

doi:10.3969/j.issn.1673-9833.2024.06.010

基于 AAPC、CS 与卡尔曼滤波的 WiFi 室内定位跟踪算法

胡久松, 孙英杰, 黄晓峰, 谷志茹, 李 浩

(湖南工业大学 轨道交通学院, 湖南 株洲 412007)

摘 要: 针对基于位置指纹的 WiFi 室内定位技术的定位精度尚未达到实际应用要求的问题, 提出一种融合自适应仿射传播 (AAPC)、压缩感知 (CS) 与卡尔曼滤波的 WiFi 室内定位跟踪算法。其中, 离线阶段使用 AAPC 算法生成具有最优聚类效应性能的聚类指纹, 在线阶段采用 CS 与最近邻算法进行位置估计。最后, 通过将卡尔曼滤波与物理限制相集成来进行定位跟踪。通过采集大量真实实验数据, 证明了所开发的算法具有更高的定位精度和更准确的轨迹跟踪效果。

关键词: WiFi 室内定位; 自适应仿射传播; 压缩感知; 卡尔曼滤波

中图分类号: TN92

文献标志码: A

文章编号: 1673-9833(2024)06-0071-08

引文格式: 胡久松, 孙英杰, 黄晓峰, 等. 基于 AAPC、CS 与卡尔曼滤波的 WiFi 室内定位跟踪算法 [J]. 湖南工业大学学报, 2024, 38(6): 71-78.

A WiFi Indoor Positioning and Tracking Algorithm Based on AAPC, CS and Kalman Filtering

HU Jiusong, SUN Yingjie, HUANG Xiaofeng, GU Zhiru, LI Hao

(College of Railway Transportation, Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: In view of the flaw that the positioning accuracy of WiFi indoor positioning technology based on position fingerprint fails to meet the practical application requirements, a WiFi indoor positioning and tracking algorithm integrating adaptive affine propagation (AAPC), compressed sensing (CS), and Kalman filtering has thus been proposed. Among them, AAPC algorithm is used to generate clustering fingerprints with the best clustering effect performance in the offline stage, followed by a position estimation during the online phase with CS and nearest neighbor algorithms adopted. Finally, localization and tracking are performed by combining Kalman filtering with physical constraints. Based on a collection of a large amount of real experimental data, it has been proven that the developed algorithm is characterized with a higher positioning accuracy and more accurate trajectory tracking effect.

Keywords: WiFi indoor positioning; adaptive affine propagation clustering (AAPC); compressed sensing (CS); Kalman filtering

收稿日期: 2023-06-07

基金项目: 湖南省教育厅优秀青年基金资助项目 (293832); 湖南省自然科学基金资助项目 (2023JJ50198, 2022JJ50005)

作者简介: 胡久松, 男, 湖南工业大学讲师, 博士, 主要研究方向为智能感知与信息处理和室内定位,

E-mail: hujiusong2008@163.com

0 引言

随着互联网技术的飞速发展和 WiFi 技术的广泛普及,室内定位技术的精确性、高效率 and 便捷性成为人们日益增长的需求,推动了多种室内定位技术的发展^[1-2]。尤其是基于位置指纹的 WiFi 室内定位技术,因其实现成本低且适用范围广而倍受瞩目,并得到了广泛应用^[3]。该技术的定位系统分为离线和在线两个阶段。

离线阶段的主要任务是数据采集和预处理。由于建立高质量的数据库需要采集大量指纹信息,这对人力和物力资源造成了巨大挑战。因此,为了在保持定位精度的同时尽量减少数据量,大量的技术方法被提出,如多元高斯混合模型^[4]、压缩感知算法^[5]、克里金算法^[6]和随机森林技术(random forest, RF)^[7]等。为了缩短定位时间,数据库构建后通常需要进行聚类处理,常用的聚类算法包括 K -means^[8]、仿射传播聚类(affinity propagation clustering, APC)^[9]和核模糊 C 均值^[10]等。

在线阶段的主要任务是通过定位算法对实时接收的信号数据进行处理,以估计目标位置。目前,位置指纹匹配算法主要分为确定性方法^[11-13]、概率性方法^[14-18]、机器学习方法^[19-21]以及压缩感知方法(compressed sensing, CS)^[22-24]。与其他几种方法相比,确定性方法更轻量化,在确保定位精度的同时此类方法的时间消耗更少。确定性方法基于 K 最近邻算法(K -nearest neighbor, KNN)^[11],在线定位阶段该算法将当前收到的信号强度值与离线数据库中相似度最高的 K 个点进行匹配,最终定位结果由这些点的中心确定,在此方法基础上通过赋予 K 个点权重提出加权 K 近邻算法(weighted K -nearest neighbor, WKNN)^[12-14],进一步提高了定位精度。为了解决 K 值固定的问题,自适应加权 K 最近邻(self-adaptive weight K -nearest Neighbor, SAWKNN)^[25]方法被提出,该方法能够根据具体情况自适应地选择 K 值。根据用户的运动状态,提出了软范围限制 K 最近邻(soft range limited K -nearest neighbors, SRL-KNN)^[26]以及受限 K 最近邻方法(restricted weight K -nearest neighbor, RWKNN)^[27]。虽然在之前的研究中确定性方法已被广泛研究和讨论,但是仍然面临以下问题:1)如何降低定位时耗,2)如何同时保证定位速度和定位精度,3)室内定位中如何对连续运动状态进行轨迹跟踪。

基于以上考虑,本研究进行如下创新:1)通过引入自适应传播放射聚类算法(adaptive affine

propagation clustering, AAPC)^[28]降低定位时耗。

2)根据不同噪声环境,通过将 CS 算法与 WKNN 算法相结合提高定位精度。3)定位完成后通过卡尔曼滤波的方法优化轨迹,实现了对用户的定位跟踪。

1 系统模型

1.1 基于位置指纹的定位系统框架

如图 1 所示,在离线过程中,终端设备会在预先设定的采样点上采集指纹数据,并对其进行预处理,之后利用 AAPC 算法将获取的指纹分为不同的指纹成员和相应的指纹数据库。在线阶段也将分为两个过程——“定位”和“跟踪”。定位阶段分为粗定位和精定位两个阶段,在粗定位阶段中,当移动终端发来定位查询请求时,定位引擎会通过计算该请求所对应的位置数据与参考数据库中相关信号之间的相似性来决定其数据属于哪一特征集。精定位过程中,采用 CS+WKNN 的联合算法获取位置估计。最后,在跟踪阶段采用卡尔曼滤波和物理限制相结合的方法进行轨迹跟踪。




图 1 基于位置指纹的定位系统框图

Fig. 1 Positioning system block diagram base on location fingerprint

1.2 定位相关的数学表达

为了保证实验数据的准确性和可靠性,当移动终端到达参考点时,需要面向东、南、西、北 4 个方向各采集某一个 AP 的若干数据(本研究中为 40 个),并且对每个方向所得的数据进行求均值处理,得到移动终端在该点对应某个 AP 在每个方向的信号强度平均值,

用 $rss_{i,j}^d$ 表示, 其中 d 为移动终端的方向, i 为该数据对应的 AP 编号, j 为移动终端所在的参考点位置。于是该点对应所有 AP 的信号强度平均值的数学表达式如公式 (1) 所示, L 为此参考点移动终端可检测到的 AP 数目。

$$rss_j^d = [rss_{1,j}^d, rss_{2,j}^d, \dots, rss_{i,j}^d, \dots, rss_{L,j}^d]。 \quad (1)$$

于是第 r 个测试点上检测到的多个 AP 的数据可表示为

$$rss_r = [rss_{1,r}, rss_{2,r}, \dots, rss_{i,r}, \dots, rss_{L,r}]。 \quad (2)$$

则在粗定位过程中, 计算信号强度与类代表之间的相似度可以表示为

$$\text{sim}_{r,c} = |rss_r - \mathbf{ch}_c|^1, \quad (3)$$

式中: c 为聚类数目; $\mathbf{ch}_c$ 为类代表。

在精定位过程中, 通过计算 rss_r 与匹配类中每个成员之间的相似度而得到最后的定位结果。

2 室内定位跟踪算法

2.1 AAPC 聚类算法

位置指纹采集完成后, 采用 AAPC 聚类算法进行聚类, 生成不同的指纹类别^[29]。式 (4) 表示 AAPC 采用二分法动态改变偏向参数 p 得到聚类结果, 聚类数为 $[2, \sqrt{N}]$ 。

$$\begin{cases} p_e = p_n, & c_n > c_i; \\ p_s = p_n, & c_n < c_i; \\ p_{n+1} = 0.5 \cdot (p_e + p_s)。 \end{cases} \quad (4)$$

式中: p_e 和 p_s 分别为二分法的起始值和结尾值; n 为迭代次数; c_i 为生成的聚类数目, 当生成的聚类数目与目标聚类数目相等时, 得到聚类结果 $\mathbf{ch}_c$, N 为参考点的总数目。

2.2 压缩感知定位

由于移动终端在定位区域内某一时刻的位置与对应的最佳参考点具有唯一性, 因此可以将当前时刻用户的位置表述为一个 1 稀疏向量 $\mathbf{a}$, 从而将室内定位的问题转化为如何恢复该稀疏向量。稀疏向量 $\mathbf{a}$ 如式 (5) 所示。

$$\mathbf{a} = [0, \dots, 0, 1, 0, \dots, 0]^T, \quad (5)$$

根据压缩感知原理, rss_r 又可以表示为

$$rss_r = \mathbf{c}_{cn} \cdot \mathbf{a} + \boldsymbol{\varepsilon}。 \quad (6)$$

式 (6) 中: $\mathbf{c}_{cn}$ 为通过 AAPC 聚类算法生成通过公式 (3) 得出的最佳匹配类; $\boldsymbol{\varepsilon}$ 为实际应用中的环境噪声。

将等式两边乘以感知矩阵 $\mathbf{P}$, $\mathbf{P}$ 为 AP 选中矩阵:

$$\mathbf{Y} = \mathbf{P} \cdot rss_r = \mathbf{P} \cdot \mathbf{c}_{cn} \cdot \mathbf{a} + \boldsymbol{\varepsilon}。 \quad (7)$$

由于 $\mathbf{P}$ 和 $\mathbf{c}_{cn}$ 具有一定的空间相关性, 不满足传感矩阵非相关性的条件, 所以将感知矩阵 $\mathbf{P}$ 和矩阵 $\mathbf{c}_{cn}$ 进行正交化处理。

令 $\mathbf{Z} = \mathbf{M}\mathbf{Y}$, 其中 $\mathbf{M}$ 定义为

$$\mathbf{M} = \mathbf{A}\mathbf{E}^\dagger。 \quad (8)$$

式中 $\mathbf{E} = \mathbf{P} \cdot \mathbf{c}_{cn}$; $\mathbf{A} = \text{orth}(\mathbf{E}^T)^T$, 其中 $(\cdot)^T$ 表示矩阵的转置, $\text{orth}(\cdot)$ 表示对某一矩阵的规范正交化操作; $\mathbf{E}^\dagger$ 为 $\mathbf{E}$ 伪逆矩阵。

则有 $\mathbf{Z} = \mathbf{M}\mathbf{Y} = \mathbf{A}\mathbf{E}^\dagger \cdot \mathbf{E} \cdot \mathbf{a} + \mathbf{M} \cdot \boldsymbol{\varepsilon} = \mathbf{A} \cdot \mathbf{a} + \mathbf{M} \cdot \boldsymbol{\varepsilon}$ 。 (9) 式中, $\mathbf{A}$ 为满足正交化的矩阵。

于是问题转化为如何求解公式 (10) 中 L_1 的范数最小化问题:

$$\hat{\mathbf{a}} = \arg\min \|\mathbf{a}\|, \text{ s. t. } \mathbf{Z} = \mathbf{A} \cdot \mathbf{a} + \mathbf{M} \cdot \boldsymbol{\varepsilon}。 \quad (10)$$

式中, $\|\cdot\|$ 是向量的 L_1 范数。

公式 (11) 为 $\mathbf{a}$ 中大于阈值的值的集合, 用 D 表示。

$$D = \{n | a(n) > \lambda\}。 \quad (11)$$

最后的位置估计为

$$LOC(x, y) = \sum_{n \in D} \mathbf{a}(n)(x_n, y_n) / \sum_{n \in D} \mathbf{a}(n)。 \quad (12)$$

CS 算法利用了信号强度的稀疏性, 可以快速采集和重建 WiFi 信号强度数据, 并且能够从稀疏数据中准确地提取出关键信息, 为提高室内定位精度提供了新途径。

2.3 WKNN 定位

WKNN 定位方法, 在实验的外部条件满足需求时, 算法的定位精度具有一定的保证, 并且由于其算法的简易性使其成为室内定位中比较经典和常用的算法。其原理如下: 首先选择出 $\mathbf{ch}_c$ 中最佳匹配的 K 个候选参考点位置, 然后采用这 K 个位置加权求和得到最后的位置估计, 如式 (13) 所示。

$$LOC(x, y) = \sum_{l=1}^K LOC(x_l, y_l) / \sum_{l=1}^K \omega_l, \quad (13)$$

式中: $\omega_l = 1 / \text{sim}(r, l)$; $LOC(x_l, y_l)$ 是指纹数据库中第 l 个指纹位置。

2.4 CS 与 WKNN 的联合定位

2.4.1 联合定位算法原理

当环境噪声较大时, 由于信号恢复效果不佳, CS 算法的定位结果误差较大。因此, 为确保定位准确性, 需要降低环境噪声水平。根据压缩感知算法的定位原理, 可以通过最小残差项对应的参考点位置来估计目标点位置, 令 $\mathbf{a}$ 求解出的非零位为 $\hat{\mathbf{a}}$, 在理想环境下, 当环境噪声很小或没有噪声时, 可以求得 $\hat{\mathbf{a}} = 1$ 。然而, 在实际应用环境中, 环境噪声的影响是不可避免的, 导致 $\hat{\mathbf{a}}$ 值不为 1, 并且偏离程度与

环境噪声的大小成正相关。即环境噪声越大, $\dot{\mathbf{a}}$ 与 1 的偏离程度越大; 环境噪声越小, $\dot{\mathbf{a}}$ 与 1 的偏离程度越小。根据这个结论, 可以判断 CS 算法得出的定位结果的准确性。取阈值 $\delta=0.1$, 判断 $|\dot{\mathbf{a}}-1|$ 与阈值的大小关系。当 $|\dot{\mathbf{a}}-1|$ 小于阈值时, 可以认为与 1 的偏离程度较小, 即 CS 算法受环境噪声影响较小; 反之, 当 $|\dot{\mathbf{a}}-1|$ 大于阈值时, 环境影响较大。因此, 文章提出的联合定位方法在环境噪声影响较小时采用 CS 算法结果, 因为此时 CS 的信号重构效果更好; 而在受到较大环境噪声影响时, WKNN 算法的结果更准确。

2.4.2 联合定位算法实现流程

首先, 当收到定位查询指令时, 系统通过查询之前离线阶段 AAPC 算法得到的聚类结果选出与之相比最相似的类, 即粗定位阶段。然后, 通过 CS 定位算法进行精定位, 精定位阶段由前文所述, 可知通过判断是否满足 $|\dot{\mathbf{a}}-1|<\delta$ 来检验得到的结果是否满足定位结果, 当满足此条件时即符合定位要求, 否则利用 WKNN 算法重新进行定位。最后, 进行位置估计, 公式如下:

$$LOC(x, y) = \begin{cases} \frac{\sum_{l=1}^K LOC(x_l, y_l)}{\sum_{l=1}^K \omega_l}, & |\dot{\mathbf{a}}-1| > \delta; \\ \frac{\sum_{n \in D} \mathbf{a}(n)(x_n, y_n)}{\sum_{n \in D} \mathbf{a}(n)}, & |\dot{\mathbf{a}}-1| \leq \delta. \end{cases} \quad (14)$$

2.5 卡尔曼滤波

卡尔曼滤波^[30-31]是通过系统的输入输出观测数据, 以最小均方差为估计基准, 通过观测数据和系统的前一时刻状态对系统当前时刻状态进行最优状态估计, 其算法模型如下。

假设每一个点的状态都可以用公式 (15) 表示, $\dot{x}_k$ 、 $\dot{y}_k$ 、 x_k 、 y_k 分别为该点在 x 轴上的位移、在 y 轴上的位移、在 x 轴上的速度、在 y 轴上的速度, 在理想状态下, 运动状态为匀速直线运动, 于是有状态方程 (16), 可知状态转移矩阵 $\mathbf{F}$, T 为定位的间隔时间, 取值为 1 s, $\mathbf{W}_k$ 代表期望为 0、协方差为 $\mathbf{Q}$ 的过程噪声。观测向量如式 (17) 所示。 $\mathbf{Z}_{k1}$ 、 $\mathbf{Z}_{k2}$ 分别为 x 轴和 y 轴的观测值。公式 (18) 给出观测方程的表达式, 可知观测矩阵为 $\mathbf{H}$, $\mathbf{V}_k$ 代表期望为 0、协方差为 $\mathbf{R}$ 的观测噪声。噪声协方差矩阵 $\mathbf{Q}$ 如式 (19) 所示^[32]。根据实验统计, q 的取值为 $200 v_{\max}^2/T$, x 轴方向和 y

轴方向的测量噪声协方差取 $\mathbf{R} = \begin{bmatrix} 20 & 0 \\ 0 & 20 \end{bmatrix}$ 。

$$\mathbf{X}_k = [\dot{x}_k \quad \dot{y}_k \quad x_k \quad y_k]^T; \quad (15)$$

$$\begin{bmatrix} \dot{x}_k \\ \dot{y}_k \\ x_k \\ y_k \end{bmatrix} = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \dot{x}_{k-1} \\ \dot{y}_{k-1} \\ x_{k-1} \\ y_{k-1} \end{bmatrix} + \mathbf{W}_k, \quad \mathbf{W}_k \sim (0, \mathbf{Q}); \quad (16)$$

$$\mathbf{Z}_k = [\mathbf{Z}_{k1} \quad \mathbf{Z}_{k2}]^T; \quad (17)$$

$$\begin{bmatrix} \mathbf{Z}_{k1} \\ \mathbf{Z}_{k2} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} \dot{x}_k \\ \dot{y}_k \end{bmatrix} + \mathbf{V}_k, \quad \mathbf{V}_k \sim (0, \mathbf{R}); \quad (18)$$

$$\mathbf{Q} = q \cdot \begin{bmatrix} \frac{T^3}{3} & 0 & \frac{T^2}{2} & 0 \\ 0 & \frac{T^3}{3} & 0 & \frac{T^2}{2} \\ \frac{T^2}{2} & 0 & T & 0 \\ 0 & \frac{T^2}{2} & 0 & T \end{bmatrix}. \quad (19)$$

用户在不同的时间段内有不同的运动方向, 因此在进行卡尔曼滤波之前需要对筛选出的坐标点进行分段处理, 速度大小默认为 1 m/s, 假设沿着 x 轴和 y 轴正方向为 +1, 则负方向为 -1, 例如在某一段沿着 x 轴进行运动, 则在这一段速度表示为 $[+1, 0]$ 。于是将筛选出的 132 个坐标点, 根据表 1 进行分段。

表 1 目标点的分段表

Table 1 A segmentation table of target points

序号	目标点	速度
1	1-23	[1, 0]
2	24-31	[0, -1]
3	32-40	[0, 1]
4	41-43	[1, 0]
5	44-52	[0, -1]
6	53-57	[0, 1]
7	58-66	[1, 0]
8	67-76	[0, -1]
9	77-92	[0, 1]
10	93-106	[0, 1]
11	107-115	[-1, 0]
12	116-119	[0, 1]
13	120-123	[0, -1]
14	124-132	[-1, 0]

分段完毕之后对卡尔曼滤波进行初始化操作。卡尔曼滤波的模型如下:

状态预测方程为

$$\hat{\mathbf{x}}_k^- = \mathbf{F} \mathbf{x}_{k-1}^-; \quad (20)$$

误差协方差预测方程为

$$\mathbf{P}_k^- = \mathbf{F} \mathbf{P}_{k-1} \mathbf{F}^T + \mathbf{Q}; \quad (21)$$

计算卡尔曼增益方程为

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}^T (\mathbf{H} \mathbf{P}_k^- \mathbf{H}^T + \mathbf{R})^{-1}; \quad (22)$$

更新预测状态方程为

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{Z}_k - \mathbf{H} \hat{\mathbf{x}}_k^-); \quad (23)$$

更新误差协方差方程为

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_k^-. \quad (24)$$

通过卡尔曼滤波的模型可知, 卡尔曼滤波需要初始化 ($k=1$ 时刻) 的对象有两个, 后验估计 $\hat{\mathbf{x}}_k$ 和其协方差矩阵 $\mathbf{P}_k$ 。卡尔曼滤波的输入为上一时刻的状态值 $\hat{\mathbf{x}}_k$ (即预测值) 和观测值 $\mathbf{Z}_k$, 实验中的预测值是已知的用户移动距离和方向, 观测值由当前时刻的真实状态提取出的位置信息加上观测噪声 $\mathbf{V}_k$ 组成, 即

$LOC(x, y)$, 当 $k=1$ 时 $\hat{\mathbf{x}}_k = \mathbf{Z}_k$, $\mathbf{P}_k$ 为 $\begin{bmatrix} \mathbf{R} & 0 \\ 0 & \mathbf{I} \end{bmatrix}$, $\mathbf{I}$ 为二

阶单位矩阵。初始化完成后, 通过卡尔曼滤波进行轨迹跟踪优化, 通过式 (23) 得到最后的实验结果。

3 实验与结果分析

本章节搭建了实验环境, 验证了 AAPC 聚类方法的有效性, 比较了联合定位算法与单项算法的实验结果, 并分析了使用卡尔曼滤波算法进行轨迹优化的实验结果。

3.1 实验环境搭建

本文采用的实验环境如图 2 所示^[26], 圆点标示了参考点 (RPs) 的位置信息。实验环境参数如表 2 所示。实验过程中, 当出现某一个 AP 信号无法检测到时, 该值采用默认值 -100 dBm。




图 2 定位区域平面图

Fig. 2 Positioning area plan

表 2 实验环境参数

Table 2 Experimental environment parameters

环境覆盖面积 / m^2	RPs 数目	AP 信号数量	参考点指纹数据
50 × 18	538	339	2 152

3.2 AAPC 算法实验结果

AAPC 算法在时耗性上显著提高, 并进一步提高

了定位准确度。实验使用联想拯救者设备, 表 3 显示了部分配置参数。引入 AAPC 聚类算法前后, 单次平均定位时间从 1.09 ms 减少至 0.90 ms, 减少了约 21%。文章采用箱形图显示定位结果的误差分布, 每个箱形图包含 6 个值: 上边缘 (1.5 倍)、上四分位 (75%)、均值 (图中用小正方形表示)、中位值、下四分位 (25%)、下边缘 (1.5 倍)。在箱形图中可以清晰地看出算法的定位误差在平均值和边缘分布的情况。图 3 显示联合算法加入 AAPC 聚类后, 下四分位从 0.27 m 变为 0, 表示获得了更多较小误差, 上四分位从 1.23 m 降至 1.15 m, 降低了约 6.9%, 说明较大误差项有所降低。使用 AAPC 聚类的联合定位算法平均误差为 0.83 m, 未使用的为 0.94 m, 定位精度提高了约 13.2%。综上, AAPC 能显著改善定位时耗和精度。

表 3 联想拯救者部分配置参数

Table 3 Lenovo Savior configuration parameters

型号	CPU	内存	显卡
R7000P2021	AMD Ryzen5 5 600 H	16 GB	NVIDIA RTX3050Ti




图 3 加入 AAPC 算法后的联合算法定位误差对比

Fig. 3 Joint algorithm position error comparison after adding AAPC algorithm

3.3 卡尔曼滤波优化轨迹

联合定位算法 CS+WKNN、CS、WKNN、RWKNN、SRL_KNN 这 5 种算法整体误差分布情况见图 4。




图 4 联合算法与单项算法对比

Fig. 4 Comparison between joint algorithm and single algorithm

由图 4 可以看出联合定位算法的平均误差最低却拥有着最高的误差定位精度, 定位精度相较于其他 4 种算法分别提高了 44%, 17%, 15%, 5%, 并且联合定位算法拥有最小的下四分位点, 这说明拥有更多的较小误差值。综上可知, 联合定位算法在平均误差与边缘分布方面拥有更好的表现, 定位的准确性更高。

图 5 呈现了目标点筛选轨迹, 而图 6 则展示了 CS、WKNN、RWKNN、SRL_KNN、CS+WKNN 这 5 种算法未经滤波处理的轨迹对比。从对比中可明显观察到, 算法轨迹与目标轨迹存在明显差异, 这主要是由算法本身误差引起的。这些误差可分为正常误差和异常误差两类。对于正常误差, 可以直接运用卡尔曼滤波进行优化, 因为其遵循物理运动规律。而对于异常误差, 则需要首先加入物理限制, 确保定位点不与障碍物碰撞, 同时限制最大速度以避免过大位移。经过实验, 最终得到了图 7 所示的轨迹, 与图 6 相比, 经过滤波之后各个算法的轨迹精确性都得到了显著提升, 卡尔曼滤波表现理想。




图 5 目标点筛选轨迹

Fig. 5 Target point filtering tracks




图 6 滤波前的轨迹对比图

Fig. 6 Comparison chart of trajectories before filtering




图 7 基于卡尔曼滤波后的定位轨迹图

Fig. 7 Localization trajectory map based on Kalman filtering

图 8 展示了经过卡尔曼滤波后 CS、WKNN、RWKNN、SRL_KNN、CS+WKNN 算法的定位误差分布图。其平均定位误差分别为 0.65, 1.02, 0.65, 0.68, 0.57 m, 其中 CS+WKNN 算法的定位误差最低, 且拥有最优的边缘误差分布。综上所述, 该算法在定位精度方面表现出较为理想的水平。




图 8 经过卡尔曼滤波后的定位精度对比

Fig. 8 Comparison of positioning accuracy after Kalman filtering

4 结论

本研究将联合定位算法和 AAPC 算法结合, 发现定位的时耗性和定位准确度都有显著的改善, 相对

于未引入AAPC的联合算法,其定位精度上升了13%,定位时间缩短了21%。并且经过实验验证,联合算法相比几种单项算法的定位精度分别有不同程度的提高。为了解决动态轨迹跟踪误差大的问题,提出了将联合定位算法与卡尔曼滤波相结合的方法。实验证实这种方法可以有效解决动态轨迹定位问题,并且显著提高了定位精度。

参考文献:

- [1] GEOK T K, AUNG K Z, AUNG M S, et al. Review of Indoor Positioning: Radio Wave Technology[J]. *Applied Sciences*, 2021, 11: 279.
- [2] ZAFARI F, GKELIAS A, LEUNG K K. A Survey of Indoor Localization Systems and Technologies[J]. *IEEE Communications Surveys & Tutorials*, 2019, 21(3): 2568–2599.
- [3] SHANG S, WANG L X. Overview of WiFi Fingerprinting-Based Indoor Positioning[J]. *IET Commun*, 2022, 16: 725–733.
- [4] 秦宁宁,王超,杨乐,等. 基于多元高斯混合模型的离线指纹数据库[J]. *电子与信息学报*, 2021, 43(6): 1772–1780.
QIN Ningning, WANG Chao, YANG Le, et al. Off Line Fingerprint Database Based on Multivariate Gaussian Mixture Model[J]. *Journal of Electronics & Information Technology*, 2021, 43(6): 1772–1780.
- [5] 田子建,贺方圆. 一种基于分布式压缩感知的矿井目标指纹数据库建立方法[J]. *电子与信息学报*, 2019, 41(10): 2450–2456.
TIAN Zijian, HE Fangyuan. A Method of Establishing Mine Target Fingerprint Database Based on Distributed Compressed Sensing[J]. *Journal of Electronics & Information Technology*, 2019, 41(10): 2450–2456.
- [6] BELMONTE-HERNÁNDEZ A, HERNÁNDEZ-PEÑALOZA G, ÁLVAREZ F, et al. Adaptive Fingerprinting in Multi-Sensor Fusion for Accurate Indoor Tracking[J]. *IEEE Sensors Journal*, 2017, 17(15): 4983–4998.
- [7] JI W Q, ZHAO K, ZHENG Z Q, et al. Multivariable Fingerprints with Random Forest Variable Selection for Indoor Positioning System[J]. *IEEE Sensors Journal*, 2022, 22(6): 5398–5406.
- [8] PINTO B, BARRETO R, SOUTO E, et al. Robust RSSI-Based Indoor Positioning System Using K-Means Clustering and Bayesian Estimation[J]. *IEEE Sensors Journal*, 2021, 21(21): 24462–24470.
- [9] SUBEDI S, GANG H S, KO N Y, et al. Improving Indoor Fingerprinting Positioning with Affinity Propagation Clustering and Weighted Centroid Fingerprint[J]. *IEEE Access*, 2019, 7: 31738–31750.
- [10] 徐金东,赵甜雨,冯国政,等. 基于上下文模糊C均值聚类的图像分割算法[J]. *电子与信息学报*, 2021, 43(7): 2079–2086.
XU Jindong, ZHAO Tianyu, FENG Guozheng, et al. Image Segmentation Algorithm Based on Context Fuzzy C-Means Clustering[J]. *Journal of Electronics & Information Technology*, 2021, 43(7): 2079–2086.
- [11] 商磊,关维国,龚瑞雪. 基于聚类优选自适应KNN的改进定位算法[J]. *传感器与微系统*, 2023, 42(3): 136–139.
SHANG Lei, GUAN Weiguo, GONG Ruixue. Improved Localization Algorithm Based on Clustering Optimization and Adaptive KNN[J]. *Transducer and Microsystem Technologies*, 2023, 42(3): 136–139.
- [12] ZHANG H, WANG Z K, XIA W C, et al. Weighted Adaptive KNN Algorithm with Historical Information Fusion for Fingerprint Positioning[J]. *IEEE Wireless Communications Letters*, 2022, 11(5): 1002–1006.
- [13] TRAN H Q, HA C. High Precision Weighted Optimum K-Nearest Neighbors Algorithm for Indoor Visible Light Positioning Applications[J]. *IEEE Access*, 2020, 8: 114597–114607.
- [14] 刘坤,吴建新,甄杰,等. 基于阵列天线和稀疏贝叶斯学习的室内定位方法[J]. *电子与信息学报*, 2020, 42(5): 1158–1164.
LIU Kun, WU Jianxin, ZHEN Jie, et al. Indoor Localization Algorithm Based on Array Antenna and Sparse Bayesian Learning[J]. *Journal of Electronics & Information Technology*, 2020, 42(5): 1158–1164.
- [15] YADAV R K, BHATTARAI B, GANG H S, et al. Trusted K Nearest Bayesian Estimation for Indoor Positioning System[J]. *IEEE Access*, 2019, 7: 51484–51498.
- [16] 聂伟,文怀志,谢良波,等. 一种基于单目视觉的无人机室内定位方法[J]. *电子与信息学报*, 2022, 44(3): 906–914.
NIE Wei, WEN Huaizhi, XIE Liangbo, et al. Indoor Localization of UAV Using Monocular Vision[J]. *Journal of Electronics & Information Technology*, 2022, 44(3): 906–914.
- [17] ZOU Q, SUN Q, CHEN L, et al. A Comparative Analysis of LiDAR SLAM-Based Indoor Navigation for Autonomous Vehicles[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(7): 6907–6921.
- [18] GERWEN J V V, GEEBELN K, WAN J, et al. Indoor Drone Positioning: Accuracy and Cost Trade-off for Sensor Fusion[J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(1): 961–974.
- [19] CHEN Z H, ZOU H, YANG J F, et al. WiFi Fingerprinting Indoor Localization Using Local Feature-

- Based Deep LSTM[J]. IEEE Systems Journal, 2020, 14(2): 3001–3010.
- [20] OWN C M, HOU J W, TAO W Y. Signal Fuse Learning Method with Dual Bands WiFi Signal Measurements in Indoor Positioning[J]. IEEE Access, 2019, 7: 131805–131817.
- [21] WANG X Y, GAO L J, MAO S W. BiLoc: Bi-Modal Deep Learning for Indoor Localization with Commodity 5 GHz WiFi[J]. IEEE Access, 2017, 5: 4209–4220.
- [22] 刘莎莉, 覃锡忠, 贾振红. 基于压缩感知信号重构的 WiFi 室内定位算法研究 [J]. 激光杂志, 2014, 35(9): 82–85.
- LIU Shali, QIN Xizhong, JIA Zhenhong. Research on WiFi Indoor Positioning System Based on Compressed Sensing Signal Reconstruction[J]. Laser Journal, 2014, 35(9): 82–85.
- [23] GLIGORIĆ K, AJMANI M, VUKOBRATOVIĆ D, et al. Visible Light Communications-Based Indoor Positioning via Compressed Sensing[J]. IEEE Communications Letters, 2018, 22(7): 1410–1413.
- [24] GONG X D, LIU J B, YANG S, et al. A Usability-Enhanced Smartphone Indoor Positioning Solution Using Compressive Sensing[J]. IEEE Sensors Journal, 2022, 22(3): 2823–2834.
- [25] HU J S, LIU D W, YAN Z, et al. Experimental Analysis on Weight K -Nearest Neighbor Indoor Fingerprint Positioning[J]. IEEE Internet of Things Journal, 2019, 6(1): 891–897.
- [26] HOANG M T, ZHU Y Z, YUEN B, et al. A Soft Range Limited K -Nearest Neighbors Algorithm for Indoor Localization Enhancement[J]. IEEE Sensors Journal, 2018, 18(24): 10208–10216.
- [27] CHEN G K, GUO X Y, LIU K, et al. RWKNN: A Modified WKNN Algorithm Specific for the Indoor Localization Problem[J]. IEEE Sensors Journal, 2022, 22(7): 7258–7266.
- [28] 胡久松, 刘宏立, 肖郭璇, 等. 应用于 WiFi 室内定位的自适应仿射传播聚类算法 [J]. 电子与信息学报, 2018, 40(12): 2889–2895.
- HU Jiusong, LIU Hongli, XIAO Guoxuan, et al. Adaptive Affine Propagation Clustering Algorithm for WiFi Indoor Positioning[J]. Journal of Electronics & Information Technology, 2018, 40(12): 2889–2895.
- [29] 胡久松, 刘宏立, 肖郭璇, 等. 一种基于压缩感知与最近邻的联合定位方法 [J]. 电子测量与仪器学报, 2018, 32(6): 72–78.
- HU Jiusong, LIU Hongli, XIAO Guoxuan, et al. Joint Location Method Based on Compressed Sensing and Nearest Neighbor[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(6): 72–78.
- [30] LIU X, ZHOU B D, HUANG P P, et al. Kalman Filter-Based Data Fusion of Wi-Fi RTT and PDR for Indoor Localization[J]. IEEE Sensors Journal, 2021, 21(6): 8479–8490.
- [31] LIPKA M, SIPPEL E, VOSSIEK M. An Extended Kalman Filter for Direct, Real-Time, Phase-Based High Precision Indoor Localization[J]. IEEE Access, 2019, 7: 25288–25297.
- [32] 王福伟, 黄智刚. 室内定位中移动目标轨迹跟踪研究 [J]. 导航定位学报, 2016, 4(1): 33–37.
- WANG Fuwei, HUANG Zhigang. Research on Moving Target Trajectory Tracking of Indoor Positioning[J]. Journal of Navigation and Positioning, 2016, 4(1): 33–37.

(责任编辑: 姜利民)