

面向无人智能小车的双验证安全定位方法

顾晓丹, 夏国正, 宋炳辰, 杨明, 罗军舟

(东南大学计算机科学与工程学院, 江苏 南京 211189)

摘要: 针对无人智能小车在网络、硬件、操作系统和软件方面存在众多安全隐患, 易受到物理或远程安全攻击, 使其偏离配送轨迹导致配送任务失败, 甚至被攻击者操控干扰工厂正常运行的问题, 提出了一种面向无人智能小车的双验证安全定位方法。在无人智能小车端, 利用已有的 Wi-Fi 网络基础设施进行指纹定位, 并设计特征融合策略实现 Wi-Fi 和磁场指纹的动态融合; 在环境端, 部署多个监测点采集无人智能小车发出的声音信号计算到达时间差, 并根据空间分割方法计算小车位置。在此基础上, 通过将无人智能小车上报的位置信息和监测点计算的位置坐标进行对比验证, 一旦发现小车位置出现异常则进行异常告警, 从而保证无人智能小车的正常运转工作。在真实室内场景下的实验结果表明, 所提方法可以有效跟踪目标设备的位置坐标, 定位精度优于现有基准算法。

关键词: 无人智能小车; 室内定位; Wi-Fi 指纹; 磁场指纹; 声源定位

中图分类号: TP393

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2024038

Dual-verified secure localization method for unmanned intelligent vehicles

GU Xiaodan, XIA Guozheng, SONG Bingchen, YANG Ming, LUO Junzhou

School of Computer Science and Engineering, Southeast University, Nanjing 211189, China

Abstract: Unmanned intelligent vehicles are exposed to high risks of network attack, hardware attack, operating system attack and software attack. They are susceptible to physical or remote security attacks, causing it to deviate from the delivery trajectory and fail the delivery task, or even be manipulated to disrupt normal operation of the factory. To address this problem, a dual-verified secure localization method for unmanned intelligent vehicles was proposed. The existing Wi-Fi network infrastructure was utilized by the vehicles for fingerprinting localization and a feature fusion strategy was designed to realize the dynamic fusion of Wi-Fi and magnetic field fingerprints. Multiple environmental monitoring points were deployed to collect the sound signals made by vehicles to calculate the position based on time difference of arrival and spatial segmentation method. Then the location reported by the vehicle was compared with the result of monitoring points for verification. Once an abnormal position was detected, an alert would be issued, ensuring the normal operation of the unmanned intelligent vehicles. The experimental results in the real indoor scenarios show that the proposed method can effectively track the positions of the target unmanned intelligent vehicle, and the positioning accuracy is better than existing benchmark algorithms.

Keywords: unmanned intelligent vehicles, indoor positioning, Wi-Fi fingerprint, magnetic field fingerprint, acoustic source localization

收稿日期: 2023-10-31; 修回日期: 2024-02-02

通信作者: 顾晓丹, xdgu@seu.edu.cn

基金项目: 国家自然科学基金资助项目(No.62072102, No.62132009, No.62102084)

Foundation Items: The National Natural Science Foundation of China (No.62072102, No.62132009, No.62102084)

0 引言

随着物联网技术的飞速发展,工业设备和各类传感器逐渐被接入工业物联网中,使工业制造各环节中的数据可以被感知、采集、交换和智能分析,从而有助于更快、更准确地进行业务决策。近年来,许多传统工厂开始着手建设智慧工厂,如构建全自动生成流水线、实时监测管理生产全过程等,以大幅提高制造效率,降低成本和减少资源消耗,促进传统工业向智能制造升级转型。其中,无人智能小车在车间配送中极大地提升了运作效率,节省了企业雇佣人工的固定成本,已广泛应用于各类智慧工厂。

为了保证无人智能小车在厂区内能正常执行配送任务,关键是能对其移动的轨迹进行追踪,而室内定位技术能够在室内环境下对目标物体进行位置监控,可以为它提供技术支撑。目前的主流方案是利用射频识别(RFID, radio frequency identification)技术进行高精度定位^[1-4],但需要部署大量的标签作为参考点,造价成本较高。而基于Wi-Fi的定位方案可以利用现有的接入点(AP, access point)作为参考点,不需要部署额外的基础设施,越来越受到研究人员的青睐^[5-9]。此外,还可以利用磁场^[10]、气压^[11]、超宽带^[12]、可见光^[13]、超声波^[14]等异质信号进行定位。然而,由于无人智能小车在网络、硬件、操作系统和软件方面存在众多安全隐患,易受到物理或远程安全攻击。当无人智能小车本身不可信时,上述依靠其对自身进行定位的方案均会失效。因此,需要研究面向无人智能小车的安全定位方法,能对其移动的轨迹进行追踪,保证其正常运转工作。

针对上述问题,本文提出了一种面向无人智能小车的双验证安全定位方法,主要研究工作如下。

1) 针对智慧工厂中无人智能小车易受物理或远程安全攻击导致其偏离运输轨迹、搬运任务失败等问题,提出了一种基于双验证的无人智能小车安全定位方法。以无人智能小车自身定位为主、监测点定位为辅,将无人智能小车上报的位置信息和监测点计算的位置坐标进行对比验证,一旦发现小车位置出现异常就进行异常告警,从而保证无人智能小车的正常运转工作。

2) 对于无人智能小车自身定位,考虑到智慧工厂中某些区域可能存在Wi-Fi信号稀疏甚至缺失的问题,基于接收信号强度(RSS, received signal strength)区分度筛选特征AP,并引入九轴传感器

校准磁场数据形成Wi-Fi指纹和磁场指纹。在此基础上,设计特征融合策略对2种指纹进行动态融合,并利用K近邻(KNN, K-nearest neighbor)算法进行指纹匹配从而获得无人智能小车的具体位置。对于监测点定位,利用双麦克风传感器采集无人智能小车发出的声音信号并计算到达时间差(TDoA, time difference of arrival),然后通过空间分割的方法进行位置预测。

3) 在真实室内场景下,利用扫地机器人搭载开发板模拟无人智能小车进行实验验证,结果表明,本文所提方法可以有效跟踪目标设备的位置坐标,定位精度优于现有基准算法。

1 相关工作

目前,室内定位的应用场景主要分为2类,一类是基于设备的定位(DBL, device-based localization),属于设备进行自我定位;另一类是基于监测点的定位(MBL, monitor-based localization),属于环境对设备的定位。

1.1 基于设备的定位

基于设备的定位是指设备利用自身的计算能力,依靠一个参照系来计算其相对位置。

在DBL场景下,基于RSS的定位方法^[15]主要使用三边定位法,利用3个参考节点AP的Wi-Fi信号强度计算相对距离,再通过几何学的方法计算出交点位置的坐标。然而此类方法受RSS波动的影响,当目标超出Wi-Fi覆盖范围时就会失效,因此目前主要基于指纹^[16-18]来进行定位。其中,RSS指纹定位方法通过在不同位置点记录下各个AP的RSS值形成指纹数据库,然后在线阶段设备通过测得的RSS与指纹数据库进行匹配得到自身的位置坐标信息。Shin等^[19]设计了基于Wi-Fi的指纹定位系统无线电探测和测距(RADAR, radio detection and ranging),通过结合RSS测距定位和指纹定位方法,实现了中值误差为2~3 m的定位精度。

此外,一些研究人员提出利用地磁场信号进行室内定位。地球磁场理论上在较小区域内的数值大小是几乎不变的,但是其容易受金属结构、钢筋混凝土结构、电流和电子设备等干扰,使磁场强度在室内不同位置呈现出较大差异,这就产生了由磁异常指纹形成的独特室内地图。同时,它只依赖室内建筑材料和磁性物体引起的复杂磁畸变^[20],因此

可以用来进行高精度室内定位^[21]。但是,磁场数据受磁场传感器方向的影响,因此需要对磁场数据进行校准后再用于定位。Lee等^[22]利用磁场矢量建立磁场指纹库,并考虑行走过程中方向的变化,根据目标设备移动过程中的磁场数据序列改进的粒子滤波算法进行室内定位。

基于RFID的室内定位技术也发展得较为成熟。Wang等^[3]利用有源RFID标签进行室内定位,通过分析环境中标签获取的信号强度来分析目标设备所处的位置信息。Shirehjini等^[4]提出了一种基于RFID的室内定位系统,利用无源RFID标签和绑定在设备上的RFID阅读器对设备进行定位,定位精度与标签的分布密度有关。

除此之外,还可以利用声波或者超声波对目标设备进行定位。An等^[23]利用声源发出的连续声音信号估计直接路径和反射路径的到达角度进行声源定位。在此基础上,Shen等^[24]提出了一种迭代对齐并消除误差的定位方法来改进室内声音多径的到达角度估计,但此类定位方法需要设备配有高精度的麦克风阵列,成本较高。

1.2 基于监测点的定位

基于监测点的定位是依靠一组监测终端协作计算连接到这些节点的设备的位置。

基于Wi-Fi的定位技术通常需要一个中央控制器来负责监测点之间的通信,进而利用三边定位法对设备进行定位。基于RSS的定位方法目前依然是应用最广泛的方法之一。RSS可以用于估计发射端和接收端设备之间的距离,值越高意味着两者之间的距离越小。如果已知传输功率,则可以使用多种不同的信号传播模型来估计绝对距离。但由于RSS易受障碍物影响,在复杂的环境下定位效果并不理想,因此有研究转向利用更细粒度的信道状态信息(CSI, channel state information)进行定位^[7-9]。与RSS相比,CSI可以提供多路子载波的相位和振幅信息,能更好地描述信号的传播途径,因此CSI的特征维度和空间分辨率更高。目前,基于CSI的几何定位方法主要有基于到达角(AoA, angle of arrival)^[7]、基于飞行时间(ToF, time of flight)^[8]、基于TDoA^[9]等的定位方法。其中,基于TDoA的定位方法是利用接收端测量的不同发射端的信号传播时间差估计不同发射端的距离之差进行定位,不需要发射端和接收

端时间同步,只需要不同发射端之间进行时间同步,其定位精度取决于信号带宽。

不同于上述基于Wi-Fi定位技术的工作,Kotrotsios等^[25]提出了一种基于蓝牙的定位方法,通过在室内分散部署蓝牙接收信标,利用深度学习估算信标与设备之间的距离,然后通过三边定位法进行位置估计,但该方法需要额外部署多个蓝牙接收信标。Krishnan等^[12]提出了一种基于超宽带(UWB, ultra wide band)的机器人MBL系统,通过利用TDoA的方法进行位置估计,均方根误差为0.15 m。然而此类方法需要在环境中部署专门的UWB设备才能进行定位,硬件成本太高。Liu等^[26]利用2个RFID阅读器绕固定轴旋转来扫描房间内的标签,根据2个RFID阅读器的时间差和角度来对标签进行定位,定位精度达到1 m以下。Zhu等^[27]提出了一种基于声源的定位方案,利用手机的双麦克风计算TDoA,将定位问题转化为平面切割问题,然而该方案仅适用于声源设备与手机之间没有障碍物的理想场景。

2 基于双验证的无人智能小车安全定位方法

针对智慧工厂中无人智能小车易受物理或远程安全攻击导致其偏离运输轨迹、搬运任务失败等问题,本文提出了一种基于双验证的无人智能小车安全定位方法,分别在无人智能小车端和监测点对小车进行定位,从而保证智慧工厂环境下无人智能小车的正常运转工作。

2.1 总体流程

本文提出的双验证安全定位方法主要可分为如下3个步骤。

步骤1 无人智能小车端自我定位。针对智慧工厂中某些区域存在无线Wi-Fi信号稀疏甚至缺失的问题,引入磁场信号进行补足,在建立位置指纹库的基础上,通过实时获取的Wi-Fi信号、磁场信号特征信息在参照系中进行比对,以实现无人智能小车具体位置的细粒度感知。

步骤2 监测点环境定位。利用双麦克风传感器采集无人智能小车发出的声音信号并计算TDoA,然后通过空间分割的方法缩小目标小车所处区域范围,进而预测得到对应的位置坐标。

步骤3 异常告警。比较无人智能小车上报的具体位置信息和监测点计算出的位置坐标,一旦超出设定的误差阈值或偏离运输轨迹,则进行异

常告警，从而保证无人智能小车的正常运转工作。

2.2 无人智能小车端自我定位

考虑到智慧工厂中某些区域可能存在无线 Wi-Fi 信号稀疏甚至缺失的问题，本文提出在无人智能小车中嵌入磁力计传感器，结合 Wi-Fi 和磁场信号进行指纹定位，从而提高小车自我定位的精度。如图 1 所示，基于 Wi-Fi 与磁场异质信号的无人智能小车指纹定位方法可分为离线指纹训练和在线指纹匹配 2 个阶段。离线指纹训练阶段，首先根据 Wi-Fi 和磁场信号设计位置指纹 F 并构造指纹库。在此过程中，需筛选特异性高的 AP 并设计动态特征融合策略，以更好地设置不同位置 Wi-Fi 和磁场信号的权重。在线指纹匹配阶段，通过实时获取目标小车周围的 Wi-Fi 与校准后的磁场信号形成指纹 f ，设计匹配算法与指纹库 R 进行比对，进而计算出目标小车的位置标签 l ，实现位置坐标的获取。

2.2.1 数据采集与处理

1) 数据采集

AP 通过 Beacon 帧广播自身信息，来为用户提供无线网络接入服务，可以从中提取对应 AP 的服务集标识 (SSID, service set identifier)、媒体访问控制 (MAC, media access control) 地址、RSS、Timestamp 等信息。对于磁场信号，通过磁场传感器可以获取设备坐标系上 X、Y、Z 轴的三维数据，同时还需要采集陀螺仪和加速度传感器上 X、Y、Z 轴的数据用于校准磁场数据。

2) Wi-Fi 指纹提取

受硬件和环境信号噪声干扰，无线网卡在捕获数据包时，会存在个别数据包的 RSS 数值与常规数

值偏离较远，也就是离群值，因此首先需要对采集到的 RSS 数据进行离群值过滤，通常通过设定阈值的方式进行过滤。但由于对不同设备监听到的 RSS 序列中离群值大小各不相同，而每次监听 RSS 是独立的且没有上下文关联，因此可以采用 3σ 模型来检测，如果数值超过 3 倍标准差就可以视为离群值。

由于室内环境中通常会存在许多 AP，且每个 AP 都有自己唯一的 MAC 地址，因此选用 MAC 地址作为 AP 的唯一标识。由于在同一位置采集到同一个 AP 的 Beacon 帧的 RSS 可能存在小幅波动的情况，本文对每个 AP 的 Beacon 帧的 RSS 进行均值计算，将 RSS 均值作为该位置处这一 MAC 地址维度的指纹特征信息。如果某个 AP 在各参考点的 RSS 十分近似，那么这个 AP 构成指纹的区分度就会较低，可以通过计算各 AP 在该区域内的标准差，将波动较小的 AP 筛选掉，最终留下的 AP 作为特征 AP。此外，在真实的室内工厂环境中，AP 是离散分布的，因此各参考点会存在一些 AP 离该位置较远，导致网卡无法捕获这些 AP 的 Beacon 帧。对于这些 AP，本文用 -100 dB 的数值进行指纹填充。

3) 磁场指纹提取

如图 2 所示，每个设备都有自己的设备坐标系，而磁场传感器可以获取基于设备坐标系上 X、Y、Z 轴的三维数据，该三维数据的标量就是该位置处的磁场强度。随着磁场传感器在空间中的转动，其设备坐标系是不断变化的，因此获取的三维数据是不具备参考价值的，需要结合陀螺仪、加速度传感器将设备坐标系下的三维数据校准到世界坐标系下，使其具备参考价值。

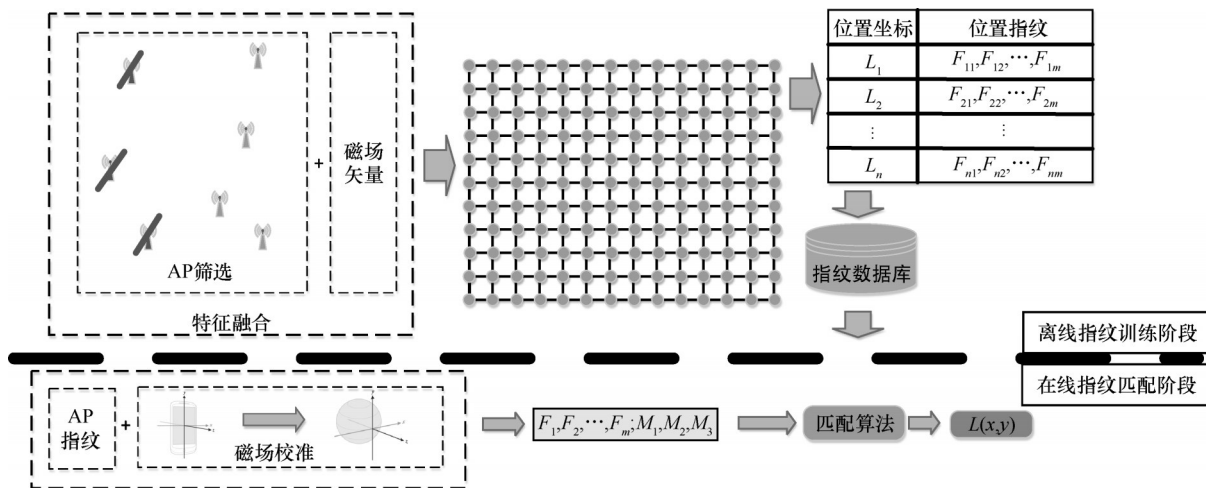


图 1 基于 Wi-Fi 与磁场异质信号的无人智能小车指纹定位方法




图2 设备坐标系和世界坐标系

$$R = \begin{bmatrix} \cos \varphi \cos \psi - \sin \varphi \sin \psi \sin \theta & \sin \varphi \cos \theta & \cos \varphi \sin \psi + \sin \varphi \cos \psi \sin \theta \\ -\sin \varphi \cos \psi - \cos \varphi \sin \psi \sin \theta & \cos \varphi \sin \theta & -\sin \varphi \sin \psi + \cos \varphi \cos \psi \sin \theta \\ -\sin \psi \cos \theta & -\sin \theta & \cos \psi \cos \theta \end{bmatrix} \quad (1)$$

其中, φ 表示磁北的方位角, θ 表示倾斜角, ψ 表示旋转角。根据磁场向量和重力向量可以得到一个平面, 而磁场向量和重力向量叉乘可以得到一个垂直于该平面的向量 W_x , 该向量表示世界坐标系下 X 轴在设备坐标系下的向量。同理可得向量 W_y 和向量 W_z 。因此可以通过式(2)将设备坐标系下的磁场矢量转换为世界坐标系下的磁场矢量。

$$R \times \begin{bmatrix} W_{x_{local}} \\ W_{y_{local}} \\ W_{z_{local}} \end{bmatrix} = \begin{bmatrix} W_{x_{global}} \\ W_{y_{global}} \\ W_{z_{global}} \end{bmatrix} \quad (2)$$

2.2.2 特征融合与指纹匹配

在室内环境中, 地磁场受钢筋、电流产生的磁场影响, 会产生磁变异现象。在这些干扰物周围, 磁场数据相较其他区域会出现明显的波动现象, 区分度更高。因此在融合 Wi-Fi 指纹和磁场指纹时, 可以根据区域不同动态地调整磁场指纹的权重进行特征融合, 从而提高无人智能小车的定位精度。

1) 特征融合

动态特征融合的基本思路是通过磁场强度计算基于邻域的磁变异系数, 再根据磁变异系数在磁场特征不明显时降低磁场特征权重, 在磁场特征明显时提高磁场特征权重。

在离线阶段采集数据时, 根据该区域内所有采集到的磁场强度数据, 利用式(3)计算这片区域磁场的相似系数 CS 和变异系数 CV。

$$CS = 1 - CV$$

$$CV = \frac{\sigma}{\mu} = \frac{\sqrt{\frac{\sum (\text{stre} - \mu)^2}{n - 1}}}{\frac{\sum \text{stre}}{n}} \quad (3)$$

其中, σ 是该区域内磁场强度的标准偏差, μ 是

具体而言, 首先利用加速度传感器、陀螺仪传感器和磁场传感器的数值通过四元素法计算欧拉角, 其中, 陀螺仪传感器原始数据存在漂移误差, 属于一种随机噪声, 需要利用卡尔曼滤波对其进行滤波处理。接着利用欧拉角通过式(1)计算旋转矩阵 R , 再利用旋转矩阵将设备坐标系下的数值转换为世界坐标系下的数值。

该区域内磁场强度的均值, stre 是采样点的磁场强度, n 是采样点个数。如果该区域内磁场数据波动较大, 则 σ 值较大, 进而计算出来的变异系数 CV 也会较大, 说明在该位置处磁场特征更明显。

通过给 CV 设定阈值的方法, 将所有区域分成磁变异明显和磁变异不明显 2 种区域, 再根据相似系数和变异系数来确定各区域 Wi-Fi 和磁场的特征权重, 如式(4)所示。

$$\alpha = \begin{cases} CV, & CV > 0.1 \\ 0, & CV \leq 0.1 \end{cases} \quad (4)$$

$$\beta = \begin{cases} CS & CS < 0.9 \\ 1 & CS \geq 0.9 \end{cases}$$

其中, α 是磁场特征权重, β 是 Wi-Fi 特征权重。

在此基础上, 为了更细粒度地划分磁变异区域, 本文对每个参考点设计基于邻域的磁变异系数。首先, 在对每一个参考点的 Wi-Fi 和磁场数据进行数据采集时, 选取附近其他 k 个点作为该参考点的邻域。接着, 计算该参考点和这 k 个点的均值和标准差, 如式(5)所示。

$$\mu = \frac{\sum_{j=1}^{k+1} m_j}{k}$$

$$\sigma = \sqrt{\frac{\sum_{j=1}^{k+1} (m_j - \mu)^2}{k - 1}} \quad (5)$$

然后, 根据式(3)计算出该参考点处的变异系数 CV_i 和相似系数 CS_i 。最终, 对于指纹地图内的 g 个参考点, 可以得到磁场特征权重集合 $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_g\}$ 和相似系数集合 $\beta = \{\beta_1, \beta_2, \dots, \beta_g\}$ 。

最终得到的指纹库中的指纹序列如表 1 所示, 其中, Location 表示参考点的位置坐标, (α, β) 表示

该位置对应的磁场特征权重和相似系数， MAC_i 表示在该位置测得的第 i 个特征 AP 的 Wi-Fi 指纹， Mag 表示该位置的磁场指纹和各坐标对应分量。

表 1 指纹库中的指纹序列

| 名称 | 值 |
|------------|------------------|
| Location | (x,y) |
| Weight | (α,β) |
| MAC_1 | rss_1 |
| \vdots | \vdots |
| MAC_i | rss_i |
| Mag_{wx} | m_{wx} |
| \vdots | \vdots |
| Mag | mag |

2) 指纹匹配

为了对无人智能小车的实时位置进行感知，需要先在离线环境中采集指纹信息，并设立坐标作为标签值。KNN 回归算法既可以进行分类也可以用于回归，通过一个测试样本寻找数据集中 K 个最相似的训练样本，再根据这 K 个样本的标签值来预测该样本的标签值。由于待测点不一定就正好处于训练样本的参考点位置上，因此本文采用 KNN 回归算法进行指纹匹配。

设训练集 $T = \{(p_1, c_1), (p_2, c_2), \dots, (p_N, c_N)\}$ ，其中， $p_i = (f_{i1}, f_{i2}, \dots, f_{iM}) \in P$ 为实例的特征向量， M 为特征维度； $c_i \in C = \{c_1, c_2, \dots, c_N\}$ 为实例的类别，共有 N 个类别。待测点 p 的特征向量表示为 $p = (f_i, f_{i+1}, \dots, f_N)$ ，通过式(6)计算待测点 p 到训练集中各对象的距离度量。

$$\text{dist}(p, p_i) = \sum_{j=1}^M |f_j - f_{ij}| \quad (6)$$

根据计算好的距离度量，在训练集 T 中找到与 p 最邻近的 k 个点，将包含这 k 个点的类别 c 的集合记作 $N_k(p) = \{c_1, c_2, \dots, c_k\}$ 。然后，由 $N_k(p)$ 中 k 个邻居的均值计算出 p 所属的预测值 c 。

$$c = \arg \sum_{p_i \in N_k(p)} c_i \quad (7)$$

其中， $i=1,2,\dots,N, j=1,2,\dots,K$ 。

在 KNN 回归算法中，当训练样本不平衡时，即一个类别的训练样本容量很大，而其他类别的训练样本容量很小时，有可能导致在输入一个新样本时，该样本的 k 个邻居中大容量类的样本占多数，

从而使结果出现误判。因此本文通过在室内环境下较为均匀地划分参考点来避免出现大容量类别，即避免出现某一个区域内的训练样本数量很多，而相邻另一片区域内的训练样本数量很少。

从式(6)可以看出，经典的 KNN 回归算法的每一个维度的特征权重都是一样的，将每一个维度计算到的距离直接相加求和作为待测点 p 与训练集里 p_i 的距离度量。而本文所构建的指纹特征包含 Wi-Fi 和磁场 2 个类别，Wi-Fi 指纹向量为 $\{MAC_1, MAC_2, \dots, MAC_i\}$ ，磁场指纹向量为 $\{Mag_{w_x}, Mag_{w_y}, Mag_{w_z}, Mag\}$ ，利用式(8)可以通过当前无人智能小车采集到的磁场数据、Wi-Fi 数据分别计算与指纹库中各数据对象的距离度量。然后，利用式(4)计算出的磁场特征权重 α 和 Wi-Fi 特征权重 β ，通过式(9)计算总的距离度量。

$$d(p_{mag}, p_{mag_i}) = \sqrt{(p_{mag} - p_{mag_i})^T (p_{mag} - p_{mag_i})}$$

$$d(p_{wifi}, p_{wifi_i}) = \sqrt{(p_{wifi} - p_{wifi_i})^T (p_{wifi} - p_{wifi_i})} \quad (8)$$

$$S_i = \alpha d(p_{mag}, p_{mag_i}) + \beta d(p_{wifi}, p_{wifi_i}) \quad (9)$$

其中， p_{mag} 是磁场特征， p_{wifi} 是 Wi-Fi 特征。

然后，对于计算后的特征集合 S ，从中选取 K 个距离度量最小的对象的坐标 $\{(x_1, y_1), (x_2, y_2), \dots, (x_k, y_k)\}$ ，再通过式(10)对这 K 个对象的坐标加权求和，得到预测位置坐标 $l = (x_{pred}, y_{pred})$ 。

$$x_{pred} = \frac{\sum_{i=1}^K w_i x_i}{\sum_{i=1}^K w_i}$$

$$y_{pred} = \frac{\sum_{i=1}^K w_i y_i}{\sum_{i=1}^K w_i} \quad (10)$$

其中， w_i 为式(9)中距离度量 S_i 的倒数。

最后，根据上述算法计算出位置坐标 l ，即可与工厂室内环境映射，得到无人智能小车所处的具体位置。

2.3 监测点环境定位

考虑到智慧工厂环境下，无人智能小车可能受物理或远程安全攻击使得其上报的位置偏离运输轨迹或上报虚假位置信息，本文提出利用小车发出的声音信号对其进行定位校验。具体而言，在工厂多个位置中部署双麦克风传感器采集音频信息和方位

信息,构成二元组 (L,Sou) ,其中, $L=(x,y,o)$ 表示方位信息, (x,y) 表示坐标, o 表示双麦克风传感器朝向, Sou 表示音频信息。由于原始音频 Sou 中存在噪声,需要从中提取出有效声音 T ,进而判断出声源距离2个麦克风的远近。然后结合 L 设计空间分割算法计算出声源所处的具体位置坐标。

由于工厂室内环境中声源与双麦克风传感器之间很可能存在障碍物,因此使用TDoA对声源进行测距定位是不切实际的。本文使用非测距的方式,根据声音到达2个麦克风的先后顺序判断声源位于传感器的哪一侧从而划分空间区域,再由多个位置测量的数据缩小目标子空间进而计算得到声源定位位置坐标,如图3所示。

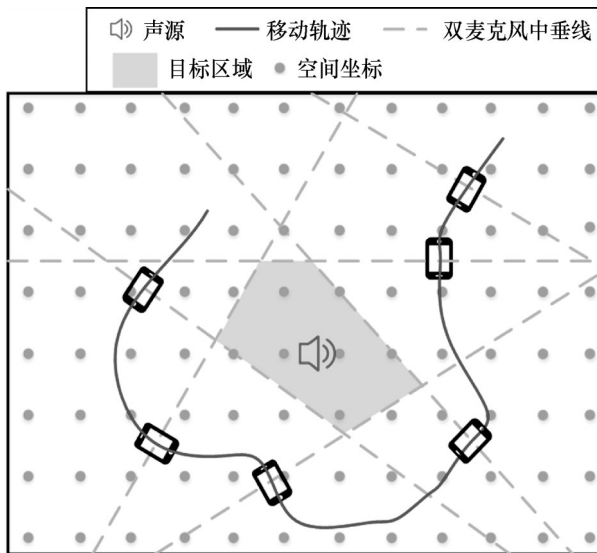


图3 声源定位位置坐标

通过双麦克风传感器采集声音信号 Sou ,然后进行数据预处理,提取有效声音 T ,分别得到2个麦克风上的数据。由于2个麦克风是时钟同步的,且型号相同,因此采集到的信号应该是波形相似但存在时间偏移的,本文采用GCC-Path算法对这2个麦克风的数据进行时间延迟估计。首先让其中一个麦克风的音频数据保持不动,另一个麦克风的音频数据以一个采样样本为单位向左或向右移动,当移动到某个位置时2个声音信号相似度最高,则将移动的样本所对应的时间作为2个信号的时延,本文使用样本数差值表示TDoA。计算出的TDoA有正负数之分,正数表示声音先到达第一个麦克风,负数表示声音先到达第二个麦克风。根据TDoA的正负符号可以判断声源更靠近哪个麦克风,如果TDoA

为0,则说明声源正好处于2个麦克风中垂线上。

为了对无人智能小车进行精确定位,需要在其移动的轨迹上设定多个监测点,并部署双麦克风传感器采集小车发出的声音信号。在经过多个位置的测量后,可以根据每一个位置处双麦克风中垂线将空间分割为多个子空间,再将整片空间以等间距划分多个坐标点,将这些坐标点代入计算,找到处于目标子空间里的坐标点,然后对这些坐标点进行均值计算得到声源位置坐标。

2.3.1 数据采集与有效声音提取

1) 数据采集

本文利用具有双麦克风的智能手机模拟双麦克风传感器采集声音信号。通过观察发现,由于2个麦克风的时钟是完全同步的,因此2个麦克风上的信号在波形上是相似的,但声音到达2个麦克风有一定时间差,因此可以通过具体的时间差值或者样本数差值来表示TDoA。本文使用双声道采集音频数据,采样频率为44 100 Hz,采集到的数据是2个麦克风合在一起的音频数据,其中奇数位和偶数位分别为不同麦克风的数据。本文使用相同的手机在空间中的不同监测点采集数据,每次采集数据时声源发出的声音都是相同的。除了采集声音数据 Sou ,还会记录每个位置点方位信息 L ,由坐标 (x,y) 和手机朝向 o (通过方向传感器计算可得)组成。

2) 有效声音提取

从麦克风上获取的声音信号 Sou 包含声源的真实声音、环境噪声以及无人智能小车自身运动产生的噪声。通过分析原始数据可以发现,声源的真实声音往往分布在低频部分,而噪声分布在高频部分,因此可采用低通滤波器对噪声进行过滤。从图4中可以明显看出,有效声音 T 应该是1.4~2.1 s的声音信号,其余部分属于环境噪声,若将这些噪声用于后续TDoA的计算中会对结果产生较大的干扰,因此需要将有效声音 T 从整段音频 Sou 中提取出来。此外,有效声音部分振幅是陡增上去的,因此可以通过方差进行量化。首先,将整段音频数据以每段400个采样样本分成 u 段,计算每段数据的方差;接着以这 u 段方差的均值作为阈值,从整体数据的两端开始,以大小为400的滑动窗口每次滑动10个样本向中间遍历,计算窗口内的方差。如果该方差大于阈值,则认为找到了有效声音的开始

或结束的时刻,进而提取有效声音 T 的音频。提取出有效声音后再根据奇偶位将 2 个麦克风的数据分离出来,用于后续 TDoA 的计算。




图4 有效声音片段

2.3.2 基于 TDoA 的无人智能小车定位

当有效声音 T 提取完成后,本文利用 TDoA 方法对无人智能小车进行定位。但由于有效声音部分的采样样本可能较大,若将整段有效声音进行计算,得出的结果不一定准确。因此本文将采样样本分成 ν 段,每段 1 500 个样本,将 2 个麦克风的同一段样本进行 TDoA 计算,得到 ν 个 TDoA 结果。根据双麦克风之间的距离和采样频率可以计算声音到达 2 个麦克风的样本数差值,从而可以得出以采样样本数量表示的 TDoA 取值范围。

如果在 ν 个 TDoA 结果里出现一个或者多个不在该范围内的情况,则认定该位置采集的声音数据无效,后续计算中不再使用该数据;如果 ν 个结果都在该范围内,则比较这 ν 个 TDoA 的正负数个数,如果正数多则说明声源离底部的麦克风更近,反之则声源离顶部的麦克风更近,如果正负数一样多则舍弃该数据。最后结合监测点方位信息 $L=(x,y,o)$ 得出四元组 (x,y,o,f) ,其中, f 表示声源处于双麦克风传感器的哪一个半区方向, 1 表示下半区即离底部麦克风更近, -1 表示上半区即离顶部麦克风更近。

通过在多个监测点测量的四元组 (x,y,o,f) ,可以计算声源所处的子空间进而推测声源的位置坐标。由于位置坐标系的 Y 轴正方向为地理正北方向,而由手机方向传感器获取的手机朝向数据范围为 $0^\circ \sim 360^\circ$,表示离正北方向顺时针旋转的角度。因此双麦克风的直线在该坐标系下的斜率 k 、中垂线 $y=$

$k_{\text{ver}}x+b$ 的斜率 k_{ver} 和常数 b 分别为

$$k = \tan(90 - o) \frac{\pi}{180} \quad (11)$$

$$k_{\text{ver}} = -\frac{1}{k} \quad (12)$$

$$b = y - k_{\text{ver}}x \quad (13)$$

根据手机朝向 o 和 f 计算声源处于中垂线的哪一侧,如式(14)所示。

$$\text{flag} = \begin{cases} 1, & ((0 < o < 90 | 270 < o < 360) \& \\ & f = -1) | 90 \leq o \leq 270 \& f = 1 \\ -1, & ((0 < o < 90 | 270 < o < 360) \& \\ & f = 1) | 90 \leq o \leq 270 \& f = -1 \end{cases} \quad (14)$$

其中, 1 表示在中垂线的下侧, -1 表示在中垂线的上侧。

对于 m 个测量点可以得到 m 个三元组 $(k_{\text{ver}}, c, \text{flag})$,接着将整片空间以等间距划分为多个坐标点 (x_i, y_i) ,将这些坐标点代入 m 个三元组计算,符合的条件如下。

$$y_i < k_{\text{ver}}x_i + b, \text{flag} = 1$$

$$y_i > k_{\text{ver}}x_i + b, \text{flag} = -1$$

找到满足以上 m 个三元组条件的所有坐标点,然后对这些坐标点均值计算得到声源位置坐标。

$$\begin{aligned} x_{\text{pred}} &= \frac{\sum x_i}{n} \\ y_{\text{pred}} &= \frac{\sum y_i}{n} \end{aligned} \quad (15)$$

最后,将预测的坐标与工厂内环境映射,得到无人智能小车所处的具体位置。

2.4 异常告警

服务器端通过多个监测点采集的数据计算出无人智能小车的具体位置坐标,并和当前小车上报的位置信息进行比对,若两者差值在预先设定的阈值范围内,则认为小车正常工作;一旦超过阈值,就进行异常告警,如式(16)所示。

$$\text{Ed}(L_a, L_b) \leq \zeta \text{Errorav}(L_a) + \gamma \text{Errorav}(L_b) \quad (16)$$

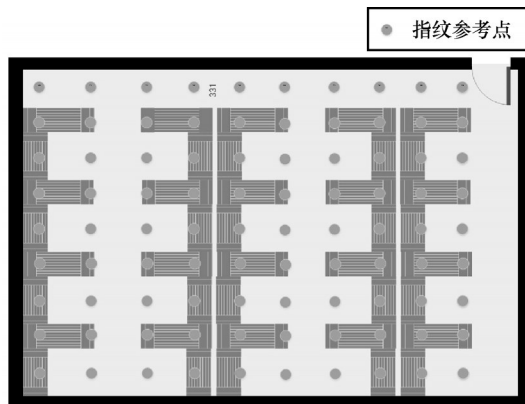
其中, L_a 和 L_b 分别表示无人智能小车上报的位置和监测点计算出来的位置, $\text{Ed}(L_a, L_b)$ 表示两者之间的欧氏距离, $\text{Errorav}(L_a)$ 和 $\text{Errorav}(L_b)$ 分别表示无人智能小车自我定位和监测点定位的平均定位误差, ζ 和 γ 为对应的权重系数。考虑不同的工厂环境下,物理结构、Wi-Fi 和磁场信号分布、无人智能小车的运转任务、速度等都各不相同,因此对于参数的设定,需要在实际应用场景中经过多次实验确定。

3 实验验证

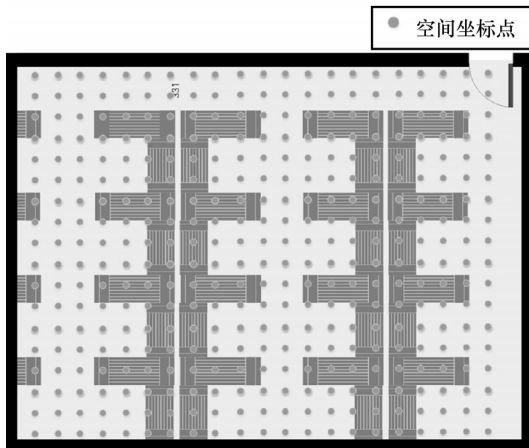
3.1 实验设置

为了验证上述算法的性能, 本文在室内场景(面积为12 m×8 m)下, 利用iRobot Rommba961080扫地机器人搭载开发板模拟无人智能小车进行定位实验验证, 如图5所示。

在基于Wi-Fi和磁场的无人智能小车自身定位实验场景中, 如图5(a)所示, 本文在室内划分了108个指纹参考点, 平均间隔为0.9 m, 并使用iRobot扫地机器人搭载可编程的ESP8266开发板进行模拟实验。其中, ESP8266开发板搭配一个MPU9250九轴传感器, 包含加速度传感器、磁场传感器和陀螺仪传感器。通过ESP8266开发板上的无线网卡采集Beacon帧信息, 同时采集MPU9250上的数据, 在局域网内通过socket将原始数据发送给服务器端。服务器端为一台安装Ubuntu18.04.6的个人计算机, Python版本为3.8.3。除此之外, 室内环境中还存在许多未知位置的AP, 本文选取其中9个作为特征AP。



(a) 基于Wi-Fi和磁场的无人智能小车自身定位实验场景



(b) 基于双麦克风的监测点环境定位实验场景

图5 无人智能小车定位实验场景

在基于双麦克风的监测点环境定位实验场景中, 如图5(b)所示, 在室内以0.5 m为间隔均匀地划分室内坐标点, 并使用Redmi K30 Pro双麦克风手机采集声音信息, 其中2个麦克风分别位于底部和顶部, 相距15.5 cm。

3.2 数据采集

本文利用ESP8266开发板自带的无线网卡捕获Beacon帧信息, 采样频率是5 Hz, 并记录解析得到AP的MAC地址和RSS数值。在采集Beacon帧信息的同时, ESP8266获取MPU9250的九轴数据, 计算出方位角、俯仰角和旋转角整合形成异质信号指纹。本文在每个参考点收集600个样本, 每个样本包含多个AP信息和磁场信息。经过特征AP筛选后, 选取9个特异性较高的AP作为Wi-Fi指纹维度, 磁场指纹维度为4。最终, 共获得64 800个训练样本, 训练出108个指纹参考点, 每个指纹的维度为13, 形成异质信号指纹库。

对于声音数据, 本文编写程序采集声音信号、手机朝向信息并记录采样时间戳, 采样率为44 100 Hz, 音频格式为wav文件, 音频位宽为16位。此外, 本文使用iRobot App的“定位Roomba”功能控制扫地机器人发出固定的声音, 一共选取20个测试点, 对于每个测试点, 通过手机在随机8个监测点采集数据, 每个监测点采集10~20 s的声音数据, 共160组数据。为了使场景更符合实际情况, 这些数据大部分情况下是在扫地机器人与手机之间存在障碍物的情况下采集的。

3.3 评价指标

为了评估无人智能小车的定位精度, 本文使用平均定位误差、最大定位误差、最小定位误差以及定位误差累积概率分布来对实验结果进行评估。

平均定位误差为

$$\frac{1}{n} \sqrt{(x_i^{\text{pred}} - x_i)^2 + (y_i^{\text{pred}} - y_i)^2} \quad (17)$$

其中, $(x_i^{\text{pred}}, y_i^{\text{pred}})$ 代表匹配算法计算出的估计位置, n 表示测试样本数量, (x_i, y_i) 表示实际位置。

最大定位误差为

$$\max \sqrt{(x_i^{\text{pred}} - x_i)^2 + (y_i^{\text{pred}} - y_i)^2} \quad (18)$$

最小定位误差为

$$\min \sqrt{(x_i^{\text{pred}} - x_i)^2 + (y_i^{\text{pred}} - y_i)^2} \quad (19)$$

定位误差累积概率分布为

$$F(x) = \int_{t=0}^{t=x} f(t) dt \quad (20)$$

其中, $f(t)$ 代表定位误差的概率密度函数。

3.4 实验结果

1) 无人智能小车端定位实验结果分析

本文首先对磁矢量校准算法进行实验分析。通过手持 ESP8266 开发板在空旷走廊的中间沿直线行走, 获取九轴传感器的原始数据, 再对磁场数据进行校准, 磁矢量三维坐标轴上校准实验结果如图 6 所示。

根据实际环境进行分析, 该实验的磁场数据是在一条空旷的走廊上采集的, 由于周围没有能够造成磁变异的物体, 磁场数据应该是较为稳定的。但从图 6 中可以明显看出, 磁场传感器原始的三维磁矢量在移动过程中随着设备坐标系的不断变化, 其数据变化幅度较大, 经过校准到世界坐标系下后, 三维磁矢量数据变得较为平稳, 与实际相符, 具备了参考价值。

考虑到在 KNN 回归算法中, K 的取值对实验结果的影响很大, 本文通过交叉验证法, 选取 20 个训练样本作为测试样本, 根据动态特征融合指纹比较不同 K 的取值情况下的平均定位误差的大小来确定 K 的取值, 实验结果如图 7 所示。当 K 取 6 时, 平均定位误差最小, 为 1.38 m, 并且随着 K 值的增大, 平均定位误差趋于平稳。对于后续的实验, 本文将 K 的取值都设置为 6。





图 7 不同 K 的取值情况下的平均定位误差


考虑到动态遮挡可能会对定位精度造成影响, 本文分别在有人员走动和无人员走动场景下进行了对比实验, 使用 Wi-Fi 和磁场动态特征融合指纹, 定位误差如表 2 所示。从表 2 中可以看出, 在无人员走动的场景下, 平均定位误差为 1.26 m, 与有人员走动相比降低了 8.70%, 最小定位误差降低了 41.67%, 说明人员等动态遮挡会影响定位精度, 与预期相符。这是因为采集到的各 AP 的 RSS 数值受人员走动的干扰, 容易产生较大波动, 指纹不够准确。为了使实验结果更符合实际场景, 本文后续的实验数据都是在有人员走动场景下进行采集的。

表 2 有人员走动和无人员走动场景下的定位误差


| 场景 | 平均定位误差/m | 最大定位误差/m | 最小定位误差/m |
|-------|----------|----------|----------|
| 有人员走动 | 1.38 | 2.03 | 0.36 |
| 无人员走动 | 1.26 | 2.01 | 0.21 |




(a) 磁矢量 X 坐标轴上校准前后的磁场强度



(b) 磁矢量 Y 坐标轴上校准前后的磁场强度



(c) 磁矢量 Z 轴上校准前后的磁场强度



(d) 磁矢量三维坐标轴上校准前后的标准差

图 6 磁矢量三维坐标轴上校准实验结果

本文评估了使用不同指纹进行定位的实验结果,其中, Wi-Fi 指纹维度为 9, 磁场指纹维度为 4。通过 40 组测试样本, 分别计算使用 Wi-Fi 指纹 (类型 I)、磁场指纹 (类型 II)、Wi-Fi 和磁场指纹 (类型 III)、Wi-Fi 和磁场动态特征融合指纹 (类型 IV) 的平均定位误差、最大定位误差和最小定位误差, 如表 3 所示, 定位误差的累积概率分布如图 8 所示。

表 3 4 种指纹类型下的定位误差

| 指纹类型 | 平均定位误差/m | 最大定位误差/m | 最小定位误差/m |
|--------|----------|----------|----------|
| 类型 I | 1.63 | 2.52 | 0.62 |
| 类型 II | 1.84 | 3.17 | 0.41 |
| 类型 III | 1.53 | 2.23 | 0.49 |
| 类型 IV | 1.38 | 2.03 | 0.36 |




图 8 4 种指纹类型下的定位误差的累积概率分布

从表 3 中可以看出, 若只用磁场进行定位, 平均误差为 1.84 m, 这是因为磁场指纹的维度只有 4, 误差较大, 最小定位误差为 0.41 m, 说明部分监测点附近存在磁变异现象明显的情况; 若只用 Wi-Fi 指纹进行定位, 则平均误差为 1.63 m, 这是由于 AP 的 RSS 数值是波动的, 很容易被行人、障碍物干扰, 定位误差较大; 当 Wi-Fi 与磁场的指纹直接融合使用时, 平均定位误差较 Wi-Fi 指纹降低了 0.1 m, 较磁场指纹降低了 0.31 m, 说明 2 种异质信号融合后能够提高指纹的特异性。

KNN 回归算法的复杂度主要与指纹库的指纹样本数量和指纹维度有关。考虑在更大场景下设置更多的参考点, 则指纹样本数量和每个指纹维度都会随之线性增长, 从而导致 KNN 回归算法执行时间大大增加, 可能无法满足无人智能小车的实时性要求。为了验证算法的可扩展性, 本文将实验场景面积进行成倍扩大 (指纹数量和指纹维度也按照相应倍数增大), 在配置 Intel(R) Core(TM) i7-9700 3.00 GHz

CPU 的个人计算机上运行 KNN 回归算法, 对应的执行效率如图 9 所示。其中, 横坐标表示指纹数量和指纹维度扩大倍数, 若指纹数量扩大 10 倍, 则指纹维度扩大 10 倍 (Wi-Fi 指纹维度扩大 10 倍, 但磁场指纹维度不变); 纵坐标表示平均执行时间。从图 9 中可以看出, 本文使用的 KNN 回归算法的时延可以满足无人智能小车实时性的要求。




图 9 KNN 回归算法执行效率

此外, 本文也将 KNN 和其他经典机器学习算法进行了对比, 定位误差如表 4 所示。从表 4 可以看出, KNN 回归算法在定位误差方面也优于传统的机器学习算法。

表 4 不同机器学习算法下的定位误差

| 算法 | 平均定位误差/m | 最大定位误差/m | 最小定位误差/m |
|--------|----------|----------|----------|
| SVM | 1.68 | 3.17 | 0.74 |
| 随机森林 | 1.87 | 3.32 | 0.51 |
| 朴素贝叶斯 | 1.72 | 2.68 | 0.53 |
| KNN 回归 | 1.53 | 2.23 | 0.49 |

2) 监测点定位实验结果分析

由于 k 个监测点处的双麦克风垂线最多将整片空间划分为 $\frac{k^2 + k + 2}{2}$ 个子区域, 因此随着监测点的增加, 各子区域的范围不断变小, 声源设备所处的子区域也在缩小, 定位误差也会随之变小。但监测点过多也意味着部署成本和计算成本的提高。本文还评估了监测点个数对定位误差的影响, 分别选取 4 个、6 个和 8 个监测点进行实验分析, 定位误差如表 5 所示。从表 5 中可以看出, 随着监测点个数的增多, 定位误差呈下降趋势, 8 个监测点的平均定位误差较 4 个采集点降低了 15.49%, 达到 1.91 m, 但相较于 6 个监测点, 下降速度变缓, 考虑到成本

问题, 本文采用 8 个监测点实现环境对无人智能小车的定位。

表 5 监测点个数对定位误差的影响

| 监测点个数/个 | 平均定位误差/m | 最大定位误差/m | 最小定位误差/m |
|---------|----------|----------|----------|
| 4 | 2.26 | 3.12 | 1.76 |
| 6 | 2.03 | 2.83 | 1.47 |
| 8 | 1.91 | 2.59 | 1.46 |

此外, 当采用 8 个监测点时, 本文以概率切割方法 (PCM, probabilistic cutting method) [27] 作为基准算法进行重现对比, 平均定位误差达到 2.5 m。这是因为 PCM 假设声源与声音采集设备之间不存在障碍物, 与真实场景不相符。因此, 本文方法更适合在真实的智慧工厂环境中使用。

4 结束语

本文针对无人智能小车易受到物理或远程安全攻击, 使其偏离配送轨迹导致任务失败, 甚至可能被攻击者操控干扰正常生产活动的问题, 提出了一种面向无人智能小车的双验证安全定位方法, 分别在无人智能小车端和监测点对其进行定位, 并将两者进行对比实验验证, 一旦发现小车位置出现异常就进行异常告警, 从而保证无人智能小车的正常运转工作。在真实室内场景下, 利用扫地机器人搭载开发板模拟无人智能小车进行实验验证, 实验结果表明, 本文所提方法可以有效跟踪目标设备的位置坐标, 定位精度优于现有基准算法。

参考文献:

- [1] HAYWARD S J, VAN LOPIK K, HINDE C, et al. A survey of indoor location technologies, techniques and applications in industry[J]. *Internet of Things*, 2022, 20: 100608.
- [2] HUYNH S M, PARRY D, FONG A C M, et al. Novel RFID and ontology based home localization system for misplaced objects[J]. *IEEE Transactions on Consumer Electronics*, 2014, 60(3): 402-410.
- [3] WANG C S, HUANG C H, CHEN Y S, et al. An implementation of positioning system in indoor environment based on active RFID[C]//*Proceedings of the 2009 Joint Conferences on Pervasive Computing (JCPC)*. Piscataway: IEEE Press, 2009: 71-76.
- [4] SHIREHJINI A A N, YASSINE A, SHIRMOHAMMADI S. An RFID-based position and orientation measurement system for mobile objects in intelligent environments[J]. *IEEE Transactions on Instrumentation and Measurement*, 2012, 61(6): 1664-1675.
- [5] LIU H, DARABI H, BANERJEE P, et al. Survey of wireless indoor positioning techniques and systems[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 2007, 37(6): 1067-1080.
- [6] XIE Y X, XIONG J, LI M, et al. mD-track: leveraging multi-dimensionality for passive indoor Wi-Fi tracking[C]//*Proceedings of the MobiCom' 19: The 25th Annual International Conference on Mobile Computing and Networking*. New York: ACM Press, 2019: 1-16.
- [7] XIONG J, JAMIESON K. ArrayTrack: a fine-grained indoor location system[C]//*10th USENIX Symposium on Networked Systems Design and Implementation (NSDI 13)*. Berkeley: USENIX Association, 2011: 71-84.
- [8] DARGIE W, POELLABAUER C. *Fundamentals of wireless sensor networks: theory and practice*[M]. New York: John Wiley & Sons, 2010.
- [9] LI S H, HEDLEY M, BENGSTON K, et al. TDOA-based passive localization of standard WiFi devices[C]//*Proceedings of the 2018 Ubiquitous Positioning, Indoor Navigation and Location-Based Services (UPINLBS)*. Piscataway: IEEE Press, 2018: 1-5.
- [10] HUANG X D, GUO S T, WU Y, et al. A fine-grained indoor fingerprinting localization based on magnetic field strength and channel state information[J]. *Pervasive and Mobile Computing*, 2017, 41: 150-165.
- [11] SHEN X F, CHEN Y S, ZHANG J H, et al. BarFi: barometer-aided Wi-Fi floor localization using crowdsourcing[C]//*Proceedings of the 2015 IEEE 12th International Conference on Mobile Ad Hoc and Sensor Systems*. Piscataway: IEEE Press, 2015: 416-424.
- [12] KRISHNAN S, SHARMA P, ZHANG G P, et al. A UWB based localization system for indoor robot navigation[C]//*Proceedings of the 2007 IEEE International Conference on Ultra-Wideband*. Piscataway: IEEE Press, 2007: 77-82.
- [13] DE-LA-LLANA-CALVO Á, LÁZARO-GALILEA J L, GARDELVICENTE A, et al. Indoor positioning system based on LED lighting and PSD sensor[C]//*Proceedings of the 2019 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*. Piscataway: IEEE Press, 2019: 1-8.
- [14] LIN Q Z, AN Z L, YANG L. Rebooting ultrasonic positioning systems for ultrasound-incapable smart devices[C]//*Proceedings of the MobiCom' 19: The 25th Annual International Conference on Mobile Computing and Networking*. New York: ACM Press, 2019: 1-16.
- [15] XUE W X, QIU W N, HUA X H, et al. Improved Wi-Fi RSSI measurement for indoor localization[J]. *IEEE Sensors Journal*, 2017, 17(7): 2224-2230.
- [16] WUB, MAZ X, POSLAD S, et al. WiFi fingerprint based, indoor, location-driven activities of daily living recognition[C]//*Proceedings of the 2018 5th International Conference on Behavioral, Economic, and Socio-Cultural Computing (BESC)*. Piscataway: IEEE Press, 2018: 148-151.
- [17] HOANG M T, YUEN B, DONG X D, et al. Recurrent neural networks for accurate RSSI indoor localization[J]. *IEEE Internet of Things Journal*, 2019, 6(6): 10639-10651.
- [18] LIU W, CHENG Q Q, DENG Z L, et al. Survey on CSI-based indoor positioning systems and recent advances[C]//*Proceedings of the 2019*

International Conference on Indoor Positioning and Indoor Navigation (IPIN). Piscataway: IEEE Press, 2019: 1-8.

- [19] SHIN B, LEE J H, LEE T, et al. Enhanced weighted K-nearest neighbor algorithm for indoor Wi-Fi positioning systems[C]//Proceedings of the 2012 8th International Conference on Computing Technology and Information Management (NCM and ICNIT). Piscataway: IEEE Press, 2012: 574-577.
- [20] GUO X M, SHAO W H, ZHAO F, et al. WiMag: multimode fusion localization system based on magnetic/WiFi/PDR[C]//Proceedings of the 2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN). Piscataway: IEEE Press, 2016: 1-8.
- [21] MORENO M V, SKARMETA A F. An indoor localization system based on 3D magnetic fingerprints for smart buildings[C]//Proceedings of the 2015 IEEE RIVF International Conference on Computing & Communication Technologies - Research, Innovation, and Vision for Future (RIVF). Piscataway: IEEE Press, 2015: 186-191.
- [22] LEE S, CHAE S, HAN D. ILoA: indoor localization using augmented vector of geomagnetic field[J]. IEEE Access, 2020, 8: 184242-184255.
- [23] ANI, SON M, MANOCHAD, et al. Reflection-aware sound source localization[C]//Proceedings of the 2018 IEEE International Conference on Robotics and Automation(ICRA). Piscataway: IEEE Press, 2018: 66-73.
- [24] SHEN S, CHEN D G, WEI Y L, et al. Voice localization using nearby wall reflections[C]//Proceedings of the 26th Annual International Conference on Mobile Computing and Networking. New York: ACM Press, 2020: 1-14.
- [25] KOTROTSIOS K, ORPHANOUDAKIS T. Accurate gridless indoor localization based on multiple bluetooth beacons and machine learning[C]//Proceedings of the 2021 7th International Conference on Automation, Robotics and Applications (ICARA). Piscataway: IEEE Press, 2021: 190-194.
- [26] LIU Y H, QIU Y. An indoor localization of UHF RFID using a hybrid approach[C]//Proceedings of the 2012 2nd International Conference on Consumer Electronics, Communications and Networks (CECNet). Piscataway: IEEE Press, 2012: 1653-1656.
- [27] ZHU S F, JIN N G, ZHENG X S, et al. A probability-based acoustic source localization scheme using dual-microphone smartphones[C]//Proceedings of the 2015 IEEE International Conference on Communications (ICC). Piscataway: IEEE Press, 2015: 6621-6626.

[作者简介]



顾晓丹(1987-),女,江苏常州人,博士,东南大学讲师,主要研究方向为移动互联网、网络安全、匿名通信等。



夏国正(1996-),男,江苏南通人,东南大学硕士生,主要研究方向为物联网、无线网络、网络安全等。



宋炳辰(1999-),男,黑龙江肇东人,东南大学博士生,主要研究方向为物联网、网络安全等。



杨明(1979-),男,江苏常州人,东南大学教授、博士生导师,主要研究方向为网络安全与隐私保护、物联网等。



罗军舟(1960-),男,浙江宁波人,东南大学教授、博士生导师,主要研究方向为未来网络体系结构、协议工程、网络安全、无线网络、云计算与大数据等。