



基于迁移学习的室内动态环境定位算法

刘参, 尚俊娜, 李蕊江, 岳克强
(杭州电子科技大学, 浙江 杭州 310018)

摘要: 传统室内指纹定位系统的精度受指纹库中参考位置节点的密度和室内环境特征等多方面因素的制约。室内环境动态变化时 RSS 波动较大, 通常不满足同分布的假设条件, 故传统指纹定位方法难以满足高精度需求。针对室内环境动态变化导致传统算法无法精准定位问题, 设计并实现了一种基于室内指纹库的迁移学习动态环境定位算法, 该算法采用迁移学习的思想把不同分布的数据集嵌入对齐到潜在特征空间中, 从而有效缓解了环境动态变化对系统造成的不利影响。本文算法实验数据均来自于真实的环境, 通过仿真得到该算法的平均定位误差是 1.23 m。

关键词: 动态定位; 迁移学习; 室内环境特征; 广义延拓插值; RSS 指纹库; 低工作量

中图分类号: TP393

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2018170

Indoor dynamic environment localization algorithm based on transfer learning

LIU Can, SHANG Junna, LI Ruijiang, YUE Keqiang
Hangzhou Dianzi University, Hangzhou 310018, China

Abstract: The accuracy of the traditional indoor fingerprint localization system is limited by many factors, such as the density of the reference location node in the fingerprint database and the characteristics of the indoor environment. When the indoor environment changes dynamically, the RSS fluctuates, and usually does not meet the assumption of the same distribution. Therefore, it was difficult to obtain high-precision requirements for conventional fingerprint positioning method. Aiming at the problem that the traditional algorithm couldn't locate accurately, an algorithm based on the indoor fingerprint database was designed and implemented. The algorithm adopted the idea of migration learning to embed different data sets into the latent feature space, and the adverse effects of environmental changes on the system were mitigated. The simulation results show that the average positioning error of this algorithm is 1.23 m.

Key words: dynamic localization, transfer learning, indoor environmental characteristic, generalized extended interpolation, received signal strength fingerprint, reduced calibration effort

收稿日期: 2018-01-09; 修回日期: 2018-05-04

通信作者: 尚俊娜, shangjn@hdu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.11603041)

Foundation Item: The National Natural Science Foundation of China (No.11603041)

1 引言

随着无线传感器网络 (wireless sensor network, WSN) 技术的发展, 室内定位技术受到越来越多的关注, 人们对室内无线定位的需求日益增大, 如仓库、超市、地下停车场、机场大厅、监狱等, 常常需要知道物品或行人的位置^[1-2]。基于接收信号强度 (received signal strength, RSS) 的定位系统不用增加额外的硬件设备, 同时具有低成本、低功耗等优势, 成为国内外研究的热点^[3]。基于 RSS 的定位系统可分为信号传播模型^[4]和无线电指纹^[5]两种, 由于室内环境复杂多变, 特别是行人、桌椅等家具移动使得 RSS 具有较大的波动性^[6], 采用滤波的方法可以减缓这种波动性, 但是该方法仍难以解决室内物体变化后的动态环境定位问题。故此, 本文采用基于 RSS 指纹库的动态环境定位方法, 避免了信号传播模型不确定性造成的定位精度下降的问题。

基于指纹库的定位系统通常分为在线训练阶段和离线定位阶段, 系统的定位精度取决于训练阶段指纹数据库的质量^[7], 包括指纹库中参考节点的采样密度和指纹信息的准确性。随着参考节点数目的增加, 指纹信息更能反映出实际室内环境中 RSS 量的变化趋势, 故系统的定位精度更高, 但在指纹库创建时需要消费巨大的人力和财力资源^[5]。基于指纹库的定位系统, 通常假设训练数据和测试数据服从相同的分布^[8], 在实际室内复杂环境中, 障碍物的遮挡、信号的干扰以及移动物体的运动等, 导致原始 RSS 指纹库中的数据失效, 此时用已失效的指纹数据进行实时动态定位, 定位精度普遍较低。故此, 低成本、高精度的动态定位系统受到越来越多学者的关注。参考文献[9]提出对路径衰减因子进行动态修复的质心定位算法, 参考文献[10]采用基于线性内插法的室内指纹定位算法, 可以减缓室内复杂环境对定位性能的影响, 但是当动态环境发生较大变化后,

系统的定位精度较低; 参考文献[11]提出针对动态环境的自适应定位方法, 但是该算法需要在变化后的环境中采集固定位置处标签节点的信息, 会带来额外的成本开支, 无法得到普遍应用; 参考文献[12]提出了基于隐性马尔可夫模型的 Ma.HMM 定位算法, 但此方法需要额外的辅助数据更新指纹库且计算复杂度较高; 参考文献[13]提出利用用户状态的方法动态更新环境变化后的指纹库, 但是需要粘贴二维码标志, 整个系统后期维护较困难, 无法在大型场所广泛应用。

为了有效缓解室内环境动态变化对定位系统精度造成的不利影响, 并且进一步减小工作量, 本文提出了一种基于迁移学习的室内动态环境定位算法。在该算法中, 首先进行室内 RSS 指纹库的创建, 为了节约成本, 本文设计了一种可以明显减少工作量同时不损失指纹库质量的广义延拓插值算法; 在进行动态环境定位时, 利用 RSS 信息在潜在特征空间的空间关联性^[14], 本文设计了一种迁移学习动态环境定位算法, 通过在环境变化以后的空间中随机采样, 找到潜在的特征空间根据领域自适应算法进行定位, 进而消除室内环境变化对系统定位性能的影响。最后通过大量的试验仿真, 证明本文所提的算法相比传统 kNN 算法^[15]和 Ma.HMM 算法^[12], 在定位精度和系统稳定性方面都有较大的改善。故此, 本文算法可实现低成本、高精度的室内动态环境定位。

2 相关工作

传统基于指纹的机器学习定位算法假设训练数据和测试数据服从相同的分布, 此时训练学习到的 RSS 映射模型直接应用在不同时间段内进行位置的估计。然而在实际室内复杂动态环境中, 障碍物的遮挡、无线电信号的干扰以及移动物体的不可预测运动等, 使得 RSS 具有明显的不确定性, 因此在多数情况下并不满足上述的同分布假设^[16]。当动态环境变化时, RSS 映射模型也会发



生变化,因此基于指纹的定位系统无法使用预先训练得到的模型进行高精度定位。

2.1 室内 RSS 指纹分布特性

经典的 RSS 对数衰减模型^[17]如式(1)所示:

$$\text{RSS} = R_0 - 10 \cdot n \cdot \lg d + X_\sigma \quad (1)$$

其中, R_0 表示接收端与锚节点相距 1 m 时的 RSS 值, n 表示路径衰减因子, d 表示测试节点与锚节点之间的距离, X_σ 表示环境噪声, 通常服从 $\mathcal{N}(0, \sigma^2)$ 的高斯分布, σ 表示环境噪声的大小, 环境噪声越大, 信号传播路径损耗越严重。 A 和 n 都是经验值, 与具体的室内环境有关, 参考文献[17]研究了不同环境下 RSS 衰减模型参数的取值范围。

根据经验可知, 在相对距离接近的参考位置处, 接收到的 RSS 信号彼此相似; 虽然在不同时间段内 RSS 具有明显的波动性, 但在同一时间范围内, 这种波动很小。图 1 是在实际室内动态环境下, 同一位置不同时间段内的 RSS 分布直方图。




图 1 同一位置不同时间段内的 RSS 分布直方图

从图 1 可知, 在固定位置处, 不同时间段内的 RSS 分布是不同的, 因此基于指纹的室内定位方法采用训练学习得到的 RSS 映射模型进行不同分布情况下的位置估计, 会得到较大的定位误差, 无法实现动态环境室内高精度定位功能^[18-19]。此时需要采用迁移学习的思想, 把前一时间段内训练得到的 RSS 映射模型根据流形对齐理论迁移学习到不同数据分布的时间段内, 以此来实现自适应动态定位功能^[20]。

2.2 迁移学习动态定位实例

$$\text{RSS 矩阵 } S_{\text{RSS}}^A = \begin{bmatrix} \text{RSS}_1^1 & \text{RSS}_1^2 & \cdots & \text{RSS}_1^{N_A} \\ \text{RSS}_2^1 & \text{RSS}_2^2 & \cdots & \text{RSS}_2^{N_A} \\ \vdots & \vdots & \ddots & \vdots \\ \text{RSS}_{M_A}^1 & \text{RSS}_{M_A}^2 & \cdots & \text{RSS}_{M_A}^{N_A} \end{bmatrix} \in \mathbb{R}^{M_A \times N_A}$$

作为训练数据集, 其中, RSS_i^j ($i=1,2,\dots,M_A$, $j=1,2,\dots,N_A$) 表示在第 i 个参考位置处接收到第 j 个锚节点 (AP) 的信号强度值, M_A 表示锚节点的个数, N_A 表示参考位置的个数。

从 S_{RSS}^A 矩阵可以看出, 在某一参考位置处, 存在唯一的接收信号强度向量, 可以认为信号强度空间与真实的物理位置空间存在某种映射关系。同时可以发现 S_{RSS}^A 矩阵隐含的 3 个重要特征^[21]: 每一列代表在某参考位置处接收的 RSS 指纹信息, 如果某两列 RSS 指纹信息比较相似, 表示该数据来自两个离得较近的位置; 每一行代表某个锚节点在所有参考位置处的 AP 指纹信息, 如果某两行数据彼此相似, 则表示这两个 AP 的位置离得较近; 矩阵中的每个元素 RSS_i^j 表示第 i 个参考位置处接收到第 j 个 AP 的信号强度, 如果信号强度具有最大值, 则表示参考位置 i 离第 j 个 AP 的位置最近。

将在不同时段内随机采样的数据作为测试数据集 $S_{\text{RSS}}^B \in \mathbb{R}^{M_B \times N_B}$, 其中, M_B 表示锚节点的个数, N_B 表示随机采样的采样数据数。由于不同时间段内的数据服从不同的分布, 故此传统机器学习算法求解到的 RSS 映射模型不再适用于测试数据

S_{RSS}^B , 然而在同一室内环境中, 锚节点的位置通常是固定的, 可认为这些锚节点在同一室内场景中属于共享锚节点 (shared anchor point, SAP), 上述 S_{RSS}^A 矩阵隐含的 3 个重要特征同样适用于测试数据 S_{RSS}^B 。

室内动态环境中 RSS 信号具有不同的分布特性, 但是在邻近的物理位置处, 不同分布下的 RSS 信号是彼此相似的, 故可以把训练数据集 S_{RSS}^A 与测试数据 S_{RSS}^B 在某潜在的低维空间中进行流形对齐, 即认为这些不同分布的数据在某个潜在空间中具有相似的特性^[18,22], 例如这些数据都与真实的物理位置相对应。以具有 2 个 SAP 的二维信号空间为例, 如图 2 所示, 在信号空间 A 和信号空间 B 内信号分布是不同的, 但是在潜在的二维物理位置空间里面存在映射对齐关系^[22], 图 2 中含有位置信息的向量 R_2 来自信号空间 A, 未含有位置信息的向量 R'_2 来自信号空间 B, 向量 R_2 和 R'_2 来自不同的信号空间, 却都来自同一个物理位置空间 L_2 , 由于信号空间 B 内未含有物理位置坐标的标签信息, 故无法把向量 R'_2 与物理位置坐标 L_2 进行映射对齐。由于同样的原因, 无法把向量 R'_3 、 R'_4 、 R'_5 与真实的位置坐标 L_3 、 L_4 、 L_5 进行对齐。由上述信号矩阵隐含的 3 个重要特征可知, 标签数据向量 R_1 在信号空间 A 中接收到来自 AP_1 的信号强度具有最大值, 故 R_1 的真实位置靠近 AP_1 , 而在信号空间 B 中, 向量 R'_1 接收到来自 SAP_1 的信号强度具有最大值, R'_1 的位置更靠近 AP_1 , 可认为向量 R_1 和 R'_1 存在固有的对应关系, 称为 RSS 相关对 $\{R_i, R'_i\}$ 。同理, 可以找到来自不同信号空间的更多 RSS 相关对 $\{R_i, R'_i\}$, 通过这种对应关系, 把 R_i 中含有位置坐标的标签信息传递给未含有位置坐标的 R'_i , 实现 R'_i 的位置坐标的标定工作。

通过使用相同类内部与不同类之间的领域关系, 把标签数据的位置坐标信息传递到未标签数据的对应物理位置处, 例如把信号空间 A 的标签向量




图2 位置空间与两个不同分布数据空间的相关性

R_1 、 R_2 、 R_3 、 R_4 、 R_5 的位置信息传递给信号空间 B 的未标签向量 R'_1 、 R'_2 、 R'_3 、 R'_4 、 R'_5 , 将上述未标签向量对齐到真实位置坐标 L_1 、 L_2 、 L_3 、 L_4 、 L_5 上, 以此来实现迁移学习动态定位。

3 迁移学习动态定位算法

图 3 是本文所提出算法示意图, 为了实现上述迁移定位功能, 需要以下几个步骤。

步骤1 数据采集——广义延拓插值算法

在原始环境中进行轻工作量、低采样密度的指纹库采集, 利用广义延拓插值算法得到高质量的指纹库, 作为含有位置信息的训练数据 X_{tra}^A , $X_{tra}^A = \left\{ \left(s_i^A, \ell_i^A \right) \right\}_{i=1}^{N_A}$, $s_i^A = \left(s_{i1}^A, s_{i2}^A, \dots, s_{im_A}^A \right)^T$, $\ell_i^A = \left(x_i^A, y_i^A \right)^T$, N_A 表示参考位置的个数, ℓ_i^A 表示第 i -th 个参考节点的物理位置, m_A 表示共享锚节点的个数, s_{ij}^A 表示在第 i -th 个参考节点处接收到的第 j -th 个 SAP 的信号强度; 当室内环境动态变化后, 随机采样若干未知位置的 RSS 指纹, 作为不含位置信息的随机采样测试数据 X_{rand}^B , $X_{rand}^B = \left\{ s_i^B \right\}_{i=1}^{N_B}$, $s_i^B = \left(s_{i1}^B, s_{i2}^B, \dots, s_{im_B}^B \right)^T$, N_B 表示随机采样的采样点数, m_B 表示锚节点的个数, 由于 A 阶段和 B 阶段处于同一室内环境中, 故 $m_B = m_A$ 。然后进行潜在空间对齐^[21]。

本文采用将插值法和拟合法融合在一起的广义延拓插值算法, 该算法充分利用延拓域 Ω'_e 的额




图3 迁移学习动态定位算法示意图

外信息,使单元域内 Ω_e 的插值函数既能够充分利用邻近单元的信息,又保证插值函数与延拓域的逼近函数相互协调^[23],单元域和延拓域的划分如图4所示。




图4 单元域及延拓域划分

广义延拓插值算法的数学模型如式(2)所示:

$$\begin{aligned} \min &= \sum_{j=1}^v \left[U^e(l_j) - u_{l_j}^q \right]^2 \\ &= \sum_{j=1}^v \left[\sum_{i=1}^t a_i^e \cdot h_i^e(l_j) - u_{l_j}^q \right]^2, l_j \in \Omega'_e \quad (2) \\ \text{s.t. } &\sum_{i=1}^t a_i^e \cdot h_i^e(l_j) = u_{l_j}^q, l_j \in \Omega'_e, 1 \leq q \leq M_A \end{aligned}$$

其中, $U^e(l_j)$ 表示拟合函数在位置 l_j 处的拟合值, v 是延拓域包含的数据个数, $u_{l_j}^q = \text{rss}_q^{l_j}$ 表示在位置 l_j 处测量的第 q 个锚节点的 RSS 值, t 是拟合函

数的项数, $h_i^e (i=1,2,\dots,t)$ 是延拓域 Ω'_e 上的一组基, $a_i^e (i=1,2,\dots,t)$ 是待定系数^[24]。

把各个单元子域拼接起来,作为整个可行域的拟合函数 $U(x)$:

$$U(x) = \sum_{e=1}^m U^e(x_e), x_e \in \Omega_e, x \in \Omega \quad (3)$$

本文采用二维正弦函数作为测试样本,验证广义延拓插值算法的精度,二维正弦函数为:

$$f(x, y) = \sin x + 2 \sin x \cos y + \cos y \quad (4)$$

其中, $x \in [0, 10], y \in [0, 5]$, 原始测试函数以 0.5 步长进行采样,通过广义延拓插值算法和双线性插值算法反演出步长为 0.1 的采样曲面,并与真实曲面进行比较,表 1 统计了不同插值算法的插值误差概率为 80% 和 90% 时的插值精度。

表1 不同算法插值精度

方法	CDF=80%	CDF=90%	平均误差
双线性插值法	0.06	0.08	0.056 8
广义延拓插值	0.03	0.04	0.031 6

从表 1 中可以看出,本文算法的插值精度明显优于双线性插值算法,本文算法可以通过稀疏

采样点还原出与真实函数变化趋势一致的高精度拟合曲面。故此, 广义延拓插值算法可以在原始低工作量、低采样密度指纹库的基础上创建出高质量插值指纹库。

步骤2 创建关联矩阵

为了实现 A 和 B 两个不同流形之间的嵌入对齐问题, 需要创建类内关联图和类间关联图^[25]。类内关联图表示矩阵 X_{tra}^A 或 X_{rand}^B 内部间的近邻特性, 采用 k 近邻算法把每个 RSS 向量与其最近的邻居连接起来, 如果矩阵中两个 RSS 向量在近邻范围内, 则对应的关联矩阵元素值 g_{ij} 为 1, 否则 g_{ij} 为 0, 以此来构造类内关联矩阵 $G_{N_A \times N_A}^A$ 或 $G_{N_B \times N_B}^B$; 类间关联图表示矩阵 X_{tra}^A 和 X_{rand}^B 数据间 RSS 相关对的近邻特性, 矩阵 X_{tra}^A 和 X_{rand}^B 来自不同的特征空间, RSS 向量之间的距离不能直接计算, 无法进行 RSS 相关对接处理, 考虑到同一室内环境中路径衰减因子在某个确定范围内取值, 而环境噪声分布不同, 需要先对原始数据进行噪声消除, 然后利用 max-RSS 准则 (对于每个共享锚节点 SAP, 不同空间中该锚节点处接收到的最大信号强度通过 RSS 相关对的方式关联起来)^[22]创建类间关联矩阵 $G_{N_A \times N_B}^{AB}$ 。

步骤3 创建流形权重矩阵

根据关联矩阵和数据矩阵建立无向图的权重矩阵 W^A 、 W^B 、 W^{AB} , 其中, 权重矩阵 $W^A = [W^A(i, j)]_{N_A \times N_A}$ 采用高斯距离核函数创建^[25]。

$$W^A(i, j) = \begin{cases} \exp\left(-\frac{\|s_i^A - s_j^A\|^2}{2\sigma_A^2}\right), & g_{ij}^A = 1 \\ 0, & \text{其他} \end{cases} \quad (5)$$

其中, $\|\cdot\|$ 表示欧氏距离, s_j^A 是数据矩阵中的列向量, $g_{ij}^A \in G^A$ 是关联矩阵中的元素, σ^A 是距离归一化因子, 常选取数据矩阵的方差。

通过上述方法可以得到权重矩阵 W^B 、 W^{AB} , 在实际应用中, 由于 SAP 的个数远远小于采样点数, 求得的 W^{AB} 往往是稀疏矩阵, 无法把不同数据集间的 RSS 相关对有效地关联起来, 因此利用

迭代规则把相同数据集内部的 W^A 、 W^B 特性传播到 W^{AB} 中^[22], 以此来增强不同数据集间 RSS 相关对的关联性。迭代规则如式 (6) 所示。

$$W_k^{AB} \leftarrow W^A \cdot W_{k-1}^{AB} \cdot W^B \quad (6)$$

其中, $k=1, 2, \dots, n$, 是迭代的次数, W_0^{AB} 是通过高斯距离核函数创建的初始权重矩阵。通过迭代足够的次数, 使 W^{AB} 矩阵能有效地把两个数据集的潜在特性关联起来。

步骤4 迁移学习定位模型及求解

$$\text{设 } P^K = \{p_i^{(K)}\}_{i=1}^{N_A+N_B} \in \mathbb{R}^{K \times (N_A+N_B)}, p_i^{(K)} = (p_i^1, p_i^2, \dots, p_i^K)^T$$

表示训练数据和测试数据在 K 维潜在空间的嵌入坐标矩阵。当 $i=1, 2, \dots, N_A$ 时, $p_i^{(K)}$ 表示训练数据集 X_{tra}^A 中第 i 个 RSS 向量 s_i^A 在 K 维潜在空间中的嵌入坐标, 当 $j=N_A+1, N_A+2, \dots, N_A+N_B$ 时, $p_j^{(K)}$ 表示测试数据集 X_{rand}^B 中第 j 个 RSS 向量 s_j^B 在 K 维潜在空间中的嵌入坐标。为了让嵌入坐标矩阵在整个空间中保持平滑, 需要增加流形正则化的约束条件^[26], 其定位模型如式 (7) 所示。

$$\begin{aligned} \widetilde{P^K} &= \min_{P^K} \left(\sum_{i=1}^{N_A} \sum_{j=1}^{N_B} (p_i^{(K)} - p_{N_A+j}^{(K)})^2 \cdot W^{AB}(i, j) \right) \\ &= \min_{P^K} P^K \cdot L^{AB} \cdot (P^K)^T \\ \text{s.t. } &(P_i^{(K)})^T \cdot P_i^{(K)} = 1, \quad i=1, 2, \dots, N_A + N_B \end{aligned} \quad (7)$$

其中, L^{AB} 是权重矩阵 W^{AB} 的拉普拉斯矩阵^[27], 如式 (8) 所示。

$$\begin{cases} L^{AB} = (1-\mu) \cdot \text{diag}(L^A, L^B) + \mu \cdot L_{(N_A+N_B) \times (N_A+N_B)}^{AB} \\ L_{(N_A+N_B) \times (N_A+N_B)}^{AB} = \begin{bmatrix} D_{N_A \times N_A}^{AB} & -W^{AB} \\ -(W^{AB})^T & D_{N_B \times N_B}^{BA} \end{bmatrix} \end{cases} \quad (8)$$

其中, L^A 、 L^B 分别是矩阵 W^A 、 W^B 的拉普拉斯矩阵, $L^A = D^A - W^A$, 矩阵 D^A 是对角矩阵, 对角线上的元素 $D^A(i, i) = \sum_{j=1}^{N_A} W^A(j, i)$, $D_{N_A \times N_A}^{AB}$ 是对角矩阵, 对角线上的元素为 $D^{AB}(i, i) = \sum_{j=1}^{N_B} W^{AB}(i, j)$,



$D_{N_B \times N_B}^{BA}$ 是对角矩阵, 对角线上的元素为 $D^{BA}(i,i) = \sum_{j=1}^{N_A} W^{AB}(j,i)$, $0 \leq \mu \leq 1$ 是类内数据与类间数据间的归一化因子, 取值越大代表类间数据的权重越高。

迁移学习定位模型式 (7) 是一个典型的数学优化问题, 根据最优化理论可知该定位模型是求解最小特征值问题^[27], 即求解出矩阵 L^{AB} 的前 K 个最小特征值 (不包括 0 特征值) 对应的特征向量, 作为 P^K 的最优估计 $\widetilde{P^K}$ 。

步骤 5 完成定位

如上所述, $\widetilde{P^K}$ 的前 N_A 个列向量是训练数据 X_{tra}^A 在 K 维潜在空间中的嵌入坐标, $\widetilde{P^K}$ 的后 N_B 个列向量是测试数据集 X_{rand}^B 的嵌入坐标, 然后根据 k 近邻或加权 k 近邻算法实现未标签数据集 X_{rand}^B 位置的自动标定。

潜在空间维度的确定通常有两种方法, 即含有位置约束和不含位置约束^[22]。含有位置约束的定位模型是把测试数据集的位置信息作为约束条件, 并将不同类之间的数据对齐到二维潜在空间中; 不含位置约束是测试数据集的位置信息仅仅参与位置标签标定过程而不参与嵌入对齐过程, 此时空间维数采用式 (9) 的方法进行确定^[28]。

$$\frac{\sum_{i=1}^d \lambda_i}{\sum_{i=1}^n \lambda_i} \leq \xi^* \quad (9)$$

其中, ξ^* 是潜在空间保留信息的阈值, d 是潜在空间的维数, λ_i 是从小到大排列的第 i 个非 0 特征值。

4 迁移学习动态定位性能仿真与测试

4.1 广义延拓插值指纹库测试及性能仿真

为得到实际环境中的 RSS 距离衰减模型, 本文在如图 5 (a) 的车库环境中进行实际测试, 采用 3 对 CC2530 芯片的 ZigBee 开发板在同一场景中每隔 0.2 m 进行 RSS 数据采集。



图 5 测试车库环境

本文算法实验数据均来自于真实的环境, 通过数据拟合得到 3 对锚节点的 RSS 距离衰减曲线, 如式 (10) 所示, 在同一个静态室内环境中, 3 条衰减曲线相差并不是很大, 因此可认为该车库环境中, RSS 距离衰减模型为式 (11):

$$\begin{cases} \text{RSS}_{1,\text{dB}} = -12.17 \times \lg d - 48.63 + X_{1,\sigma} \\ \text{RSS}_{2,\text{dB}} = -11.53 \times \lg d - 45.72 + X_{2,\sigma} \\ \text{RSS}_{3,\text{dB}} = -11.61 \times \lg d - 46.12 + X_{3,\sigma} \end{cases} \quad (10)$$

$$\text{RSS}_{\text{dB}} = -11.73 \times \lg d - 46.68 + X_{\sigma} \quad (11)$$

其中, $X_{\sigma} \sim \mathcal{N}(0.001, 15.468)$ 是 Gaussian 白噪声。

本文在 MATLAB 2014b 软件中对广义延拓插值算法的性能进行仿真, 其中, RSS 传播模型采用式 (11) 实测的参数, 在车库环境为 20 m×15 m 范围内, 13 个锚节点分布如图 6(a)所示。原始 RSS 指纹库是通过每隔 2 m 采集 RSS 指纹建立的, 此时原始指纹库的单位面积内的采样密度为 0.25, 广义延拓插值算法的插值距离是 0.5 m, 故广义延拓插值 RSS 指纹库的采样密度为 4, 相比较原始指纹库采样密度提高了 16 倍。其中含有室内环境噪声与不含环境噪声的插值算法的仿真结果如图 6(b)所示, 其中室内环境噪声是服从 $X_{\sigma} \sim \mathcal{N}(0.001, 15.468)$ 分布的高斯白噪声。通过图 6(b)可知, 通过与真实 RSS 指纹库相比较, 插值以后的 RSS 误差在 2 dBm、5 dBm 和 10 dBm 精度以内的置信概率分别为 70%、82% 和 95%, 说明该算法通过对低采样密度的原始指纹库进行插值, 可形成与真实指纹库接近的高质量 RSS 指纹库, 故此广义延拓插值算法可以节省大量的人力和财力资源。

4.2 模型参数对定位性能的影响

本文提出的迁移学习动态定位模型可以有效




图6 室内锚节点分布及广义延拓插值算法性能仿真

解决室内环境发生动态变化以后的定位问题,该模型由很多关键参数构成,例如室内锚节点 AP 的个数、潜在空间的保留信息阈值 ξ^* 、完成定位时 k 近邻或加权 k 近邻算法的近邻个数、高斯距离核函数的距离归一化因子 σ^A 以及迭代规则中的迭代次数等。故此本文主要对上述前 3 个关键参数进行研究,分别讨论这些参数对迁移学习动态定位性能的影响。

4.2.1 室内锚节点 AP 个数对定位性能的影响

图 7 是平均定位误差 RMSE 随室内锚节点 AP 个数的变化情况曲线,随着 AP 数量的增加,迁移学习动态定位算法与 k 近邻、加权 k 近邻定位算法的平均定位误差逐渐变小。但是定位误差并不是随着 AP 数量增加单调减小的,因为待定位节点可能会选取距离较远的 AP,此时锚节点距离较远,信号较弱, RSS 数值较小,受环境影响严重,不利于定位。

4.2.2 潜在空间的保留信息阈值对定位性能的影响

潜在空间的保留信息阈值 ξ^* 是一个在 (0,1) 范围内取值的常数,由式 (9) 可知,阈值代表潜在对齐空间的维度,当阈值 ξ^* 确定以后,室内环境发生动态变化后计算出来的潜在空间的维数是不固定的,这种动态调整维数的方法避免了使用固定维数带来的问题。图 8 是潜在空间的




图7 锚节点 AP 个数对定位性能的影响

保留信息阈值对定位性能的影响,从图 8 中可知,当阈值 ξ^* 比较小时,相当于潜在空间的维数较小,无法准确地把环境变化后的潜在信息进行有限映射,此时定位误差比较大,想要达到高精度定位比较困难;随着阈值 ξ^* 的增大,位置结算所需的定位潜在空间维数增加,平均定位误差会减小,但是当阈值 $\xi^*=0.3$ 左右时,平均定位误差最小;阈值 $\xi^*>0.8$ 后,潜在空间维数较大,会引入更多无用的位置指纹信息,造成平均定位误差变大。因此可以把 $\xi^*=0.3$ 作为最佳的潜在空间维数的阈值。

4.2.3 定位时 k 近邻的近邻个数对定位性能的影响

参数 k 是迁移学习动态定位算法完成定位时 k





图8 潜在空间的保留信息阈值对定位性能的影响

近邻算法所使用的近邻数, 当 $AP=8$ 时, 平均定位误差与 k 之间的关系如图 9 所示。随着近邻个数 k 值变大, 参与定位的参考节点近邻个数变多, 系统的平均定位误差变小。但经过大量仿真发现, k 值并非越大越好, 如果 k 值很大, 会把距离待定位目标节点较远的指纹点纳入近邻数中, 在求解位置坐标时这些距离较远的指纹往往是无效的信息, 故此会影响系统整体的定位精度。从图 9 中可以看出 k 取 6 时平均定位误差最小, 可作为最佳的 kNN 近邻个数。

图9 近邻个数 k 对定位性能的影响

4.3 迁移学习定位性能仿真

为了验证本文所提出的迁移学习动态定位算法的定位性能, 本文所选的室内环境与图 5(a)中是同一个车库, 不同的是车库中停放的车辆发生明显改变, 如图 5(b)所示, 经过测试得到该环境

下 RSS 衰减模型如式 (12) 所示, 其中室内车库变化前后地 RSS 衰减曲线如图 10 所示。从图 10 可知, 当环境变化后, RSS 衰减得更厉害。室内锚节点 AP 的个数为 13 个, 潜在空间的保留信息阈值 $\xi^*=0.3$, 完成定位时 k 近邻或加权 k 近邻算法的近邻个数为 6 个, 距离归一化因子 σ^A 选取训练数据 X_{tra}^A 或者测试数据 X_{rand}^B 的方差, 迭代规则中的迭代次数为 3 次。本文采用传统 kNN 算法^[15]处理环境变化后的指纹定位系统作为对比方案, 定位性能仿真结果如图 11 所示, 其中不同算法的定位精度概率分布见表 2。

$$RSS_{dB} = -16.25 \times \lg d - 60.35 + \mathcal{N}(0, 15.283) \quad (12)$$




图10 车库环境变化前后 RSS 衰减曲线




图11 不同算法定位误差累积分布曲线

从图 11 和表 2 可以看出, 迁移学习定位算法在 0.5 m、1 m 和 1.5 m 内的定位精度置信概率分别为 9.5%、29.1%和 57.6%, 分别高出传统 kNN 算法 9.5%、16.8%和 33.8%, 高出 Ma.HMM 算法 0.5%、8.8%和 15.2%, 并且迁移学习算法的平均定位精度是 1.23 m, 传统 kNN 算法^[15]的平均定位精

表2 不同算法定位精度的概率分布值

方法	0.5 m	1.0 m	1.5 m	2.0 m	2.5 m	平均精度/m
kNN 算法 ^[15]	0	12.3%	23.8%	30.3%	40.7%	3.28
Ma.HMM 算法 ^[12]	9.0%	20.3%	42.4%	64.5%	77.5%	1.74
迁移学习算法	9.5%	29.1%	57.6%	80.5%	100%	1.23

度为 3.28 m, Ma.HMM 算法^[12]的平均定位精度为 1.74 m, 迁移学习定位算法的定位误差有 57.6%的概率在 1.5 m 以内, 而传统机器学习算法的定位误差高达 5 m。这说明当室内环境特征发生较大改变的时候, 本文所提出的迁移学习动态定位算法和基于隐性马尔可夫模型的 Ma.HMM 定位算法^[12]的性能更加优越, 且比传统 kNN 算法更有利于实现小误差高精度定位 (平均定位误差在 1.2 m 左右)。故此本算法无论在定位精度、定位误差范围还是小误差定位的置信概率方面, 相比传统机器学习定位算法都具有明显的优势。

通过上述实验可知, 室内环境特征发生明显改变时, 传统机器学习指纹定位算法已经无法进行室内定位, Ma.HMM 算法虽然能够进行迁移定位但是定位误差较大, 而本文所提出的迁移学习动态定位算法具有较小的定位误差范围和较高的定位精度度。

5 结束语

为了消除室内环境动态变化对系统定位性能造成的不利影响, 本文设计了一种迁移学习动态定位算法, 通过在环境变化以后的空间中随机采样, 找到潜在的特征空间进行位置的标定功能, 从而避免了原始指纹库失效造成的定位精度降低的问题。此外, 本文提出的定位算法还需要进一步改善, 特别是动态定位问题, 可以采用流形对齐、深度学习等人工智能算法, 充分利用定位节点之间的空间关联性, 进一步提升定位系统的定位精度, 同时系统应该具有判断异常数据的能力, 以保障系统的定位质量和人性化体验。基于此,

上述定位技术目前也处于研究阶段。


参考文献:

- [1] LUO C, CHENG L, CHAN M C, et al. Pallas: self- bootstrapping fine-grained passive indoor localization using WiFi monitors[J]. IEEE Transactions on Mobile Computing, 2017, PP(99): 1.
- [2] 朱亚萍, 夏玮玮, 章跃跃, 等. 基于 RSSI 和惯性导航的融合室内定位算法[J]. 电信科学, 2017, 33(10): 99-106.
ZHU Y P, XIA W W, ZHANG Y Y, et al. A hybrid indoor localization algorithm based on RSSI and inertial navigation[J]. Telecommunications Science, 2017, 33(10): 99-106.
- [3] 徐小良, 高健, 黄河, 等. 基于 RSS 空间线性相关的 WLAN 位置指纹定位算法[J]. 电信科学, 2017, 33(3): 14-21.
XU X, GAO J, HUANG H, et al. Fingerprint localization algorithm based on linear spatial dependence of WLAN RSS[J]. Telecommunications Science, 2017, 33(3): 14-21.
- [4] 尚俊娜, 程涛, 盛林, 等. 广义延拓插值模型在 RSSI 测距方法中的应用[J]. 传感技术学报, 2016, 29(11).
SHANG J N, CHENG T, SHENG L, et al. Application of generalized extended interpolation method in distance measurement based on RSSI[J]. Chinese Journal of Sensors and Actuators, 2016, 29(11).
- [5] HASSAN-ALI M, PAHLAVAN K. A new statistical model for site-specific indoor radio propagation prediction based on geometric optics and geometric probability[J]. IEEE Transactions on Wireless Communications, 2002, 1(1): 112-124.
- [6] KING T, KOPF S, HAENSELMANN T, et al. COMPASS: a probabilistic indoor localization system based on 802.11 and digital compasses[C]//ACM Workshop on Wireless Network Testbeds, Experimental Evaluation and Characterization, September 29, 2006, Los Angeles, CA, USA. New York: ACM Press, 2006: 34-40.
- [7] YOUSSEF M A, AGRAWALA A, SHANKAR A U. WLAN location determination via clustering and probability distributions[C]//IEEE International Conference on Pervasive Computing and Communications, March 23-26, 2003, Fort Worth, TX, USA. Piscataway: IEEE Press, 2003: 143-150.
- [8] 张伟, 花向红, 邱卫宁, 等. Wi-Fi 指纹定位的一种新组合算法[J]. 测绘工程, 2017, 26(3): 14-18.
ZHANG W, HUA X H, QIU W N, et al. A new combinatorial optimization algorithm for WiFi positioning[J]. Engineering of Surveying and Mapping, 2017, 26(3): 14-18.
- [9] 张宏刚, 黄华. 基于 RSSI 路径损耗因子动态修正的三边质心定位算法[J]. 传感技术学报, 2016, 29(11).
ZHANG H G, HUANG H. Dynamic correction algorithm for



- trilateral centroid localization based on RSSI path loss factor[J]. Chinese Journal of Sensors and Actuators, 2016, 29(11).
- [10] 张梦丹, 卢光跃, 王宏刚, 等. 基于线性内插法改进的室内定位算法[J]. 电信科学, 2017, 33(1): 9-15.
ZHANG M D, LU G Y, WANG H G, et al. An improved indoor location algorithm based on linear interpolation[J]. Telecommunications Science, 2017, 33(1): 9-15.
- [11] SOROUR S, LOSTANLEN Y, VALAEE S, et al. Joint indoor localization and radio map construction with limited deployment load[J]. IEEE Transactions on Mobile Computing, 2015, 14(5): 1031-1043.
- [12] CAI X, CHEN L, CHEN G. Constructing adaptive indoor radio maps for dynamic wireless environments[R]. 2013.
- [13] 陈斌涛, 刘任任, 陈益强, 等. 动态环境中的 WiFi 指纹自适应室内定位方法[J]. 传感技术学报, 2015(5): 729-738.
CHEN B T, LIU R R, CHEN Y Q, et al. WiFi fingerprint based self-adaptive indoor localization in the dynamic environment[J]. Chinese Journal of Sensors and Actuators, 2015(5): 729-738.
- [14] YIN J, YANG Q, NI L M. Learning adaptive temporal radio maps for signal-strength-based location estimation[J]. IEEE Transactions on Mobile Computing, 2008, 7(7): 869-883.
- [15] 孔港港, 杨力, 孙聃石, 等. 一种基于位置指纹定位的 K-均值聚类算法的改进[J]. 全球定位系统, 2016, 41(5): 89-92.
KONG G G, YANG L, SUN D S, et al. Research on an algorithm of fingerprint location based on K-means and WKNN[J]. GNSS World of China, 2016, 41(5): 89-92.
- [16] 戴文渊. 基于实例和特征的迁移学习算法研究[D]. 上海: 上海交通大学, 2008.
DAI W Y. Instance-based and feature-based transfer learning[D]. Shanghai: Shanghai Jiao Tong University, 2008.
- [17] ALI S, NOBLES P. A novel indoor location sensing mechanism for IEEE 802.11 b/g wireless LAN[C]//The Workshop on Localization, March 22, 2007, Hannover, Germany. Piscataway: IEEE Press, 2007: 9-15.
- [18] SUN Z, CHEN Y, QI J, et al. Adaptive localization through transfer learning in indoor Wi-Fi environment[C]//Seventh International Conference on Machine Learning and Applications. IEEE Computer Society, Dec 13-18, 2008, San Diego, CA, USA. Piscataway: IEEE Press, 2008: 331-336.
- [19] ZHENG V W, XIANG E W, YANG Q, et al. Transferring localization models over time[C]// AAAI Conference on Artificial Intelligence, AAAI 2008, July 13-17, 2008, Chicago, Illinois, USA. New York: ACM Press, 2008: 1421-1426.
- [20] DAI W, CHEN Y, XUE G R, et al. Translated learning: transfer learning across different feature spaces[C]//Conference on Neural Information Processing Systems, December 8-10, 2008, Vancouver, British Columbia, Canada. New York: ACM Press, 2008: 353-360.
- [21] PAN S J, SHEN D, YANG Q, et al. Transferring localization models across space[C]// National Conference on Artificial Intelligence, July 13-17, 2008, Chicago, Illinois. New York: ACM Press, 2008: 1383-1388.
- [22] WANG H Y, ZHENG V W, ZHAO J, et al. Indoor localization in multi-floor environments with reduced effort[C]//IEEE International Conference on Pervasive Computing and Communications, March 29-April 2, 2010, Mannheim, Germany. Piscataway: IEEE Press, 2010: 244-252.
- [23] 施浒立, 颜毅华, 徐国华. 工程科学中的广义延拓逼近法(精)[M]. 北京: 科学出版社, 2005.
SHI H L, YAN Y H, XU G H. Generalized continuation approximation method in engineering science(fine)[M]. Beijing: Science Press, 2005.
- [24] 张志富, 裴军, 胡超, 等. 车载动中通信号跟踪的广义延拓逼近算法[J]. 西安电子科技大学学报(自然科学版), 2017, 44(4): 112-117.
ZHANG Z F, PEI J, HU C, et al. Generalized extended approximation algorithm for vehicle satellite communication on the move[J]. Journal of Xidian University(Natural Science), 2017, 44(4): 112-117.
- [25] ZHOU C F, MA L, TAN X Z. Joint semi-supervised RSS dimensionality reduction and fingerprint based algorithm for indoor localization[R]. 2014.
- [26] BELKIN M, NIYOGI P, SINDHWANI V. Manifold regularization: a geometric framework for learning from labeled and unlabeled examples[J]. Journal of Machine Learning Research, 2006, 7(1): 2399-2434.
- [27] BELKIN M, NIYOGI P. Laplacian Eigenmaps for dimensionality reduction and data representation[M]. Cambridge: MIT Press, 2003.
- [28] FANG S H, LIN T. Principal component localization in indoor WLAN environments[J]. IEEE Transactions on Mobile Computing, 2011, 11(1): 100-110.

[作者简介]



刘参(1990—), 男, 杭州电子科技大学通信工程学院硕士生, 主要研究方向为无线传感器网络、无线定位等。

尚俊娜(1979—), 女, 博士, 杭州电子科技大学通信工程学院副教授, 主要研究方向为通信信号处理、智能算法。

李蕊江(1993—), 男, 杭州电子科技大学通信工程学院硕士生, 主要研究方向为信号处理、无线定位等。

岳克强(1984—), 男, 博士, 杭州电子科技大学电子信息学院讲师, 主要研究方向为进化计算、通信信号处理。