由表 6 可见，本文提出的算法相较于 FKF 与 IMM 算法，在整体定位精度上实现了显著提升。具体而言，所提算法在 Y 轴方向的整体 RMSE 为 0.88 m，较 FKF 算法降低 0.99 m、精度提升 52.94%，较 IMM 算法降低 0.28 m、精度提升 24.14%。这些量化结果充分印证了本文算法在无缝定位场景中的优越性。

表 6 同类型无缝定位算法 Y 轴方向误差均值
(单位: 米)

Tab.6 Root mean square errors (RMSE) in the Y-axis of same-type seamless positioning algorithms (Unit: m)

均方根误差	室外	室内外过渡	室内	总体
FKF	1.72	1.80	2.18	1.87
IMM	1.50	0.89	1.19	1.16
本文算法	1.28	0.49	0.42	0.88

4 结论

本文针对无人车辆室内外无缝定位过程中区域识别模糊导致的定位精度退化问题，提出了一种粒子群优化支持向量机 (PSO-SVM) 算法。通过实验验证得出，本文所述方法能够有效进行环境区域识别，弥补了 LC-GNSS 以及 UWB 在信号受阻情况下定位缺失的不足，同时优化了 IMM 算法中子模型切换概率，提升了整体融合定位精度。并且相较于单一传感器、单一定位模型、FKF 算法以及传统的 IMM 算法，本文算法具有明显优势，通过本文算法输出的车辆定位精度在多维度下表现均衡，可以有效提高无人车辆室内外无缝定位的准确性和连续性，展现出优越、稳定的定位性能以及对复杂环境的良好适应性。

参考文献(References):

[1] 杨秀建, 敖鹏, 沈世全, 等. 面向复杂环境的 UWB/LiDAR/IMU 组合定位方法[J]. 中国惯性技术学报, 2024, 32(07): 654-662.
Yang X, Ao P, Shen S, et al. UWB/LiDAR/IMU combined localization method for complex environment[J]. Journal of Chinese Inertial Technology, 2024, 32(07): 654-662.

[2] Zhao X, Tang P, Song Q, et al. Experimental analysis of multipath effects on GNSS positioning in urban canyon[C]//2021 IEEE 4th International Conference on Electronic Information and Communication Technology (ICEICT). China, August 18-20, 2021: 557-562.

[3] 李旭, 孔鑫, 刘锡祥, 等. 基于交互多模型距离平滑的 UWB/IMU 因子图组合导航方法[J]. 中国惯性技术学报, 2022, 30(3): 322-327.
Li X, Kong X, Liu X, et al. UWB/IMU factor graph integrated navigation method based on interactive multi-model distance smoothing[J]. Journal of Chinese Inertial Technology, 2022, 30(3): 322-327.

[4] Fernandez-Prades C, Presti L, Falletti E. Satellite radio

localization from GPS to GNSS and beyond: novel technologies and applications for civil mass market[J]. Proceedings of the IEEE, 2011, 99(11): 1882-1904.

[5] Li Y, Chen R, Niu X, et al. Inertial sensing meets machine learning: Opportunity or challenge[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 23(8): 9995-10011.

[6] 武文博, 吕志伟, 周玟龙, 等. 基于组合历元新息抗差的 GNSS/INS 欺骗检测方法[J]. 中国惯性技术学报, 2024, 32(04): 354-362.
Wu W, Lyu Z, Zhou W, et al. GNSS/INS spoofing detection method based on combined epoch innovation robustness[J]. Journal of Chinese Inertial Technology, 2024, 32(04): 354-362.

[7] Zhang S, Tang H, Chen L, et al. A seamless pedestrian localization system based on GNSS/IMU/UWB/MAP integration[J]. IEEE Internet of Things Journal, 2025, 12(11): 16653-16667.

[8] Kohtake N, Morimoto S, Kogure S, et al. Indoor and outdoor seamless positioning using indoor messaging system and GPS[C]//Proceedings of the international conference on indoor positioning and indoor navigation (IPIN2011), Guimarães, Portugal. 2011: 21-23.

[9] Feng T, Liu Y, Yu Y, et al. CrowdLOC-S: Crowdsourced seamless localization framework based on CNN-LSTM-MLP enhanced quality indicator[J]. Expert Systems with Applications, 2024, 243: 122852.

[10] Li X, Wu Z, Shen Z, et al. An indoor and outdoor seamless positioning system for low-cost UGV using PPP/INS/UWB tightly coupled integration[J]. IEEE Sensors Journal, 2023, 23(20): 24895-24906.

[11] 张威奕, 曾庆喜, 张鹏娜, 等. 基于 UKF 的车辆 GPS/蜂窝网无缝定位算法[J]. 中国惯性技术学报, 2015, 23(01): 76-80.
Zhang W, Zeng Q, Zhang P, et al. Vehicle GPS/cellular network seamless positioning algorithm based on UKF[J]. Journal of Chinese Inertial Technology, 2015, 23(01): 76-80.

[12] Yao L, Li M, Xu T, et al. GNSS/UWB/INS indoor and outdoor seamless positioning algorithm based on federal filtering[J]. Measurement Science and Technology, 2023, 35(1): 015135.

[13] 张容阁. 基于 UWB/GNSS/IMU 的机器人室内外无缝定位技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2020.
Zhang R. Research on indoor-outdoor seamless robot positioning technology based on UWB/GNSS/IMU[D]. Harbin: Harbin Institute of Technology, 2020.

[14] 王琳. 室内外无缝定位中的情境感知方法研究[D]. 上海: 上海交通大学, 2017.
Wang L. Research on context awareness in indoor and outdoor seamless positioning[D]. Shanghai: Shanghai Jiao Tong University, 2017.

[15] Li M, Zhou P, Zheng Y, et al. IODetector: A generic service for indoor/outdoor detection[J]. ACM Transactions on Sensor Networks (TOSN), 2014, 11(2): 1-29.

[16] Zhu Y, Luo H, Wang Q, et al. A fast indoor/outdoor transition detection algorithm based on machine learning[J]. Sensors, 2019, 19(4): 786.

[17] 曾庆栋, 陈光辉, 李文鑫, 等. 基于粒子群-支持向量机算法的激光诱导击穿光谱钢铁快速检测与分类[J]. 光谱学与光谱分析, 2024, 44(06): 1559-1565.
Zeng Q, Chen G, Li W, et al. Classification of special steel based on LIBS combined with particle swarm optimization and support vector machine[J]. Spectroscopy and Spectral Analysis, 2024, 44(06): 1559-1565.

[18] Xu J. An extended one-versus-rest support vector machine for multi-label classification[J]. Neurocomputing, 2011, 74(17): 3114-3124.