

基于核自适应滤波的无线传感网络定位算法研究

李军^{1,2} 赵畅¹

(1. 兰州交通大学自动化与电气工程学院, 兰州 730070;

2. 甘肃省轨道交通电气自动化工程实验室, 兰州 730070)

摘要: 针对动态室内环境的变化及时变的接收信号强度(Received signal strength, RSS)对定位精度的影响,提出了一类基于核自适应滤波算法的农业无线传感器网络室内定位方法。核自适应滤波算法具体包括量化核最小均方(Quantized kernel least mean square, QKLMS)算法及固定预算(Fixed-budget, FB)核递推最小二乘(Kernel recursive least-squares, KRLS)算法。QKLMS算法基于一种简单在线矢量量化方法替代稀疏化,抑制核自适应滤波中径向基函数结构的生长。FB-KRLS算法是一种固定内存预算的在线学习方法,与以往的“滑窗”技术不同,每次时间更新时并不“修剪”最旧的数据,而是旨在“修剪”最无用的数据,从而抑制核矩阵的不断增长。通过构建RSS指纹信息与物理位置之间的非线性映射关系,核自适应滤波算法实现WSN的室内定位,将所提出的算法应用于仿真与物理环境下的不同实例中,在同等条件下,还与其他核学习算法、极限学习机(Extreme learning machine, ELM)等定位算法进行比较。仿真实验中2种算法在3种情形下的平均定位误差分别为0.746、0.443 m,物理实验中2种算法在2种情形下的平均定位误差分别为0.547、0.282 m。实验结果表明,所提出的核自适应滤波算法均能提高定位精度,其在线学习能力使得所提出的定位算法能自适应环境动态的变化。

关键词: 核自适应滤波; 量化核最小均方算法; 核递推最小二乘算法; 无线传感网络; 室内定位

中图分类号: TP391.4; TN92 **文献标识码:** A **文章编号:** 1000-1298(2018)04-0241-08

Wireless Sensor Network Location Algorithms Based on Kernel Adaptive Filtering

LI Jun^{1,2} ZHAO Chang¹

(1. School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China

2. Rail Transit Electrical Automation Engineering Laboratory of Gansu Province, Lanzhou 730070, China)

Abstract: For the change of dynamic indoor environment and the effect of time-varying received signal strength on positioning accuracy, a class of indoor positioning algorithms for agricultural wireless sensor networks using kernel adaptive filtering was proposed, which included quantized kernel least mean square (QKLMS) as well as fixed-budget kernel recursive least-squares (FB-KRLS) algorithm. The QKLMS algorithm used a simple vector quantization approach as an alternative of sparsification to curb the growth of the radial basis function structure in kernel adaptive filtering. The FB-KRLS algorithm was an online kernel method by fixed memory budget, which was capable of recursively learning nonlinear mapping and tracking change over time. In contrast to a previous sliding-window based technique, the presented algorithm did not prune the oldest data point in every time instant but it was aimed to prune the least significant data point, thus suppressing the growth of kernel matrix. The kernel adaptive filtering algorithms achieved the indoor positioning for WSNs by building the non-linear mapping relations between the RSS fingerprint information and the physical location. The employed algorithms were applied to different indoor positioning instances in the simulation and physical environments for WSNs, under the same circumstances, compared with other kernel-based learning methods and extreme learning machine (ELM) etc. In the simulation experiment, the average localization error of the two algorithms was respectively 0.746 m and 0.443 m under three scenarios, and the average localization error of the two algorithms in the physical experiments was respectively 0.547 m and 0.282 m under two scenarios.

收稿日期: 2017-09-18 修回日期: 2017-10-14

基金项目: 国家自然科学基金项目(51467008)和兰州交通大学优秀科研团队项目(201701)

作者简介: 李军(1969—),男,教授,博士,主要从事计算智能及其应用研究, E-mail: lijun691201@mail.lzjtu.cn

Experimental results showed that the proposed adaptive filtering algorithms can improve the positioning accuracy, and its online learning ability made the proposed two localization algorithms all adaptable to the dynamic changes of the environments.

Key words: kernel adaptive filtering; quantized kernel least mean square algorithm; kernel recursive least square algorithm; wireless sensor networks; indoor positioning

0 引言

随着农业无线传感网络基于位置服务 (Location based service, LBS) 的需求与日俱增, 诸如 WiFi 路由器等现有 WiFi 结构在农业信息化领域中被广泛使用, 位置信息在 WSN 的监测活动中至关重要, 而受资源和环境限制, 均配置全球定位系统 (Global positioning system, GPS) 接收器的节点部署并不实际, 而且 GPS 信号易被建筑物阻挡, 在室内环境下信号很差, 因此研究农业 WSN 的室内定位方法十分重要^[1-2]。

目前, 几乎所有的移动装置均配备了 WiFi 接收器, 研究 WiFi 室内定位系统 (Indoor positioning systems, IPS)^[3-5], 提供满足农业信息化环境下 LBS 的需求已成为可行。802.11 接口内置了提供接收信号强度^[6] (Received signal strength, RSS) 信息的功能, 由于位置指纹定位技术利用内嵌 WiFi 功能的移动设备所测得的 RSS 进行物理位置估计, 避免了对复杂信号传输模型的建立, 且无需知道各接入点 (Access point, AP) 的确切位置, 因此, 研究基于不同计算智能算法的位置指纹定位方法^[7-8]具有很好的应用前景。

考虑特征提取技术, 文献[9]给出一种 PCA-LSSVR 室内定位的算法; 文献[10]给出一种 KDDA-SVR 的定位算法, 利用核判别分析抑制噪声并提取最具判别力的定位特征; 文献[11]提出一种基于核主元分析 (Kernel principal component analysis, KPCA) 与改进的加权 k 近邻算法结合的室内定位方法, 均有效提高了定位精度。作为一种单隐层前馈网络 (SLFNs) 的快速学习算法——极限学习机 (ELM)^[12] 及在线极限学习机 (OS-ELM)^[13] 算法, 也已成功应用于 WSN 的室内指纹定位中, 且在线算法还对环境动态变化具有自适应性。另一方面, 在线核自适应滤波学习算法的研究已引起人们广泛关注^[14-17], 应用于一般非线性系统预测及辨识中。

鉴于核自适应滤波算法在时变非线性系统辨识中的成功应用, 以及文献[7-8]中 SVM 等核学习方法在室内定位中的成功应用, 针对农业 WSN 室内定位, 本文提出基于一类包括 QKLMS 及 FB-KRLS 的核自适应滤波算法, 应用于仿真及实际的 WSN 位

置指纹定位实例中, 以期达到适应动态室内环境的变化, 降低时变的 RSS 值对定位精度影响的效果。

1 基于核自适应滤波算法的指纹定位

将核学习算法应用于位置指纹定位中, 具体包含 2 个阶段: ①标定阶段, 是指在感兴趣的区域, 根据选定的标定点通过移动装置测量来自不同 AP 的 RSS 值, 单位为 dBm, 对每个标定点收集若干次, 与该标定点物理坐标一同构建指纹数据库, 即称之为无线电地图。②定位 (在线或实时) 阶段, 是指在定位区域内任意选择未知的测试点, 实时收集该点在不同 AP 下的 RSS 指纹值, 利用核自适应滤波算法, 通过匹配已有指纹数据库中已测得的指纹进行估计, 从而获取用户的定位位置。

若无线电地图中数据对为: (s_i, q_i) , $i = 1, 2, \dots, l$, 其中, $s_i \in \mathbf{R}^n$ 是第 i 个定位位置处所接收的来自 v 个 AP 的 RSS 值, $q_i = (x_i, y_i)$ 为定位位置的物理坐标。核自适应滤波算法首先需将输入 s_i 映射至高维非线性特征空间, 即 $\phi: s \in \mathbf{R}^n \rightarrow \phi(s) \in F \subseteq \mathbf{R}^V$, 定义核函数 $k(s_i, s_j) = \phi(s_i)^T \phi(s_j)$, 则可以得到满足 Mercer 条件的由核函数作为元素构成的核矩阵 $\mathbf{K} = \Phi^T \Phi$, 其中 $\Phi = [\phi(s_1) \ \phi(s_2) \ \dots \ \phi(s_l)]$ 。通常非线性核函数选取高斯径向基 (RBF) 函数或多项式核函数等即可。

受自适应滤波在线学习算法的启发, 核自适应滤波是基于核学习的在线序列估计算法, 即在获取第 i 个数据对 (s_i, q_i) 时, 在已对前 $(i-1)$ 个数据完成估计 (记为 f_{i-1}) 的基础上, 进行学习算法的在线更新, 以获取当前非线性映射关系 f 的估计值, 记为 f_i 。针对指纹数据库, 应用核自适应滤波算法训练, 以建立定位特征与物理坐标之间的非线性映射关系 $f(s)$, 即

$$f(s) = \sum_{i=1}^N \alpha_i k(s_i, s) \quad (1)$$

式(1)中, 非线性映射关系的实现是由支持向量 s_i 的线性组合完成的。

1.1 基于 QKLMS 的室内定位算法

KLMS 算法将线性 LMS 算法延伸至特征空间 F 中。将高维非线性特征空间的输入 $\phi(s_i)$ 记为 ϕ_i , 对于序列数据 (ϕ_i, q_i) , 应用 LMS 算法, 即有

$$\begin{cases} \omega_0 = 0 \\ e_i = q_i - \omega_{i-1}^T \phi_i \\ \omega_i = \omega_{i-1} + \eta e_i \phi_i \end{cases} \quad (2)$$

式中 e_i ——已获取第 i 个数据时的预测误差
 η ——学习率
 ω_i ——特征空间中的权向量估计值

由于 $f_i = \omega_i^T \phi(\cdot)$, 由式(2)及性质 $\phi(s) = k(s, \cdot)$, 在原空间上的 KLMS 算法为

$$\begin{cases} f_0 = 0 \\ e_i = q_i - f_{i-1}(s_i) \\ f_i = f_{i-1} + \eta e_i k(s_i, \cdot) \end{cases} \quad (3)$$

式(3)表明, KLMS 算法在本质上等价于一个不断增长的 RBF 网络, 即随着每个新数据的获取, 分配一个新的以输入 s_i 为中心的核单元, ηe_i 是其系数。

QKLMS 算法则由对特征向量 ϕ_i 的量化得到, 具体体现为式(2)的权值更新方程中。此时, 式(3)的 KLMS 算法变形为

$$\begin{cases} f_0 = 0 \\ e_i = q_i - f_{i-1}(s_i) \\ f_i = f_{i-1} + \eta e_i k(Q[s_i], \cdot) \end{cases} \quad (4)$$

式中 $Q[\cdot]$ ——原空间 U 上的量化算子, 记 $s_q(i) = Q[s_i]$

量化技术被广泛用于数据压缩、语音与图像编码中, 式(4)的量化方法可以对输入(或特征)空间进行压缩, 因此, 通过减小网络的大小(中心的数目)达到核自适应滤波中的紧凑 RBF 结构表示。QKLMS 的网络大小显然总是小于量化码本的数量, 量化码本即字典。

QKLMS 算法的关键问题是向量量化技术的设计, 即如何将数据选为码本向量, 如何找到最近的码本向量表示。为适应在线学习, 码本向量必须提前获取, 即码本向量直接从在线数据中训练得到, 自适应地增长。定义 C_i 为第 i 个数据到来时的所有码本向量构成的矩阵, C_i^j 为矩阵第 j 列的元素构成的码本向量。另一方面, 对高斯核函数而言, 为度量特征空间中的数据距离, 可得到

$$\begin{aligned} \|\phi_i - \phi_j\|_F &= \sqrt{(\phi_i - \phi_j)^T (\phi_i - \phi_j)} = \\ &= \sqrt{2 - 2k(s_i, s_j)} = \\ &= \sqrt{2 - 2 \exp\left(\frac{-\|s_i - s_j\|^2}{2\sigma^2}\right)} \end{aligned} \quad (5)$$

式中 $\|\cdot\|_F$ ——特征空间 F 中的范数
 σ ——核参数

由式(5)可得, 特征空间 F 中的距离随原空间中的距离变化而单调递增。因此, 由式(5)可定义

量化阈值

$$\varepsilon_U = \sqrt{2 - 2 \exp\left(\frac{-\varepsilon_U^2}{2\sigma^2}\right)} \quad (6)$$

其中 $\varepsilon_U = \|s_i - s_j\|$
 式中 ε_U ——原空间 U 中的量化阈值

且有 $\|s_q(i) - s_i\| \leq \varepsilon_U$, 定义量化因子 $\gamma = \frac{\varepsilon_U}{\sigma}$ 。

综上, 基于 QKLMS 的位置指纹定位算法具体实现步骤如下:

- (1) 序列给定数据对 $(s_i \in U, q_i), i = 1, 2, \dots$ 。
- (2) 在线训练阶段。给定 $\eta > 0, \sigma > 0$ 及量化阈值 $\varepsilon_U > 0$, 当 $i = 1$ 时, 给定码本向量矩阵(数据中心的集合)的初始值 $C_1 = [s_1]$, 系数向量 $\alpha_1 = [\eta q_1]$ 。
- (3) $i = i + 1, N = \text{size}(C_{i-1})$, 计算自适应滤波输出

$$\hat{q}_i = \sum_{j=1}^N \alpha_{i-1}^j k(C_{i-1}^j, s_i) \quad (7)$$

式中 α_{i-1}^j ——第 i 个数据到来时所得到的系数向量的第 j 个元素

$$(4) \text{ 计算误差} \quad e_i = q_i - \hat{q}_i \quad (8)$$

$$\text{计算输入向量和所有码本向量之间的最小距离} \quad \text{dis}(s_i, C_{i-1}) = \min_{1 \leq j \leq N} \|s_i - C_{i-1}^j\| \quad (9)$$

(5) 如果 $\text{dis}(s_i, C_{i-1}) \leq \varepsilon_U$, 码本向量矩阵维持不变, 即 $C_i = C_{i-1}$, 量化 s_i 到最近的中心, 通过更新最近中心的系数向量而完成, 即

$$\alpha_i^* = \alpha_{i-1}^* + \eta e_i \quad (10)$$

其中最近中心的索引号 $j^* = \arg \min_{1 \leq j \leq N} \|s_i - C_{i-1}^j\|$ 。

否则, 将 s_i 置为新的码本向量(中心), 更新系数向量, 即

$$\begin{cases} C_i = [C_{i-1}, s_i] \\ \alpha_i = [\alpha_{i-1}; \eta e_i] \end{cases} \quad (11)$$

(6) 迭代计算步骤(3)至步骤(5), 直至依次完成所有训练数据的学习。

(7) 在线测试阶段, 基于已训练的 QKLMS 模型, 对待测试的 RSS 指纹数据进行定位。即由式(7)计算待测试的 RSS 指纹值所对应的物理位置估计值。

从实现过程看, QKLMS 算法在某种程度上相似于稀疏化的 KLMS 算法, 关键的不同在于该算法利用“冗余数据”对最近中心的系数进行局部更新, 系数的更新能增强码本向量的利用效率, 因而会使得网络的表示更加紧凑, 估计精度更好, 当量化阈值 $\varepsilon_U = 0$ 时, 即退化为 KLMS 算法。

1.2 基于 FB-KRLS 的室内定位算法

在离线训练阶段, 当 l 个输入-输出数据对依次

获取后,标准的KRLS算法可以看成寻找式(12)的最优系数,使其最小化,即

$$J(\alpha) = \min_{\alpha} |q - K\alpha|^2 + \lambda \alpha^T K\alpha \quad (12)$$

式中 q ——包含训练输出 q_i 的向量, $\in \mathbf{R}^l$
 K ——核矩阵,其元素 $K_{i,j} = k(s_i, s_j)$
 λ ——正则化参数

式(12)的解为

$$\alpha = (K + \lambda I)^{-1} q \quad (13)$$

式中 I ——单位阵, $I \in \mathbf{R}^{l \times l}$

KRLS 算法的目标是随着新数据的依次获取递推更新式(13)的解,其计算负担主要取决于核矩阵 K 的大小, K 则由输入数据的数目 l 确定。在求解式(13)过程中,随着 l 的不断增长,会出现导致 K 无限增长的缺陷。为抑制核矩阵的无限增长,ALD 准则^[14]、“滑动窗口”技术^[15]等方法被广泛采用,这些方法通过提取数据中的有限“字典”用于预测建模,从而限制了核矩阵的大小,均取得了较好效果。FB-KRLS 算法使用了“固定内存预算”技术,该技术采用了主动学习策略构建“字典”,在每次时间更新时,将新的数据增加至内存中,然后将内存中现有的最无关的数据丢弃,从而维持内存中的现有数据数目大小不变。这种“修剪”技术已经成功应用于神经网络设计^[18]中。

FB-KRLS 算法在线学习过程中,固定内存的数据大小为 M ,针对时变的数据,算法的计算复杂度将不高于 $O(M^2)$ 。在第 i 个时刻,即获取第 i 个数据对 (s_i, q_i) 时,为算法描述方便,记核矩阵 K_i 为式(13)中的 $(K + \lambda I)$ 。

基于 FB-KRLS 的位置指纹定位算法具体实现步骤如下:

(1) 序列给定数据对 $(s_i \in U, q_i), i = 1, 2, \dots$ 。

(2) 在线训练阶段。初始化固定内存的大小(字典容量) M 的取值及 λ , 学习率 η , 高斯核参数 σ 的取值,当 $i = 1$ 时, $K_1 = [k(s_1, s_1) + \lambda]$, 计算 K_1^{-1} 及式(13)中的 α 。

(3) $i = i + 1$, 获取新的数据 (s_i, q_i) , 更新储存在内存中所有已有数据的输出,即

$$q_i = q_i - \eta k(s_i, s_i) (q_i - q_i) \quad (t = 1, 2, \dots, M) \quad (14)$$

(4) 将新数据 (s_i, q_i) 加入内存中,这相应于对当前核矩阵 K_{i-1} 扩充行与列,令

$$\tilde{K}_i = \begin{bmatrix} K_{i-1} & b \\ b^T & c \end{bmatrix}$$

由矩阵求逆公式可得到

$$\tilde{K}_i^{-1} = \begin{bmatrix} K_{i-1}^{-1} (I + g b b^T (K_{i-1}^{-1})^T) & -g K_{i-1}^{-1} b \\ -g (K_{i-1}^{-1} b)^T & g \end{bmatrix} \quad (15)$$

其中 $g = (c - b^T \tilde{K}_{i-1}^{-1} b)^{-1}$

$$c = k_{ii} + \lambda \quad b = k_{i-1}(s_i)$$

$$k_{i-1}(s_i) = [k(s_1, s_i) \quad \dots \quad k(s_{i-1}, s_i)]^T$$

(5) 当 i 的取值大于 M 时,对所有储存在内存中的数据对,考虑按误差丢弃准则^[19]计算,即

$$d(s_t, q_t) = \frac{|\alpha_t|}{[\tilde{K}_i^{-1}]_{t,t}} \quad (16)$$

式中 (s_t, q_t) ——内存中的第 t 个数据对

α_t —— α 中的第 t 个元素

$[\tilde{K}_i^{-1}]_{t,t}$ ——矩阵的第 t 个对角元素

按式(16)确定 $d(s_t, q_t) = \min$ 的数据 (s_L, q_L)

及索引号 L ,从内存中丢弃,对核矩阵 \tilde{K}_i ,删去其第 L 行、 L 列元素后,其矩阵记为 K_i^L 。

为完成该步骤,首先,定义置换矩阵 P_L, H_L 为

$$P_L = \begin{bmatrix} 0 & O & 1 & O \\ O & I_{L-2} & O & O \\ 1 & O & 0 & O \\ O & O & O & I_{M-L+1} \end{bmatrix}$$

$$H_L = \begin{bmatrix} O & I_{L-1} & O \\ 1 & O & O \\ O & O & I_{M-L} \end{bmatrix}$$

式中 I ——单位矩阵, $I \in \mathbf{R}^{i \times i}$

O ——具有相应维数的零矩阵

且有 $P_L^{-1} = P_L, H_L^{-1} = H_L^T$ 。

计算 $\tilde{K}_i^L = P_L \tilde{K}_i P_L$, 则有 $(\tilde{K}_i^L)^{-1} = P_L \tilde{K}_i^{-1} P_L$ 。其次,移除 \tilde{K}_i^L 的第 1 行和第 1 列,以得到 K_i^L 。为计算 $(K_i^L)^{-1}$,需考虑的矩阵运算性质为

$$\tilde{K}_i = \begin{bmatrix} a & b^T \\ b & K_i \end{bmatrix} \quad (17)$$

$$\left\{ \begin{aligned} (\tilde{K}_i)^{-1} &= \begin{bmatrix} e & f^T \\ f & G \end{bmatrix} \\ K_i^{-1} &= G - f f^T / e \end{aligned} \right. \quad (18)$$

由式(18)的性质,可计算 $(K_i^L)^{-1}$ 。最后,计算 $K_i^{-1} = H_L (K_i^L)^{-1} H_L$ 。

(6) 基于更新后的内存数据,由式(13)计算新的 α 。

(7) 循环计算步骤(3)至步骤(6),直至所有训练数据依次完成。

(8) 测试阶段,基于已训练的 FB-KRLS 模型,对待测试的 RSS 指纹数据 s_j 进行定位,即

$$\hat{q}_j = k_M(s_j)^T \alpha_M \quad (19)$$

2 实验

将基于 QKLMS 及 FB-KRLS 的核自适应滤波算法应用到仿真与实际的 WSN 室内定位实例中。同等条件下,还与 KPCA-SVM、KPCA-LSSVM、ELM、KELM、KPLS、OS-ELM、ALD-KRLS、SW-KRLS 等算法进行对比实验。SVM 使用 LIBSVM 软件完成,各种不同核学习方法中,均选取高斯核函数

$$k(s_i, s_j) = \exp(-\|s_i - s_j\|^2 / (2\sigma^2))$$

定位精度评估指标是平均定位误差,即测试点距离误差的平均值。定义实际坐标点 (x_0, y_0) 与预测坐标点 (x, y) 之间的距离误差 e 为

$$e = \sqrt{(x - x_0)^2 + (y - y_0)^2} \quad (20)$$

2.1 仿真实例

与文献[13]一致,仿真实验环境为 400 m^2 的房间,将 4 个 WiFi 路由器,即 4 个 AP 分别安置在房间的 4 个墙角,使用的室内环境路径损耗模型为最普遍的 ITU 室内传输模型。使用室内环境路径损失传输模型 ITU 模型^[13]模拟每个 WiFi 路由器发出的 WiFi 信号。ITU 传输模型描述了总的路径损失 P_L (dBm) 与距离 d (m) 之间的关系,表示如下

$$P_L(d) = P_{L_0} - 10\alpha \lg d + X_\sigma \quad (21)$$

式中 P_{L_0} ——路径损失系数,可给定为 -40 dBm

X_σ ——具有 0 均值、方差为 0.5 的标准正态分布噪声

α ——路径损失指数

为了模拟动态的室内环境,定义 α 为 2、2.5、3.5 分别表示 3 种不同的情形:场景 1、场景 2、场景 3。场景 1 负责收集在 10 个随机选择点处,来自 4 个 AP 的 WiFi RSS 指纹值作为训练数据集。场景 2 与场景 3 均收集随机选择的 5 个校验点及 5 个测试点的 RSS 指纹值,不同场景下的每个点均独立收集 200 个 RSS 指纹值。

与文献[13]的实验一致,定义如下的训练数据集:环境 1:场景 1 中 10 个点作为训练点,无校验。环境 2:场景 1 的训练点及场景 2 的 5 个校验点。环境 3:场景 2 的训练点及场景 3 的 5 个校验点。

测试数据为 10 个测试点,分别选取场景 2 及场景 3 的 5 个测试点。由校验点进行交叉验证,可选取不同定位方法较优的模型参数。训练阶段就是针对 3 种不同的训练数据,分别建立不同的 QKLMS、FB-KRLS 模型;测试阶段即是对 10 个测试点进行模型更新与在线定位。

实验选取高斯核函数的核参数 $\sigma = 3$, QKLMS

算法中,选取量化阈值 $\varepsilon_U = 0.6$, $\eta = 0.1$, 量化因子 $\gamma = 0.2$ 。FB-KRLS 算法中,选取固定内存 $M = 90$, 学习率 $\eta = 0.1$, 正则化参数 $\lambda = 0.1$ 。对比实验中,ALD-KRLS 算法中,选取最大字典容量 $m_{\max} = 300$, 阈值 $\mu = 0.001$ 。SW-KRLS 算法中,选取窗口长度 $M = 90$, 正则化参数 $\lambda = 0.1$ 。其他的对比核学习算法有 KPLS^[20]、KELM^[21]等, KPCA 与 SVM 等结合的算法中,由于 KPCA^[11]已选取高斯核函数,因而 SVM 或 LSSVM 选取线性核函数即可,选取 KPCA 的非线性主元数目为 100, KPLS 中潜在变量数目为 100, ELM 及 OS-ELM 方法的参数选取与文献[13]一致。

另外需要强调的是,在仿真实验中, QKLMS 算法和 KRLS 算法均采用了自适应模型更新的定位方法完成测试阶段的实验。初始的模型参数由训练阶段的数据产生,若需要对测试阶段的第 1 个测试数据进行定位,首先利用训练阶段得到的模型参数对其进行定位,当其真实定位位置获得后,用此真值对原有的模型参数进行更新,再用更新后的模型对下一时刻的测试数据进行定位。这一自适应定位过程持续至所有测试数据完成定位为止,这也体现了在线算法的优势。

图 1a 给出 3 种实验场景训练下, QKLMS 算法的定位误差累计概率分布图。图 1b 则给出在 3 种实验场景训练下, FB-KRLS 算法的定位误差累计

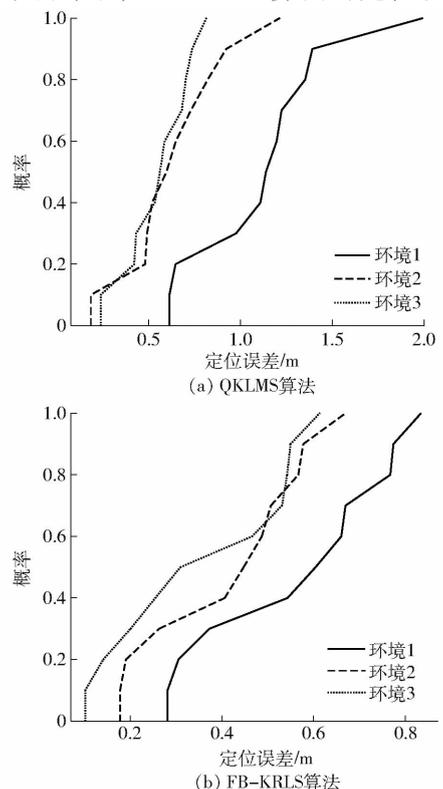


图 1 3 种实验环境下定位误差的累计概率分布
Fig. 1 Cumulative probability distributions of positioning error under three experimental environments

概率分布图。从图 1 看出,不同场景下 2 种算法经训练后均取得了不错的定位效果,且在场景 3 的情形下,2 种算法均各自取得了最好的定位效果,但 FB-KRLS 算法的定位精度最优。需要说明的是,QLMS 算法与 FB-KRLS 算法相比,由于无矩阵求逆运算,在计算效率上则更佳。

表 1 给出了不同情形下,QLMS、FB-KRLS 算法与其他定位算法的具体定位精度比较,由表 1 可以看出,文献[13]的 OS-ELM 算法的定位精度优于其他离线定位算法,但 SW-KRLS 算法及本文的 QLMS 算法、FB-KRLS 算法的定位精度均优于文献[13]的结果,这是由于核自适应滤波算法使用了自适应更新及正则化 L_2 范数的优点所至,更适宜于在时变环境下的跟踪定位。对表 1 中 3 种情形下的定位误差进行平均,可以得到 2 种算法的平均定位误差分别为 0.746、0.443 m。实验也证实基于 QLMS 或 KRLS 等的核自适应滤波算法的在线预测定位,均对动态环境的变化具有很好的自适应性,其中,QLMS 算法的计算效率相比 KRLS 算法更高。

表 1 QKLMs、FB-KRLS 算法与其他算法的定位精度对比

Tab.1 Comparison of positioning accuracy of QKLMs and FB-KRLS algorithm with other algorithms m

定位算法	环境 1	环境 2	环境 3
KPCA-SVM	4.864	5.372	6.146
KPCA-LSSVM	5.227	5.701	6.430
ELM	5.109	5.608	5.656
KELM	5.326	5.492	5.731
KPLS	5.252	5.190	5.393
OS-ELM ^[13]	3.103	2.563	1.794
ALD-KRLS	3.330	3.329	3.327
SW-KRLS	1.927	1.715	1.693
QKLMs	1.091	0.607	0.539
FB-KRLS	0.551	0.410	0.367

2.2 物理实例

本节实验采用 KIOS 研究中心公开的 WiFi 定位数据集^[22],其实验环境是 560 m² 的办公楼,平面部署如图 2 所示,其中包括小隔间、私人办公室、一间会议室及走廊,安装基于 IEEE 802.11b 标准的 9 个固定 AP,以覆盖整个楼层的 WiFi 信号。使用 HTC 智能手机及配置 Windows Mobile 操作系统的 HP iPAQ hw6915 PDA 等 5 个不同的移动设备同时进行数据收集。训练数据的获取是在 105 个参考位置记录指纹,即所能接收到的 AP 的 RSS 值,约为 2 100 个指纹,其中每个参考位置共收集 20 次 RSS 值。测试数据是在 14 d 后沿着预先规定的路线行走进

行收集的,在 96 个位置记录指纹,每个位置收集 10 次 RSS 值,约为 960 个指纹。其中,大多数测试位置点不同于参考位置点。RSS 范围在 -99 ~ -10 dBm 之间,由于存在信号干扰或网络中断等因素,导致极个别位置点收集不到某个 AP 的 RSS,可用 -99 dBm 替代。

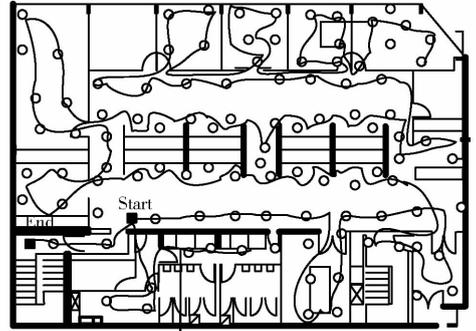


图 2 实验环境部署示意图

Fig.2 Deployment diagram of experimental environment

实验选择 HTC Flyer Android 和 HP iPAQ 2 种移动设备收集到的数据,采取交叉验证法,QLMS 中选取核参数 $\sigma = 2.5$, $\varepsilon_U = 0.5$, $\eta = 0.1$, 量化因子 $\gamma = 0.2$ 。在 FB-KRLS、ALD-KRLS、SW-KRLS 算法中,选取核参数 $\sigma = 20$ 。FB-KRLS 算法中,选取 $M = 300$, $\eta = 0.5$, $\lambda = 0.9$ 。ALD-KRLS 算法中,选取字典最大容量 $m_{\max} = 500$, 阈值 $\mu = 0.01$, SW-KRLS 算法中,设置窗口长度 $M = 250$, 选取正则化参数 $\lambda = 0.01$ 。

用于实验对比的其他核学习算法与 2.1 节相同,实验中选取 KPCA 的非线性主元数目为 10, KPLS 中潜在变量数目为 30。在 ELM 及 OS-ELM 方法中,隐含层节点数目为 200, 激活函数选取 hardlim 函数。与 2.1 节相同,QLMS 与 KRLS 算法均采用了自适应模型更新的定位算完成测试阶段的实验。若测试阶段不更新模型参数,其定位精度会有下降且无法体现动态自适应递推算法的优势。

图 3 给出了在应用 HTC 手机与 iPAQ 收集 9 个固定 APs 的 RSS 值情形下,不同定位方法的定位误差累计概率分布曲线。由图 3 可以看出,QLMS 算法与 FB-KRLS 算法的定位误差略低于其他算法,其中 FB-KRLS 算法的定位精度最高,但 QLMS 算法的计算效率高。

表 2 给出了 HTC 与 iPAQ 在固定 APs 的 RSS 情况下,不同定位算法的具体定位精度。由表 2 可以看出,QLMS、KRLS 算法的定位精度优于 SVM、ELM、KELM、OS-ELM 等算法,FB-KRLS 算法在 2 种不同数据集的动态环境下进行实验,其定位精度的变化波动较小,相比 QLMS 算法,分别提高了约 54.5%、40.8%,但其算法运行过程中涉及矩阵求逆

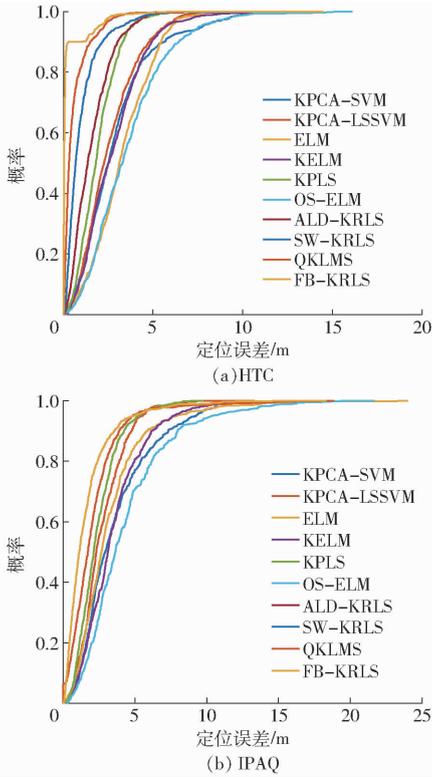


图 3 不同定位算法距离误差累计概率分布
Fig. 3 Cumulative probability distributions of distance error using different positioning algorithms

运算,计算效率不如 QKLMS 算法。不同核自适应滤波学习算法对动态的环境具有较强的自适应性。若对表 2 两种情形下的定位误差进行平均,可以得到所提出的 2 种核自适应滤波算法的平均定位误差分别为 0.547、0.282 m。

实验结果证实 QKLMS 和不同 KRLS 算法的定位精度变化波动较小,具有很强的自适应性,这也进一步验证了在线核自适应滤波算法的有效性,且随着数据集的规模变大,递推学习的优势将会进一步

体现。另外, QKLMS 算法与之相比,由于无矩阵求逆运算,在计算效率上更佳。

表 2 QKLMS、FB - KRLS 算法与其他算法的定位精度对比
Tab. 2 Comparison of positioning accuracy of QKLMS and FB - KRLS algorithms with other algorithms m

定位算法	HTC	IPAQ
KPCA - SVM	2.933	3.636
KPCA - LSSVM	2.589	2.664
ELM	3.255	3.259
KELM	2.237	2.627
KPLS	1.922	2.389
OS - ELM	3.241	3.313
ALD - KRLS	1.599	2.079
SW - KRLS	1.009	1.643
QKLMS	0.605	0.488
FB - KRLS	0.275	0.289

3 结论

(1) 提出了一类基于核自适应滤波的 WSN 室内定位算法,具体包括 QKLMS 及 FB - KRLS 算法。QKLMS 算法通过在线向量量化方法,对特征空间中的输入进行量化处理,合理控制网络结构的大小。FB - KRLS 算法则通过固定内存数据容量的方法,使用“修剪”技术丢弃内存中最无意义的的数据,达到合理控制核矩阵的规模,以适应于大规模数据的训练。

(2) 核学习算法在一定程度上能提高回归建模的非线性逼近能力,仿真和实际物理室内定位实例的实验验证了本文的核自适应滤波算法的有效性,所提出的 QKLMS 算法和 FB - KRLS 算法还能在一定程度上克服时变 RSS 引入的干扰影响,这充分体现了自适应滤波的作用。

参 考 文 献

- 1 王俊,李树强,刘刚. 无线传感器网络三维定位交叉粒子群算法[J/OL]. 农业机械学报, 2014,45(5):233 - 238. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20140536&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2014.05.036.
WANG Jun, LI Shuqi, LIU Gang. Three-dimensional localization method of agriculture wireless sensor networks based on crossover particle swarm optimization[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2014,45(5):233 - 238. (in Chinese)
- 2 王新,许苗,张京开,等. 温室作业机具室内定位方法研究[J/OL]. 农业机械学报, 2017, 48(1):21 - 28,13. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170104&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2017.01.004.
WANG Xin, XU Miao, ZHANG Jingkai, et al. Greenhouse agricultural machinery indoor positioning method[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017,48(1):21 - 28,13. (in Chinese)
- 3 DEAK G, CURRAN K, CONDELL J. A survey of active and passive indoor localisation systems[J]. Computer Communications, 2012, 35(16):1939 - 1954.
- 4 GU Y, LO A, NIEMEGERE I. A survey of indoor positioning systems for wireless personal networks[J]. IEEE Communications Surveys & Tutorials, 2009, 11(1): 13 - 32.
- 5 YANG C, SHAO H R. WiFi-based indoor positioning[J]. IEEE Communications Magazine, 2015, 53(3):150 - 157.
- 6 KAEMARUNSI K, KRISHNAMURTHY P. Analysis of WLAN's received signal strength indication for indoor location

- fingerprinting[J]. *Pervasive & Mobile Computing*, 2012, 8(2):292-316.
- 7 BRUNATO M, BATTITI R. Statistical learning theory for location fingerprinting in wireless LANs[J]. *Computer Networks*, 2005, 47(6):825-845.
- 8 石柯, 陈洪生, 张仁同. 一种基于支持向量回归的 802.11 无线室内定位方法[J]. *软件学报*, 2014, 25(11):2636-2651. SHI Ke, CHEN Hongsheng, ZHANG Rentong. Indoor location method based on support vector regression in 802.11 wireless environments[J]. *Journal of Software*, 2014, 25(11):2636-2651. (in Chinese)
- 9 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*, 2015, 36(2):408-414. (in Chinese)
- 10 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*, 2011, 33(4):896-901. (in Chinese)
- 11 李华亮, 钱志鸿, 田洪亮. 基于核函数特征提取的室内定位算法研究[J]. *通信学报*, 2017, 38(1):158-167. LI Hualiang, QIAN Zhihong, TIAN Hongliang. Research on indoor localization algorithm based on kernel principal component analysis[J]. *Journal on Communications*, 2017, 38(1):158-167. (in Chinese)
- 12 DWIYASA F, LIM M H, ONG Y S, et al. Extreme learning machine for indoor location fingerprinting[J]. *Multidimensional Systems and Signal Processing*, 2017, 28(3):867-883.
- 13 ZOU H, LU X, JIANG H, et al. A fast and precise indoor localization algorithm based on an online sequential extreme learning machine[J]. *Sensors*, 2015, 15(1):1804-1824.
- 14 ENGEL Y, MANNOR S, MEIR R. The kernel recursive least-squares algorithm[J]. *IEEE Transactions on Signal Processing*, 2004, 52(8):2275-2285.
- 15 VAERENBERGH S V, VIA J, SANTAMARIA I. Nonlinear system identification using a new sliding-window kernel RLS algorithm[J]. *Journal of Communications*, 2007, 2(3):1-8.
- 16 CHEN B, ZHAO S, ZHU P, et al. Quantized kernel least mean square algorithm[J]. *IEEE Transactions on Neural Networks & Learning Systems*, 2012, 23(1):22-32.
- 17 VAERENBERGH S V, SANTAMARIA I, LIU W, et al. Fixed-budget kernel recursive least-squares [C] // 2010 IEEE International Conference on Acoustics Speech and Signal Processing (ICASSP), 2010: 1882-1885.
- 18 HASSIBI B, STORK D G, WOLFF G J. Optimal brain surgeon and general network pruning[C] // IEEE International Conference on Neural Networks, 1993: 293-299.
- 19 KRUIF B J D, VRIES T J A D. Pruning error minimization in least squares support vector machines[J]. *IEEE Transactions on Neural Networks*, 2003, 14(3):696-702.
- 20 ROSIPAL R, TREJO L J. Kernel partial least squares regression in reproducing kernel hilbert space[J]. *Journal of Machine Learning Research*, 2001, 2(2):97-123.
- 21 李军, 李大超. 基于优化核极限学习机的风电功率时间序列预测 [J]. *物理学报*, 2016, 65(13):130501. LI Jun, LI Dachao. Wind power time series prediction using optimized kernel extreme learning machine method[J]. *Acta Physica Sinica*, 2016, 65(13):130501. (in Chinese)
- 22 LAOUDIAS C. Device self-calibration in location systems using signal strength histograms [J]. *Journal of Location Based Services*, 2013, 7(3):165-181.

(上接第 264 页)

- 24 成思源, 刘俊, 张湘伟. 基于手持式激光扫描的反求设计实验[J]. *实验室研究与探索*, 2011, 30(8):153-155. CHENG Siyuan, LIU Jun, ZHANG Xiangwei. Experimental teaching of the reverse design based on hand-held laser scanning[J]. *Research and Exploration in Laboratory*, 2011, 30(8):153-155. (in Chinese)
- 25 GINO V D B. Efficient collision detection of complex deformable models using AABB trees[J]. *Journal of Graphics Tools*, 1997, 2(4):1-13.
- 26 SHOUCHE S P, RASTOGI R, BHAGWAT S G, et al. Shape analysis of grains of Indian wheat varieties. [J]. *Computers & Electronics in Agriculture*, 2001, 33(1):55-76.
- 27 IGATHINATHANE C, PORDESIMO L O, BATCHELOR W D. Major orthogonal dimensions measurement of food grains by machine vision using ImageJ[J]. *Food Research International*, 2009, 42(1):76-84.
- 28 陈晨, 吴崇友, 江涛. 基于逆向工程的水稻精准模型构建及试验验证[J]. *农机化研究*, 2017, 39(10):46-52. CHEN Chen, WU Chongyou, JIANG Tao. Precise modeling method of rice based on reverse engineering and test verification[J]. *Journal of Agricultural Mechanization Research*, 2017, 39(10):46-52. (in Chinese)
- 29 杨春周, 滕克难, 程月波. 作战效能评估指标权重的确定[J]. *计算机仿真*, 2008, 25(10):5-7. YANG Chunzhou, TENG Ke'nan, CHENG Yuebo. Determination of the weight values of indexes for the combat capability[J]. *Computer Simulation*, 2008, 25(10):5-7. (in Chinese)
- 30 DUAN L, YANG W, HUANG C, et al. A novel machine-vision-based facility for the automatic evaluation of yield-related traits in rice[J]. *Plant Methods*, 2011, 7(1):44-57.