

6-6-2020

Application of KPCA-ESN Method in Wi-Fi Based Indoor Positioning

Li Jun

College of Automation and Electrical Engineering, Lanzhou Jiao Tong University, Lanzhou 730070, China;

Chen Ying

College of Automation and Electrical Engineering, Lanzhou Jiao Tong University, Lanzhou 730070, 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.

Application of KPCA-ESN Method in Wi-Fi Based Indoor Positioning

Abstract

Abstract: Aiming at the problem that the positioning accuracy is affected by the dynamic indoor environment and time-varying received signal strength (RSS) values, a *Wi-Fi based indoor positioning method using kernel principal component Analysis (KPCA) and echo state networks (ESN) is proposed. The KPCA method is used to preprocess the RSS fingerprints effectively and extract the nonlinear principal components of the inputs of the model. On the basis of KPCA, the extracted principal components are taken as the inputs to the ESN network, the nonlinear mapping between corresponding positioning features and physical locations is then established by the ESN.* The proposed KPCA-ESN method is then applied to Wi-Fi based indoor positioning instances by simulation and physical environment experiments. Compared with the other positioning methods under the same condition, experimental results confirm that the proposed method has higher positioning accuracy, and can also automatically timely adapt to environmental dynamics.

Keywords

echo state networks, kernel principal component analysis, Wi-Fi, indoor positioning, received signal strength

Recommended Citation

Li Jun, Chen Ying. Application of KPCA-ESN Method in Wi-Fi Based Indoor Positioning[J]. Journal of System Simulation, 2017, 29(12): 3042-3050.

KPCA-ESN 方法在 Wi-Fi 室内定位中的应用

李军, 陈颖

(兰州交通大学自动化与电气工程学院, 兰州 730070)

摘要: 针对动态的室内环境及时变的接收信号强度(Received Signal Strength, RSS)值对定位精度的影响, 提出一种基于核主成分分析(Kernel Principal Component Analysis, KPCA)和回声状态网络(Echo State Networks, ESN)相结合的 Wi-Fi 室内定位方法。KPCA 方法对 RSS 指纹信息进行预处理, 有效提取模型输入的非线性主元。利用 ESN 方法构建所提取出的定位特征与物理位置之间的非线性映射关系。将所提出的 KPCA-ESN 方法应用于仿真与物理环境的 Wi-Fi 室内定位实例中, 在同等条件下, 还与其他定位方法进行比较。结果表明, 该方法定位精度较高, 能够适应动态环境变化。

关键词: 回声状态网络; 核主成分分析; Wi-Fi; 室内定位; 接收信号强度

中图分类号: TP391.4

文献标识码: A

文章编号: 1004-731X (2017) 12-3042-09

DOI: 10.16182/j.issn1004731x.joss.201712015

Application of KPCA-ESN Method in Wi-Fi Based Indoor Positioning

Li Jun, Chen Ying

(College of Automation and Electrical Engineering, Lanzhou Jiao Tong University, Lanzhou 730070, China;)

Abstract: Aiming at the problem that the positioning accuracy is affected by the dynamic indoor environment and time-varying received signal strength (RSS) values, a Wi-Fi based indoor positioning method using kernel principal component Analysis (KPCA) and echo state networks (ESN) is proposed. The KPCA method is used to preprocess the RSS fingerprints effectively and extract the nonlinear principal components of the inputs of the model. On the basis of KPCA, the extracted principal components are taken as the inputs to the ESN network, the nonlinear mapping between corresponding positioning features and physical locations is then established by the ESN. The proposed KPCA-ESN method is then applied to Wi-Fi based indoor positioning instances by simulation and physical environment experiments. Compared with the other positioning methods under the same condition, experimental results confirm that the proposed method has higher positioning accuracy, and can also automatically timely adapt to environmental dynamics.

Keywords: echo state networks; kernel principal component analysis; Wi-Fi; indoor positioning; received signal strength

引言

随着资产定位追踪、室内导航等室内环境下基

于位置服务(Location-based Service, LBS)的需求与日俱增, 基于无线保真技术(Wireless Fidelity, Wi-Fi)的室内定位^[1-4]方法的研究已经引起国内外学者的广泛关注。

目前, 大多数 Wi-Fi 室内定位系统应用无线电传输模型^[5-6]或位置指纹技术^[7-9]进行探测定位。文献[5]给出一种改进的接收信号强度指示



收稿日期: 2015-10-21 修回日期: 2016-02-25;
基金项目: 国家自然科学基金(51467008);
作者简介: 李军(1969-), 男, 甘肃天水, 博士, 教授, 研究方向为计算智能与非线性系统建模/控制;
陈颖(1990-), 女, 甘肃东乡, 硕士生, 研究方向为交通信息及控制。

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

• 3042 •

(Received Signal Strength Index, RSSI)的多维标度室内定位算法;文献[6]给出一种基于 RSSI 和分步粒子群算法的定位方法,具有很好的定位效果,能够满足室内定位跟踪及低成本定位系统的需求。但是,实际的室内环境中,获取每个 Wi-Fi 接入点(Access Point, AP)的精确传输模型通常较为复杂,在一定程度上影响了最终的定位精度。与此相反,位置指纹技术利用内嵌 Wi-Fi 功能的移动设备所测得的接收信号强度(Received Signal Strength, RSS)值进行物理位置估计,作为一种基于经验数据的非线性逼近技术,该方法避免了对复杂信号传输模型的建模,而且无需知道各 AP 的确切位置,因而被广泛应用。文献[7]给出一种基于模式识别技术的加权 k 近邻(Weighted K-Nearest Neighbors, WKNN)改进算法, k 近邻(K-Nearest Neighbors, KNN)方法通过最小化欧氏距离,即定位阶段待测试的指纹与已知的参考指纹之间的距离,估计待测试点的位置,该方法易于实现,但数据集增大时,其定位精度较差。文献[8]将支持向量机(Support Vector Machine, SVM)方法应用于基于位置指纹的室内定位,定位精度高,通过与其它定位方法的比较,验证了该方法的有效性。针对动态的室内环境及时变的 RSS 值对定位精度的影响,文献[9]给出了基于在线极限学习机(Online Sequential Extreme Learning Machine, OS-ELM)的室内定位算法,该方法对环境动态的变化具有较好的自适应能力,其定位精度很高。

目前,回声状态网络(Echo State Networks, ESN)^[10-11]作为一种新型的动态递归神经网络,已引起广泛关注。其核心结构随机生成,稀疏且保持不变的状态储备池(State Reservoir, SR),具有存储历史信息的“回声”特性,使 ESN 具有极强的短期记忆能力。ESN 网络的 SR 中神经元之间的连接权值在初始化时随机产生且无需训练,仅需训练输出权值。因此,与 SVM、ELM 一样,ESN 方法具有很强的非线性逼近能力,可以应用于室内定位。

另一方面,还可考虑对所有测量到的 RSS 值

进行特征提取的预处理技术,以进一步提高室内定位的精度。如与主成分分析方法相结合,文献[12]给出一种基于主成分分析-最小二乘支持向量回归((Principal Component Analysis-least Square Support Vector Regression, PCA-LSSVR)的室内定位算法;文献[13]给出一种基于核直接判别分析和支持向量回归(Kernel Direct Discriminant Analysis-Support Vector Regression, KDDA-SVR)的室内定位算法,通过利用核判别分析抑制噪声并提取最具判别力的定位特征,可进一步提高定位精度。鉴于非监督学习方法-核主成分分析^[14](Kernel Principal Component Analysis, KPCA)可在高维核特征空间上进行数据的特征提取,与 PCA 不同,它能有效地提取数据的非线性特征,同样可考虑将其用于室内定位的 RSS 指纹数据预处理中。

由上分析,结合 KPCA 与 ESN 方法的各自优点,本文提出一种基于 KPCA-ESN 的 Wi-Fi 位置指纹室内定位方法,并给出相应的算法实现。将该方法应用于仿真及实际的 Wi-Fi 位置指纹定位系统实例中,在同等条件下,还将与 WKNN、SVM、极限学习机(Extreme Learning Machine, ELM)及核极限学习机^[15](Kernel Extreme Learning Machine, KELM)等现有定位算法进行比较,以验证本文方法的有效性。

1 KPCA-ESN 指纹定位方法

PCA 是一种广泛采用的特征提取方法,它仅涉及在数据原始空间上进行线性化处理的技术。KPCA 作为一种非监督技术,它是输入数据经变换后在高维非线性特征空间上执行线性 PCA 的方法。

1.1 KPCA

KPCA 利用核技术将低维空间的数据映射到高维特征空间后,通过线性代数在特征空间提取主元。

若无线电地图中的 l 个样本数据为:

$(\mathbf{q}_i, \mathbf{s}_i), i=1, \dots, l$, 其中, $\mathbf{q}_i = (x_i, y_i)$ 表示第 i 个定位位置的物理坐标, $\mathbf{s}_i \in \mathbf{R}^n$ 是第 i 个定位位置处所接收的来自 n 个 AP 的 n 个 RSS 值。

首先将 \mathbf{s}_i 非线性映射到 N 维特征空间:
 $\phi: \mathbf{s} \in \mathbf{R}^n \rightarrow \phi(\mathbf{s}) \in F \subseteq \mathbf{R}^N$, 构成 $l \times N$ 维的矩阵 $\mathbf{S} = [\phi(\mathbf{s}_1) \ \phi(\mathbf{s}_2) \ \dots \ \phi(\mathbf{s}_l)]^T$ 。数据预先经过中心化处理, 则其协方差矩阵 Σ 可表示为: $\mathbf{L}\Sigma = \mathbf{S}^T \mathbf{S}$ 。

定义核矩阵 $\mathbf{K} = \mathbf{S}\mathbf{S}^T$, 则其元素 $K_{i,j} = k(\mathbf{s}_i, \mathbf{s}_j) = \phi(\mathbf{s}_i)^T \phi(\mathbf{s}_j)$, 首先, 对 \mathbf{K} 进行中心化处理:

$$\hat{\mathbf{K}} = \mathbf{K} - \frac{1}{l} \mathbf{j}\mathbf{j}^T \mathbf{K} - \frac{1}{l} \mathbf{K}\mathbf{j}\mathbf{j}^T + \frac{1}{l^2} (\mathbf{j}^T \mathbf{K} \mathbf{j}) \mathbf{j}\mathbf{j}^T \quad (1)$$

式中: \mathbf{j} 为所有元素均为 1 的列向量。

其次, 对 $\hat{\mathbf{K}}$ 与 Σ 进行特征值分解, 则有:

$$\hat{\mathbf{K}} = \mathbf{V}\mathbf{A}\mathbf{V}^T, \quad \mathbf{L}\Sigma = \mathbf{U}\mathbf{A}_N\mathbf{U}^T \quad (2)$$

式中: 正交矩阵 \mathbf{V} 的列向量 \mathbf{v}_i 为 $\hat{\mathbf{K}}$ 的特征向量; 正交矩阵 \mathbf{U} 的列向量 \mathbf{u}_i 为 $\mathbf{L}\Sigma$ 的特征向量。

利用 $\hat{\mathbf{K}}$ 与 $\mathbf{L}\Sigma$ 的对称性, 能将 $\mathbf{L}\Sigma$ 的特征向量与特征值 (\mathbf{u}, λ) 变换为 $\hat{\mathbf{K}}$ 对应的特征向量与特征值 $(\mathbf{S}\mathbf{u}, \lambda)$ 。令:

$$t = \text{rank}(\mathbf{S}\mathbf{S}^T) = \text{rank}(\mathbf{S}^T \mathbf{S}) \leq \min(N, l)$$

则 \mathbf{U} 的前 t 列特征向量构成的矩阵 \mathbf{U}_t 可表示为:

$$\mathbf{U}_t = \mathbf{S}^T \mathbf{V}_t \mathbf{A}_t^{-1/2} \quad (3)$$

式中: 假定 $\hat{\mathbf{K}}$ 与 $\mathbf{L}\Sigma$ 的前 t 个非零特征值是按降序排列的。

由式(3)可知, $\mathbf{L}\Sigma$ 的第 j 个特征向量 \mathbf{u}_j 具有相应的对偶表示, 即可由核矩阵 $\hat{\mathbf{K}}$ 的相应特征向量 \mathbf{v}_j 乘以尺度化因子系数 $\lambda_j^{-1/2}$, 如式(4)所示:

$$\begin{aligned} \mathbf{u}_j &= \lambda_j^{-1/2} \sum_{i=1}^l (\mathbf{v}_j)_i \phi(\mathbf{s}_i) \\ &= \sum_{i=1}^l \alpha_i^j \phi(\mathbf{s}_i), \quad j=1, \dots, t \end{aligned} \quad (4)$$

式中: 向量 \mathbf{u}_j 的对偶变量 $\alpha^j = \lambda_j^{-1/2} \mathbf{v}_j$; \mathbf{v}_j, λ_j 分别为 $\hat{\mathbf{K}}$ 的第 j 个特征向量及对应的特征值。

考虑式(4), 在核空间上, 计算训练数据 $\phi(\mathbf{s})$ 在前 k 个对偶特征向量上的投影, 即计算非线性主元如下:

$$\begin{aligned} \tilde{\phi}(\mathbf{s}_i) &= \left(\mathbf{u}_j^T \phi(\mathbf{s}) \right)_{j=1}^k = \left(\left\langle \sum_{i=1}^l \alpha_i^j \phi(\mathbf{s}_i), \phi(\mathbf{s}) \right\rangle \right)_{j=1}^k \\ &= \left(\sum_{i=1}^l \alpha_i^j k(\mathbf{s}_i, \mathbf{s}) \right)_{j=1}^k \end{aligned} \quad (5)$$

式中: α_i^j 为第 j 个主元的第 i 个元素, KPCA 方法最多可提取的非线性主元数目为训练样本的数目 l 。将特征值 λ 按照降序排列, 可选取前 k 个主元 ($k \leq l$), 即 $\tilde{\phi}(\mathbf{s}_i) \subseteq \mathbf{R}^k$ 。

考虑高斯 RBF 核函数具有良好的局部逼近特性及光滑性等优点, 它能很好地逼近未知非线性函数。考虑到 KPCA 提取的主元也需要在非线性特征空间中, 能最大程度地表示原始数据。因此, 在本算法实现过程中, 将选取如下的高斯 RBF 核函数形式, 即:

$$k(\mathbf{s}_i, \mathbf{s}_j) = \exp\left\{-\|\mathbf{s}_i - \mathbf{s}_j\| / 2\delta^2\right\} \quad (6)$$

式中: δ 为高斯 RBF 核函数的宽度。

1.2 ESN 网络

ESN 网络由输入层、储备池、输出层 3 部分组成, 基本结构如图 1 所示。式中: 输入权值 $\mathbf{W}_{in} \in \mathbf{R}^{N_x \times N_u}$, 储备池权值 $\mathbf{W} \in \mathbf{R}^{N_x \times N_x}$, 输出权值 $\mathbf{W}_{out} \in \mathbf{R}^{N_y \times (N_u + N_x + N_y)}$, 反馈连接权值 $\mathbf{W}_{ob} \in \mathbf{R}^{N_x \times N_y}$ 。与传统递归神经网络不同, 网络初始化时, 储备池是由稀疏连接的神经元随机生成的。 \mathbf{W}_{in} 与 \mathbf{W}_{ob} 也是随机生成并保持不变, 网络只需训练计算输出权值。

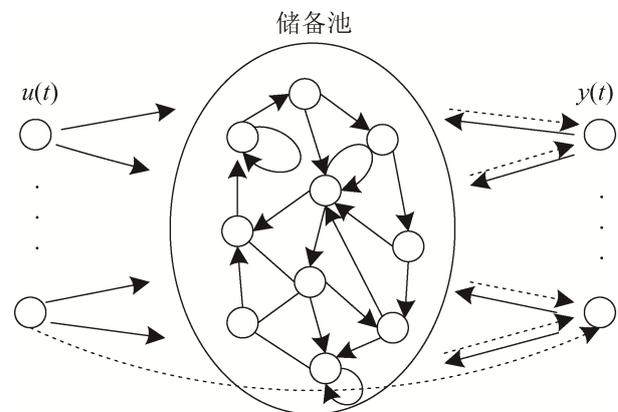


图 1 ESN 的基本结构
Fig. 1 Basic structure of echo state network

网络的状态更新方程为:

$$\mathbf{x}(t) = f(\mathbf{W}_{in}\mathbf{u}(t) + \rho\mathbf{W}\mathbf{x}(t-1) + \mathbf{W}_{ofb}\mathbf{y}(t-1) + \mathbf{v}(t)) \quad (7)$$

式中: $f(\cdot)$ 为储备池内部神经元的激活函数, 本文中用 $\tanh(\cdot)$ 函数; ρ 为 \mathbf{W} 的谱半径, 且当 \mathbf{W} 的最大特征向量 $|\sigma_{\max}| \leq 1$ 时, $0 \leq \rho < 1$, 网络具有回声状态特性; $\mathbf{u}(t)$ 、 $\mathbf{x}(t)$ 、 $\mathbf{y}(t)$ 分别为 t 时刻网络的输入、储备池输出及网络输出。

相应的网络输出方程为:

$$\mathbf{y}(t) = f_{out} \left(\mathbf{W}_{out} \begin{bmatrix} \mathbf{u}(t) \\ \mathbf{x}(t) \\ \mathbf{y}(t-1) \end{bmatrix} \right) \quad (8)$$

式中: $f_{out}(\cdot)$ 为输出层神经元激活函数, 可取线性函数; 矩阵 $[\cdot]$ 为 ESN 输入层、储备池、输出层向量的合并。

考虑应用批处理数据的离线学习算法进行网络训练。给定导师训练样本集:

$$\left\{ \mathbf{u}(t), \mathbf{y}_{target}(t) \right\}_1^T$$

式中: $\mathbf{y}_{target}(t)$ 是 t 时刻的期望输出; T 为训练样本数据集的长度。

具体的网络训练算法如下描述:

Step 1: 确定网络结构, 即结合实际问题, 首先确定 N_u 、 N_y 的大小, 储备池神经元 N_x 的大小可以由交叉验证方法确定。其次, 网络初始化时, 参数的选取还需保证 ESN 网络的“回声”特性及稳定性。结合文献[10]及经验公式, \mathbf{W}_{in} 、 \mathbf{W}_{back} 分别由 $[-0.2, 0.2]$ 与 $[-1, 1]$ 的均匀分布随机产生, 储备池的 \mathbf{W} 在 $[-1, 1]$ 的均匀分布随机生成, 网络连接稀疏度为 $\min(10/N_x, 1)$ 的稀疏矩阵, 且其谱半径 $\rho < 1$;

Step 2: 更新网络的储备池内部状态。由训练样本序列驱动网络运行, 则根据公式(7)计算 t 时刻储备池输出为 $\mathbf{x}(t)$;

Step 3: 为使 ESN 网络避免瞬态初始值的影响, 训练时丢弃前 T_0 时刻的值。 T_0 时刻后, 收集不同时刻的 $\tanh^{-1} \mathbf{y}_{target}(t)$ 作为矩阵 $\mathbf{\Gamma}$ 的列向量, 同时, 收集不同时刻的输入、储备池状态、输出的

合并作为矩阵 \mathbf{X} 的列向量。其中, $\mathbf{\Gamma} \in \mathbf{R}^{N_y \times (T-T_0+1)}$ 、 $\mathbf{X} \in \mathbf{R}^{(N_u+N_x+N_y) \times (T-T_0+1)}$ 。

Step 4: \mathbf{W}_{out} 的计算。考虑岭回归的最小二乘法进行求解, 即正则项系数能够在训练误差和输出权值大小之间起到好的折衷, 避免输出矩阵幅值过大所导致的对噪声的敏感和“过拟合”现象。输出权值矩阵的计算为:

$$\mathbf{W}_{out} = \mathbf{\Gamma} \mathbf{X}^T (\mathbf{X} \mathbf{X}^T + \eta \mathbf{I})^{-1} \quad (9)$$

式中: η 为正则项系数, η 越大, 正则化效果越强; $\mathbf{I} \in \mathbf{R}^{(N_u+N_x+N_y) \times (N_u+N_x+N_y)}$ 为单位矩阵。

1.3 KPCA-ESN 室内定位方法

结合 KPCA 与 ESN 的各自优点, 将 KPCA 方法用于 Wi-Fi 室内定位的数据预处理中, 按照特征值的大小, 依次选取所对应的非线性主元作为 ESN 网络的输入, 可实现 KPCA-ESN 的室内定位方法。

图 2 给出了基于 KPCA-ESN 方法的位置指纹室内定位的总体流程图。

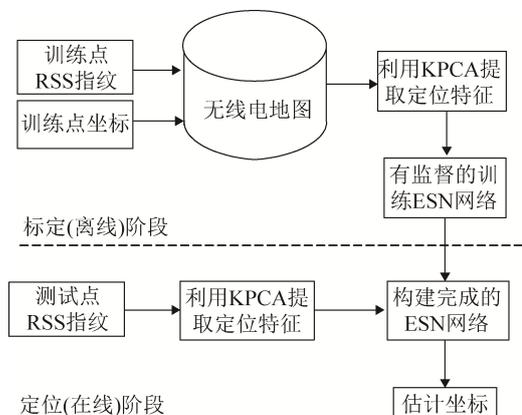


图 2 基于 KPCA-ESN 方法的室内定位流程图
Fig. 2 Flow chart of indoor positioning based on KPCA-ESN method

图 2 中, 标定 (离线) 阶段, 是指在感兴趣的区域, 通过移动装置在选定的标定点测量来自不同 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无线电地图。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, 进行 KPCA 特征提取, 利用已训练的 ESN 网络, 估计出测试点的物理位置。由图 2 的分析可知, 本文方法的核心是, 利用 KPCA 对 RSS 指纹值进行数据预处理, 提取非线性定位特征, 以定位特征和相应的物理坐标为样本数据对, 完成 ESN 网络的训练, 以建立定位特征与物理坐标之间的非线性映射关系。

KPCA-ESN 方法的 Wi-Fi 指纹定位算法实现步骤如下:

Step 1: 训练阶段, 对训练点的 RSS 指纹 $s_i \in \mathbf{R}^n, (i=1, \dots, l)$ 归一化为零均值, 方差为 1 的数据;

对 RSS 指纹数据进行归一化是为了避免特征之间数据的差异过大, 导致算法的稳定性变差, 类似于神经网络数据的预处理, 这使得 KPCA 算法的效果更好。

Step 2: KPCA 算法的实现。首先, 考虑式(6)定义的高斯核函数, 给定核参数 δ 与非线性主元的数目 k ; 其次, 由式(1)~(5), 提取前 k 个非线性主元 $\tilde{\phi}(s)$;

Step 3: ESN 算法的实现。首先, 初始化 ESN 网络的结构及给定正则化系数; 其次, 通过交叉验证实验, 由式(7)~(9)训练 ESN 网络, 获取较优的网络参数值;

Step 4: 测试阶段, 由训练阶段基于 KPCA 算法进行预处理时得到的核主元数目及特征向量, 对归一化后的测试点 RSS 指纹, 直接进行计算, 以获取相应的非线性定位特征;

Step 5: 应用已训练的 ESN 网络进行定位, 由式(8) 计算出测试点 RSS 指纹值所对应的物理位置。

需要注意的是: 通过 KPCA 方法对 RSS 指纹 s_i 进行预处理, 若提取非线性主元的数目为 k , 则 ESN 网络的输入将为:

$$\tilde{\phi}(s_t) \in \mathbf{R}^k, t=1, \dots, l$$

式中: l 为样本数目; $\tilde{\phi}(s_t)$ 则由公式(5)给出。

2 实验

将 KPCA-ESN 方法应用到仿真与实际的 Wi-Fi 室内定位实例中。ESN 网络在训练过程中可添加 $[-1 \times 10^{-4}, 1 \times 10^{-4}]$ 均匀分布的噪声, 以提高网络训练的稳定性。本节实例中, 本文方法在同等条件下, 均与 WKNN^[7]、SVM^[8]、ELM^[15]、KELM^[15]、OS-ELM^[9]等其它不同定位方法进行比较。SVM 使用 LIBSVM^[16]软件完成, SVM、KELM 核函数的选取与式(6)相同。

定位精度使用的评估指标是平均定位误差。若定义实际物理位置的坐标 (x_0, y_0) 与估计位置的坐标 (x, y) 之间的距离误差 e 定义如下:

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

式中: 平均定位误差即所有测试点的距离误差 e 的平均值。

2.1 仿真实验

仿真实验环境为 20×20 平方米的房间, 假定 4 个 Wi-Fi 路由器分别安置在房间的 4 个墙角。与文献[9]一致, 使用室内环境路径损失传输模型-ITU 模型^[17]模拟每个 Wi-Fi 路由器发出的 Wi-Fi 信号。ITU 传输模型描述了总的路径损失 PL(dBm)与距离 d (m)之间的关系, 表示如下:

$$PL(d) = PL_0 - 10\alpha \log(d) + X_\sigma$$

式中: PL_0 为路径损失系数, 实验中可给定为 -40 dBm, X_σ 是具有 0 均值、方差 $\sigma = 0.5$ 的标准正态分布噪声, α 为路径损失指数。

为了模拟动态的室内环境, 定义 α 依次等于 2、2.5、3.5 分别表示场景 1、场景 2、场景 3。场景 1 收集 4 个 Wi-Fi 路由器的随机 10 个点的 Wi-Fi RSS 指纹值作为训练数据。场景 2 与场景 3 均收集 5 个训练点及 5 个测试点的 RSS 指纹值, 不同场景的每个点均收集 200 个 Wi-Fi RSS 指纹。为与文献[9]的实验结果比较, 可产生如下不同的训练数据:

- 10+0: 以场景 1 的 10 个点作为训练点;
- 10+5: 以 10+0 及场景 2 的 5 个训练点;
- 15+5: 以 10+5 及场景 3 的 5 个训练点

测试数据为场景 2 及场景 3 各自选取的 5 个测试点。为衡量本文方法的定位精度及自适应性, 离线阶段就是针对上述三种不同的训练数据通过 KPCA 进行预处理后, 分别建立 ESN 模型; 在线阶段即是对 10 个测试点进行定位。

在 KPCA-ESN 方法中, 式(6)核函数的参数由交叉验证法选取 $\delta=2$, 非线性主元 $k=10$ 。KPCA-ESN 及单一 ESN 方法中, 储备池的 N 为 200, 稀疏度为 $1/15$, $\rho=0.8$ 。WKNN 方法的近邻数为 3, ELM 的激活函数使用 hardlim 函数, 隐含层节点数目为 380, 可获得较优的实验结果。

KPCA-ESN 在不同实验环境中进行定位的定位误差累计概率结果见图 3。从图 3 可看出, 本文方法的定位效果非常好。不同方法的具体定位精度对比如表 1 所示。由表 1 看出, 其定位精度高于 WKNN、SVM、ELM、KELM 方法, 略高于 OS-ELM、ESN 方法的定位精度。以文献[9]给出的平均定位误差为参考值, KPCA-ESN 定位精度分别提高了约 94.9%, 表明 KPCA-ESN 的定位精度相当高。从表 1 进一步看出, 实验环境变化时, KPCA-ESN 方法的平均定位误差仅有小于 0.1m 的变化波动。这表明本文方法的定位性能好, 且对环境的动态变化具有很好的自适应性。

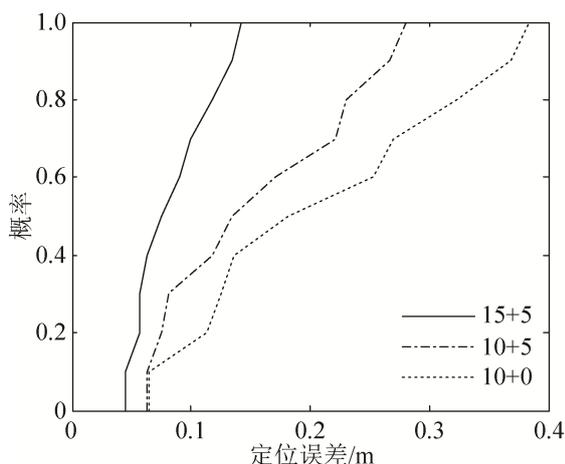


图 3 在不同环境下基于 KPCA-ESN 方法定位的距离误差累计概率分布

Fig. 3 Cumulative probability of distance error for KPCA-ESN method in different environments

表 1 KPCA-ESN 方法与其它方法的定位精度比较
Tab. 1 Comparison of positioning accuracy using KPCA-ESN method and other methods

定位方法	10+0	10+5	15+5
WKNN	4.976	5.068	5.423
SVM	4.864	5.665	6.290
ELM	5.045	5.665	5.656
KELM	5.326	5.673	5.731
OS-ELM ^[9]	3.103	2.563	1.794
ESN	2.032	1.873	1.014
KPCA-ESN	0.230	0.170	0.091

2.2 KIOS 研究中心的 Wi-Fi 定位实例实验

实验选取 KIOS 研究中心提供的实际数据集^[18], 实验环境是大约 560 m² 的办公楼, 平面布署如图 4 所示, 其中包括小隔间、私人办公室、实验室、一间会议室及走廊。实验环境安装 9 个固定的 APs, 使用基于 IEEE 802.11b 标准的 Wi-Fi 覆盖了整个楼层。另外, 楼层的不同位置还可接收到数目不定的相邻 APs 发出的信号, 并且, 在某些位置有多于 60 个 APs 可被探测到。

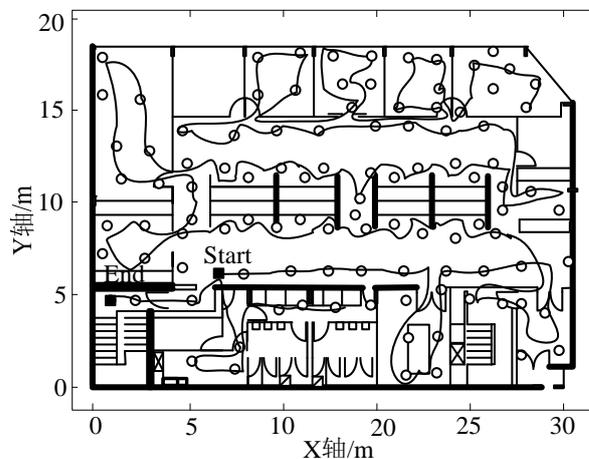


图 4 实验环境的部署示意图

Fig. 4 Deployment of the experimental environment

使用 HTC 智能手机及配置 Windows 操作系统的 HP iPAQ hw6915 PDA 等五种移动装置同时进行数据收集。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 APs 的 RSS 值, 约为 2100 个指纹, 其中每个参考位置收集 20 次 RSS 值。测试数据是在两个星期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, 大多数位置点不同于离线阶段的参考位置点。RSS 值的范围在 -99~ -10 dBm 之间, 由于存在信号干扰或网络中断等因素, 导致一些位置点收集不到某个 AP 的 RSS 值, 可用 -99 dBm 替代丢失的 RSS 值。

本节实验仅使用 HTC 手机与 iPAQ 掌上电脑两种移动设备所收集的数据。由于移动设备自身的特点, 在相同位置点所能够接收信号的 APs 数目不同, 依次为 40 及 67 个。

在 KPCA-ESN 方法中, 式(6)核函数的参数由交叉验证法可选取为 $\delta = 1.5$, 非线性主元 $k = 11$ 。KPCA-ESN 方法及基本 ESN 方法中, 储备池的 N 为 150, 稀疏度为 $1/15$, $\rho = 0.85$ 。WKNN 方法的近邻数为 25, ELM 的激活函数使用 sin 函数, 隐含层节点数目为 200, 此时, 可获得较优的实验结果。

图 5 与图 6 分别给出了在应用 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图。从图 5、图 6 可以看出, KPCA-ESN 与 ESN 方法的定位误差明显优于其它方法, 由于 APs 数目较少, 应用 KPCA 提取非线性主元的优势不够明显。

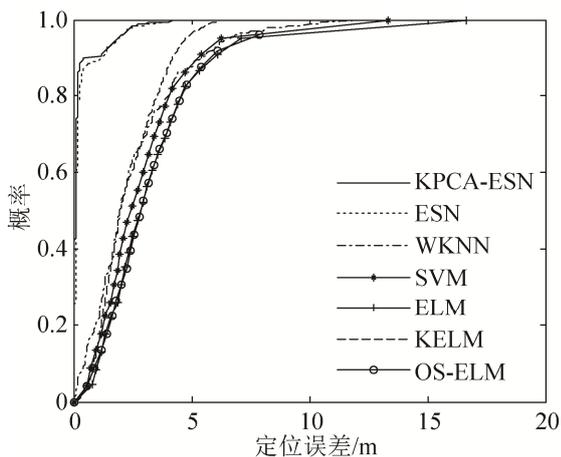


图 5 基于 iPAQ 的 9APs 下的不同定位方法距离误差累计概率分布

Fig. 5 Cumulative probability distribution of distance error for different positioning methods from 9APs by iPAQ device

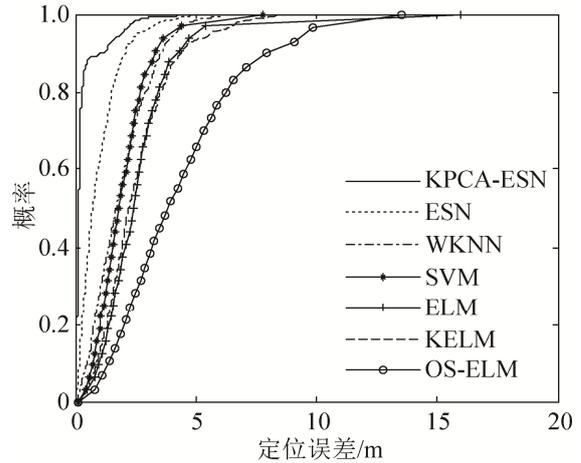


图 6 基于 HTC 的 9APs 下的不同定位方法距离误差累计概率分布

Fig. 6 Cumulative probability distribution of distance error for different positioning methods from 9APs by HTC device

不同方法的具体定位精度比较结果由表 2 给出。从表 2 可以看出, KPCA-ESN 方法的定位精度优于 WKNN、SVM、ELM、KELM、OS-ELM 等方法, 略高于 ESN 方法的定位精度。与单一 ESN 方法相比, KPCA-ESN 方法在两种不同数据集进行实验的动态环境下, 其定位精度的变化波动较小, 分别提高了约 15.4%、18.8%, 这表明 KPCA-ESN 定位方法对动态的环境具有较强的自适应性。

表 2 收集 9APs 的 RSS 值时 KPCA-ESN 方法与其它方法定位精度比较

Tab. 2 Comparison of positioning accuracy using KPCA-ESN method and other methods based on RSS values from 9APs

定位方法	9APs(iPAQ)	9APs(HTC)
WKNN	2.120	1.891
SVM	2.856	1.944
ELM	3.357	2.533
KELM	2.537	2.223
OS-ELM	3.241	4.313
ESN	0.365	0.991
KPCA-ESN	0.310	0.805

图 7 与图 8 分别给出了应用 HTC 手机与 iPAQ 收集 9 个 APs 及多个邻近 APs 的 RSS 值时, 不同定位方法的定位误差累计概率分布曲线图。从图 7、图 8 可以直观看出, KPCA-ESN 方法的定位误差明显优于其它方法, 这表明随着邻近 APs 的引

入, 应用 KPCA 对 RSS 指纹值进行特征提取是非常有效的。不同方法的具体定位精度对比结果则由表 3 给出, 由表 3 看出, KPCA-ESN 方法的定位精度明显优于 WKNN、SVM、ELM、KELM、OS-ELM 方法, 也优于单一 ESN 方法。若以具有较高定位精度的 ESN 方法为基准, KPCA-ESN 方法的定位精度依次提高约 65.5%、88.8%; 同时, 当设备不同时, 其定位精度也仅有 0.244 m 的变化波动, 这体现了本文方法对定位环境的动态变化仍然具有较强的抗干扰与适应能力。

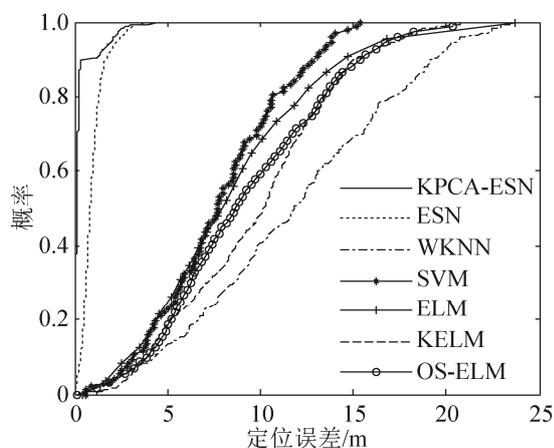


图 7 基于 iPAQ 的 67Aps 下的不同定位方法的距离误差累计概率分布

Fig. 7 Cumulative probability distribution of distance error for different positioning methods from 67Aps by IPAQ device

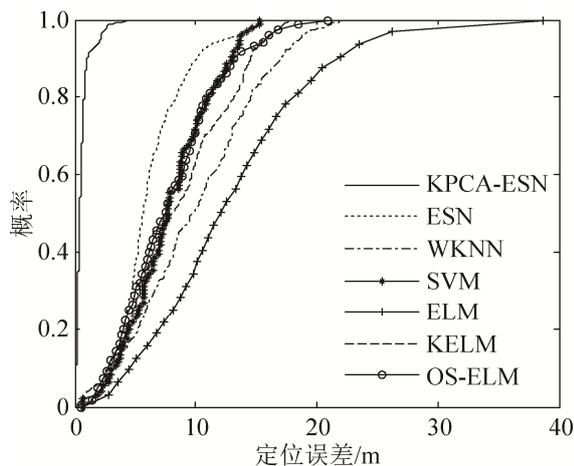


图 8 基于 HTC 的 40Aps 下的不同定位方法的距离误差累计概率分布

Fig. 8 Cumulative probability distribution of distance error for different positioning methods from 67Aps by HTC device

表 3 收集 67Aps 与 40Aps 的 RSS 值时 KPCA-ESN 方法与其它方法定位精度比较

Tab. 3 Comparison of positioning accuracy using KPCA-ESN method and other methods based on RSS values from 67Aps and 40Aps

定位方法	67Aps (iPAQ)	40Aps (HTC)
WKNN	11.833	9.950
SVM	7.887	7.904
ELM	8.440	12.793
KELM	9.797	8.124
OS-ELM	8.233	7.832
ESN	0.994	5.229
KPCA-ESN	0.343	0.587

3 结论

基于位置指纹的 Wi-Fi 室内定位方法具有低成本、高精度的优点, 但是, 由于室内环境的动态变化及移动设备收集 RSS 值的时变性等影响因素, 使得现有的定位方法存在定位精度不高, 抗干扰能力较弱等不足。将统计机器学习算法融入到传统室内定位方法中, 则能有效地提高室内定位精度。结合 KPCA 及 ESN 网络二者的各自优点, 本文提出一种新颖的基于 KPCA-ESN 的方法, 可应用于 Wi-Fi 室内定位应用中。ESN 网络作为一种动态神经网络, 其特有的回声特性, 在很大程度上能进一步提高网络的非线性逼近能力, 而通过对 RSS 指纹数据进行 KPCA 方法的预处理, 则能有效提取定位特征, 克服由于时变的 RSS 值所引入的干扰。仿真和实例实验表明了本文方法的有效性与应用潜力。

参考文献:

- [1] Yang C, Shao H R. WiFi-based indoor positioning[J]. IEEE Communications Magazine (S0163-6804), 2015, 53(3): 150-157.
- [2] Bahl P, Padmanabhan V N. RADAR: an in-building RF-based user location and tracking system[C]// Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies(INFOCOM 2000). Tel Aviv, Israel: IEEE, 2000: 775-784.
- [3] Mainetti L, Patrono L, Sergi I. A survey on indoor positioning systems[C]// 22nd International Conference on Telecommunications and Computer Networks

- (SoftCOM 2014). Split, Croatia: IEEE, 2014: 111-120.
- [4] 李佳徽, 张焱, 栾凤宇, 等. 基于多径指纹的概率匹配室内定位方法[J]. 清华大学学报 (自然科学版), 2015, 55(5): 514-519,525.
Li J H, Zhang Y, Luan F Y, et al. Multipath-based probabilistic fingerprinting method for indoor positioning[J]. Journal of Tsinghua University (S1000-0054), 2015, 55(5): 514-519,525.
- [5] 石欣, 印爱民, 陈曦. 基于 RSSI 的多维标度室内定位算法[J]. 仪器仪表学报, 2014, 35(2): 261-268.
Xin S, Yin A, Xi C, et al. RSSI and multidimensional scaling based indoor localization algorithm[J]. Chinese Journal of Scientific Instrument (S0254-3087), 2014, 35(2): 261-268.
- [6] 冯秀芳, 吕淑芳. 基于 RSSI 和分步粒子群算法的无线传感器网络定位算法[J]. 控制与决策, 2014, 29(11): 1966-1972.
Feng X F, Lv S F. Wireless sensor networks locating algorithm based on RSSI and split-step particle swarm optimization algorithm[J]. Kongzhi Yu Juece/control & Decision (S1001-0920), 2014, 29(11):1966-1972.
- [7] Jekabsons G, Kairish V, Zuravlyov V. An Analysis of Wi-Fi Based Indoor Positioning Accuracy[J]. Scientific Journal of Riga Technical University. Computer Sciences. Applied Computer systems (S1407-7493), 2011, 44(1): 131-137.
- [8] Brunato M, Battiti R. Statistical learning theory for location fingerprinting in wireless LANs[J]. Computer Networks (S1389-1286), 2005, 47(6): 825-845.
- [9] Zou H, Jiang H, Lu X, et al. An online sequential extreme learning machine approach to WiFi based indoor positioning[C]// 2014 IEEE World Forum on Internet of Things (WF-IoT), Seoul, South Korea: IEEE, 2014: 111-116.
- [10] Jaeger H, Haas H. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless telecommunication[J]. Science (S0036-8075), 2004, 304(2): 78-80.
- [11] Mantas L, Jaeger H. Reservoir computing approaches to recurrent neural network training[J]. Computer Science Review (S1574-0137), 2010, 3(3): 127-149.
- [12] 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 Y, Huang J, Xu K. 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.
- [13] 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 Y B, Deng Z A, Lin M. WLAN indoor positioning algorithm based on KDDA and SVR[J]. JEIT (S1009-5896), 2011, 33(4):896-901.
- [14] Shawe-Taylor J, Cristianini N. Kernel methods for pattern analysis[M]. Cambridge, U.K: Cambridge university press, 2004: 111-194.
- [15] Huang G B, Zhou H M, Ding X J, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics (S1083-4419), 2012, 42(2): 513-529.
- [16] Chen B -J, Chang M -W, Lin C -J. Load Forecasting Using Support Vector Machines: A Study on EUNITE Ccompetition 2001[J]. IEEE Transactions on Power Systems (S0885-8950), 2004,19(4): 1821-1830.
- [17] Chrysikos T, Georgopoulos G, Kotsopoulos S. Site-specific validation of ITU indoor path loss model at 2.4 GHz[C]// 10th IEEE International Symposium on a World of Wireless, Mobile and Multimedia Networks(WOWMOM 2009). Kos Island, Greece: IEEE. 2009: 1-6.
- [18] Laoudias C, Piché R, Panayiotou C G. Device self-calibration in location systems using signal strength histograms[J]. Journal of Location Based Services (S1748-9725), 2013, 7(3): 165-181.