

# 基于 KPCA 的无线层析成像定位方法

陆俊<sup>1</sup>, 柯炜<sup>1,2</sup>, 金杰<sup>1</sup>, 陈梦玲<sup>1</sup>, 王彦力<sup>1</sup>, 左浩然<sup>1</sup>

(1. 南京师范大学江苏省光电子技术重点实验室, 物理科学与技术学院, 江苏 南京 210023)

(2. 江苏省地理信息资源开发与应用协同创新中心, 江苏 南京 210023)

**[摘要]** 无线层析成像(radio tomographic imaging, RTI)技术作为无设备目标定位(device-free localization, DFL)的主要方式之一,在被定位目标不携带任何定位装置的情况下仍能实现定位,具有广泛的应用前景。但由于接收信号强度(received signal strength, RSS)信息容易受到环境变化和噪声的影响,RTI 成像图上往往不可避免地存在着背景噪点,有时甚至还有伪目标出现在图像上。为了提高 RTI 成像质量,本文提出一种基于核主成分分析(kernel principal component analysis, KPCA)的增强型 RTI 方法,该方法利用 KPCA 的学习能力来提取有效受目标影响的链路特征信息,从而达到克服噪声影响和提高定位精度的目的。室内外实验结果表明,该方法的成像质量和定位精度都要优于现有 RTI 方法。

**[关键词]** 无线层析成像,无设备定位,接收信号强度,核主成分分析

**[中图分类号]** O451 **[文献标志码]** A **[文章编号]** 1001-4616(2020)01-0031-09

## Wireless Tomography Positioning Method Based on KPCA

Lu Jun<sup>1</sup>, Ke Wei<sup>1,2</sup>, Jin Jie<sup>1</sup>, Chen Mengling<sup>1</sup>, Wang Yanli<sup>1</sup>, Zuo Haoran<sup>1</sup>

(1. Jiangsu Key Laboratory on Opto-electronic Technology, School of Physics Science and Technology,  
Nanjing Normal University, Nanjing 210023, China)

(2. Jiangsu Center for Collaborative Innovation in Geographical Information Resource Development and Application, Nanjing 210023, China)

**Abstract:** Radio Tomography Imaging (RTI) technology is one of the main methods of device-free localization (DFL). It can still achieve positioning without being positioned with any positioning device, and with a wide range of application prospects. However, since the Received Signal Strength (RSS) information is easily affected by environmental changes and noise, background noise is inevitably present on the RTI image, and sometimes even pseudo targets appear on the image. In order to improve the quality of RTI, this paper proposes an enhanced RTI method based on Kernel Principal Component Analysis (KPCA), which uses the learning ability of KPCA to extract the link characteristic information that is effectively affected by the target, in order to overcome the effects of noise and improve positioning accuracy. The results of indoor and outdoor experiments show that the imaging quality and positioning accuracy of this method are better than the existing RTI method.

**Key words:** radio tomography imaging, device-free localization, received signal strength, kernel principal component analysis

随着 5G 和物联网技术的快速发展,无线定位在诸多应用场景中发挥着越来越重要的作用。但目前绝大多数定位系统,都要求定位目标必须携带与定位系统相匹配的定位设备(如 GPS 接收机、手机等)等才能实现定位。然而,在人员搜救、入侵检测、人质解救以及特殊条件下老人照料等应用场合,被定位目标一般不会或不愿携带相应定位装置,此时传统的定位方法将无法使用。为解决这一类定位问题,无需定位目标携带任何定位装置,也无需定位目标主动参与定位过程的无设备目标定位(device-free localization, DFL)技术应运而生<sup>[1-2]</sup>,并受到广泛关注。

与过去基于摄像头<sup>[3]</sup>、超宽带雷达<sup>[4]</sup>、红外<sup>[5]</sup>和超声波<sup>[6]</sup>等技术的无设备目标定位不同,利用无线传感器网络的 DFL 技术因其成本低、通用性好并具有能够穿透墙壁、烟雾进行定位等优点,因而成为当前定

收稿日期:2019-02-01.

基金项目:2018 年江苏省研究生科研创新项目(KYCX18\_1187).

通讯作者:柯炜,副教授,研究方向:无线电定位. E-mail: kewe@njnu.edu.cn

位领域的一个研究热点.

在无线传感器网络(wireless sensor network, WSN)中,当一个目标在传感器节点之间运动时,目标将吸收、衍射、反射或散射电磁波引起信号的衰减. 这些时变的信号链接衰落携带着目标的位置信息,使得在监测区域可以捕捉到目标的移动. RTI 就是通过无线电的携带的位置信息测量目标区域中的环境信息,从而实现定位.

目前基于无线传感器网络的主流 DFL 方法有 2 大类,一类是指纹定位方法<sup>[7-8]</sup>,另一类是射频层析成像方法(radio tomographic imaging, RTI)<sup>[9-10]</sup>. 指纹基的 DFL 要求事先建立离线指纹数据库,然后在定位阶段通过用当前测量值比对数据库中测量值的方式进行定位,该类方法要求随着环境的变化不时进行数据库更新,对人力和物力投入要求较高. RTI 方法最早是由 Neal Patwari<sup>[9-10]</sup>等人提出的阴影基的成像定位方法,通过在目标区域的边缘布置若干收发节点,根据每个节点接收到的信号强度(received signal strength, RSS)的变化来反映目标的影响,并借鉴医学 CT 思想用反演图像的方式呈现出定位结果,该方法由于其直观性强而受到较多关注. 在阴影基 RTI 方法基础上, Zhao 和 Patwari 等人开始尝试采用基于方差的 RTI 方式<sup>[6-7]</sup>;接着基于直方图的 RTI<sup>[8]</sup>,利用信道分集的 RTI<sup>[9]</sup>和采用定向天线的 RTI<sup>[10]</sup>等后续研究层出不穷,进一步提高了 RTI 的性能.

虽然 RTI 技术受到广泛关注并取得一定进步,但基于 RSS 的 RTI 定位仍然存在一个根本问题有待解决,即 RSS 测量值的高波动性对成像质量和定位结果的影响. 众所周知, RSS 测量值容易受到各种因素的影响,即使无目标存在时 RSS 测量值也会发生比较明显的变化. 为了清楚地展示 RSS 变化的特点,我们在室内固定摆放 2 个 2.4 GHz 频段的无线收发模块,两个模块间距 1 m,收发间隔 5 ms,连续测量 1 min 数据,统计结果如图 1 所示. 从图 1 可以看出,即使室内环境无明显改变,并且无目标影响,但从同一接收器收集的 RSS 的变化仍高达 6 dB. 再加上目前 DFL 系统普遍采用低成本的无线模块,其读数本身也会带来 1 dB~2 dB 的误差. 因此,这种 RSS 测量值的自身波动往往会导致对有效链路的误判,把没有目标影响的链路当作目标影响的链路,反之亦然,进而会严重影响 RTI 成像质量.

针对上述问题,提高 RTI 成像质量的核心就在于如何有效地去除随机因素影响,得到真正受目标影的测量值. 为解决此问题,文献[11]提出了一种分层 RSS 模型,该模型有助于描述细粒化的 RSS 的变化程度,提高分辨 RSS 变化的灵敏度. 文献[12]则利用阴影链路的时域和空域先验信息来消除干扰链路影响. 然而,这些工作都需要根据先验模型来区分有效链路和噪声影响的链路,并不能自适应地克服环境的动态影响. 因此,本文提出一种基于核主成分分析的增强型 RTI 方法,该方法利用核主成分分析的学习能力自适应地从受噪声污染的测量值中分离出目标引起的扰动部分进行定位,从而有效克服 RSS 值波动大的影响,提高定位精度.

本文的其余部分内容如下:首先,在第 1 节给出 RTI 的背景信息和本文研究的基础和动机;第 2 节为文章核心内容,介绍核主成分分析的工作流程,以及结合卡尔曼滤波技术,将其应用到无设备追踪中;第 3 节为实验结果和分析;第 4 节对本文进行总结并列举未来的工作.

## 1 系统模型与问题陈述

### 1.1 系统模型

在 DFL 中,当一个目标在定位区域内移动时,目标会吸收、反射或散射电磁波而引起信号强度的改变. 这些信号强度的变化随着目标在不同位置而发生改变,检测这些变化就有可能实现对无设备目标的定位.

假设 WSN 中的传感器节点为  $L$ ,那么该传感网络就有  $M=L(L-1)/2$  条双向无线链路. 所有传感器节点包围的区域叫做监测区域,并将监测区域均匀划分为  $N$  个格点,格点在 RTI 中可以称为像素,并用矢量  $\mathbf{x} \in R^N$  表示. 那么 RTI 定位模型可以表示为<sup>[13]</sup>:




图 1 接收信号强度指示(RSS)的时域变化

Fig. 1 Time domain variation of received signal strength indicator

$$\mathbf{y} = \mathbf{\Psi}\mathbf{x} + \mathbf{n}, \quad (1)$$

式中,  $\mathbf{y} = [y_1, \dots, y_M]^T \in R^M$  表示目标出现前后  $M$  条链路的 RSS 变化.  $[n_1, \dots, n_M]^T \in R^M$  表示各种噪声和干扰.  $\mathbf{\Psi} = [\psi_1, \dots, \psi_M]^T \in R^{M \times N}$  表示权重矩阵,  $\psi_i(j)$  表示链路  $i$  的阴影衰落上的像素  $j$  的权重. 本文采用绝大多数 RTI 使用的椭圆权重模型, 该模型假设目标只对椭圆区域内的像素点产生影响, 而椭圆区域外的像素点的影响忽略不计, 可用下式表述<sup>[13-14]</sup>:

$$\psi_i(j) = \frac{1}{\sqrt{d_i}} \begin{cases} 1, & \text{如果 } d_{ij}(1) + d_{ij}(2) < d_i + \lambda, \\ 0, & \text{其他情形,} \end{cases} \quad (2)$$

式中,  $d_i$  表示链路  $i$  的长度,  $d_{ij}(1)$  与  $d_{ij}(2)$  是像素  $j$  的中心与链路  $i$  上的两端节点之间的距离.  $\lambda$  表示椭圆的短轴长度.

## 1.2 问题陈述

RTI 的原理是通过检测目标对链路的影响来实现目标定位的, 但由于电磁波极易受环境的影响, 因而当某些链路上的测量值变化不是由目标引起而是由其他噪声引起时将会引起 RTI 成像质量的大为降低, 甚至会出现没有目标像或出现伪目标的情况. 为了清楚展示环境噪声对链路测量的影响, 本文构建了如图 2(a) 所示的实验系统, 该网络由 8 个节点组成, 这些节点由 2.4 GHz 频段的 TI CC2530 芯片构成, 并结合 ZigBee 协议<sup>[15-16]</sup> 建了 RTI 定位系统. 当目标处于区域中心时, 本文挑选 1~2 号节点构成的第 1 条链路 (目标未影响) 和 2~6 号节点构成的第 11 条链路 (目标影响) 测量值进行对比分析. 分别记录 100 s 有目标存在时的测量数据和无目标存在时的背景测量数据, 并得到目标出现前后这两条链路 RSS 变化的差值, 然后进行如下归一化操作:

$$\Delta RSS_i^t = \frac{\Delta RSS_i^t - \min(\Delta RSS)}{\max(\Delta RSS) - \min(\Delta RSS)}, \quad (3)$$

式中,  $i = 1, \dots, 28; t = 1, \dots, 100, \Delta RSS_i^t$  为  $t$  时刻第  $i$  条链路的 RSS 的变化值, 为规定时间内所有链路的 RSS 的变化值, 本文实验采集了 100 s 内的 RSS 变化值. 100 s 内 28 条链路归一化后的原始 RSS 变化值波动显著, 如图 2(b) 所示. 图 2(c) 展示了第 1 条链路也就是目标没经过的链路的 100 s 内归一化后的原始 RSS 变化波动. 图 2(d) 展示了第 11 条链路也就是有目标经过的链路的 100 s 内归一化后的原始 RSS 变化波动. 从以上图对比可以看出, 每一条链路的测量值都波动明显, 即使没有目标影响的链路也可能出现较大

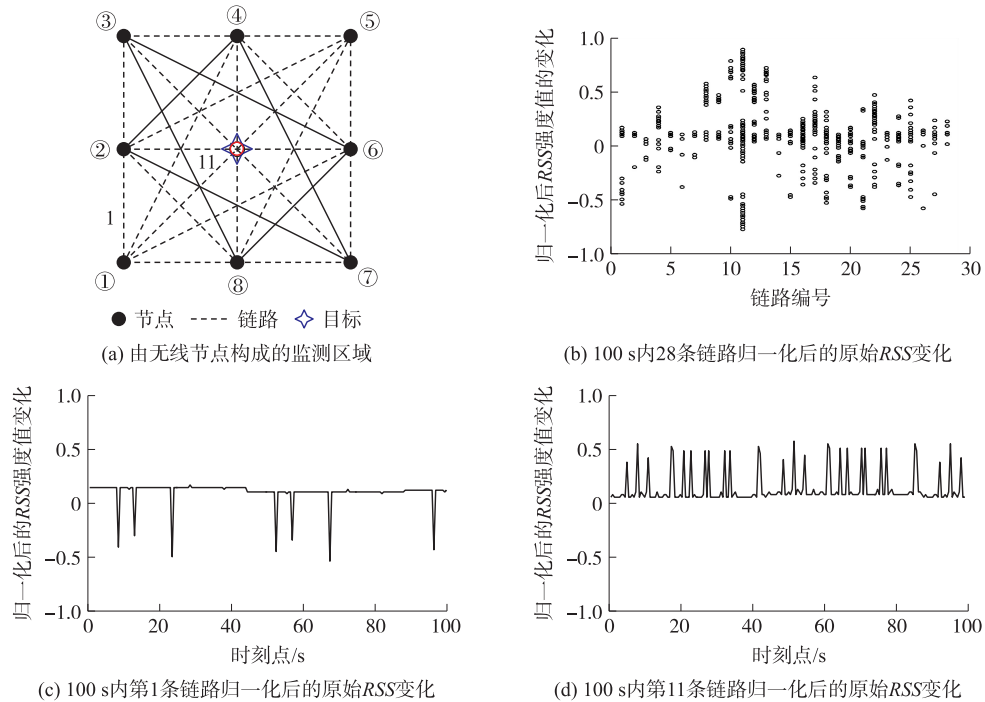


图2 无线层析成像网络的图示

Fig. 2 A diagram of a radio tomographic imaging network

的变化,因此如果原始数据不经过任何处理,直接使用该 RSS 的变化值进行 RTI 成像,往往会出现没有目标像或出现伪目标的情况。

## 2 通过核主成分分析实现定位

为了克服 RSS 易受噪声影响的缺点,本文利用 KPCA 从 RSS 的变化波动中提取只由目标存在对链路造成影响部分。KPCA 算法实际上就是加核的 PCA 算法<sup>[17-18]</sup>,它主要针对于非线性可分问题,给出了一种对该类问题进行特征提取的有效方式。与 PCA 特征提取算法类似,KPCA 算法只是先将原始非线性可分数据通过某种变换映射到线性可分的高维空间,然后将该高维空间看成是新的原始空间,再对此空间内的数据通过 PCA 算法来提取特征,得到特征提取结果。

而本文采集到的受噪声影响的数据不是线性可分数据,通过简单的 PCA 处理并不能得到其中的有效链路数据特征。通过这种训练方式,我们可以从时变的 RSS 测量值中学习到有用特征,其就是只有目标在监测区域内影响的链路和有效测量值。如图 3 所示,本文提出系统的详细架构。传统的 WSN 中的 RTI 技术,只是简单地将原始采集到的 RSS 测量结果输出到目标的正确位置。然而,本文在采集到原始 RSS 测量值之后,将其通过 KPCA 预处理,得到去除环境噪声后的由目标引起的阴影衰落分布,这样就能得到目标所处的准确位置。本文 KPCA 主要先将采集的 RSSI 数据通过引入核函数将其变换到高维特征空间中,然后在高维特征空间中进行 PCA 降维处理<sup>[19]</sup>。

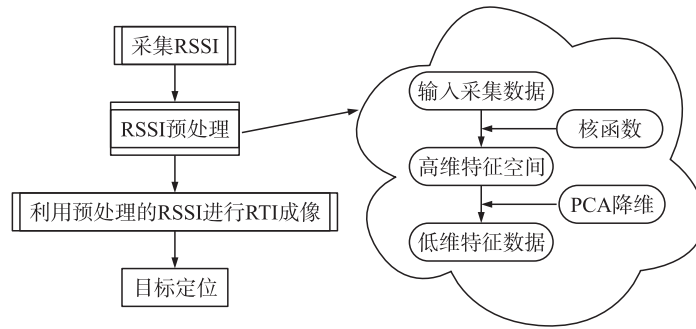


图 3 本文系统的详细架构

Fig. 3 Detailed architecture of the system

### 2.1 输入空间样本

假设有人在监测区域时,链路  $k$  的 RSS 记为  $R_{loc}^k$ ,同时在部署区域内没有目标时的参考 RSS 值记为  $R_{emp}^k$ .  $t$  时刻 RSS 的测量变化值  $\Delta R_{loc}^t$  由下面公式决定:

$$\Delta \vec{R}_{loc}^t = \{ \Delta R_{loc}^k = R_{loc}^k - R_{emp}^k \mid k = 1, \dots, K \}. \quad (4)$$

$K$  表示监测区域中所有链路的总数, $t$  代表总的轮询数。该系统是为了利用 RSS 的测量值的变化来估计目标的位置。

### 2.2 核主成分分析

假设中心化后的样本数据为  $\mathbf{x}_{d \times N}$ ,  $N$  为样本个数, $d$  为样本的维度。将其映射到高维特征空间中  $\phi(\mathbf{x})$ ,其特征向量为  $\mathbf{w}_i (i=1, \dots, D)$  的  $D$  维向量  $D \gg d$ ,  $\lambda_i (i=1, \dots, D)$  为其对应的特征值。高维空间的 PCA 如下:

$$\phi(\mathbf{x}) \phi(\mathbf{x})^T \mathbf{w}_i = \lambda_i \mathbf{w}_i, \quad (5)$$

空间中的任一向量,都可以由该空间中的所有样本线性表示<sup>[20]</sup>,将特征向量  $\mathbf{w}_i$  利用样本集合  $\phi(\mathbf{x})$  线性表示如下:

$$\mathbf{w}_i = \sum_{k=1}^N \alpha_i \phi(\mathbf{x}_k) = \phi(\mathbf{x}) \boldsymbol{\alpha}, \quad (6)$$

将公式(6)代入公式(5)中,得到如下形式:

$$\phi(\mathbf{x}) \phi(\mathbf{x})^T \phi(\mathbf{x}) \boldsymbol{\alpha} = \lambda_i \phi(\mathbf{x}) \boldsymbol{\alpha}. \quad (7)$$

进一步,等式两边同时乘以  $\phi(\mathbf{x})^T$ ,得到如下公式:



$$\phi(\mathbf{x})^T \phi(\mathbf{x}) \phi(\mathbf{x})^T \phi(\mathbf{x}) \boldsymbol{\alpha} = \lambda_i \phi(\mathbf{x})^T \phi(\mathbf{x}) \boldsymbol{\alpha}. \quad (8)$$

考虑到该方法的基础是实现了一种由输入空间到特征空间的非线性映射,对任意对称、连续且满足 Mercer 条件<sup>[21]</sup>的函数  $\mathbf{K}$ ,定义如下:

$$\mathbf{K} = \phi(\mathbf{x})^T \phi(\mathbf{x}). \quad (9)$$

将其代入公式(8),并且两边同时除以  $\mathbf{K}$ ,得到与 PCA 相似度极高的求解公式:

$$\mathbf{K}\boldsymbol{\alpha} = \lambda_i \boldsymbol{\alpha}. \quad (10)$$

常用的核函数有以下 4 种形式:线性核函数,多项式核函数,高斯径向基核函数,多层感知器核函数.

### 2.3 核主成分分析的实现步骤

$\Delta \mathbf{R} = [\Delta R_1, \Delta R_2, \dots, \Delta R_t] (\Delta R_1, \Delta R_2, \dots, \Delta R_t \in \mathbf{R}^m)$  表示在测试时间内采集到的  $t$  个原始采集样本集,  $\mathbf{U} = [u_1, u_2, \dots, u_t] (u_1, u_2, \dots, u_t \in \mathbf{R}^p)$  表示输出样本集,  $p < m$ , 核函数为  $k$ , 正定核为  $\mathbf{K}$ , 则 KPCA 的具体步骤如下:

步骤一:根据给定的核函数  $k$ , 求得正定核  $\mathbf{K}$ .  $K_{ij} = k(\Delta R_i, \Delta R_j) = \phi(\Delta R_i) \cdot \phi(\Delta R_j) = \phi(\Delta R_i)^T \phi(\Delta R_j)$ , 根据  $\mathbf{L} = \mathbf{K} - \mathbf{K} \cdot \mathbf{M} - \mathbf{M} \cdot \mathbf{K} + \mathbf{M} \cdot \mathbf{K} \cdot \mathbf{M}$  求出  $\mathbf{L}$ , 其中矩阵  $\mathbf{M}_{m \times m}$  表示每个元素都为  $1/m$  的方阵.

步骤二:计算矩阵  $\mathbf{L}$  的所有特征值, 对这些特征值进行排序, 选出前  $p$  个特征值  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ , 然后计算他们所对应的特征向量  $\nu_1, \nu_2, \dots, \nu_p$ .

步骤三:根据公式  $w_i = \frac{1}{\sqrt{\lambda_i}} \mathbf{Q} \nu_i$ , 其中  $\mathbf{Q} = [\phi(\Delta R_1), \phi(\Delta R_2), \dots, \phi(\Delta R_m)]$ , 求  $\mathbf{W} = [w_1, w_2, \dots, w_p]$ , 即特征提取算法中所需要的特征矩阵.

步骤四:由  $u_i = \mathbf{W}^T \phi(\Delta \mathbf{R}) = \frac{1}{\sqrt{\lambda_i}} \mathbf{Q}^T \nu_i^T \phi(\Delta \mathbf{R}) = \frac{1}{\sqrt{\lambda_i}} \nu_i^T [k(\Delta R_1, \Delta \mathbf{R}), k(\Delta R_2, \Delta \mathbf{R}), \dots, k(\Delta R_m, \Delta \mathbf{R})]$ ,  $i = 1, 2, \dots, p$ , 计算得  $u_i \in \mathbf{R}^p$ , 由  $\mathbf{U} = [u_1, u_2, \dots, u_t]$  组成的特征集就是输出特征集, 至此算法结束.

为了验证 KPCA 在 RTI 中的性能, 本文用图 2 中相同的实测链路数据, 经过 KPCA 处理后, 所得结果如图 4 所示. 对比图 4(a) 和图 2(b), 可以发现非目标影响链路的波动明显减小, 与受目标影响链路之间差别变得明显. 如图 4(b)、(c) 所示, 100s 内第 1 条链路经过 KPCA 处理过后的数据基本无明显的波动变化, 而 100 s 内第 11 条链路经过 KPCA 处理过后的数据存在很稳定的波动变化.




图 4 经过 KPCA 处理的链路数据(a), 以及(b), (c)

Fig. 4 Link data processed by KPCA(a), (b) and (c)

从此例可以看出, KPCA 能够从无规律的实测数据中找到受目标影响的波动特征. 而本文所用的 RTI 技术正是根据这一规律给出的权重矩阵进行无线层析成像, 有望提高成像效果.

## 3 结果与讨论

为全面衡量本文方法的有效性, 本文使用室内外不同环境的实验数据对不同模型的定位结果进行了对比分析. 对于室外环境, RTI 系统由 20 个测量节点组成, 均匀分布在室外  $10.0 \text{ m} \times 10.0 \text{ m}$  方形区域周围 (如图 5(a) 所示), 相邻节点之间距离为  $2.0 \text{ m}$ . 无线节点同样以 TI 公司  $2.4 \text{ GHz}$  频段的 CC2530 芯片为基础, 并结合 ZigBee 协议构建了 DFL 定位系统. 该在室外定位的基础上, 为了反映室内墙壁、家具等对 RTI 成像的影响, 又在南京师范大学格物楼室内选择  $7.5 \text{ m} \times 5.0 \text{ m}$  的方形区域, 同样在周围均匀布置 20 个收

发节点进行定位实验(如图 8(a)所示),此时相邻节点之间距离为 1.5 m( $y$  方向)和 1.0 m( $x$  方向). 同时为了提高跟踪效果,本文引入卡尔曼滤波以提高跟踪精度.

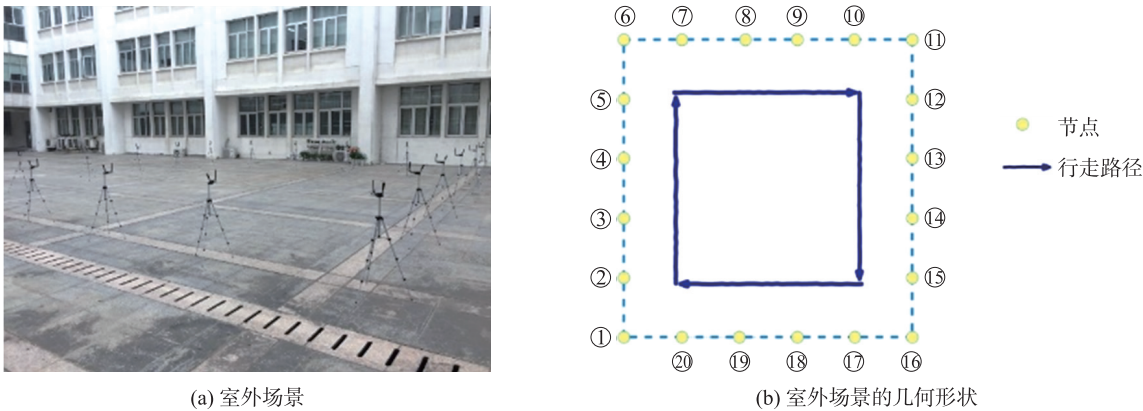


图 5 室外场景  
Fig. 5 Experimental setup in outdoor scene

3.1 室外场景中的实验结果

本文在室外实验中分别记录了 40 个具有单个目标和跟踪路径的测试样本. 在 RTI 中,本文使用的权重矩阵是经典的椭圆模型<sup>[15]</sup>,椭圆的短轴长度设置为 0.15 m. 我们将监视区域划分为 2 500 像素. 每个像素的大小为 0.15 m×0.1 m. 训练样本是本文实测 30 s 内采集到的空背景数据减去有目标在监测区域所得到的输入空间样本,由于空背景和有目标的样本数都为 15 个,因此本文的输入空间样本个数为 225 个,同时每个样本包含 190 条链路信息,那么输入空间样本的维度为 225×190.

本文将在南京师范大学行健楼庭院(4.0 m,6.0 m)处采集到的原始输入空间的第 1 个样本、第 100 个样本和第 200 个样本的 RTI 成像与由 KPCA 处理后的数据的做了比较,如图 6 所示. 由于 KPCA 可以从时




图 6 目标处于(4.0 m,6.0 m)处的 RTI 成像图  
Fig. 6 RTI imaging of target at(4.0 m,6.0 m)

间变化测量值中学习有用的特征,因此它显示出良好的成像效果. 我们可以看到原始数据的 RTI 成像由于环境干扰而存在严重的背景噪声,这不仅存在伪目标,而且存在复杂的背景噪声,如图 6(a)、(b)和(c)所示. 如图 6(d)所示,我们可以完美地清楚地找到没有伪目标和干净背景的目标位置.

南京师范大学行健楼庭院内跟踪示例的结果展示,如图 7 所示. 通过比较没有滤波的路径和通过卡尔曼滤波器滤波的路径,我们可以看出通过卡尔曼滤波的跟踪结果非常接近真实的行走路径. 本文提出的 KPCA 结合卡尔曼滤波给出的跟踪结果很好地符合实际情况.

室外跟踪误差的详细统计结果如表 1 所示.

表 1 中给出了由实测 RTI 估计出的,通过 KPCA 预处理后的以及 KPCA 结合卡尔曼滤波估计的跟踪路径的最大误差、平均误差和标准偏差. 从中可以发现,利用 KPCA 结合卡尔曼滤波的方法将有助于定位和跟踪,这意味着易于从射频信号收集正确的位置. 然而,它无法从最大误差中完全解决无线层析成像的缺点. 实验结果表明,本文所提方法在平均误差上提升了 1.34 m,标准偏差误差提升了 1.02 m,很好地提升了室外跟踪效果.

3.2 室内场景的实验结果

本文在室内场景中采集了 36 个被定位的目标点以及一个跟踪路径. 采集数据的标准和上文室外采集标准一致,因此输入空间样本的维度同样为 225×190.



(a) 室内场景





图 7 室外场景跟踪结果比较

Fig. 7 Comparison of outdoor scene tracking results

表 1 室外跟踪路径的跟踪误差 3 种统计值分布

Table 1 Distribution of three statistical values of tracking errors of outdoor tracking paths m

路径估计	最大误差	平均误差	标准偏差误差
实测估计	3.42	1.76	1.28
KPCA 估计	1.63	0.79	0.53
KPCA+KF 估计	1.32	0.42	0.26



(b) 室内场景的几何形状

图 8 室内场景

Fig. 8 Experimental setup in indoor scene

本文将在南京师范大学格物楼室内中的(2.0 m,3.0 m)处采集到的原始输入空间的第 1 个样本、第 100 个样本和第 200 个样本的 RTI 成像与通过 KPCA 处理后的数据做了比较,如图 9 所示. 由于 KPCA 可以从时间变化测量值中学习有用的特征,因此它显示出良好的成像效果. 我们从图 9(a)、(b)和(c)所示可以看到原始数据的 RTI 成像由于环境干扰而存在严重的背景噪声,这不仅存在伪目标,而且存在复杂的背景噪声. 如图 9(d)所示,我们可以非常容易地找到没有伪目标和干净背景的目标位置.

南京师范大学格物楼室内跟踪示例的结果展示如图 10 所示. 通过比较没有滤波的路径和通过卡尔曼滤波器滤波的路径,可以看出通过卡尔曼滤波器的跟踪结果非常接近真实的行走路径. 因此,本文提出的稀疏自编码器结合粒子滤波给出的跟踪结果很好地符合实际情况.



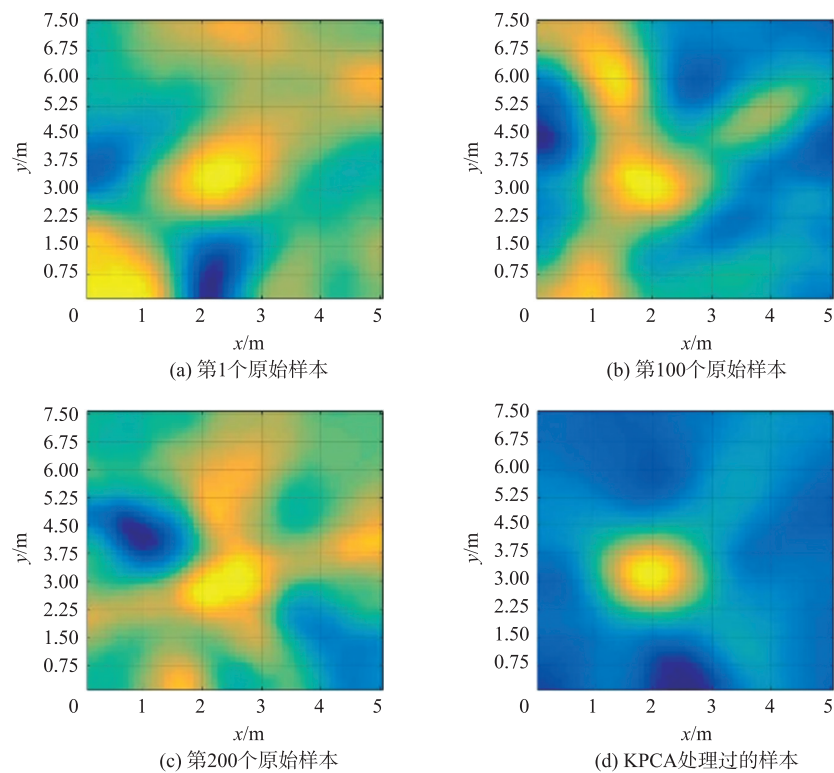


图 9 目标处于(2.0m,3.0m)处的 RTI 成像图

Fig. 9 RTI imaging of the target at (2 m,3 m)




图 10 室内场景跟踪结果比较

Fig. 10 Comparison of indoor scene tracking results

室内的跟踪误差的详细统计结果如表 2 所示. 表中给出了由实测 RTI 估计出的,通过 KPCA 预处理后的及 KPCA 结合卡尔曼滤波估计的跟踪路径的最大误差、平均误差和标准偏差. 从中可以发现,利用 KPCA 结合卡尔曼滤波的方法将有助于定位和跟踪,这意味着易于从射频信号收集正确的位置. 然而,它无法从最大误差中完全解决无线层析成像的缺点. 实验结果表明,所提议的方法在平均误差提升了 1.14 m,标准偏差误差提升了 1.07 m,很好地提升了室内跟踪的效果.

表 2 室内跟踪路径的跟踪误差 3 种统计值分布

Table 2 Distribution of three statistical values of tracking errors for indoor tracking paths

路径估计	最大误差	平均误差	标准偏差误差
实测估计	3.98	1.92	1.64
KPCA 估计	1.89	0.92	0.84
KPCA+KF 估计	1.56	0.78	0.57

4 结论

为克服 RSS 容易受到环境变化和噪声影响的问题,本文提出一种利用 KPCA 的学习能力来提取有效链路特征信息的方法,并用此有效特征信息提高 RTI 成像质量. 在此基础上,结合卡尔曼滤波技术将该方法应用到无设备目标跟踪. 室内外不同环境下的实验结果表明,该方法的成像质量和定位精度都要优于现有 RTI 方法. 下一步工作将考虑将本文方法推广到多目标 DFL 中.

[参考文献]

[1] 刘凯,夏然,柴柯. 结合非涅尔理论的免携带设备定位研究[J]. 传感技术学报,2015,38(2):298-302.  
[2] 孙立奎,王洪玉,吴力飞,等. 基于信号差分特性的被动入侵检测方法[J]. 传感技术学报,2012,25(11):1549-1555.



- [3] SANG H P, SO H W, JONG B L. Smart home-digitally engineered domestic life[J]. Personal and ubiquitous computing, 2003, 7(3-4):189-196.
- [4] 李禹. UWB-TWDR 的运动目标检测及定位[D]. 长沙:国防科学技术大学, 2003, TN95:1-59.
- [5] TSIMHONI O, BARGMAN J, MICHAEL J, et al. Pedestrian detection with near and far infrared night vision enhancement[J]. The journal of the illuminating engineering society of North America(Leukos), 2004, 4(2):113-128.
- [6] BORENSTEIN J, KOREN Y. Noise rejection for ultrasonic sensors in mobile robot applications[C]//Proceedings 1992 IEEE International Conference on Robotics and Automation. Nice, France, 1992, 2:1727-1732.
- [7] LE DORTZ N, GAIN F, ZETTERBERG P, et al. WiFi fingerprint indoor positioning system using probability distribution comparison[C]//2012 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP). Kyoto, Japan, 2012:2301-2304
- [8] KOO J, CHA H. Localizing WiFi access points using signal strength[J]. IEEE communications letters, 2011, 15(2):187-189.
- [9] PATWARI N, WILSON J. RF sensor networks for device-free localization: measurements, models and algorithms[J]. Proceedings of IEEE, 2010, 98(11):1961-1973.
- [10] WILSON J, PATWARI N. A fade-level skew-laplace signal strength model for device-free localization with wireless networks[J]. IEEE transactions on mobile computing, 2012, 11(6):947-958.
- [11] LUO Y, HUANG K, GUO X, et al. A hierarchical RSS model for RF-based device-free localization[J]. Pervasive and mobile computing, 2016, 31:124-136.
- [12] WANG Z, LIU H, MA H, et al. Enhancing indoor radio tomographic imaging based on interference link elimination[J]. Digital signal processing, 2015, 44:26-36.
- [13] WILSON J, PATWAR N. Radio tomographic imaging with wireless networks[J]. IEEE transactions on mobile computing, 2010, 9:621-632.
- [14] KALTIOKALLIO O, BOCCA M, PATWARI N. A fade level-based spatial model for radio tomographic imaging[J]. IEEE transactions on mobile computing, 2014, 13(6):1159-1172.
- [15] DAE M H, JAE H L. Design and implementation of smart home energy management systems based on zigbee[J]. IEEE transactions on consumer electronics, 2010, 56(3):1417-1425.
- [16] JENNIFER Y, BISWANATH M, DIPAK G. Wireless sensor network survey[J]. Computer networks, 2008, 52(12):2292-2330.
- [17] STEPHAN L, GEORGIOS T, STEFANOS Z. Euler principal component analysis[J]. International journal of computer vision, 2013, 101(3):498-518.
- [18] NAN L, HAN W. Weighted principal component extraction with genetic algorithms[J]. Applied soft computing, 2012, 12(2):961-974.
- [19] WANG L W, WANG X, ZHANG X R, et al. The equivalence of two-dimensional PCA to line-based PCA[J]. Pattern recognition letters, 2005, 26(1):57-60.
- [20] CANNON A. Nonlinear principal predictor analysis: application to the lorenz system[J]. Journal of climate, 2006, 19(4):579-589.
- [21] SHENG B H, WANG J L, LI P. The covering number for some Mercer kernel Hilbert spaces[J]. Journal of complexity, 2008, 24(2):241-258.

[责任编辑:顾晓天]