

基于 KDDA 和 SFLA-LSSVR 算法的 WLAN 室内定位算法

张 勇^{1,2} 李飞腾¹ 王昱洁¹

¹(合肥工业大学计算机与信息学院 合肥 230009)

²(芜湖创业园留学人员博士后科研工作站 安徽芜湖 241000)

(hfgdwhb@163.com)

Indoor Positioning Algorithm for WLAN Based on KDDA and SFLA-LSSVR

Zhang Yong^{1,2}, Li Feiteng¹, and Wang Yujie¹

¹(School of Computer and Information, Hefei University of Technology, Hefei 230009)

²(Post-Doctoral Research Center of Wuhu Overseas Student Pioneer Park, Wuhu, Anhui 241000)

Abstract The time-varying received signal strength (RSS) degrades the indoor positioning accuracy in wireless local area network (WLAN). A novel indoor positioning algorithm based on kernel direct discriminant analysis (KDDA) and shuffled frog leaping algorithm and least square support vector regression (SFLA-LSSVR) is proposed to address the problem. Firstly the proposed algorithm employs kernel function strategy to map RSS signal to the field of nonlinear, which is sampled from each access point (AP), and extracts nonlinear features effectively, and reconstructs the positioning information, and discards the redundant positioning features and noise. Secondly, LSSVR algorithm is employed to build the mapping relation model between positioning features and physical locations, and SFLA is employed to optimize the parameters of the relation model, and then test points' locations are predicted by using the relation model. Experimental results show that the positioning accuracy of the proposed algorithm is much superior to WKNN, ANN, LSSVR algorithm under the condition of the same sampling numbers, and the number of RSS signal which is sampled from each AP is significantly reduced in the same positioning accuracy, and the proposed algorithm is a WLAN indoor positioning algorithm with good performance.

Key words received signal strength (RSS); wireless local area network (WLAN); indoor positioning; kernel direct discriminant analysis (KDDA); shuffled frog leaping algorithm (SFLA); least square support vector regression (LSSVR)

摘 要 针对接收信号强度(received signal strength, RSS)的时变性降低 WLAN 室内定位精度的问题,提出了一种基于核直接判别分析(kernel direct discriminant analysis, KDDA)和混洗蛙跳最小二乘支持向量回归机(SFLA-LSSVR)的定位算法,该算法通过核函数策略将采集的各接入点(access point, AP)的 RSS 信号映射到非线性领域,有效提取了非线性定位特征,重组定位信息,去除冗余定位特征和噪声;然后采用 LSSVR 算法构建指纹点定位特征数据与物理位置的映射关系模型,采用 SFLA 算法优化该关系模型的参数,并用该关系模型对测试点的位置进行回归预测.实验结果表明:提出算法在相同的采样次数下的定位精度明显优于 WKNN,ANN,LSSVR 算法,并且在相同的定位精度下,采样次数较大减少,是一种性能良好的 WLAN 室内定位算法.

收稿日期:2016-01-13;修回日期:2016-04-13

基金项目:国家科技支撑计划项目(2013BAH52F01)

This work was supported by the National Key Technology Research & Development Program of China (2013BAH52F01).

通信作者:李飞腾(18205697955@163.com)

关键词 接收信号强度;无线局域网;室内定位;核直接判别分析;混洗蛙跳算法;最小二乘支持向量回归机

中图法分类号 TP393.17

随着智能手机的普及以及移动互联网的发展,室内位置服务越来越受到重视,尤其在复杂的室内环境,如机场大厅、医院、地铁站、地下停车场等环境中,常常需要确定用户在室内环境的位置信息^[1].在室内环境中,基于接收信号强度(received signal strength, RSS)的无线局域网(wireless local area network, WLAN)室内定位技术^[2]要比北斗、GPS、蜂窝网等定位技术的定位精度更高一些.该定位系统热点廉价、部署容易、无需专门的硬件、接入方便,其带宽高、穿透力强、覆盖范围广,因此得到了广泛的关注.

WLAN 室内定位主要方法有定位感知、几何测量、场景分析等^[3].场景分析法包括指纹识别法和信号传播模型法.指纹识别法由于其算法灵活、定位相对准确,成为了研究的热门方向.

位置指纹定位算法^[4]分为 2 个方面:1)离线阶段无线电地图(radio map)的建立方法;2)在线阶段匹配 radio map 实现定位的方法.其中匹配定位算法主要有加权 K 邻居(weighted k -nearest neighbors, WKNN)算法、人工神经网络(artificial neural network, ANN)算法^[5]、概率法以及支持向量机(support vector machine, SVM)算法等. WKNN 算法^[6]找出多个测试点 RSS 和指纹点 RSS 有着最小距离的指纹点,然后根据距离的大小加权,将指纹点坐标的加权值作为测试点的坐标;WKNN 算法简单且容易实现,但是由于其只是考虑到单一的测试点和指纹点之间的关系,而忽略了不同指纹点之间的 RSS 更深层次的关系,因此定位精度不高.文献[7]提出一种基于 BP 神经网络定位的模型,由于 BP 神经网络本质上是梯度下降法且是一种局部搜索的优化方法,因此收敛速度慢且容易陷入局部最优.文献[8]提出采用 SVR 构建接收信号强度与物理位置的非线性映射关系,使得定位精度有所提高,但其受 RSS 的时变性影响较大. radio map 的建立方法主要是 RSS 特征值法.

在 WLAN 室内定位环境中,多径效应和人员走动造成信号受到不规则干扰,阴影效应造成信号损耗,以上这几种影响使得在相同位置接收到各个接入点(access point, AP)的 RSS 值具有复杂的时变统计特性,从而降低了室内定位的精度.在建立 radio map 过程中,如果直接采用各个 AP 的 RSS

值作为输入的定位特征值,那么 RSS 信号的时变性、不同 AP 之间的相关性,以及判别能力弱的 AP 的 RSS 值将会受采集设备硬件所产生的噪声和外界环境影响所产生的噪声的影响比较大,以上 3 个因素对室内定位的精度影响较大.针对这个问题,本文提出应用基于核直接判别分析^[9-10](kernel direct discriminant analysis, KDDA)变换将采集各个 AP 的原始 RSS 信号映射到高维非线性空间,挖掘非线性定位特征,提取主要定位特征.在在线匹配定位过程中,由于 SVM 在统计样本量较少的情况下也能获得良好的统计规律;混洗蛙跳算法^[11](shuffled frog leaping algorithm, SFLA)因其容易实现和更强的全局优化能力的特点而被广泛应用于多元函数优化、带约束优化问题等.本文提出应用基于混洗蛙跳算法优化的最小二乘支持向量回归机(SFLA-LSSVR),首先使用最小二乘支持向量回归机^[12-14](least square support vector regression, LSSVR)来建立 radio map 与其对应位置坐标的非线性关系;其次,通过 SFLA 算法对 LSSVR 进行参数优化;最后,以优化后的关系对测试点的位置进行回归预测.通过实验对比验证了 KDDA 提取非线性定位特征的有效性及 SFLA-LSSVR 的参数优化和建立回归方程的优势.同时通过与 LSSVR, WKNN, ANN, KDDA-LSSVR 算法的实验结果对比,表明了该算法具有较高的定位精度.

1 KDDA-SFLA-LSSVR 算法

指纹识别算法是通过观察者在场景中各个指纹点和测试点上测得来自各 AP 的信号强度值,然后将测试点的信号强度值和指纹点的信号强度值进行匹配,预测出测试点的位置信息.指纹识别算法分为 2 个部分:离线阶段和在线阶段.

1) 离线阶段.在场景中选定指纹点,然后采集各个指纹点上的 RSS 值,通过 KDDA 变换提取原始 RSS 样本的定位特征值;将定位特征和相应的指纹点位置为输入样本对,采用 SFLA 算法来优化 LSSVR 算法的参数,完成 LSSVR 的学习训练过程,得出定位特征和物理位置的最小二乘支持向量回归函数.

2) 在线阶段,在场景中选定测试点,将采集到的测试点 RSS 值通过 KDDA 变换,输入构建好的

最小二乘支持向量回归函数中,估计出测试点的实际位置.该定位算法的流程如图 1 所示:




Fig. 1 KDDA-SFLA-LSSVR localization algorithm process

图 1 KDDA-SFLA-LSSVR 定位算法流程

1.1 KDDA 变换原理

KDDA 变换基本原理:通过建立从输入空间到隐式的高维特征空间的非线性映射,使得在输入空间非线性和复杂的分布模型在高维特征空间变得线性可分和简单化,再应用常规的 Fisher 线性判别分析^[15](linear discriminant analysis, LDA)提取有效的非线性定位特征.

设 RSS 样本集为 $Z_{ij} \in \mathbb{R}^N$,定位环境中参考点的数目为 C ,每个样本采集各 AP 的 RSS 值的次数为 C_i ,RSS 样本总数为 $L = \sum_{i=1}^C C_i$, N 表示使用 AP 的个数, Z_{ij} 表示在第 i 个参考点上第 j 次采集各 AP 的 RSS 值,其中 $i=1,2,\dots,C, j=1,2,\dots,C_i$.

将原始的 RSS 信号映射到高维非线性空间: $Z_{ij} \in \mathbb{R}^N \rightarrow \phi(Z_{ij}) \in F$. 特征空间 F 中的类间、类内散度矩阵分别为

$$\mathbf{S}_{\text{BTW}} = \frac{1}{L} \sum_{i=1}^C C_i (\bar{\phi}_i - \bar{\phi})(\bar{\phi}_i - \bar{\phi})^T, \quad (1)$$

$$\mathbf{S}_{\text{WTH}} = \frac{1}{L} \sum_{i=1}^C \sum_{j=1}^{C_i} (\phi_{ij} - \bar{\phi}_i)(\phi_{ij} - \bar{\phi}_i)^T, \quad (2)$$

其中, $\bar{\phi}_i = \frac{1}{C_i} \sum_{j=1}^{C_i} \phi(Z_{ij}) = \frac{1}{C_i} \sum_{j=1}^{C_i} \phi_{ij}$ 和 $\bar{\phi} = \frac{1}{L} \sum_{i=1}^C \sum_{j=1}^{C_i} \phi(Z_{ij}) = \frac{1}{L} \sum_{i=1}^C \sum_{j=1}^{C_i} \phi_{ij}$ 分别为 F 中第 i 个指纹点的平均值和 F 中总体的平均值.

KDDA 变换的优化目标是在 F 中找出最具判别力的 M 维基向量 Ψ :

$$\Psi = \arg \max_{\Psi} \left(\frac{\text{tr}(\Psi^T \mathbf{S}_{\text{BTW}} \Psi)}{\text{tr}(\Psi^T \mathbf{S}_{\text{WTH}} \Psi)} \right). \quad (3)$$

满足式(3)的最具判别力基向量 Ψ 所提取的原

始 RSS 样本的定位特征具有类间离散度最大化、类内离散度最小化,因此 KDDA 变换能最大程度上的区分不同参考点从而有效地判别定位.

KDDA 变换首先计算出 $\mathbf{S}_{\text{BTW}}$ 的特征值和相应的特征向量,分别设为 λ_i 和 $\mathbf{e}_i$,然后选取 m 个最大的特征值及其对应的特征向量, $m \leq C-1$. 令:

$$\mathbf{E} = (\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_m) \mathbf{V} = (\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_m) = \Phi_b \mathbf{E}, \quad (4)$$

$$\mathbf{A}_b = \text{diag}(\lambda_1^2, \lambda_2^2, \dots, \lambda_m^2). \quad (5)$$

设 $\mathbf{U} = \mathbf{V} \mathbf{A}_b^{-\frac{1}{2}}$, 则有:

$$\mathbf{U}^T \mathbf{S}_{\text{BTW}} \mathbf{U} = \mathbf{I}. \quad (6)$$

计算出 $\mathbf{U}^T \mathbf{S}_{\text{WTH}} \mathbf{U}$ 的特征值和特征向量,分别记为 λ_i 和 $\mathbf{p}_i$, 其中 $i=1,2,\dots,m$; 然后选取最小的 $M(\leq m)$ 个特征值及其所对应的特征向量,分别记为

$$\mathbf{A}_w = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_M), \quad (7)$$

$$\mathbf{P} = (\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_M). \quad (8)$$

设矩阵 $\mathbf{Q} = \mathbf{U} \mathbf{P}$ 可以得到:

$$\mathbf{Q}^T \mathbf{S}_{\text{WTH}} \mathbf{Q} = \mathbf{A}_w, \quad (9)$$

那么最优判别基向量可以表示为

$$\Psi = \mathbf{Q} \mathbf{A}_w^{-\frac{1}{2}} = (\Psi_1, \Psi_2, \dots, \Psi_M). \quad (10)$$

因此 RSS 样本集 Z_{ij} 在最优判别基上的投影系数为

$$Y_Z = \Psi^T \cdot \phi(Z) = \Theta \cdot \gamma(\phi(Z)), \quad (11)$$

其中, $\gamma(\phi(Z))$ 为 RSS 样本集 $Z_{ij} \in \mathbb{R}^N$ 的核矩阵:

$$\gamma(\phi(Z)) = [\phi_{11}^T \phi(Z), \phi_{12}^T \phi(Z), \dots, \phi_{\alpha_c}^T \phi(Z)]. \quad (12)$$

Θ 是一个 $M \times L$ 的变换矩阵:

$$\Theta = \frac{1}{\sqrt{L}} (\mathbf{E} \mathbf{A}_b^{-\frac{1}{2}} \cdot \mathbf{P} \cdot \mathbf{A}_w^{-\frac{1}{2}})^T (\mathbf{B} \cdot (\mathbf{A}_{LC}^T - \frac{1}{L} \mathbf{1}_{LC}^T)), \quad (13)$$

其中, $\mathbf{B} = \text{diag}(\sqrt{C_1}, \sqrt{C_2}, \dots, \sqrt{C_c})$, $\mathbf{1}_{LC}$ 是一个 $L \times C$ 的矩阵, 每个元素为 1, $\mathbf{A}_{LC} = \text{diag}(a_{c1}, a_{c2}, \dots, a_{cc})$ 是一个 $L \times C$ 的块对角矩阵.

1.2 SFLA-LSSVR 算法

由式(11)得出通过 KDDA 变换分别得到新的指纹点定位特征样本集 $Z' = Y_{z_i} \in \mathbb{R}^M$ 和新的测试点定位特征测试集 $T' = Y_{t_j} \in \mathbb{R}^M$; 与其相对应的物理坐标分别为 $L_{P_i} = (x_{p_i}, y_{p_i})$ 和 $L_{Q_j} = (x_{q_j}, y_{q_j})$, 其中 $i=1,2,\dots,L, j=1,2,\dots,Q_c, L$ 为指纹点的总个数, Q_c 为测试点的总个数. LSSVR 是支持向量回归机(support vector regression, SVR)的改进,很好地解决了小样本、非线性、高维数的问题,提高了求解速度和泛化能力. 依据结构风险化最小原则, LSSVR 优化问题如下:

$$\min J(\boldsymbol{\omega}, \boldsymbol{\xi}) = \frac{1}{2} \|\boldsymbol{\omega}\|^2 + \frac{C}{2} \sum_{i=1}^L \eta_i^2, \quad (14)$$

$$\text{s. t. } y_i = \boldsymbol{\omega}^T \Phi(Z') + b + \eta_i, \quad (15)$$

其中, $i=1, 2, \dots, L$, $\boldsymbol{\omega}$ 为权系数, b 为偏置, C 为惩罚参数, η_i 为误差, $\Phi(\cdot)$ 为输入空间到特征空间的映射。

可采用拉格朗日函数求解式(14)(15):

$$L(\boldsymbol{\omega}, b, \boldsymbol{\eta}, \boldsymbol{\alpha}) = \frac{1}{2} \|\boldsymbol{\omega}\|^2 + \frac{C}{2} \sum_{i=1}^L \eta_i^2 - \sum_{i=1}^L \alpha_i (\boldsymbol{\omega}^T \cdot \Phi(Z') + b + \eta_i - y_i), \quad (16)$$

其中, $\boldsymbol{\alpha} = (\alpha_1, \alpha_2, \dots, \alpha_p)^T$, α_i 是拉格朗日乘子。

LSSVR 使用的是参数相对少、适应能力较强的径向基核函数:

$$K(\mathbf{Z}_m, \mathbf{Z}_n) = \exp\left(-\frac{1}{2\delta^2} \|\mathbf{Z}_m - \mathbf{Z}_n\|^2\right). \quad (17)$$

因此得出位置坐标和 RSS 值的回归函数分别是:

$$x = \sum_{i=1}^L \alpha_i K(\mathbf{Z}', \mathbf{Z}'_i) + b, \quad (18)$$

$$y = \sum_{i=1}^L \alpha'_i K(\mathbf{Z}', \mathbf{Z}'_i) + b', \quad (19)$$

其中, α'_i 和 b' 为相应求得的拉格朗日乘子和偏置。

核宽度 δ 和惩罚参数 C 是 LSSVR 算法重要的 2 个参数, 它们的选取直接影响着该算法的学习能力和泛化能力。

SFLA 有着良好的全局优化能力, 并且参数设置比较简单, 可以对 LSSVR 模型的 (C, δ) 的参数组合进行优化; 因而采用 SFLA 和 LSSVR 的混合算法来计算最小二乘支持向量回归函数。

使用 SFLA-LSSVR 算法回归预测步骤如下:

步骤 1. 初始化种群, 种群的数目 $F=M \times N$, M 表示整个种群被分成子种群的个数, N 表示每个子种群青蛙的个数, 每个子种群最大迭代次数 $N_{\max}$, 在 $C \in [C_{\min}, C_{\max}]$ 和 $\delta \in [\delta_{\min}, \delta_{\max}]$ 的范围内随机给每只青蛙一组参数序列 (C, δ) 。

步骤 2. 将整个种群中的 F 只青蛙按照指定的适应度的降序排序, 适应度计算:

$$fit = 1/(1+E), \quad (20)$$

$$E = \frac{1}{2} \sum_{i=1}^L (\hat{x}_{p_i} - x_{p_i})^2 + (\hat{y}_{p_i} - y_{p_i})^2, \quad (21)$$

其中, $\hat{L}_{p_i} = (\hat{x}_{p_i}, \hat{y}_{p_i})$, $i=1, 2, \dots, L$, $\hat{x}_{p_i}$ 和 $\hat{y}_{p_i}$ 分别是由式(18)(19)得出指纹点的预测 x 坐标和 y 坐标。

步骤 3. 将整个种群分成 M 组: $Y_1, Y_2, \dots, Y_M$,

每组有 N 只青蛙, 第 1 只青蛙进入 Y_1 , 第 2 只青蛙进入 Y_2 , 直到第 M 只青蛙进入到 Y_M , 然后再将第 $M+1$ 只青蛙分入 Y_1 , 第 $M+2$ 只青蛙分入 Y_2 , 以此类推, 直到所有青蛙分配完毕。

步骤 4. 用 P_g 表示整个种群中最好位置的青蛙, P_b 表示本组位置最好的青蛙, P_w 表示本组位置最差的青蛙, 每次进化中更新最差位置的青蛙:

蛙跳步长更新:

$$S_i = rand() \times (P_b - P_w). \quad (22)$$

位置更新:

$$P_w(k+1) = P_w(k) + S_i, \quad (23)$$

其中, $S_{\max} \geq S_i \geq -S_{\max}$, $rand() \in [0, 1]$, $k=1, 2, \dots, N$, $S_{\max}$ 是允许青蛙移动的最大距离。如果计算后新的解较优, 则用其替代最差个体, 否则用 P_g 代替 P_b 重复上过程, 如果还不能生成更好的青蛙, 就随机生成一个新的位置的青蛙取代原来最坏的青蛙 P_w 。

步骤 5. 将青蛙混合, 重新按照适应度的值降序排序, 并且及时更新 P_g 。每个子种群执行着自身的局部搜索策略, 直到子群体进化到一定阶段后, 再将所有青蛙混合来实现各子种群之间的全局交换, 全局交换和局部深度搜索的平衡策略使得该算法能够跳出局部极值点, 向着全局最优的方向进行。

步骤 6. 达到最大迭代次数 $N_{\max}$ 时, 停止迭代, 输出 (C, δ) 最优参数组合, 转入步骤 7; 否则跳转至步骤 3。

步骤 7. 用优化得到 (C, δ) 构建最小二乘支持向量回归函数, 将 T' 输入到回归函数中, 得出测试点的估计物理位置。

2 实验结果与分析

2.1 实验条件

实验环境如图 2 所示, 该室内定位环境是在合肥工业大学逸夫楼 6 楼, 定位区域包括办公室、过道, 办公室内有办公桌椅、书柜等物品, 墙的材料是混凝土, 铝合金窗户和金属门, 其中办公室为定位区域 A, 过道为定位区域 B。实验选用 6 个型号为 DWL-2414N 的 AP, 固定高度为 2 m, 使用三星 GT-N5110 的平板电脑采集各 AP 的 RSS 值, 采集位置离地高度是 1.2 m。实验选取了 25 个指纹点和 30 个测试点, 其中 A 区域选取 9 个指纹点和 10 个测试点, B 区域选取 16 个指纹点和 20 个测试点。指纹点

的间距是 3 m,测试点位置是随机选取. 每个位置采集 200 个样本,每秒 2 个样本.




Fig. 2 Experimental environment of WLAN indoor positioning
图 2 WLAN 室内定位实验环境

定义第 i 个测试点的定位误差 err_i 和平均定位误差 $AverErr$:

$$err_i = \sqrt{(x_i - x'_i)^2 + (y_i - y'_i)^2}, \quad (24)$$

$$AverErr = \frac{1}{n} \sum_{i=1}^n err_i, \quad (25)$$

其中, (x_i, y_i) 是第 i 个测试点的实际坐标, (x'_i, y'_i) 是第 i 个测试点的估计坐标, n 是测试点的总数目.

2.2 实验结果分析

为了验证 KDDA-SFLA-LSSVR 算法的有效性,实验对比了 WKNN 算法、ANN 算法、LSSVR 算法和 KDDA-LSSVR 算法. KDDA 算法中 m 表示保留类间散度矩阵最大特征值所对应的特征向量的个数, M 表示保留类内散度矩阵最小特征值所对应的特征向量的个数,通过多次试验在 50 次、100 次、150 次、200 次采样样本时最优参数组合 m 和 M 的取值分别是:7,4;8,5;9,5;10,8. SFLA 算法种群数目为 1000,子种群数为 100,迭代次数为 6, $C_{\min}$, $C_{\max}$, $\delta_{\min}$, $\delta_{\max}$ 分别为 0.01,1000,0.01,1000. KDDA 算法和 LSSVR 都是选择高斯核函数;WKNN 算法的近邻数 K 为 3;ANN 算法隐藏层神经元数为 20 的 6-20-2 的 3 层 BP 神经网络结构.

图 3 所示是在 KDDA 变换中参数 m 和 M 的变化对 KDDA-LSSVR 算法平均定位误差的影响,实验使用了 100 个样本. 随着 m 的增大,最优平均定位误差分别是 2.285 m,2.122 m,1.989 m,1.913 m,2.062 m,其中 $m=8$ 且 $M=5$ 时,平均定位误差最小. 随着 m 的变大,所获得的类间离散度信息变大,定位特征的判别力变大,平均定位误差减小;当 $m=8$ 且 $M=5$ 时到达拐点,此时平均定位误差最小;当

m 继续变大时,所加入的定位特征判别能力弱,且引入了采集设备硬件所产生的噪声、外界环境影响所产生的噪声等,导致平均定位误差变大.




Fig. 3 The influence of parameters m and M on the average positioning error
图 3 参数 m 和 M 对平均定位误差的影响

图 4 所示的是使用 SFLA 优化算法平均定位误差的对比,对于由 KDDA 提取出的有效的定位特征通过 LSSVR 构建定位特征和物理位置的映射关系的过程,SFLA 有着良好的全局优化 LSSVR 算法的核宽度参数 δ 和惩罚参数 C 的能力,使得 LSSVR 有着更好的学习能力和泛化能力,在采样次数为 50,100,150,200 次时,KDDA-LSSVR 比 KDDA-SFLA-LSSVR 平均定位误差分别高出 11.03%,8.98%,7.61%,3.05%,结果表明使用 SFLA 优化算法对 KDDA-LSSVR 算法的定位精度有着较大的提高.




Fig. 4 The average positioning error comparison for the use of SFLA optimization algorithm
图 4 使用 SFLA 算法优化算法平均定位误差的对比

图 5 所示的是在不同的采样次数下 4 种定位算法平均定位误差的对比. LSSVR 算法平均定位精度要比 WKNN 和 ANN 算法高. WKNN 算法没有充

分利用到 RSS 的统计特性,平均定位误差最大;ANN 算法利用到了 RSS 的统计特性,但是容易陷入局部最优,平均定位精度要高于 WKNN 算法;LSSVR 算法相对于 ANN 算法有着更快的求解速度和更好的泛化能力,因此以上 3 种算法中 LSSVR 算法平均定位精度最高. KDDA-SFLA-LSSVR 算法定位精度明显高于上面 3 种算法,在采样次数为 50 次时,KDDA-SFLA-LSSVR 算法平均定位误差为 1.985 m,小于上面 3 种算法在采样次数 200 次时的平均定位误差,它们分别是 2.120 m,2.099 m,2.053 m,因而使用 KDDA-SFLA-LSSVR 算法能够较大减少样本的采样次数. KDDA 算法对原始 RSS 信号进行了有效的定位特征挖掘和提取,SFLA 算法优化 LSSVR 参数,使得 KDDA-SFLA-LSSVR 算法平均定位精度明显要高于 WKNN,ANN,LSSVR 算法.




Fig. 5 The average positioning error comparison under four kinds of positioning algorithms
图 5 4 种定位算法平均定位误差的对比

图 6 所示的是在 RSS 信号采样次数为 150 次时,4 种定位算法定位误差累计概率分布曲线图.当




Fig. 6 The positioning error's cumulative distribution probability under four kinds of positioning algorithms
图 6 4 种定位算法定位误差累计概率分布对比

定位误差小于等于 2 m 时,KDDA-SFLA-LSSVR 算法累计概率是 73.33%,WKNN,ANN,LSSVR 算法的累计概率分别是 43.33%,46.67%,60.00%,当累计概率为 50%时,KDDA-SFLA-LSSVR,LSSVR,ANN,WKNN 算法定位误差值分别为 1.28 m,1.71 m,2.07 m,2.16 m,从统计学概率分布可以得出相比于其他 3 种算法,KDDA-SFLA-LSSVR 算法有着更高的定位精度.

3 结束语

针对 RSS 的时变性影响 WLAN 室内定位精度的问题,本文提出了一种基于 KDDA 和 SFLA-LSSVR 结合的 WLAN 室内定位算法.一方面从理论分析说明了该算法的可行性,首先将原始的 RSS 信号通过 KDDA 算法映射到高维的非线性空间,挖掘出非线性定位特征,使得各样本点之间离散度最大、样本点内部之间的离散度最小,去除冗余定位特征和噪声;然后将提取出的定位特征和物理坐标作为输入样本对输入到 LSSVR 算法中来建立定位特征和物理位置的最小二乘支持向量回归函数,通过 SFLA 算法优化 LSSVR 算法的核宽度参数 δ 和惩罚参数 C ;最后将测试点 RSS 信号经 KDDA 变换后输入回归函数,得到测试点估计位置.另一方面通过实验对比可以看出 KDDA-SFLA-LSSVR 算法在相同的采样次数情况下的定位精度明显高于 WKNN,ANN,LSSVR 算法,在定位精度相同的情况下能较大减少采样样本数,是一种性能良好的 WLAN 室内定位方法.

参 考 文 献

[1] Yang Yinggu, Lo A, Niemegeers I. A survey of indoor positioning systems for wireless personal networks [J]. IEEE Communications Surveys & Tutorials, 2009, 11(1): 13-32

[2] Zhang Minghua, Zhang Shensheng, Cao Jian. Indoor location based on signal strength in wireless local area network [J]. Computer Science, 2007, 34(6): 68-75 (in Chinese)

(张明华, 张申生, 曹健. 无线局域网中基于信号强度的室内定位[J]. 计算机科学, 2007, 34(6): 68-75)

[3] Du Feng, Tian Shiwei, Li Guangxia. WLAN positioning review [C/CD/OL] //Proc of the 5th China Satellite Navigation Conf. Beijing: CNKI, 2014 [2016-01-01]. <http://www.docin.com/p-1412405289.html> (in Chinese)

- (杜峰, 田世伟, 李广侠. WLAN 定位综述[C/CD/OL]. //第 5 届中国卫星导航学术年会论文集. 北京: 中国知网, 2014 [2016-01-01]. <http://www.docin.com/p-1412405289.html>)
- [4] Liu Jianglong, Wan Yihe, Xu Baogen, et al. A novel indoor positioning method based on location fingerprinting [C] // Proc of the 9th Int Conf on Communications, Circuits and Systems (ICCCAS). Piscataway, NJ: IEEE, 2013: 239-242
- [5] Borenovic M, Neskovic A. ANN based models for positioning in indoor WLAN environments [C] //Proc of the 19th Telecommunications Forum. Piscataway, NJ: IEEE, 2011: 305-312
- [6] Zhang Guowei, Xu Zhan, Liu Dan. Research and improvement on indoor localization based on RSSI fingerprint database and K-nearest neighbor points [C] //Proc of the 9th Int Conf on Communications, Circuits and Systems (ICCCAS). Piscataway, NJ: IEEE, 2013: 68-71
- [7] Li Ying, Hu Zhigang. An indoor location model based on BP neural network [J]. Computer Technology and Automation, 2007, 26(2): 78-80 (in Chinese)
(李瑛, 胡志刚. 一种基于 BP 神经网络的室内定位模型 [J]. 计算机技术与自动化, 2007, 26(2): 78-80)
- [8] Deng Zhian, Xu Yubing. A support vector regression algorithm for indoor positioning in wireless local area network [J]. Chinese Journal of Scientific Instrument, 2009, 30(6): 578-582 (in Chinese)
(邓志安, 徐玉滨. 基于支持向量机回归算法的 WLAN 室内定位系统[J]. 仪器仪表学报, 2009, 30(6): 578-582)
- [9] Lu J W, Plataniotis K N, Venetsanopoulos A N. Face recognition using kernel direct discriminant analysis algorithms [J]. IEEE Trans on Neural Networks, 2003, 14(1): 117-126
- [10] Guo Jinyu, Li Yuan, Kong Xiaoguang, et al. Palm print identification based on local projection and kernel direct discriminant analysis [J]. Journal of Optoelectronics Laser, 2011, 22(1): 128-130 (in Chinese)
(郭金玉, 李元, 孔晓光, 等. 基于局部保持投影和核直接判别分析的掌纹识别 [J]. 光电子激光, 2011, 22(1): 128-130)
- [11] Hasanien H M. Shuffled frog leaping algorithm-based static synchronous compensator for transient stability improvement of a grid-connected wind farm [J]. IET Renewable Power Generation, 2014, 8(6): 722-730
- [12] Mustafa M W, Sulaiman M H, Shareefh H, et al. Reactive power tracing in pool-based power system utilising the hybrid genetic algorithm and least squares support vector machine [J]. IET Generation, Transmission & Distribution, 2012, 6(2): 133-141
- [13] Issac N S, Palanisamy P, Zhang W J, et al. Log-gabor wavelets based breast carcinoma classification using least square support vector machine [C] //Proc of the 4th IEEE Int Conf on Imaging Systems and Techniques (IST). Piscataway, NJ: IEEE, 2011: 219-223
- [14] Suykens J A K, Gestel T V, Brabanter J D, et al. Least Square Support Vector Machines [M]. River Edge, NJ: World Scientific Publishing, 2002: 71-111
- [15] Lu J W, Plataniotis K N, Venetsanopoulos A N. Face recognition using LDA-based algorithms [J]. IEEE Trans on Neural Networks, 2003, 14(1): 192-200



Zhang Yong, born in 1973. Postdoctoral, associate professor. His main research interests include intelligent information processing, WLAN indoor positioning.



Li Feiteng, born in 1991. Master candidate. His main research interests include intelligent information processing, WLAN indoor positioning, pattern recognition.



Wang Yujie, born in 1980. PhD, lecturer. Her main research interests include intelligent information processing, pattern recognition.