

基于 K - OPLS 的无线传感网络室内定位跟踪算法

李 军 后新燕

(兰州交通大学自动化与电气工程学院, 兰州 730070)

摘要: 针对基于指纹的无线传感网络室内定位, 提出了一种基于核隐变量正交投影 (Kernel-based orthogonal projection to latent structures, K - OPLS) 的定位算法。在 O - PLS 的模型框架下, K - OPLS 算法应用“核技巧”将描述变量映射至高维特征空间, 给出了描述变量和响应变量之间的非线性关系, 以实现模型的预测成分及与响应-正交成分的计算。K - OPLS 算法集核偏最小二乘建模和正交信号校正预处理方法于一体, 在一定程度上有效地改进了模型性能, 增强了模型解释性。基于 RSSI 指纹信息, 构建锚节点与处于参考位置的非锚节点之间的非线性映射关系, K - OPLS 算法可以实现 WSN 的室内定位跟踪。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, 还与核岭回归 (KRR)、核极限学习机 (KELM)、核信噪比 (KSNR)、核偏最小二乘 (KPLS)、核自适应滤波等其他核学习算法进行比较。仿真实验中, 基于小波核的 WK - OPLS 算法在无噪声和有噪声环境下的跟踪估计误差分别为 0.232 6、1.320 5 m。物理实验中, 基于小波核的该算法跟踪估计误差为 0.249 3 m。实验结果表明, 所提算法有效提高了定位精度, 而且具有一定的除噪能力。

关键词: 无线传感网络; 室内定位; 核方法; 隐变量正交投影; 跟踪

中图分类号: TP391.4; TN92 **文献标识码:** A **文章编号:** 1000-1298(2019)06-0265-07

Indoor Positioning Tracking Algorithm of Wireless Sensor Network Based on K - OPLS

LI Jun HOU Xinyan

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

Abstract: For the wireless sensor network based on fingerprint indoor positioning, an indoor positioning algorithm based on kernel-based orthogonal projection to latent structures (K - OPLS) was proposed. O - PLS was a universal linear multivariate data modeling algorithm, which can remove the irrelevant components in the input and output, that was, eliminating the variation components from the description variable (input) that were orthogonal to the response variable (output). Under the model framework of O - PLS, the ‘kernel trick’ was applied by the K - OPLS algorithm to map the description variable to the high-dimensional feature space, and the nonlinear relation between the description and response variables was given, so as to achieve the calculation of the predictive component of the model and the response-orthogonal component. Therefore, the essence of K - OPLS algorithm was to integrate the kernel partial least square modeling and orthogonal signal correction preprocessing method, which can effectively improve the performance of the model and enhance the interpretation of the model to some extent. Based on RSSI fingerprint information, the K - OPLS algorithm can achieve the indoor localization tracking for WSNs by building the nonlinear mapping relation between anchor node and non-anchor node in the reference position. The proposed algorithm was applied to different examples in the simulation and physical environment. Under the same conditions, it was also compared with other kernel-based learning algorithm, such as kernel ridge regression (KRR), kernel extreme learning machine (KELM), kernel signal to noise ratio (KSNR), kernel partial least squares (KPLS), and kernel adaptive filtering etc. In the simulation experiment, the tracking error of the WK - OPLS algorithm based on wavelet kernel was 0.232 6 m and 1.320 5 m, respectively, in no-noise and noisy environments. In physical experiments, the tracking error of the algorithm based on wavelet kernel was 0.249 3 m. The experimental results

收稿日期: 2018-11-16 修回日期: 2019-01-02

基金项目: 国家自然科学基金项目(51467008)

作者简介: 李军(1969—), 男, 教授, 博士, 主要从事计算智能及其非线性系统预测、建模研究, E-mail: lijun691201@mail.lzjtu.cn

showed that the proposed algorithm not only improved the positioning accuracy effectively, but also had a certain ability to remove noise.

Key words: wireless sensor network; indoor positioning; kernel method; orthogonal projection to latent structures; tracking

0 引言

近年来,无线传感网络(Wireless sensor networks, WSN)技术已经被广泛应用于工业控制^[1]、智能家居^[2]、精细农业^[3]、环境感知^[4]和健康监测^[5]等诸多领域。同时,随着定位追踪、室内导航等室内环境下基于位置服务(Location based service, LBS)需求的日益增多,在商业区域和住宅建筑中诸如WiFi路由器等现有WiFi结构配置已被大面积使用,几乎所有的移动装置均配备了WiFi接收器。传统的定位方法是通过全球定位系统(Global positioning system, GPS)直接进行定位,由于GPS接收机能耗高,且信号容易被建筑物等阻挡,在室内环境下性能受到很大影响,因此研究无线传感网络室内定位算法很有必要。

现有的室内定位技术主要有ToA(Time of arrival)、时间差定位(Time difference of arrival, TDoA)、到达角(Angle of arrival, AoA)和基于接收信号强度指示(Received signal strength indicator, RSSI)的方法等,这些方法组合了三角测量或三边测量等技术,基于距离估计以获取未知节点的位置。与ToA、TDoA及AoA相比,基于RSSI的方法具有低功耗与无需额外装置的低成本优势,其定位方法主要包括连通性测量定位及指纹定位技术^[6]。指纹定位技术不需要对网络中的通信模式做任何假设,只需在预置阶段收集所需的指纹数据库,避免了对复杂信号传输模型的直接建模,而且也无需各锚节点的确切位置,因而被广泛应用。目前,基于WiFi位置指纹定位的方法已取得许多成功应用^[7-10]。

考虑到主成分分析(Principal component analysis, PCA)等特征提取技术可以有效提取原始位置指纹特征,若与现有定位算法结合,则可有效提高WSN的室内定位精度。将PCA延伸至高维特征空间,则可形成核主成分分析(Kernel principal component analysis, KPCA)算法,用于提取原始位置指纹的非线性特征,有效地挖掘数据的内在特征。文献[11]将KPCA与改进的WKNN算法结合,提高了定位准确率,降低了平均定位误差。结合PCA的优点,偏最小二乘(Partial least square, PLS)回归^[12]是基于监督学习的线性回归建模算法,它充分利用

输入和输出变量之间的协方差信息提取数据的潜在特征,能够有效地处理高维数据和变量间的多重共线性。文献[13]提出了一种基于隐变量正交投影(Orthogonal projections to latent structures, O-PLS)算法,该算法集成了正交信号校正的数据滤波技术,将与输出正交的内在变化从预测模型结构中分离,增强了模型的解释性。同样基于“核技巧”,将数据映射至非线性高维特征空间中,以核矩阵替换描述变量矩阵,在保留O-PLS模型框架的基础上,使得描述变量与响应变量之间存在强大的非线性映射关系,可形成K-OPLS算法,K-OPLS算法进一步改进了模型的预测性能,并已成功应用于回归与分类中^[14]。

在普通最小二乘线性回归的基础上,通过加入正则项对参数进行压缩惩罚,可形成一种L2-范数正则化最小二乘回归建模技术——岭回归(Ridge regression, RR)算法,它同样可以克服变量间的多重共线性,将其延伸至非线性特征空间,可形成核岭回归(Kernel ridge regression, KRR)算法,也称为最小二乘支持向量机(Least square support vector machine, LSSVM),KRR在非线性的建模方面也具有很好的应用潜力^[6]。

鉴于K-OPLS算法在回归与分类中的应用潜力,以及SVR、KRR等核学习算法在WSN定位中的成功应用^[6,9],本文提出一种基于K-OPLS算法的室内指纹定位跟踪算法。将所提出的算法应用于仿真及实际的WiFi位置指纹定位跟踪实例中,在同等条件下,与KRR、核极限学习机(Kernel extreme learning machine, KELM)^[15]、核信噪比(Kernel signal to noise ratio, KSNR)^[16]、核偏最小二乘(Kernel partial least squares, KPLS)等算法以及固定预算(Fixed-budget)核递推最小二乘(Kernel recursive least-squares, KRLS)、量化核最小均方(Quantized kernel least mean square, QKLMS)两种核自适应滤波算法^[17]等进行比较,以验证本文算法的有效性。

1 基于K-OPLS算法的指纹定位跟踪

假设在实验区域分布着两种传感器:锚节点以及非锚节点。锚节点具有固定的位置,记作 $\mathbf{a}_i, i = 1, 2, \dots, N_a$,其中 N_a 表示锚节点的个数。非锚节点

是可移动的且位置未知,因此需要定期定位,在给定时刻 t 的节点位置可记为 $\mathbf{y}_j(t)$, $j=1,2,\dots,N_y$,其中 N_y 表示位置未知的非锚节点数目。将 K-OPLS 算法应用于无线传感网络室内位置指纹定位跟踪中,具体包括两个阶段:

(1) 离线阶段。在此阶段中,以均匀或随机散布的方式在实验区域产生 N 个参考位置,记为 \mathbf{y}_l , $l=1,2,\dots,N$,在每个参考位置布置一个节点执行测量任务,接收来自 N_a 个锚节点发送的信号,测量来自锚节点的 RSSI 值,可获得 N 对 $(\mathbf{x}_l, \mathbf{y}_l)$ 数据,从而形成位置指纹数据库,其中 \mathbf{x}_l 是在离线位置 \mathbf{y}_l 处所接收的信号功率向量,可记为

$$\mathbf{x}_l = (x_{a_1, p_l}, x_{a_2, p_l}, \dots, x_{a_{N_a}, p_l}) \in \mathbf{R}^{N_a}$$

基于这种指纹数据库收集信息的方式,其目标是构造从向量 \mathbf{x}_l 与相对应的参考位置坐标之间的映射关系,第 l 个参考位置的第 s 维坐标可记为 $y_{l,s}$,其中 $s=1,2,\dots,D$, D 为空间维数, $y_{l,s}$ 是 $\mathbf{y}_l = [y_{l,1} \ y_{l,2} \ \dots \ y_{l,D}]^T$ 的一个元素,且满足映射关系 $f_s(\cdot): \mathbf{R}^{N_a} \rightarrow \mathbf{R}$,考虑 D 维输出的情形,其映射关系 $f(\cdot): \mathbf{R}^{N_a} \rightarrow \mathbf{R}^D$ 。若采用基于核学习的算法作为非线性逼近函数,则可以很好地构造这种映射关系。

(2) 在线阶段。在此阶段中,使用离线阶段的映射关系 $f(\cdot)$ 来估计未知移动节点的位置。在 t 时刻,通过第 j 个未知的非锚节点接收来自不同锚节点的 RSSI 值,获取信号功率向量 $\mathbf{x}_j(t)$,基于多维输出的映射关系 $\hat{\mathbf{y}}_j = f(\mathbf{x}_j(t))$ 估计该移动节点的位置坐标。

K-OPLS 算法应用“核技巧”处理描述变量和响应变量之间的非线性建模关系,它是 O-PLS 方法的非线性延伸,具有在特征空间中与结构噪声有关的预测变化进行分离建模的特性。

1.1 K-OPLS 算法的模型训练

若指纹数据库中的 N 对 $(\mathbf{x}_l, \mathbf{y}_l)$ 数据已给定,其中 $l=1,2,\dots,N$,则可定义描述变量矩阵 $\mathbf{X} = [\mathbf{x}_1 \ \mathbf{x}_2 \ \dots \ \mathbf{x}_N]^T \in \mathbf{R}^{N \times N_a}$ 与响应变量矩阵 $\mathbf{Y} = [\mathbf{y}_1 \ \mathbf{y}_2 \ \dots \ \mathbf{y}_N]^T \in \mathbf{R}^{N \times D}$,将输入数据映射至高维特征空间,即 $\mathbf{x}_l \rightarrow \phi(\mathbf{x}_l) \in \mathbf{R}^{M^*}$,则输入数据矩阵 $\Phi(\mathbf{X}) = [f(\mathbf{x}_1) \ f(\mathbf{x}_2) \ \dots \ f(\mathbf{x}_N)]^T$,核函数及相应的核矩阵可分别定义为

$$k(\mathbf{x}_i, \mathbf{x}_j) = f(\mathbf{x}_i)^T f(\mathbf{x}_j)$$

$$\mathbf{K} = \Phi(\mathbf{X}) \Phi(\mathbf{X})^T$$

按照 O-PLS 方法的算法实现,在 K-OPLS 方法的算法实现中,将以核矩阵 \mathbf{K} 替换输入数据矩阵 \mathbf{X} ,以对偶的形式完成。需要注意的是, \mathbf{K} 通过与 \mathbf{Y}

正交的成分在算法每一步的迭代过程中完成仿射压缩。在模型训练过程中, \mathbf{K} 由两种变换后的数据矩阵实例构成,一种代表 O-PLS 算法中的预测权重矩阵 \mathbf{W}_p ,维数为 $N_a \times D$,其中 D 为待预测成分的数目,在整个算法实现过程中应当保留。另一种按照与 \mathbf{Y} 正交的变化相应进行仿射压缩。令 $\mathbf{K}^{i,i}$ 表示 \mathbf{K} 的不同压缩矩阵形式,其中 $\mathbf{K}^{1,1}$ 表示原始的核矩阵 \mathbf{K} 。 \mathbf{K} 的第 1 种实例为 $\mathbf{K}^{1,1}$,在计算预测得分矩阵的过程中利用了预测加权矩阵。 \mathbf{K} 的第 2 种实例 $\mathbf{K}^{i,i}$,表示计算与 \mathbf{Y} 正交的成分。 $\mathbf{K}_{tr, tr}$ 表示为训练核矩阵,则原始训练核矩阵中心化有

$$\mathbf{K}_{tr, tr}^{1,1} = \left(\mathbf{I}_{tr} - \frac{1}{N} \mathbf{O}_{tr} \mathbf{O}_{tr}^T \right) \mathbf{K} \left(\mathbf{I}_{tr} - \frac{1}{N} \mathbf{O}_{tr} \mathbf{O}_{tr}^T \right) \quad (1)$$

式中 \mathbf{I}_{tr} ——单位阵

\mathbf{O}_{tr} ——元素全为 1 的列向量, $\mathbf{O}_{tr} \in \mathbf{R}^N$

K-OPLS 模型训练步骤为:

(1) 通过特征值分解求取输出矩阵的载荷向量,可表示为

$$(\mathbf{C}_p, \Sigma_p) = \text{eigs}(\mathbf{Y}^T \mathbf{K}_{tr, tr}^{1,1} \mathbf{Y}, D) \quad (2)$$

式中 \mathbf{Y} ——输出矩阵, $\mathbf{Y} \in \mathbf{R}^{N \times D}$

\mathbf{C}_p ——输出载荷矩阵, $\mathbf{C}_p \in \mathbf{R}^{D \times D}$

Σ_p ——特征值组成的对角阵, $\Sigma_p \in \mathbf{R}^{D \times D}$

eigs 为 Matlab 中的特征值分解函数,其输出结果为前 D 个特征值对应的特征向量及相应的对角阵。

此步骤对应于 O-PLS 方法对 $\mathbf{Y}^T \mathbf{X}$ 进行奇异值分解。

(2) 根据已知的输出载荷矩阵 \mathbf{C}_p 求解 \mathbf{Y} 的得分矩阵 \mathbf{U}_p ,即

$$\mathbf{U}_p = \mathbf{Y} \mathbf{C}_p \quad (3)$$

此步骤与 O-PLS 方法一致。

(3) 若 A_o 为与 \mathbf{Y} 正交的成分数目,置 $i=1$,计算第 i 次压缩后的预测得分矩阵,可表示为

$$\mathbf{T}_{ptr}^i = \mathbf{K}_{tr, tr}^{1, i} \mathbf{U}_p \Sigma_p^{-1/2} \quad (4)$$

此步骤对应于 O-PLS 方法中 $\mathbf{T}_p = \mathbf{X} \mathbf{W}_p$,其中 \mathbf{T}_p 为第 i 次仿射压缩后的预测得分矩阵。

(4) 计算第 i 个与 \mathbf{Y} 正交的载荷向量,即

$$(\mathbf{c}_o^i, \sigma_o^i) = \text{eigs}(\mathbf{T}_{ptr}^{i, T} (\mathbf{K}_{tr, tr}^{i, i} - \mathbf{T}_{ptr}^i \mathbf{T}_{ptr}^{i, T}) \mathbf{T}_{ptr}^i, 1) \quad (5)$$

式中 σ_o^i ——对与 \mathbf{Y} 正交的成分 i 进行估计的特征值

\mathbf{c}_o^i ——第 i 个与输出正交的载荷向量, $\mathbf{c}_o^i \in \mathbf{R}^D$

此步骤对应于 O-PLS 方法中对 $\mathbf{E}^T \mathbf{T}_p$ 进行奇异值分解,其中 \mathbf{E} 为 \mathbf{X} 的残差矩阵。

(5) 计算第 i 个与 \mathbf{Y} 正交的得分向量,即

$$\mathbf{t}_{otr}^i = (\mathbf{K}_{tr, tr}^{i, i} - \mathbf{T}_{ptr}^i \mathbf{T}_{ptr}^{i, T}) \mathbf{T}_{ptr}^i \mathbf{c}_o^i (\sigma_o^i)^{-1/2} \quad (6)$$

式中 \mathbf{t}_{otr}^i ——第 i 个与 \mathbf{Y} 正交的 \mathbf{X} 得分向量, $\mathbf{t}_{otr}^i \in \mathbf{R}^N$

此步骤对应于 O-PLS 中计算正交得分向量 \mathbf{t}_o ,

$\mathbf{t}_o = \mathbf{X}\mathbf{w}_o$, \mathbf{w}_o 为与输出向量正交的权值向量。

(6) 将第 i 个与输出正交的得分向量 \mathbf{t}_{otr}^i 标准化, 可得

$$\|\mathbf{t}_{otr}^i\| = \sqrt{\mathbf{t}_{otr}^{i,T} \mathbf{t}_{otr}^i} \quad (7)$$

$$\mathbf{t}_{otr}^i \leftarrow \frac{\mathbf{t}_{otr}^i}{\|\mathbf{t}_{otr}^i\|} \quad (8)$$

(7) 对与 \mathbf{Y} 正交的变化, 计算与 \mathbf{W}_p 相联系的沿一个方向经第 i 次仿射压缩后的核矩阵, 即

$$\mathbf{K}_{tr, tr}^{1, i+1} = \mathbf{K}_{tr, tr}^{1, i} (\mathbf{I}_{tr} - \mathbf{t}_{otr}^i \mathbf{t}_{otr}^{i,T}) \quad (9)$$

(8) 对与 \mathbf{Y} 正交的变化, 计算沿各个方向经第 i 次仿射压缩后的核矩阵, 即

$$\mathbf{K}_{tr, tr}^{i+1, i+1} = (\mathbf{I}_{tr} - \mathbf{t}_{otr}^i \mathbf{t}_{otr}^{i,T}) \mathbf{K}_{tr, tr}^{i, i} (\mathbf{I}_{tr} - \mathbf{t}_{otr}^i \mathbf{t}_{otr}^{i,T}) \quad (10)$$

此步骤在 O-PLS 方法中对应于第 i 个与 \mathbf{Y} 正交成分剔除后被压缩的 \mathbf{X} 。

(9) 令 $i = i + 1$, 若 $i \leq A_o$, 则执行步骤 (4) ~ (9), 否则停止压缩, 并且计算所有正交向量剔除后的得分矩阵, 具体可表示为

$$\mathbf{T}_{ptr}^{A_o+1} = \mathbf{K}_{tr, tr}^{1, A_o+1} \mathbf{U}_p \boldsymbol{\Sigma}_p^{-1/2} \quad (11)$$

此步骤对应于 O-PLS 中 $\mathbf{T}_p = \mathbf{X}\mathbf{W}_p$, 其中 \mathbf{X} 为对与 \mathbf{Y} 正交的变化, 依次进行仿射压缩后的矩阵。

(10) 计算所有正交向量剔除后的回归系数矩阵, 即

$$\mathbf{B}_i = [(\mathbf{T}_{ptr}^{A_o+1})^T \mathbf{T}_{ptr}^{A_o+1}]^{-1} (\mathbf{T}_{ptr}^{A_o+1})^T \mathbf{U}_p \quad (12)$$

式中 \mathbf{B}_i —— $\mathbf{U}_p - \mathbf{T}_p$ 的回归系数矩阵, $\mathbf{B}_i \in \mathbf{R}^{D \times D}$

1.2 K-OPLS 算法的模型测试

给定未知的非锚节点 $\mathbf{y}_j \in \mathbf{R}^D$ 接收来自不同锚节点的 RSSI 值, 可构建测试数据集 $(\mathbf{x}_j, \mathbf{y}_j)$, $j = 1, 2, \dots, N_y$ 。因此, 测试输入、输出矩阵分别为 $\mathbf{X}_{te} = [\mathbf{x}_1 \ \mathbf{x}_2 \ \dots \ \mathbf{x}_{N_y}]^T \in \mathbf{R}^{N_y \times N_a}$, $\mathbf{Y}_{te} = [\mathbf{y}_1 \ \mathbf{y}_2 \ \dots \ \mathbf{y}_{N_y}]^T \in \mathbf{R}^{N_y \times D}$ 。定义测试-训练数据形成的核矩阵为 $\mathbf{K}_{te, tr}$, 则模型测试过程的预测输出计算步骤如下:

(1) 计算测试-训练数据形成的核矩阵, 即

$$\mathbf{K}_{te, tr} = \langle \boldsymbol{\Phi}(\mathbf{X}_{te}), \boldsymbol{\Phi}(\mathbf{X}) \rangle \quad (13)$$

其中 $\boldsymbol{\Phi}(\mathbf{X}_{te}) = [f(\mathbf{x}_1) \ f(\mathbf{x}_2) \ \dots \ f(\mathbf{x}_{N_y})]^T$

(2) 对测试-训练数据核矩阵中心化, 则有

$$\mathbf{K}_{te, tr}^{1, 1} = \left(\mathbf{K}_{te, tr} - \frac{1}{N} \mathbf{O}_{te} \mathbf{O}_{tr}^T \mathbf{K}_{tr, tr} \right) \cdot \left(\mathbf{I}_{tr} - \frac{1}{N} \mathbf{O}_{tr} \mathbf{O}_{tr}^T \right) \quad (14)$$

式中 \mathbf{O}_{te} ——元素全为 1 的列向量, $\mathbf{O}_{te} \in \mathbf{R}^{N_y}$

(3) 令 $i = 1$, 计算测试-训练数据核矩阵 $\mathbf{K}_{te, tr}^{1, 1}$ 经过第 i 次压缩后的预测得分矩阵, 可表示为

$$\mathbf{T}_{pte}^i = \mathbf{K}_{te, tr}^{i, 1} \mathbf{U}_p \boldsymbol{\Sigma}_p^{-1/2} \quad (15)$$

此步骤对应于 O-PLS 方法中计算第 i 次压缩

后的测试预测得分矩阵 \mathbf{T}_p , 其中 $\mathbf{T}_p = \mathbf{X}\mathbf{W}_p$ 。

(4) 计算测试-训练数据核矩阵中第 i 个与 \mathbf{Y}_{te} 正交的得分向量, 可表示为

$$\mathbf{t}_{ote}^i = (\mathbf{K}_{te, tr}^{i, i} - \mathbf{T}_{pte}^i \mathbf{T}_{ptr}^{i, T}) \mathbf{T}_{ptr}^i \mathbf{c}_o^i (\boldsymbol{\sigma}_o^i)^{-1/2} \quad (16)$$

式中 \mathbf{t}_{ote}^i ——第 i 个与 \mathbf{Y} 正交的 \mathbf{X}_{te} 得分向量, $\mathbf{t}_{ote}^i \in \mathbf{R}^{N_y \times 1}$

(5) 对测试数据中第 i 个与 \mathbf{Y}_{te} 正交的得分向量进行标准化处理, 即

$$\|\mathbf{t}_{ote}^i\| = \sqrt{\mathbf{t}_{ote}^{i,T} \mathbf{t}_{ote}^i} \quad (17)$$

$$\mathbf{t}_{ote}^i \leftarrow \frac{\mathbf{t}_{ote}^i}{\|\mathbf{t}_{ote}^i\|} \quad (18)$$

(6) 对与 \mathbf{Y}_{te} 正交的变化量, 计算沿一个方向经第 i 次仿射压缩后的测试-训练数据核矩阵, 即

$$\mathbf{K}_{te, tr}^{i+1, 1} = \mathbf{K}_{te, tr}^{i, i} - \mathbf{t}_{ote}^i \mathbf{t}_{otr}^{i,T} (\mathbf{K}_{tr, tr}^{i, i})^T \quad (19)$$

(7) 对与 \mathbf{Y}_{te} 正交的变化量, 计算沿各个方向经第 i 次仿射压缩后的测试-训练数据核矩阵, 即

$$\mathbf{K}_{te, tr}^{i+1, i+1} = \mathbf{K}_{te, tr}^{i, i} - \mathbf{K}_{te, tr}^{i, i} \mathbf{t}_{otr}^i \mathbf{t}_{otr}^{i,T} - \mathbf{t}_{ote}^i \mathbf{t}_{otr}^{i,T} \mathbf{K}_{tr, tr}^{i, i} + \mathbf{t}_{ote}^i \mathbf{t}_{otr}^{i,T} \mathbf{K}_{tr, tr}^{i, i} \mathbf{t}_{otr}^i \mathbf{t}_{otr}^{i,T} \quad (20)$$

此步骤相应于 O-PLS 中在与 \mathbf{Y}_{te} 正交的变化方向上, 依次进行仿射压缩后得到的矩阵 \mathbf{X}_{te} 。

(8) 令 $i = i + 1$, 若 $i \leq A_o$, 则返回至步骤 (3), 否则算法终止。基于仿射压缩后的测试-训练数据核矩阵, 计算更新后的预测得分矩阵, 即

$$\mathbf{T}_{pte}^{A_o+1} = \mathbf{K}_{te, tr}^{A_o+1, 1} \mathbf{U}_p \boldsymbol{\Sigma}_p^{-1/2} \quad (21)$$

此步骤对应于 O-PLS 方法中, 计算预测得分矩阵 \mathbf{T}_{pte} , 其中 $\mathbf{T}_{pte} = \mathbf{X}_{te} \mathbf{W}_p$ 。

(9) 由回归系数矩阵 \mathbf{B}_i 、训练输出载荷矩阵 \mathbf{C}_p 、预测得分矩阵 $\mathbf{T}_{pte}^{A_o+1}$ 计算测试数据的预测输出, 即

$$\hat{\mathbf{Y}} = \mathbf{T}_{pte}^{A_o+1} \mathbf{B}_i \mathbf{C}_p^T \quad (22)$$

式中 $\hat{\mathbf{Y}}$ ——未知移动节点的位置坐标估计值

此步骤与 O-PLS 方法中计算预测输出一致。

2 实验

为验证 K-OPLS 方法的有效性, 将其应用于无线传感网络室内定位跟踪中。在同等条件下, 与 ELM、KRR、KELM、KPLS、KSNR、近似线性依赖 (ALD)-KRLS、KLMS 以及文献 [17] 给出的 FB-KRLS 及 QKLMS 算法等进行对比实验。不同核学习算法均选取高斯核函数

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / (2\sigma^2)) \quad (23)$$

式中 σ ——核参数

考虑到由于小波核函数具有小波信号的局部分析及对突变信号检测的多分辨分析能力, 在 K-OPLS 方法中使用 Morlet 小波核函数, 简记为 WK-

OPLS方法。小波核函数为

$$k(\mathbf{x}_i, \mathbf{x}_j) = (\cos(\omega_0 \|\mathbf{x}_i - \mathbf{x}_j\|) / \delta) \cdot \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / (2\delta^2)) \quad (24)$$

式中 ω_0 ——中心频率

δ ——小波伸缩因子

定位精度指标是平均估计误差,即测试点距离误差的平均值。定义实际坐标点 $(y_{i,1}, y_{i,2})$ 与预测坐标点 $(\hat{y}_{i,1}, \hat{y}_{i,2})$ 之间的估计误差为

$$e = \sqrt{(y_{i,1} - \hat{y}_{i,1})^2 + (y_{i,2} - \hat{y}_{i,2})^2} \quad (25)$$

2.1 仿真实例

仿真实验在 $100 \text{ m} \times 100 \text{ m}$ 的区域内进行,均匀地在该区域内布置 100 个离线位置节点以及若干个锚节点,为了提高实验精度,安置在离线位置的参考节点均接收 10 次来自锚节点的信号,其 RSSI 测量值的获取使用常见的 Okumura - Hata 模型^[18]进行计算。

Okumura - Hata 模型描述了信号功率 P_L (dBm) 与距离 d (m) 之间的关系

$$P_L = P_0 - 10\alpha \lg d + \xi \quad (26)$$

式中 P_0 ——初始功率,为 150 dBm

ξ ——影响 RSSI 测量值的噪声, ξ 服从均值为 0、方差为 0.3 的正态分布

α ——路径损失指数,为 4

d ——锚节点与处于离线位置处的非锚节点之间的欧氏距离

实验选取高斯核函数的核参数 $\sigma = 4$,小波核函数的 $\omega_0 = 0.07, \delta = 12$ 。KRR 算法中,选取正则化系数 $\lambda = 1 \times 10^{-4}$,K-OPLS 算法中,选取与 \mathbf{Y} 正交的数目 $A_o = 50$ 。KELM 算法中,正则化系数 $\lambda = 1 \times 10^{-2}$ 。QKLMS 算法中,选取学习速率 $\eta = 0.1$,量化因子 $\gamma = 0.1$,当量化因子 $\gamma = 0$ 时,即为 KLMS 算法。ALD - KRLS 算法中,最大字典容量 $m_{\max} = 100$,阈值 $\mu = 0.01$,正则化系数 $\lambda = 1 \times 10^{-3}$ 。FB - KRLS 算法中,选取固定内存为 $M = 300$,正则化参数 $\lambda = 1 \times 10^{-3}$ 。KPLS 算法中,选潜在变量数目为 50,ELM 算法中,选节点函数为 Sigmoid 函数,隐层神经元个数为 50。KSNR 算法中,正则化系数 $\lambda = 1 \times 10^{-9}$ 。

在不考虑噪声的情形下,图 1 给出了不同锚节点数目时定位跟踪精度,可以看出当锚节点数目选择为 7 时,实验的平均定位误差最小。图 2 给出了不同参考节点数目时定位跟踪精度,可以看出随着参考节点数目的增加,提高了定位跟踪精度。

若锚节点个数选择为 5,首先考虑在无噪声且锚节点及节点均匀布置的情形下,生成某个特定的

用于测试的轨迹,图 3 给出了 K-OPLS 算法在该区域内跟踪某移动轨迹的估计曲线,可以看出 K-OPLS 算法取得了不错的定位效果,显示了该算法在无线传感网络室内定位的有效性。




图 1 估计误差与锚节点数目的关系

Fig. 1 Relationship between estimation error and number of anchors




图 2 估计误差与参考节点数目的关系

Fig. 2 Relationship between estimation error and number of offline position




图 3 无噪声环境下节点均匀分布时 K-OPLS 算法的估计轨迹

Fig. 3 Estimation of trajectory in absence of noise under uniform distribution

在此情形下,K-OPLS 算法与 ELM 及其他基于核学习定位算法估计跟踪误差比较如表 1 所示。从表 1 可看出,K-OPLS 算法的估计误差为 0.293 8 m,WK-OPLS 算法的估计误差为 0.232 6 m,远高于 ELM 算法的精度,因此,基于小波核的 WK-OPLS 算法具有最好的定位精度。

表1 无噪声时不同算法的估计误差

Tab.1 Estimation error for different techniques

without noise		m
跟踪算法	估计误差	
ELM	1.461 4	
KRR	0.978 9	
KELM	0.476 3	
ALD-KRLS	0.991 5	
FB-KRLS ^[17]	0.440 1	
KLMS	0.733 9	
QKLMS ^[17]	0.801 0	
KSNR	0.551 9	
KPLS	0.753 4	
K-OPLS	0.293 8	
WK-OPLS	0.232 6	

考虑锚节点及节点随机安置在区域内且加入标准正态分布噪声的情形,各算法的参数设置不变。在该区域内,基于K-OPLS算法跟踪某移动轨迹的估计曲线如图4所示,从图4可以看出,在含有噪声、离线位置节点随机分布情形下,K-OPLS算法同样可取得较好的定位效果。




图4 噪声环境下节点随机分布时K-OPLS算法的轨迹估计

Fig.4 Estimation of trajectory in presence of noise under random distribution

考虑到在线学习算法可以实时调整模型,将QKLMS、ALD-KRLS等算法与所提出的K-OPLS算法的精度进行对比。表2给出了在噪声环境下,K-OPLS算法与ELM及其他基于核学习的定位算法轨迹跟踪时的定位误差。由表2可得,K-OPLS和WK-OPLS算法在精度上均优于其他算法,其中,K-OPLS算法的估计误差为1.322 4 m,WK-OPLS算法的估计误差为1.320 5 m,QKLMS、FB-KRLS等核自适应滤波算法由于可以对模型自适应地做出调整,它们也较适宜于时变环境下的跟踪定位。从表1、2可以看出,K-OPLS算法在精度上均优于KPLS算法,此外,同文献[17]相比,K-OPLS

算法的定位精度也优于FB-KRLS与QKLMS算法,进一步验证了所提算法解释能力更强且具有一定的消除噪声能力。

表2 有噪声时不同算法估计误差

Tab.2 Estimation error for different techniques

with noise		m
跟踪算法	估计误差	
ELM	2.867 2	
KRR	1.769 8	
KELM	1.615 4	
ALD-KRLS	1.664 6	
FB-KRLS ^[17]	1.468 7	
KLMS	2.051 6	
QKLMS ^[17]	2.280 4	
KSNR	1.499 7	
KPLS	1.540 6	
K-OPLS	1.322 4	
WK-OPLS	1.320 5	

2.2 物理实例

与文献[6]一致,物理实例实验采用帕多瓦大学信息工程系SIGNET实验室所提供的实际数据集^[19],其实验在约10 m × 10 m的房间内进行,在距离天花板50 cm处部署了48个均匀分布的EyesIFX节点。房间内的家具和人,会对节点所接收的RSSI值有一定干扰与影响。选择其中5个节点作为锚节点,其余43个节点被看作安置在离线位置的参考节点。为取得更好的测量结果,在该区域内通过依赖于现有节点与新位置节点之间的欧氏距离作为加权函数得到额外的57个参考节点。这使得全部的参考节点为100个。按照同样的方式产生某移动轨迹作为测试时的跟踪目标。

不同算法的参数选取与2.1节实验基本一致,其中,KSNR算法中,正则化系数 $\lambda = 1 \times 10^{-14}$ 。小波核函数的 $\omega_0 = 0.05, \delta = 20$ 。K-OPLS算法在该区域内跟踪某移动轨迹的估计曲线如图5所示,可

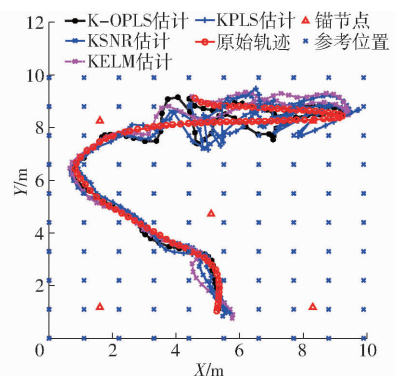


图5 实际数据K-OPLS算法的轨迹估计

Fig.5 Estimation of trajectory using real data based on K-OPLS algorithm

以看出 K-OPLS 算法在真实物理环境下也能取得较好的定位效果。

表 3 给出了 K-OPLS 算法与 ELM 及其他基于核学习的定位算法进行轨迹跟踪时的估计误差。可以看出 K-OPLS 算法在精度上明显优于其他定位算法,其中 WK-OPLS 跟踪估计误差为 0.249 3 m,此外,KSNR 算法将信噪比融入到核空间中,使得该算法对于噪声具有一定的抗干扰能力,也取得了较好的跟踪效果。

表 3 真实环境下的不同算法估计误差

Tab.3 Estimation error for different techniques in real environment m

跟踪算法	估计误差
ELM	0.620 2
KRR	0.561 5
KELM	0.334 8
ALD-KRLS	0.520 4
FB-KRLS ^[17]	0.326 7
KLMS	0.370 7
QKLMS ^[17]	0.409 5
KSNR	0.312 7
KPLS	0.404 7
K-OPLS	0.251 6
WK-OPLS	0.249 3

对于 K-OPLS 算法,当选择正交成分数目 $A_o = 50$ 时,模型对输入变化的解释能力及对输出变化的预测能力指标^[20]分别为 $R_y^2 = 99.99\%$ 、 $Q_y^2 = 100\%$ 。图 6 给出了对于位置 $y_{i,1}$ 进行估计的预测成分 T_{ptr}^1 与正交成分 $t_{otr}^1 \sim t_{otr}^3$ 各自的概率密度估计图,从图 6 可看出,预测成分 T_{ptr}^1 的概率密度估计范围为 $[-1, 1]$,正交成分 $t_{otr}^1 \sim t_{otr}^3$ 的概率密度估计范围主要位于

$[-0.05, 0.1]$ 、 $[-0.1, 0.1]$ 之间,这表明正交成分对模型的预测能力的贡献基本为 0,可认为结构噪声已被剔除。




图 6 T_{ptr}^1 与 $t_{otr}^1 \sim t_{otr}^3$ 的概率密度函数估计

Fig.6 Estimation diagrams of probability density function of

T_{ptr}^1 versus $t_{otr}^1 \sim t_{otr}^3$

3 结论

(1)提出了基于 K-OPLS 的无线传感网络室内定位算法。K-OPLS 算法将输入数据映射至高维特征空间中,将特征空间中与输出无关的数据剔除,因此所建立的模型更为紧凑,且模型的解释性更强。

(2)核学习算法在一定程度上提高了回归建模的非线性逼近能力,仿真和物理实例的实验验证了所提算法的有效性。K-OPLS 算法相对于其他几种算法,在一定程度上克服了噪声干扰。

(3)在定位跟踪应用中,K-OPLS 算法与 ELM 及其他基于核学习的算法相比,不仅使得模型具有更强解释能力、更低模型复杂度及有效的滤除结构,而且其参数的调节也更为方便。

参 考 文 献

[1] IQBAL Z, KIM K, LEE H N. A cooperative wireless sensor network for indoor industrial monitoring[J]. IEEE Transactions on Industrial Informatics, 2017, 13(2):482-491.

[2] GHAYVAT H, LIU J, MUKHOPADHYAY S C, et al. Wellness sensor networks: a proposal and implementation for smart home for assisted living[J]. IEEE Sensors Journal, 2015, 15(12):7341-7348.

[3] KHAN S. Wireless sensor network based water well management system for precision agriculture[C]//2016 26th International Telecommunication Networks and Applications Conference (ITNAC). IEEE, 2016:44-46.

[4] TRANCA D C, ROSNER D, CURATU R, et al. Industrial WSN node extension and measurement systems for air, water and environmental monitoring: IoT enabled environment monitoring using NI WSN nodes[C]//2017 16th RoEduNet Conference: Networking in Education and Research (Roedunet). IEEE, 2017:1-6.

[5] MAW H, XIAO H, CHRISTIANSON B, et al. BTG-AC: break-the-glass access control model for medical data in wireless sensor networks[J]. IEEE Journal of Biomedical & Health Informatics, 2015, 20(3):763-774.

[6] MAHFOUZ S, MOURAD-CHEHADE F, HONEINE P, et al. Kernel-based machine learning using radio-fingerprints for localization in WSNS[J]. IEEE Transactions on Aerospace & Electronic Systems, 2015, 51(2):1324-1336.

[7] KOYUNCU H, YANG S H. A 2D positioning system using WSNs in indoor environment[J]. International Journal of Electrical and Computer Sciences IJECS-IJENS, 2011, 11(3):70-77.

[8] 田洪亮, 钱志鸿, 梁潇, 等. 离散度 WKNN 位置指纹 Wi-Fi 定位算法[J]. 哈尔滨工业大学学报, 2017, 49(5):94-99. TIAN Hongliang, QIAN Zhihong, LIANG Xiao, et al. Discrete degree WKNN location fingerprinting algorithm based on Wi-Fi [J]. Journal of Harbin Institute of Technology, 2017, 49(5):94-99. (in Chinese)

- [29] 于争. 信号完整性揭秘[M]. 北京: 机械工业出版社, 2013.
- [30] JOHNSON H, GRAHAM M. High-speed digital design: a handbook of black magic[M]. Upper Saddle River, NJ: Prentice Hall, 1993.
- [31] TORRENTS J M, PALLAS-ARENY R. Compensation of impedance meters, when using an external front-end amplifier[J]. IEEE Transactions on Instrumentation and Measurement, 2002, 51(2): 310 – 313.
- [32] VEAL B W, BALDO P M, PAULIKAS A P, et al. Understanding artifacts in impedance spectroscopy[J]. Journal of the Electrochemical Society, 2015, 162(1): 47 – 57.
- [33] CARDU R, LEONG P H, JIN C T, et al. Electrode contact impedance sensitivity to variations in geometry[J]. Physiological Measurement, 2012, 33(3): 817 – 830.
- [34] MCADAMS E T, JOSSINET J, LACKERMEIER A, et al. Factors affecting electrode-gel-skin interface impedance in electrical impedance tomography[J]. Medical and Biological Engineering and Computing, 1996, 34(6): 397 – 408.
- [35] YANG L, DAI M, XU C, et al. The frequency spectral properties of electrode-skin contact impedance on human head and its frequency-dependent effects on frequency-difference EIT in stroke detection from 10 Hz to 1 MHz[J]. PloS One, 2017, 12(1): e170563.
- [36] NGUYEN D T, KOSOBRODOV R, BARRY M A, et al. Electrode-skin contact impedance: in vivo measurements on an ovine model[J]. Journal of Physics: Conference Series, 2013, 434:012023.
- [37] LIU X, YAO J, ZHAO T, et al. Image reconstruction under contact impedance effect in micro electrical impedance tomography sensors[J]. IEEE Transactions on Biomedical Circuits and Systems, 2018, 12(3): 623 – 631.
- [38] PRABHAKARAN S, SULLIVAN C R. Impedance-analyzer measurements of high-frequency power passives: techniques for high power and low impedance[C]//Conference Record of the 2002 IEEE Industry Applications Conference. 37th IAS Annual Meeting, 2002.
- [39] HALTER R J, HARTOV A, PAULSEN K D. A broadband high-frequency electrical impedance tomography system for breast imaging[J]. IEEE Transactions on Biomedical Engineering, 2008, 55(2): 650 – 659.
- [40] HILHORST M A. Dielectric characterisation of soil[M]. Wageningen, Netherlands: DLO Institute of Agricultural and Environmental Engineering, 1998.

(上接第 271 页)

- [9] WU Z, LI C, NG K Y, et al. Location estimation via support vector regression[J]. IEEE Transactions on Mobile Computing, 2007, 6(3): 311 – 321.
- [10] 王俊, 刘刚. 基于遗传 BP 算法的温室无线传感器网络定位方法[J]. 农业工程学报, 2012, 28(21): 156 – 163.
WANG Jun, LIU Gang. Localization method of wireless sensor network for greenhouse based on genetic BP algorithm[J]. Transactions of the CSAE, 2012, 28(21): 156 – 163. (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] WOLD S, SJOSTROM M, ERIKSSON L. PLS-regression: a basic tool of chemometrics[J]. Chemometrics & Intelligent Laboratory Systems, 2001, 58(2): 109 – 130.
- [13] TRYGG J, WOLD S. Orthogonal projections to latent structures (O – PLS)[J]. Journal of Chemometrics, 2002, 16(3): 119 – 128.
- [14] RANTALAINEN M, BYLESJO M, CLOAREC O, et al. Kernel-based orthogonal projections to latent structures (K – OPLS)[J]. Journal of Chemometrics, 2007, 21(7 – 9): 376 – 385.
- [15] HUANG G B. An insight into extreme learning machines: random neurons, random features and kernels[J]. Cognitive Computation, 2014, 6(3): 376 – 390.
- [16] GOMEZ-CHOVA L, CAMPS-VALLS G. Learning with the kernel signal to noise ratio[C]//IEEE International Workshop on Machine Learning for Signal Processing (MLSP). IEEE, 2012: 1 – 6.
- [17] 李军, 赵畅. 基于核自适应滤波的无线传感网络定位算法研究[J/OL]. 农业机械学报, 2018, 49(4): 241 – 248.
LI Jun, ZHAO Chang. Wireless sensor network location algorithms based on kernel adaptive filtering[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(4): 241 – 248. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180427&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.04.027. (in Chinese)
- [18] MEDEISIS A, KAJACKAS A. On the use of the universal Okumura-Hata propagation prediction model in rural areas[C]//VTC2000-Spring. IEEE 51st Vehicular Technology Conference Proceedings, 2000: 1815 – 1818.
- [19] ZANCA G, ZORZI F, ZANELLA A, et al. Experimental comparison of RSSI-based localization algorithms for indoor wireless sensor networks[C]//Proceedings of the Workshop on Real-world Wireless Sensor Networks. ACM, 2008: 1 – 5.
- [20] TRYGG J, WOLD S. O2 – PLS, a two-block (X – Y) latent variable regression (LVR) method with an integral OSC filter[J]. Journal of Chemometrics, 2003, 17(1): 53 – 64.