

6-4-2020

Fingerprinting Positioning Algorithm for WiFi Based on Locally Weighted Regression and Support Vector Regression Optimized by Artificial Bee Colony

Wang Yan

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Wuxi 214122, China;

Fucheng Yin

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Wuxi 214122, China;

Zhicheng Ji

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Wuxi 214122, China;

Dahu Yan

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Wuxi 214122, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Fingerprinting Positioning Algorithm for WiFi Based on Locally Weighted Regression and Support Vector Regression Optimized by Artificial Bee Colony

Abstract

Abstract: Since the traditional location fingerprinting algorithms have poor positioning accuracy and cost laborious efforts constructing fingerprinting database during the offline phase, a novel LWR-ABCSVR positioning algorithm was proposed, that the derived algorithm was based on the locally weighted regression (LWR) method and support vector regression was optimized by artificial bee colony (ABCSVR) algorithm. *By using the proposed algorithm, the fingerprinting database was expanded by LWR step. The ABCSVR algorithm was employed to build the nonlinear relationship between the RSS values of reference points and their locations. The position of mobile terminal was predicted by the constructed model.* Simulation results indicate that the proposed algorithm performs better than traditional location fingerprinting algorithms, in terms of positioning accuracy and database constructing costs.

Keywords

WiFi, LWR algorithm, ABC algorithm, SVR algorithm, positioning technique

Recommended Citation

Wang Yan, Yin Fucheng, Ji Zhicheng, Yan Dahu. Fingerprinting Positioning Algorithm for WiFi Based on Locally Weighted Regression and Support Vector Regression Optimized by Artificial Bee Colony[J]. Journal of System Simulation, 2017, 29(6): 1193-1200.

基于 LWR-ABCSVR 的 WiFi 指纹定位算法

王艳, 殷富成, 纪志成, 严大虎

(江南大学物联网技术应用教育部工程研究中心, 无锡 214122)

摘要: 针对在 WiFi 环境下, 传统的位置指纹定位算法定位精度不够高和指纹数据库构建困难的问题提出了一种基于线性加权回归(LWR)和蜂群优化的支持向量回归机(ABCSVR)的 LWR-ABCSVR 定位算法。该算法通过 LWR 在离线阶段对采集到的位置指纹数据库进行扩充; 利用 ABCSVR 构建物理位置和 RSS 之间的非线性关系, 并通过构建的预测模型完成定位。实验结果表明, 该算法的定位精度远高于传统的几种定位算法, 并且可以在一定程度上减少构建指纹数据库的工作量, 是一种综合性能良好的定位算法。

关键词: WiFi; LWR 算法; ABC 算法; SVR 算法; 定位技术

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X (2017) 06-1193-08

DOI: 10.16182/j.issn1004731x.joss.201706005

Fingerprinting Positioning Algorithm for WiFi Based on Locally Weighted Regression and Support Vector Regression Optimized by Artificial Bee Colony

Wang Yan, Yin Fucheng, Ji Zhicheng, Yan Dahu

(Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Wuxi 214122, China)

Abstract: Since the traditional location fingerprinting algorithms have poor positioning accuracy and cost laborious efforts constructing fingerprinting database during the offline phase, a novel LWR-ABCSVR positioning algorithm was proposed, that the derived algorithm was based on the locally weighted regression (LWR) method and support vector regression was optimized by artificial bee colony (ABCSVR) algorithm. By using the proposed algorithm, the fingerprinting database was expanded by LWR step. The ABCSVR algorithm was employed to build the nonlinear relationship between the RSS values of reference points and their locations. The position of mobile terminal was predicted by the constructed model. Simulation results indicate that the proposed algorithm performs better than traditional location fingerprinting algorithms, in terms of positioning accuracy and database constructing costs.

Keywords: WiFi; LWR algorithm; ABC algorithm; SVR algorithm; positioning technique

引言

近年来, 随着传感器技术、通信技术和普适计算(Pervasive Computing)的发展以及智能终端的普

及, 基于位置的服务(Location-Based Services, LBS)受到了人们越来越多的关注^[1], 并被广泛地应用于导航、目标识别和个人事务处理等多个领域。位置获取是 LBS 的基础, LBS 的提升需要定位精度高、可行性强、定位时延小且部署成本低的定位技术支撑。

目前应用最为广泛的定位系统是全球定位系统(Global Positioning System, GPS)。GPS 通过 4 个



收稿日期: 2016-10-21 修回日期: 2016-11-08;
基金项目: 国家自然科学基金(61572238), 江苏省杰出青年基金(BK20160001), 江苏省产学研联合创新资金-前瞻性联合研究项目(BY2016022-24);
作者简介: 王艳(1978-), 女, 江苏无锡, 博士, 副教授, 硕导, 研究方向为无线传感器网络、制造物联网技术。

<http://www.china-simulation.com>

• 1193 •

或 4 个以上 GPS 卫星接收到的信号时间差完成对移动终端的位置估计, 可以提供全天候、高精度、全球覆盖的定位服务。但是在复杂的城市和室内环境下, GPS 信号容易受到干扰和屏蔽, 在这些情况下 GPS 的定位效果并不理想。因此, 在很多场景下要使用其他无线定位技术进行定位^[2]。

目前主流的定位技术还包括无线传感器网络(Wireless Sensing Networks, WSN)、红外线、超声波、射频识别(Radio Frequency Identification, RFID)、超宽带(Ultra Wide Band, UWB)、ZigBee 和无线保真(wireless fidelity, WIFI)定位技术等。相比其他几种定位技术, WiFi 定位技术具有通信标准成熟、信号覆盖广泛、可定位移动终端数量多和无需额外硬件等优点, 被认为是解决 GPS 定位在城市和室内环境定位效果差这一问题的关键^[3]。

WiFi 环境下常见的无线定位算法可以分为两类: 几何测量法和场景分析法。几何测量法包括信号到达时间(Time of Arrival, TOA)、信号到达时间差(Time Difference of Arrival, TDOA)、信号到达角(Angle of Arrival, AOA)和接收信号强度(Received Signal Strength, RSS)等方法。这类算法通过直接或间接测量移动终端(Mobile Terminal, MT)与多个 AP 之间的距离或角度关系计算出 MT 的位置, 该类算法需要预先知道 AP 的具体位置。其中 RSS 算法通过信号传播模型将 RSS 测量值转化为 AP 与 MT 之间的距离完成定位^[4], 尽管该方法简单易行, 但其定位精度较低无法满足实际应用的需求。TOA、TDOA 和 AOA 算法有着不俗的定位精度, 但这三种算法的实现需要添加用于时间测量或角度测量的硬件设备, 这将带来昂贵的硬件开销^[5]。因此这些算法虽然在特定的场景中获得了不错的应用效果^[6], 但不适宜在 WiFi 环境下大范围部署。

场景分析法的代表是位置指纹法, 位置指纹法有着较高的定位精度, 不需要额外的硬件投入, 也不需要知道 AP 的具体位置, 是在 WiFi 环境下最适合部署的定位算法。常见的位置指纹法包括加权 K 最近邻算法(Weighted K-Nearest, WKNN)、人工

神经网络算法(Artificial Neural Network, ANN)和支持向量机算法(Support Vector Machine, SVM)。

WKNN 算法容易实现, 但定位精度不高; 文献[7]采用了 ANN 算法, 定位精度有一定提高; 文献[8]使用了支持向量机解决定位问题, 由于支持向量机的泛化能力强于 ANN, 该算法的定位精度进一步提高。然而, 文献[8]并没有提及如何选取支持向量机的参数, 但支持向量机的参数左右着支持向量机的定位性能。同时, 位置指纹法需要在离线阶段进行耗时耗力的人工测量来构建指纹地图, 当要求更高的定位精度时, 往往需要增大指纹采集的密度。

针对上述方法的缺陷, 本文提出了一种 LWR-ABCSVR 定位算法。该算法通过线性加权回归(Locally Weighted Regression, LWR)产生人造指纹点扩充指纹数据库, 同时在构建物理位置与 RSS 值函数关系时通过人工蜂群算法(Artificial Bee Colony, ABC)对支持向量回归机(Support Vector Regression, SVR)的参数进行寻优。实验表明, 本文提出的算法的定位精度优于传统的 SVR 定位算法, 在相同精度的要求下可以减少指纹采集的工作量。

1 LWR-ABCSVR 定位算法

基于 WiFi 的位置指纹定位方法利用 RSS 值与实际位置的关联进行定位。该方法分为两个阶段: 离线训练阶段和在线定位阶段。

离线训练阶段主要完成指纹数据库的构建工作。即选定各个指纹点的物理位置, 在每个指纹点处测量各个 AP 在该位置的 RSS 值, 构建起位置与 RSS 值之间的对应关系, 并将这些信息存储起来供在线定位时使用。在线定位阶段, 测量各个 AP 在 MT 处的 RSS 值, 通过指纹数据库中位置与 RSS 值的对应关系完成定位。

本文提出的 LWR-ABCSVR 算法的定位系统框图如图 1 所示。在离线训练阶段, 先对定位区域中选定的参考点进行 RSS 数据采集, 再通过 LWR 算法扩充采集到的数据集, 最后使用 ABCSVR 算

法构建物理位置和 RSS 之间的映射关系; 在线定位时移动终端测量实际的 RSS 值, 即可通过构建好的定位模型估计出移动终端的位置。

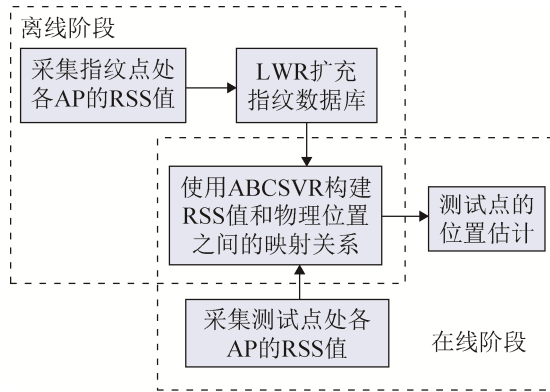


图 1 LWR-ABCSVR 系统框图
Fig. 1 LWR-ABCSVR system block diagram

1.1 支持向量回归方法

假设 $s = [s_1, s_2, \dots, s_n]^T$ 为移动终端在位置 (x, y) 处接收到来自 n 个 AP 的信号强度所构成的向量。则解决定位问题的关键就是获得物理位置与信号强度之间的函数关系, 即求解式(1)中的 $f(\bullet)$ 和 $g(\bullet)$ 。 $f(\bullet)$ 和 $g(\bullet)$ 均为非线性函数, 可以使用神经网络和支持向量机等机器学习方法对位置和信号强度之间的非线性关系进行拟合^[7-8]。

$$\begin{aligned} x &= f(s) \\ y &= g(s) \end{aligned} \quad (1)$$

本文采用支持向量机方法解决 WiFi 定位问题。支持向量机来源于统计学习理论(Statistical Learning Theory, SLT), 是一种能够有效解决小样本学习问题的通用学习算法^[9]。与神经网络等传统的机器学习方法不同, 支持向量机在考虑训练函数训练误差的同时, 通过 VC 维大小控制置信范围, 从而使得实际期望风险最小。因此相比之下, 支持向量机有着更强的泛化能力。在 WiFi 定位算法中, 可以使用 ϵ 不敏感支持向量回归机方法拟合 RSS 值和物理位置之间的关系^[10]。

下面以对 RSS 值与物理位置 x 轴坐标之间关系的拟合, 来介绍 ϵ 不敏感 SVR 的原理。假设有一个从空间 R^N 到特征空间 F 的非线性映射 ϕ , RSS

值在 F 中的映射为 $\phi(s)$, 且 x 和 $\phi(s)$ 之间的关系为线性的, 即:

$$x = \phi(s)^T w + b \quad (2)$$

式(2)中 w 为权重向量, 其维数与 $\phi(s)$ 相同, b 为偏置常数。训练目标就是求得 w 与 b 的最优值, 以使得 SVR 的泛化性能最好。回归学习函数的泛化性能通过回归学习的期望风险函数 $R(w)$ 评估。

$$R(w) = \int L(x, f(s, w)) dF(s, x) \quad (3)$$

$$L(x, f(s, w)) = \max(0, |f(s, w) - x| - \epsilon) \quad \epsilon > 0 \quad (4)$$

式(3)中 $\{f(s, w)\}$ 是预测函数集, 可以表示任何函数集。 $L(x, f(s, w))$ 是由于用 $\{f(s, w)\}$ 对 x 进行预测而造成的损失。对于 ϵ 不敏感 SVR 当损失小于等于 ϵ 时即认为训练损失为 0, 以减少噪声对训练数据的影响, 这可以一定程度上提升泛化性能。 $F(s, x)$ 为信号强度与 x 坐标之间的联合概率密度分布, 该函数一般无法求出。但是, 通过结构风险最小化原则可以将优化问题转化为:

$$\begin{aligned} \min J(w) &= \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s.t.} &\begin{cases} (\phi(s_i)^T w + b) - x_i \leq \epsilon + \xi_i \\ x_i - (\phi(s_i)^T w + b) \leq \epsilon + \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0, C \geq 0 \end{cases} \end{aligned} \quad (5)$$

式中: $\|w\|$ 控制置信范围的大小; $\sum_{i=1}^l (\xi_i + \xi_i^*)$ 控制经验风险, 即训练误差; C 为惩罚因子, 是用于平衡置信范围和经验风险的参数。根据对偶原理^[9], w 可以被一定数量的支持向量线性表示, 即 $w = \sum_{i=1}^{NSV} \alpha_i \phi(s_i)$, 则式(2)可写作:

$$x = \sum_{i=1}^{NSV} \alpha_i \phi(s)^T \phi(s_i) + b \quad (6)$$

式中: SV 表示支持向量集合; α_i 为权重系数。 $\phi(s)^T \phi(s_i)$ 可以不用显式计算, 而是通过计算核函数得出。高斯核函数具有良好的局部特征提取能力和平滑特性^[11], 因此这里使用高斯核函数:

$$\phi(s)^T \phi(s_i) = K(s, s_i) = \exp(-g \|s - s_i\|^2) \quad (7)$$

式中: $K(\bullet, \bullet)$ 和 g 分别是核函数和相应的核参数。

式(6)即可转化为:

$$x = \sum_{i=1}^{NSV} \alpha_i K(s, s_i) + b \quad (8)$$

给定参数 C, g, ε 对(5)式进行凸二次优化, 即可得到支持向量机权重 w 的全局最优解。y 坐标的求解过程与上述方法类似。

1.2 基于 ABC 和交叉验证的参数优化

支持向量机的性能与支持向量机参数(惩罚因子 C 、核参数 g 、不敏感系数 ε)的选择有着极为紧密的联系^[12]。因此, 支持向量机参数的选择将极大地影响 SVR 定位算法的定位性能。然而, 在现有基于 SVR 的 WiFi 定位算法研究中, SVR 参数地选取并没有得到足够的重视。文献[8]对于如何选取 SVR 参数没有提及。文献[13]中使用了网格搜索选取 SVR 的最优参数, 然而网格搜索法的寻优精度不高^[14], 不能获得较理想的 SVR 参数。

针对 SVR 参数寻优问题, 本文使用人工蜂群算法优化 SVR 参数。ABC 算法由 Karaboga 于 2005 年提出, 是一种模拟蜜蜂采蜜行为的新型群集智能优化算法, 主要优点是设置参数少、收敛速度快且不容易陷入局部最优^[15]。

另外, 对参数组合的性能评价易受到训练样本的影响, 对于相同的 (C, g, ε) , 不同的训练样本也会造成拟合性能不同。在对于小样本的训练过程中, 参数寻优受到样本随机性的影响更为明显, 不利于 SVR 的泛化。因此, 本文在 ABC 寻优过程中引入 K -fold 交叉验证对 (C, g, ε) 的每个返回值进行综合性能评价。基于 ABC 和交叉验证的参数优化过程如下。

步骤 1: 归一化处理已经采集到的位置指纹数据训练样本集 $\{x_i, s_i\}$ 。

步骤 2: 人工蜂群算法初始化, 设置种群个数 N 、食物源最大循环次数 L 和最大迭代次数 S 。

步骤 3: 根据 K -fold 交叉验证原则确定 ABC 算法中的适应度函数。综合性能评价指标为 K -fold 交叉验证测试集拟合结果的均方误差。将训练数据随机等分为 K 份, 本文中 K 取 5, 这样可以保证训练数据远多于测试数据。对于一个蜜源 $f_i = [C, g, \varepsilon]$, 以训练数据的一个子集作为测试集, 其他 4 个子集

作为训练集, 训练后对测试集进行预测, 测试结果的均方误差为:

$$mse = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i) \quad (9)$$

将测试数据换为另一个子集, 再取其他 4 个子集作为训练数据, 直到对所有子集都进行一次预测, 取 5 组均方误差的均值 \overline{mse} 作为 K -fold 交叉验证的均方误差。该蜜源相应的适应度由(10)式确定。

$$V_{obj} = \frac{1}{1 + mse} \quad (10)$$

步骤 4: 随机生成 $N/2$ 个蜜源, 蜜蜂搜索得到适应度最佳的蜜源。

步骤 5: 雇佣蜂按式(11)对记忆中原蜜源的领域进行搜索, 以记住适应度最佳的蜜源, 搜索完成后范围蜂巢共享蜜源信息。

$$v_{ij} = f_{ij} + \varphi_{ij}(f_{ij} - f_{kj}) \quad (11)$$

式中: v_{ij} 为随机寻找的新蜜源; $k \in \{1, 2, \dots, N/2\}$, $j \in \{1, 2, 3\}$ 为随机选择的下标, 且 $i \neq k$ 。 φ_{ij} 为 $[-1, 1]$ 之间的随机数, 对应初始解的邻域。

步骤 6: 观察蜂根据获得的蜜源信息, 按照与适应度相关的概率公式(12)选择蜜源的位置, 以与雇佣蜂相同的方式搜索蜜源。若蜜源 f_i 经过 L 次循环后不能被改进, 则该蜜源被放弃。该位置的雇佣蜂转变为侦查蜂, 按式(13)寻找新蜜源。

$$P_i = \frac{F_i}{\sum_{n=1}^{N/2} F_n} \quad (12)$$

$$f_i = f_{\min} + \text{rand}(0, 1)(f_{\max} - f_{\min}) \quad (13)$$

步骤 7: 重复步骤 5、6 直到达到最大迭代次数 S , 输出适应度最佳的蜜源 f_{best} 作为 SVR 的参数进行训练。在线定位阶段将 RSS 实时测量值输入 SVR 模型中即可得到位置估计。

1.3 局部加权回归扩充指纹数据库

在离线阶段采集大量的位置指纹极为耗时耗力, 因此当定位系统部署范围较大时, 很难获得精确的定位结果。为了减少指纹采集的工作量, 文献[16]使用了信号传播衰减模型来预测 RSS 值,

这需要得到所有 AP 的位置和定位区域内所有墙壁的分布。即便这些信息都是可获得的, 推导出的模型也不能较精确地估计 RSS 值, 这是由于在不同区域内有不同的信号衰减模型^[17]。

本文使用局部加权回归, 通过对原始测量点的局部插值预测 RSS 值, 既充分利用了邻近位置之间的 RSS 值有一定相似性, 又考虑到了在不同区域的信号衰减模型不相同。LWR 是针对全局模型性能不好, 或者难以获得全局模型的问题提出的, 其优点在于不需要明确给出数据的全局函数^[18]。

本文对每一个 AP 进行一次 LWR, 对于第 i 个 AP 在位置 $q=(x,y)$ 处

$$s = F(q) = a_0 + a_1x + a_2y = \mathbf{a}^T \mathbf{l} \quad (14)$$

$$\mathbf{a} = [a_0, a_1, a_2]^T, \mathbf{l} = [1, q]^T$$

通过加权最小二乘法求解参数矩阵:

$$\mathbf{a} = \arg \min \sum_{j=1}^r w(\mathbf{q}, \mathbf{q}_j) (F(\mathbf{q}_j) - s_j)^2 \quad (15)$$

式中: r 为实际测量点的个数; s_j 为该 AP 在第 j 个测量点处的 RSS 实际测量值; q 为人造测量点的位置坐标; $w(\bullet)$ 为权重函数, 取决于 q 与 q_i 之间的欧氏距离, 这里使用高斯核函数作为权重:

$$w(\mathbf{q}, \mathbf{q}_i) = \exp(-\alpha\mu)$$

$$\mu = \frac{d(\mathbf{q}, \mathbf{q}_i)}{d(\mathbf{q}, \mathbf{q}_*)} \quad (16)$$

式中: α 为控制插值局部性的核参数; $d(\bullet)$ 表示两点之间的欧氏距离。 q_* 为与 q 之间距离最大的实际测量点, 当 $q_* = q_i$ 时 $\mu = 1$, 这就使得与 q 距离越近的点所贡献的权重越大。

令 $\mathbf{W}(q) = \text{Diag}(w(\mathbf{q}, \mathbf{q}_1), w(\mathbf{q}, \mathbf{q}_2), \dots, w(\mathbf{q}, \mathbf{q}_r))$ 则:

$$\mathbf{a} = (\mathbf{L}^T \mathbf{W}(q) \mathbf{L})^{-1} \mathbf{L}^T \mathbf{W}(q) \mathbf{S} \quad (17)$$

$$\mathbf{L}^T = [l_1, l_2, \dots, l_r], \mathbf{S} = [s_1, s_2, \dots, s_r]^T$$

结合式(14)即可求出该 AP 在 q 处的信号强度值。由于权重矩阵与位置 q 密切相关, 因此在不同区域内的回归模型不相同, 这就使得 LWR 可以较精确的估计各个位置的 RSS 值。

2 仿真分析

2.1 实验环境

为了检验本文提出的 LWR-ABCSVR 定位算法的定位性能, 本文使用学者 Gints Jekabsons 采集的 WiFi 指纹数据作为仿真数据集^[19], 进行 matlab 仿真。如图 2, 数据采集区域的面积大约为 860 m², 包括 8 间教室, 4 间办公室和走廊。文献[19]中测量了 57 个 AP 在 82 个测量点处的信号强度值, 在每个测量点处每个方向测量 30 次, 测量时间间隔为 1 s, 每个测量点处共计采样 120 次。其中 5 个 AP 为信号强度较强的本地 AP; 9 个为其他楼层的 AP; 剩余的 43 个为附近大楼中的 AP, 这些 AP 仅在很小的区域内可以被探测到。两个相邻测量点之间的距离约为 3.7 m。另外, 文中还以相同的方式采集了 68 个测试点的信号强度值。本文只使用该数据集中信号强度最强的 14 个 AP 的数据进行仿真。

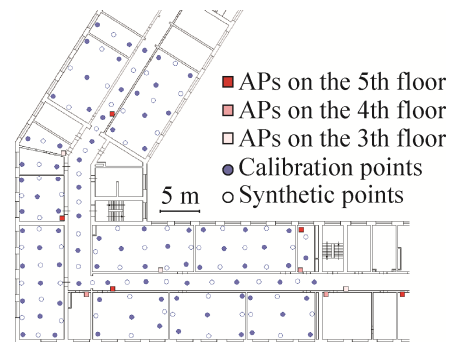


图 2 实验环境^[19]

Fig. 2 Experimental environment

2.2 实验结果

首先, 为了验证 ABC 对 SVR 参数寻优的有效性, 分别使用网格搜索 SVR 和 ABCSVR 构建定位模型, 并对测试点进行定位。ABC 算法中, 种群个数为 80、最大循环次数为 100、最大迭代次数为 200。本文还实现了 ANN 算法和 WKNN 算法。SVR 均采用高斯核; ANN 隐含层为 Sigmoid 函数, 采用隐含层神经元数目为 12 的 3 层误差反向传播结构, WKNN 的近邻数 K 设置为 2。实验中使用了 LIBSVM 工具箱^[20]。

从图 3 可以看出四种算法在采样次数较少时, 定位误差都比较大, 随着采样次数增大定位误差减小。ANN 算法的定位误差最大, 这说明了 ANN 算法的泛化性能较差。而 ABCSVR 定位方法的误差相比网格搜索 SVR 的定位误差明显减小, 采集次数为 30 时 ABCSVR 算法的定位误差已经小于网格搜索 SVR 算法采样次数为 120 次时的平均定位误差。这说明了采用 ABC 和交叉验证的方法对支持向量回归机的参数寻优可以有效减少定位误差。然而, 在该实验环境下 SVR 算法精度低于文献[8]中的 2 m, 这是由于本文的实验环境相对复杂, 且指纹采集密度远低于文献[8]。且在该试验环境下, 由于训练样本有限, 各种机器学习算法的精度并没有高于 WKNN 算法。




图 3 平均定位误差对比

Fig. 3 Comparison of average positioning errors

图 4 为采样次数为 120 次时, 几种定位算法的定位误差累计概率曲线图。当平均定位误差在 3 m 以内时 ABCSVR 算法的累计概率为 60.29%, 而网格搜索 SVR、ANN 算法的累计概率分别为 36.75% 和 19.12%。平均定位误差在 4 m 以内时三种算法的累计概率分别为 73.53%、54.41% 和 36.76%。给定最大误差前提下的累计概率表示算法的定位准确度, 定位准确度越高表征算法的连续性越好, 误差波动性越小。图 4 说明了使用 ABC 和交叉验证的方法对 SVR 参数寻优可以有效提高定位精度。

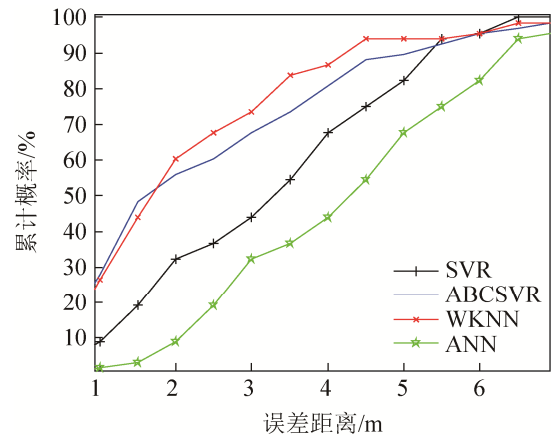


图 4 四种算法定位准确度对比

Fig. 4 Positioning precisions of four algorithms

同时, 为了验证 LWR 扩充指纹数据库的有效性, 本文选取了 50 个人工指纹点, 使用 LWR 估算其相应的信号强度值。选取人工指纹点的大致原则是使两个测量点之间有一个人工指纹点, 人工指纹点的具体位置分布在图 2 中给出。该部分实现了扩充指纹数据库后的 ABCSVR 和 WKNN 算法, 并将实验结果与未扩充前作对比。

从图 5 中可以看出, LWR-WKNN 算法比 WKNN 算法的平均定位误差小。LWR-ABCSVR 较 ABCSVR 的平均定位误差减小, 且减小幅度较大, LWR-ABCSVR 在采样次数为 60 时的定位误差已经小于 ABCSVR、WKNN 和 LWR-WKNN 算法在采样次数为 120 次的定位误差。这说明了通过 LWR 扩充指纹数据库可以有效提高 ABCSVR 算法的定位精度。这就意味着在达到相同定位精度的前提下可以通过 LWR 扩充指纹数据库的方式减少人工采样点的个数, 这可以有效减少指纹数据库采集阶段的工作量。

图 6 为采样次数为 120 次时, 扩充指纹数据库前后 WKNN 和 ABCSVR 算法的定位准确度对比。平均误差在 3 m 以内时 LWR-ABCSVR、ABCSVR、LWR-WKNN、WKNN 的定位准确度分别为: 82.35%、67.65%、77.94%、73.53%。平均误差在 3.5m 以内时四种算法的定位精度分别为 89.70%、73.53%、88.23% 和 83.82%。整体而言, 扩充指纹

数据库后的算法定位准确度也高于扩充之前, 这再次说明了使用 LWR 扩充指纹数据库可以提升定位算法的定位性能。

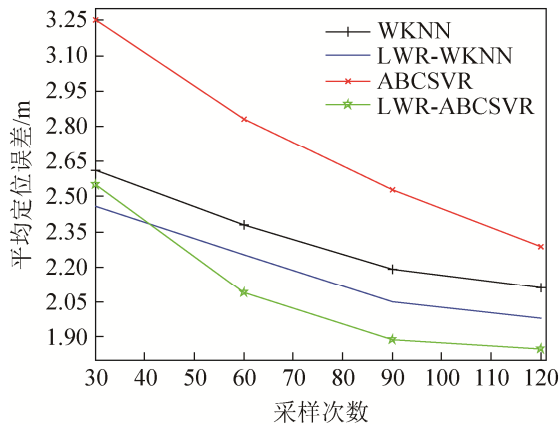


图 5 扩充指纹数据库前后定位误差对比

Fig. 5 Positioning errors before and after fingerprinting database was expanded

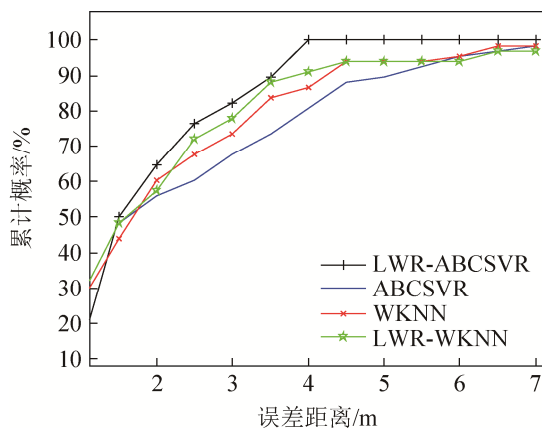


图 6 扩充指纹数据库前后定位准确度对比

Fig. 6 Positioning precision before and after fingerprinting database was expanded

此外, 为了比较算法的综合性能, 需要验证算法的实时性, 本文对表 1 中几种算法的训练时间和预测时间进行了测试。表 1 列出了几种算法的定位平均误差、误差中位数、训练时间和预测时间。可以看到本文提出的 LWR-ABCSVR 算法的定位误差远小于其他几种算法。虽然使用 ABC 进行参数寻优和使用 LWP 扩充指纹数据库后会使得算法的训练时间大幅度提高, 但其预测时间并不算长。由于训练过程将在离线阶段进行, 在线定位阶段只需按照训练好的参数进行预测, 因此本文算法的实时

性只与预测时间有关。虽然实时性略有降低, 但是 LWR-ABCSVR 定位算法对定位精度的提升和对离线阶段数据采集工作量的减少其效果都是明显的。综上所述本文提出的 LWR-ABCSVR 算法的定位性能优于传统的网格搜索 SVR 等算法。

表 1 算法综合性能比较

Tab. 1 Comparison of integrated performance of algorithms

算法名称	平均 误差/m	误差中 位数/m	训练 时间/s	预测 时间/s
WKNN	2.11	1.67	0	0.035
ANN	4.17	4.21	40.516	0.231
网格搜索 SVR	3.18	3.32	38.687	0.460
ABCSVR	2.31	1.71	174.417	0.557
LWR-ABCSVR	1.85	1.59	305.397	0.648

3 结论

本文针对在 WiFi 环境下, 传统的位置指纹定位算法定位精度不够高和指纹数据库构建困难的问题, 提出了一种 LWR-ABCSVR 定位算法。该算法首先通过 LWR 在离线阶段对采集到的位置指纹数据库进行扩充; 然后利用 ABCSVR 构建物理位置和 RSS 之间的非线性预测关系, 并通过构建的预测模型完成定位。通过对比实验可以看出, 本文提出的 LWR-ABCSVR 定位算法的定位精度高于 WKNN、ANN 和网格搜索 SVR 定位算法, 并且可以在一定程度上减少指纹采集的工作量。虽然其他几种算法在训练时间和预测时间上有一定的优势, 但是 LWR-ABCSVR 定位算法对定位精度的提升和对离线阶段数据采集工作量的减少, 其效果都是明显的, 综合考虑本文算法的性能更优越。

参考文献:

- [1] Chen X, Pang J. Protecting query privacy in location-based services [J]. Geoinformatica (S1384-6175), 2012, 18(1): 95-133.
- [2] Xifeng Liu, Yunbin Yuan. Model analysis method (MAM) on the effect of the second-order ionospheric delay on GPS positioning solution [J]. Chinese Science Bulletin (S1001-6538), 2010, 55(15): 1529-1534.
- [3] Liu R P, Hedley M, Yang X. WLAN Location Service

- with TXOP [J]. IEEE Transactions on Computers (S0018-9340), 2013, 62(3): 589-598.
- [4] Bahl P, Padmanabhan V N. RADAR: An In-Building RF-based User Location and Tracking System [J]. Institute of Electrical & Electronics Engineers Inc (S0160-8347), 2000, 2(1): 775-784.
- [5] 石雪军, 纪志成. 基于射频识别的室内定位系统算法研究 [J]. 系统仿真学报, 2015, 27(6): 1294-1300. (Shi Xuejun, Ji Zhicheng. Indoor Positioning System Algorithm Based on RFID [J]. Journal of System Simulation (S1004-731X), 2015, 27(6): 1294-1300.)
- [6] 孙继平, 李晨鑫. 基于 WiFi 和计时误差抑制的 TOA 煤矿井下目标定位方法 [J]. 煤炭学报, 2014, 39(1): 192-197. (Sun Jiping, Li Chenxin. TOA underground coal mine target positioning method based on WiFi and timing error suppression [J]. Journal of China Coal Society (S0253-9993), 2014, 39(1): 192-197.)
- [7] Mok E, Cheung B K S. An Improved Neural Network Training Algorithm for Wi-Fi Fingerprinting Positioning [J]. ISPRS International Journal of Geo-Information (S2220-9964), 2013, 2(3): 854-868.
- [8] 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. (Deng Zhian, Xu Yubin. A Support Vector Regression Algorithm for Indoor Positioning in Wireless Local Area Networks [J]. Chinese Journal of Scientific Instrument (S0254-3087), 2009, 30(6): 578-582.)
- [9] 张学工. 关于统计学习理论与支持向量机 [J]. 自动化学报, 2000, 26(1): 32-42. (Zhang Xuegong. Introduction to Statistical Learning Theory and Support Vector Machines [J]. Acta Automatica Sinica (S0254-4156), 2000, 26(1): 32-42.)
- [10] 邓志安. 基于学习算法的 WLAN 室内定位技术研究 [D]. 哈尔滨: 哈尔滨工业大学, 2012. (Deng Zhian. Research on Learning Based WLAN Indoor Positioning Techniques [D]. Harbin, China: Harbin Institute of Technology, 2012.)
- [11] 徐玉滨, 邓志安, 马琳. 基于核直接判别分析和支持向量回归的 WLAN 室内定位算法 [J]. 电子与信息学报, 2011, 33(4): 896-901. (Xu Yubin, Deng Zhian, Ma Lin. WLAN Indoor Positioning Algorithm Based on KDDA and SVR [J]. Journal of Electronics & Information Technology (S1009-5896), 2011, 33(4): 896-901.)
- [12] 刘路, 王太勇. 基于人工蜂群算法的支持向量机优化 [J]. 天津大学学报(自然科学与工程技术版), 2011, 44(9): 803-809. (Liu Lu, Wang Tai-yong. Support Vector Machine Optimization Based on Artificial Bee Colony Algorithm [J]. Journal of Tianjin University (Science and Technology) (S0493-2137), 2011, 44(9): 803-809.)
- [13] 张勇, 黄杰, 徐科宇. 基于 PCA-LSSVR 算法的 WLAN 室内定位方法 [J]. 仪器仪表学报, 2015, 36(2): 408-414. (Zhang Yong, Huang Jie, Xu Keyu. Indoor positioning algorithm for WLAN based on principal component analysis and least square support vector regression [J]. Chinese Journal of Scientific Instrument (S0254-3087), 2015, 36(2): 408-414.)
- [14] 纪昌明, 周婷, 向腾飞, 等. 基于网格搜索和交叉验证的支持向量机在梯级水电系统隐随机调度中的应用 [J]. 电力自动化设备, 2014, 34(3): 125-131. (Ji Changming, Zhou Ting, Xiang Tengfei, et al. Application of support vector machine based on grid search and cross validation in implicit stochastic dispatch of cascaded hydropower stations [J]. Electric Power Automation Equipment (S1006-6047), 2014, 34(3): 125-131.)
- [15] Karaboga D. An Idea Based on Honey Bee Swarm for Numerical Optimization [R]. Technical Eporttr06. Turkey: Computer Engineering Department, Engineering Faculty, Erciyes University, 2005.
- [16] Hossain A K M M, Van H N, Jin Y, et al. Indoor Localization Using Multiple Wireless Technologies [C]// Mobile Adhoc and Sensor Systems, 2007. MASS: IEEE International Conference. USA: IEEE, 2007: 1-8.
- [17] Du Y, Yang D, Xiu C. A Novel Method for Constructing a WIFI Positioning System with Efficient Manpower [J]. Sensors (S1424-8220), 2015, 15(4): 8358-8381.
- [18] William S Cleveland, Susan J Devlin. Locally Weighted Regression: An Approach to Regression Analysis by Local Fitting [J]. Journal of the American Statistical Association (S0162-1459), 1988, 83(403): 569-610.
- [19] Jekabsons G, Kairish V, Zuravlyov V. An Analysis of Wi-Fi Based Indoor Positioning Accuracy [J]. Scientific Journal of Riga Technical University Computer Sciences (S1407-7493), 2012, 44(1): 131-137.
- [20] Chang C C, Lin C J. LIBSVM: A library for support vector machines [J]. ACM Transactions on Intelligent Systems & Technology (S2231-1961), 2011, 2(3): 389-396.