

DOI: 10.19650/j.cnki.cjsi.J1905087

# 基于 WiFi 交错信号与深度神经网络的 室内人群数量检测方法\*

陈丹, 阴存翊, 江灏, 邱晓杰, 陈静

(福州大学电气工程与自动化学院 福州 350100)

**摘要:**针对现有室内人群数量检测方法存在适用场景范围受限、检测精度低等问题,提出一种基于深度神经网络的人群数量检测方法,无需被检测人员携带设备便可实现区域内人群数量检测。该方法采用多个 WiFi 传感节点覆盖室内区域,节点间通过相互探测信号获得交错 WiFi 链路数据;运用深度神经网络进行特征学习,提取人数变化对 WiFi 信号影响的关联特征,训练得到该区域人群数量感知模型;将实时采集的 WiFi 信号送入该模型即可获得人群数量的估计。采用所提方法在一个较为复杂的室内环境进行了实验测试,结果表明该方法能够准确实现室内人数检测,检测精度达到 82.23%,平均误差仅为 0.37 人;与其他机器学习算法相比,该模型具备更高的检测精度,适用于多种应用场景。

**关键词:**无线网络;人数统计;无需携带设备;深度学习

**中图分类号:** TN98 TH89 **文献标识码:** A **国家标准学科分类代码:** 510.99

## Indoor crowd counting method based on WiFi crossover signals and deep neural network

Chen Dan, Yin Cunyi, Jiang Hao, Qiu Xiaojie, Chen Jing

(School of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350100, China)

**Abstract:** The existing indoor crowd counting methods face the problems limited scenarios, and low detection accuracy, etc. A crowd counting method based on deep neural networks without carrying equipment is proposed in this study. Multiple wireless fidelity (WiFi) sensor nodes are employed to cover indoor areas. The crossover WiFi link data are obtained by detecting signals among sensor nodes. Deep neural network is utilized to learn and extract the features of the effect of the change of the indoor crowd number on WiFi signals. The crowd counting model is trained for the indoor area, and it can be used to estimate the number of crowd by inputting real-time WiFi signals into the model. Evaluation experiments are implemented in a complex indoor office environment. Results show that the proposed method can realize accurate crowd counting with an accuracy of 82.23% and the mean error of 0.37 people. Compared with other machine learning methods, the deep neural network perception model has higher detection accuracy and can be applied to various application scenarios.

**Keywords:** wireless fidelity; occupancy counting; device free; deep learning

## 0 引 言

近年来,城市建筑智能化趋势不断增强,根据室内的人员信息对建筑控制系统实施更有效的控制和管理战略,

将助力城市建筑地智能化发展。其中,如何获取室内人员的数量信息成为了制约建筑智能化发展的关键问题<sup>[1]</sup>。

现有的人员计数方法主要可以分为两类:基于图像<sup>[2-4]</sup>的方法和基于无线信号<sup>[5-9]</sup>的方法。其中,基于图像的方法主要使用摄像机来监测人员的运动。

收稿日期:2019-05-02 Received Date:2019-05-02

\* 基金项目:国家自然科学基金青年科学基金(61703105,61703106)、福建省自然科学基金面上项目(2017J01500)、福建省教育厅青年科研项目(JAT170107)、福建省高校青年自然科学基金重点项目(JZ160415)、福州大学引进人才科研启动项目(XRC-1623,XRC-17011)、福建省高校杰出青年科研人才计划(601934)资助项目

Maddalena 等<sup>[9]</sup>提出使用多摄像机的人群计数系统,基于像素点特征分析,可对大规模人群数量进行有效检测。但是,基于图像进行人数检测的方法主要缺点在于:监控存在死角、信号易受干扰且造价高,且直接接触个人隐私,无法适用于室内部分私密环境。基于无线信号的方法是利用蓝牙<sup>[10-11]</sup>、WiFi<sup>[12-13]</sup>和 RFID<sup>[14-16]</sup>等估计室内使用设备的人数来间接检测室内人群数量。Weppner 等<sup>[17]</sup>提出基于 iBeacon 技术,利用智能手机作为被检测设备实现了 75% 的室内人数估计;Zhang 等<sup>[18]</sup>用 RFID 标签进行区域内的人数监测工作,人群检测精度 95% 左右。上述方法需监测目标携带或绑定特定设备,在实际应用与紧急事件中难以保证人员携带设备,从而影响人数统计精度。于是,人群数量检测无需室内人员携带设备(设备无关)成为该领域研究热点。设备无关检测的基本思想是:人体对无线信号的吸收以及不同人群数量带来的多径效应会对无线信号产生影响,通过信号的变化特征来区分室内人群数量<sup>[19-21]</sup>。由于路由器的广泛部署,WiFi 信号被逐渐应用于人群检测中。Zou 等<sup>[22]</sup>提出一种基于 CSI 的高精度室内人员估计系统,融合细粒度的 CSI 以及多种信号特征进行分析,实现对 7 个人 96% 的估计。然而 CSI 目前只支持少部分特殊的 WiFi 设备,使用与推广上受到很大限制<sup>[23]</sup>。相较于 CSI 信号,RSSI(received signal strength indication)信号更易获取,Depatla 等<sup>[24]</sup>提出基于 WiFi 路由器的人员状态检测系统,通过分析对 RSSI 信号的影响估计室内人员状态,精度达到 63%,人数上限仅为 7 人,由于 RSSI 信号特征维度比 CSI 更低,现有基于 RSSI 信号进行人员检测的方法对不同人数下的信号特征获取能力有限,存在检测人数少、检测精度较低等问题<sup>[25]</sup>。如何利用 RSSI 信号进行较高精度的设备无关人群数量检测是难点所在。综合考虑 RSSI 信号特征,研究一种有效提取 RSSI 信号特征的方法对基于普通路由器 WiFi 信号上进行人群数量检测的研究具有重要意义。

针对以上问题,本文提出了一种基于深度神经网络(deep neural networks, DNN)的室内人群数量检测方法。该方法是一种无需人员携带特殊设备即可进行人群数量检测的方法。通过部署多个 WiFi 传感节点,利用节点间相互探测得到的交错信号,提升 RSSI 信号的数据维度。根据不同人群数量对 WiFi 信号造成不同的影响,采集不同人群数量变化下的交错 RSSI 信号矩阵。运用 DNN 进行自动特征提取,训练人群数量感知模型,实现室内人群数量的实时检测。

## 1 实验原理

### 1.1 系统概述

系统基本原理如图 1 所示,在室内环境中部署  $n$  个传感节点(可由路由器改造),传感节点之间相互感知,探测彼此之间的 RSSI 信号强度,共构成  $N(N=n \times n)$  条 RSSI 信号传播链路。各传感节点通过 UDP 通讯将各链路的 RSSI 信号通过主路由器发送至服务端处理。这  $N$  条 RSSI 信号链路形成一张覆盖室内环境的探测网,可用一个  $n \times n$  的交错 RSSI 信号矩阵表示。由于人体对 WiFi 信号的吸收以及人员在移动过程中对 WiFi 信号的多径效应都将导致 RSSI 信号发生波动,室内人群数量的变化必然会对传播链路造成影响,使各传感节点检测到的 RSSI 信号值发生变化,使得在不同人员数量下的信号矩阵发生改变。由于室内人员活动对 WiFi 信号的影响是复杂的,难以用显式的数学模型来反映其内在特征联系。于是,本文采用深度学习解决 RSSI 信号特征提取问题。通过采集不同人数下 RSSI 信号矩阵数据,构建 DNN 模型,对矩阵数据进行训练,提取出不同人员数量对应的矩阵特征,进而固化模型。模型一旦训练完毕,只需将当前实时的信号矩阵数据投入训练好的深度神经网络感知模型中,随即得到对应的室内人员数量估计,从而实现了对人数的检测。

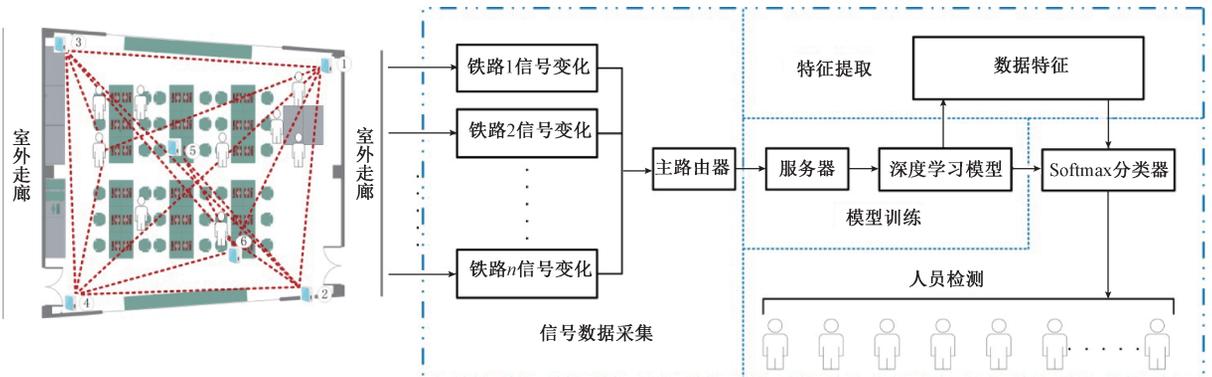


图 1 系统原理结构

Fig.1 Diagram of system schematic structure

## 1.2 数据采集与分析

本系统的数据采集依靠部署在目标区域内的传感节点,节点之间相互感知,每个传感节点既作为 RSSI 信号的发射端,又作为信号接收端。传感节点向外发射信号的同时,主动监听其它传感节点发射的信号并截取其数据包包头,包头中含有该传感节点相对另一传感节点之间的 RSSI 信号强度值。 $n$  个传感节点之间互相发射、相互监听信号,每个传感节点可获取其余  $n-1$  个传感节点的 RSSI 信号值以及一个相对自身的信号值,故每个传感节点可获得  $n$  个 RSSI 交错信号值。各传感节点通过 UDP 通讯将获得的  $n$  个 RSSI 交错信号值实时通过主路由器发送至服务器中进行汇总,生成一个  $n \times n$  的 RSSI 交错信号矩阵  $\hat{\mathbf{R}}$ :

$$\hat{\mathbf{R}} = \begin{pmatrix} R_{1,1} & R_{1,2} & \cdots & R_{1,n} \\ R_{2,1} & R_{2,2} & \cdots & R_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ R_{n,1} & R_{n,2} & \cdots & R_{n,n} \end{pmatrix} \quad (1)$$

式中: $n$  为传感节点个数,元素  $R_{i,j}$  ( $i, j$  分别表示矩阵内第  $i$  行第  $j$  列) 表示第  $i$  个传感节点检测到第  $j$  个传感节点的 RSSI 交错信号值。RSSI 交错信号矩阵是实时检测的,检测频率  $> 10$  Hz。矩阵中对角线元素的值是传感节点自耦合的信号,在实验中将 RSSI 信号检测设备紧贴传感节点进行检测近似表示传感节点相对自身的值,该值以具体环境进行实际测量为准。

由于在检测区域内人群数量的不同会造成各传感节点之间信号的传播受到不同程度的影响,导致各传感节点之间检测到的 RSSI 交错信号值产生变化,使得 RSSI 交错信号矩阵中元素  $R_{i,j}$  大小发生改变。以在 6 个传感节点下不同人数的 RSSI 交错信号矩阵为例,如图 2 所示,其中颜色越浅表示两个传感节点间的 RSSI 信号强度越强。图 2(a) 为上午 9 点室内人数为 1 人的 RSSI 交错信号矩阵,图 2(b) 为下午 3 点室内人群数 1 人的 RSSI 交错信号矩阵。可以明显看到虽然 RSSI 信号数据略有不同,在相同的人群数量下,矩阵中各传感节点之间检测到的 RSSI 交错信号值较为接近,且在矩阵的颜色分布上呈现一致性。说明相同人数具有相似的矩阵特征表现。图 2(c) 是室内人群数为 3 人的 RSSI 交错信号矩阵,图 2(d) 为室内人群数为 15 人的 RSSI 交错信号矩阵。对比图 2(a)、(c)、(d) 可见,对应不同人群数量,交错信号矩阵中的有些元素值与颜色显示出较大的差异,矩阵特征有着明显的不同。由此可知,不同的 RSSI 交错信号矩阵特征会反映不同的人群数量,通过对交错信号矩阵提取有效的特征,便可对不同人群数量进行区分,实现人群数量的检测。然而,由于室内人员活动的复杂性,人员移动和行为都会对 WiFi 信号产生影响,仅仅通过矩

阵的相似性匹配是无法对人数进行准确估计的。于是本文将采用 DNN 进行自动的特征提取和模型训练,得到室内人员数量深度感知模型。

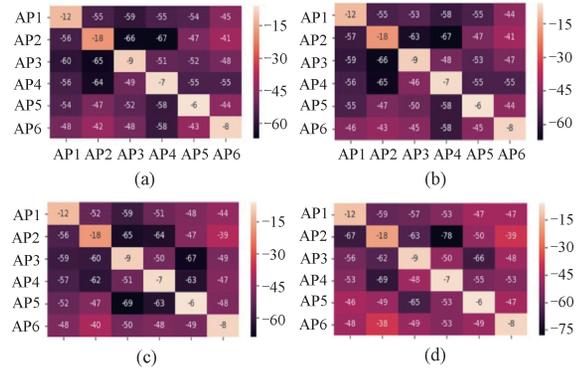


图2 RSSI 信号矩阵样本对比

Fig.2 Comparison among samples of RSSI signals matrix

## 1.3 基于 DNN 的室内人员数量深度感知模型

### 1) DNN 深度感知模型

DNN 通过多层网络结构实现自动特征提取,相比传统机器学习算法具有高鲁棒性、高泛化能力等特点。本文采用如图 3 所示的 DNN 结构,网络主要由输入层、隐藏层和输出层构成,其中选用 BN (batch normalization) 层<sup>[26]</sup> 作为隐藏层,隐藏层采用全连接的方式进行连接。对每一个神经元  $x_i$  引入了一对可学习重构参数  $\gamma, \beta$ , 对上一层输出数据进行重构:

$$y_i = \gamma_i \hat{x}_i + \beta_i \quad (2)$$

式中: $y_i$  为对应各神经元经过参数重构后得到的输出。在每一层 BN 层后加入了“LeakyReLU”<sup>[27]</sup> 激活层,将各层输入与输出的线性关系进行非线性化处理,使其具备更加接近真实的表现形式。

经过 BN 隐藏层对数据的训练之后,最后一层隐藏层输出的数据最终流向输出层,获得一个  $1 \times k$  维的向量  $\mathbf{z}_k$ , 使用“softmax”<sup>[28]</sup> 激活函数对数据进行梯度归一化处理,使得输出向量的每项范围都在  $(0, 1)$  之间:

$$\tau(z)_j = \frac{e^{z_j}}{\sum_{i=1}^k e^{z_i}} \quad (3)$$

式中: $\tau(z)$  表示一个  $1 \times k$  维的向量。最终获得在向量  $\tau(z)$  上  $k$  个输出节点对应的分布概率,从中选取对应分布概率所构成的输出向量中拥有最大权重的项所对应的第  $K$  ( $K \in \{1, \dots, k\}$ ) 项作为输出值,即为输入 RSSI 信号矩阵数据经由网络训练所得到的室内人员数量。

### 2) 模型训练和验证

利用传感节点采集室内不同人数情况下的 RSSI 信号矩阵数据作为样本数据。将输入的  $n \times n$  维的 RSSI 信

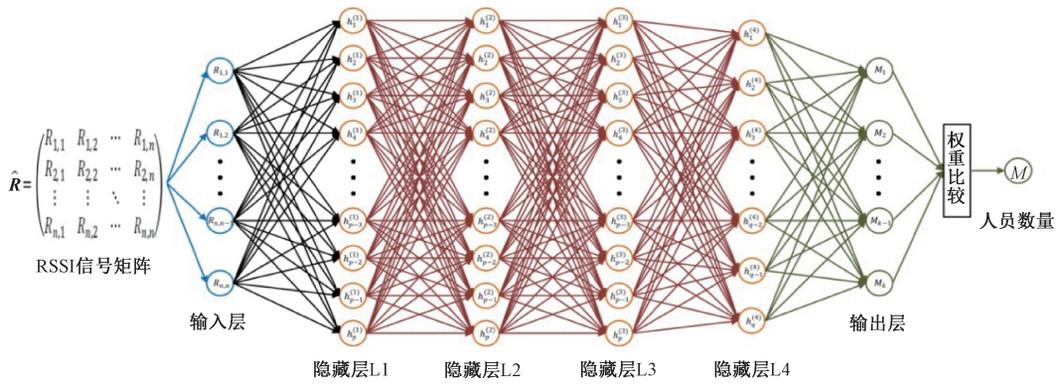


图 3 DNN 网络结构

Fig.3 Structure of DNN network

号样本数据进行按行展开,得到一个  $1 \times l (l = n \times n)$  维度的向量,每个元素表征着每两个传感节点间的 RSSI 信号值。同时为每个 RSSI 信号矩阵打上与之相应的人数标签,标签为  $1$  个  $1 \times k$  维的向量, $k$  值表示本文检测的人群数量上限,当该 RSSI 信号矩阵对应的室内人数为  $M (M \in \{1 \dots k\})$  时,在向量中的第  $M$  个元素置 1,其余元素置 0。

将上述样本数据集取一定比例划分为训练集数据与测试集数据。将训练数据经由 DNN 网络各层处理:对应的输入样本矩阵展开后的向量  $1 \times l (l = n \times n)$  与输出人数  $K$  之间的关系可由式(4)表示:

$$K = \tau \left[ \sum_{i=1}^l BN(\omega_i, x_i) \right] \quad (4)$$

将输出人数  $K$  与对应标签  $M$  进行比较,计算出训练输出值  $K$  与对应标签之间的误差  $loss$ ,并将其从输出层向隐藏层反向传播,直至输入层。在反向传播的过程中,根据误差  $loss$  使用链式法则进行 BN 层梯度参数变化的计算和不断迭代调整,优化算法采用随机梯度下降法。

训练过程分批次进行,每次迭代结束后采用测试集的数据进行精度验证,算法迭代到最大迭代次数后终止。将验证得到最优结果的模型参数固化保存下来,得到最终的 DNN 深度感知模型。模型一旦训练完毕,只需输入 RSSI 信号矩阵数据即可获得当前的室内人员数量的估计值。

## 2 实验结果与分析

### 2.1 实验环境

本文在典型的实验环境下进行模型训练和实验测试,讨论了基于 BN 层的 DNN 网络不同参数下的模型性能以及如何选取合适的参数,并分析了不同传感节点数量与布局对测试结果的影响,最后与不同机器学习算法做对比,以此验证本文人群数据检测方法的有效性。

实验环境如图 4 所示,面积约为  $187.5 \text{ m}^2$ ,包括室内实验区域以及两侧的室外走廊,室内实验区域有办公设备等用品,常驻人员为 15 人,室内人员活动状态多变。室内实验区域的 4 个角落各放置一个传感节点,其余两个传感节点布置在中心处,其离地高度为  $1 \sim 1.5 \text{ m}$ ,尽量实现传感节点在空间中的均匀分布。传感节点采用改装的 TPlink WR703 N 路由器作为传感节点(如图 4 中所示  $s1 \sim s6$ ),安装了基于 openwrt 固件上进行开发的 RSSI 信号采集程序,使之在 802.11n 协议的 2.4 GHz 频段上进行工作。同时,平台还包括 1 个 TP-Link886 N 作为主路由器以及一台服务器进行深度学习模型训练和实时在线检测。服务器的配置为: Intel Core i7-6 850 K 的 CPU,一个 NVIDIA GeForce GTX 1080 Ti 的 GPU 和 32G 的内存,搭载 Ubuntu 16.04 的系统。

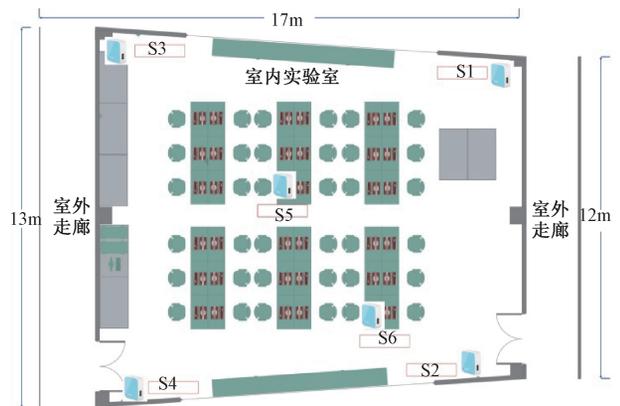


图 4 实验环境

Fig.4 Layout of the testbed

为了保证所采集的数据具有普适性,在实验区域进行了连续一个星期的 RSSI 交错矩阵信号数据采集,采集过程不限制室内人员活动,室内人员可以任意走动,保持正常的行为和活动。传感节点采集频率约为 10 Hz。通过人工手动统计室内人数,即室内人数发生变化时,手动

记录当前人数。之后将所采集到的 RSSI 数据根据对应的人数从 0,1,2……,15 分为 16 类。经过筛选、滤波、均值化处理。从每类中各抽取 550 个样本作为实验数据,打乱后随机选取 80% 样本,共 7 040 个矩阵作为训练数据,剩余 20% 的样本共 1 760 个矩阵作为测试数据。

### 2.2 模型训练与测试

由于在实验中布设了 6 个传感节点,所以采集到的 RSSI 交错矩阵维度为:6×6,即 DNN 网络的输入层的网络神经元为 36 个;DNN 模型结构设为第 1~第 3 层隐藏层的节点数各为 200 个,第 4 层隐藏层神经元为 50 个,输出层节点数为 16 个。训练总步数为 1 000 步,记录每步的训练及测试结果。如图 5 所示为每步的训练结果与测试结果。训练精度不断提高的同时,测试精度在波动中逐渐提高,在第 601 步时发生测试精度跃升至 70.17%,并于第 603 步时渐渐稳定在了 81% 附近。整个训练过程中,在第 828 步时获得最好的结果,达到了 82.23% 的测试精度,并固化该模型,保存网络各参数。为进一步验证该模型性能,在室内人群数量从 0~15 人共 16 类情况下对该模型进行不同误差人数的检测精度测试与均方根误差 (RMS) 测试,在本文中,选取了误差人数为 0 与误差人数在 0~1 范围内的检测精度测试。

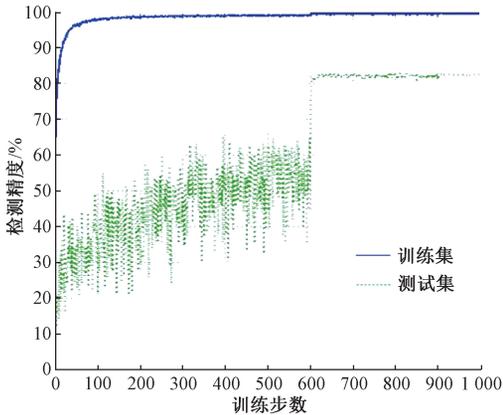


图 5 训练过程的训练精度与测试精度

Fig.5 Training accuracy and test accuracy during the training process

测试结果如图 6 所示,横轴坐标值表示测试的数据涵盖从 0 至该值对应人数范围内的测试数据。例如,横轴坐标值为 8 时,选取从室内人群数量为 0~8 人范围内的测试数据进行测试。在误差人数为 0、测试人群数范围在 0~15 人时,模型测试实现约 82% 的准确检测率,在误差人数在 1 人以内时,对应的测试人群数范围在 0~15 人时的准确率达到近 93%,表明相邻人数对应的数据特征存在相似性的情况下,该模型仍然实现了准确的检测。*RMS* 表示的是测试值与真实值的偏差,在检测人数在 0~1 人范围内,测试值与真实值达到了 0 偏差,即可

以非常准确的判断室内有无人员存在的情况。随着人群数量范围的增加,测试结果 *RMS* 值始终低于 0.4,测试值相较于真实值偏差较小。上述测试表明该模型能够准确的实现室内人群数量的检测。

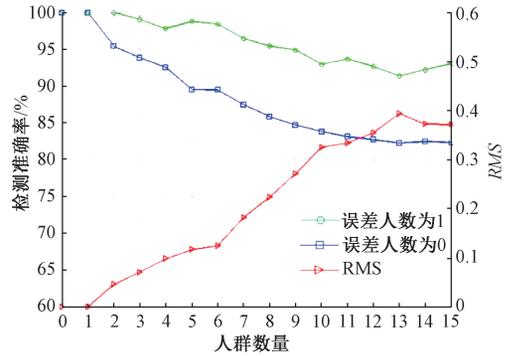


图 6 不同误差人数的检测精度与 RMS 值

Fig.6 Detection accuracy of different error numbers and RMS

### 2.3 网络不同神经元数量下的实验结果

为探究网络隐藏层神经元个数对实验结果的影响,在保持隐藏层层数不变的情况下,分别进行节点数为:50、100、150、200、250、350 的实验。如图 7 所示,随着隐藏层神经元数的增加,人员计数训练精度由 50 个节点数的 82.88% 到 350 个节点数时的 99.55% 一直都保持增加。随着训练精度的提高,测试精度从 77.22% 开始提升,在节点为 200 个处达到峰值处的 82.33%。但是,在节点超过 200 个时,测试精度出现下降的情况,下降至 81.94%,之后随着节点的增加测试精度围绕 81.94% 上下略微浮动。隐藏层的节点数的增减对深度学习网络有着较为明显的影响,节点数的增加将会使网络获得更为完整的信息处理能力;但是节点过多会使训练出现过拟合现象,还会增大服务器的运算压力。为保证网络有足够高的性能与泛化能力,在保证精度的前提下,综合考虑多种因素,前 3 层的节点数选取为 200。

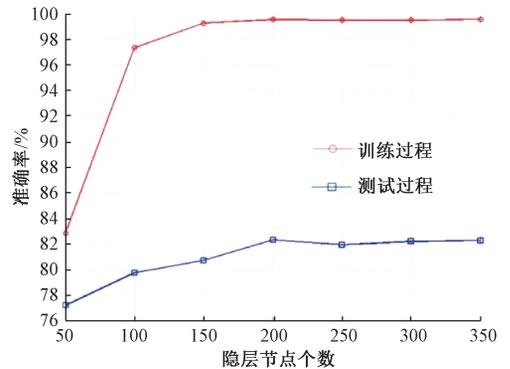


图 7 隐藏层不同节点个数对准确率的影响

Fig.7 Influence of different hidden layer node number on accuracy

### 2.4 不同网络层数下的实验结果

为进一步研究网络层数对实验结果的影响,保持隐藏层神经元个数不变的情况下,将网络的隐藏层层数由 1 层逐层增加至 7 层分别进行训练,结果如图 8(a)、(b) 所示,前期随着隐藏层数的增加,训练、测试误差与网络的训练、测试时间呈反比,随着训练及测试时间增加的同时,训练与测试误差在不断降低,并在层数为 4 时测试误差达到最优值:0.371 6,此时的训练时间与测试时间分别为:387.036 3 s 与 88.3 ms。但是,当隐藏层层数超过 4 层后,在网络的训练时间与测试时间仍旧不断增加的情况下,测试误差呈现饱和趋势,甚至出现较大的增加,在网络层数增大到 7 层时,误差上升至 0.389 3 出现了过拟合的现象。适当的层数设置不仅可以提高网络的特征提取能力,对计算效率的提升有很大帮助。通常情况下,随着网络层数的增大,对结果的提升有较大的帮助。但层数的增加会使网络结构更加复杂,导致计算量的增大,增大到一定程度时会出现饱和甚至过拟合的现象。因此,综合考虑训练结果的准确率以及训练时间,该实验中选取隐藏层的层数为 4 层。

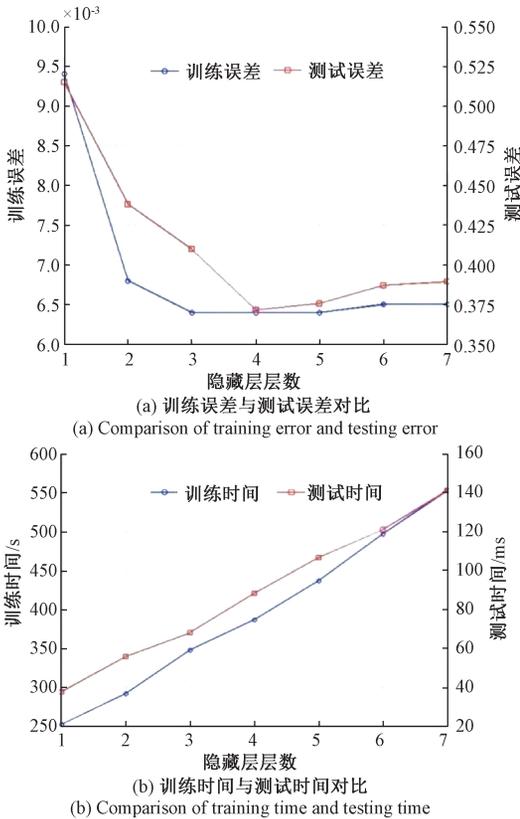


图 8 隐藏层层数变化对结果的影响

Fig.8 The effects with the different number of hidden layers

### 2.5 不同传感节点布局对实验结果的影响

考虑传感节点不同布局方式对本文方法检测精度的

影响。在布局方面,传感节点分布是需要覆盖目标区域的,因此在保障区域内 4 个角落布设传感节点外,重点讨论区域内部传感节点的布局,采用两组 5 个传感节点不同布局的人群数量检测实验进行对比分析。第一组实验传感节点的布局如图 9(a)所示,在实验环境中的 4 个角落以及图中靠近右下角位置布置传感节点;第二组实验传感节点的布局如图 9(b)所示。在实验环境中的 4 个角落以及靠近中心位置布置传感节点。分别在两种实验布局下进行数据采集并筛选出 16 类,每类各 550 个  $5 \times 5$  维度的 RSSI 交错矩阵数据作为训练数据。DNN 网络输入层的网络神经元设置为 25 个,其与网络参数不变,进行模型训练,将训练好的模型输入同样的测试数据进行测试。

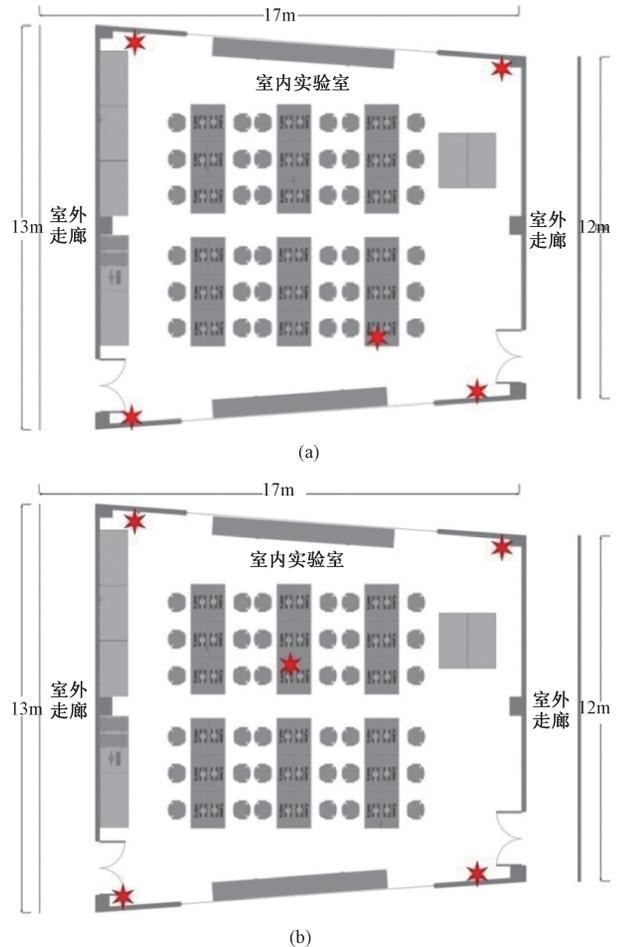


图 9 传感节点的不同布局方式

Fig.9 Different layout of sensor nodes

测试结果如果图 10 所示,图 10 为传感节点不同布局方式下检测的误差人数累计概率分布,反映了允许不同误差人数下的分类准确度。在误差人数为 0 时,第一组实验的累计概率为 63.75%,即 0 误差的分类检测精度为 63.75%;对应的,第二组实验误差人数为 0 时的累计

概率为 71.31%。通过实验对比分析,第二组实验的测试结果要明显优于第一组实验。其主要原因是,第二组实验传感节点的布设方式相对第一组实验在空间位置的分布上更平均,从而使各传感节点的信号在空间中的覆盖更加均匀。在第二组实验传感节点布局方式下,训练过程能够更有效地提取出不同人群数量下交错信号矩阵的特征,实现更为有效的人群数量检测。因此在传感节点布局上需要尽可能均匀分布。

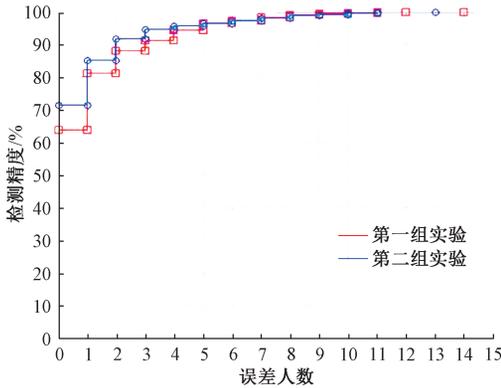


图 10 传感节点不同布局方式下的测试结果

Fig.10 Training results of sensor nodes with different layouts

## 2.6 不同传感节点数量对实验结果的影响

进一步讨论不同传感节点数量对实验结果产生的影响,分别在传感节点数量分别为 3、4、5、6 下进行模型训练和测试实验。不同数量下的传感节点布置方式如下:传感节点数量为 3 时,将 3 个传感节点布置在任意 3 个角落中;4 个传感节点的布置方式是将每个传感节点布设在环境中的 4 个角落中;5 个传感节点时,在 4 个角落各布置一个,并在中心处放置一个;传感节点数量为 6 时,与图 4 布局相同。当传感节点数量分别为 3、4、5 时,将其对应的 DNN 网络输入层的神经元数量分别设置为 9、16、25,其余网络参数不变,进行相应的数据采集,分别进行模型训练,6 节点的模型不再重复训练。

测试结果如图 11 和表 1 所示,图 11 为传感节点不同数量下模型检测精度的累积概率误差。可见当允许误差人数为 0 时,在 3、4、5、6 节点对应的累积概率分别为 44.60%、52.90%、71.99%、82.23%。其平均误差分别为 1.55、1.53、0.73 和 0.37。传感节点的数量会对实验结果产生较大的影响。传感节点数量的不同,一方面将会使该传感节点所在区域的 RSSI 信号覆盖密度发生变化,覆盖密度越大会使得交错信号矩阵更好地获取信号对人数的变化情况;另一方面,随着传感节点数量的增加,RSSI 交错矩阵的维度越多,交错矩阵表达的空间信息变化更加丰富,网络能够更有效的提取到不同人数下的信号特征,从而提高结果的准确率。但传感节点数量的增

加将导致实验成本的增加,所采集到的矩阵维度增加也将导致输入节点的增加,使得网络更加复杂。

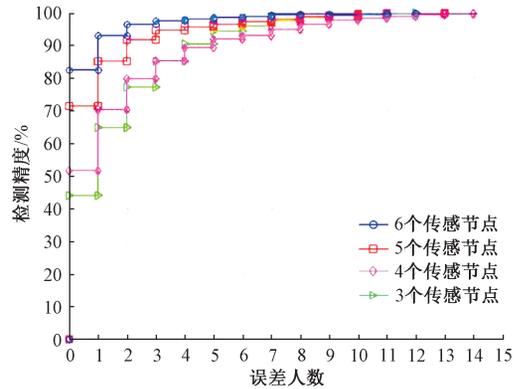


图 11 不同传感节点数量下人数误差实验的累积概率分布对比

Fig.11 CDFs of errors of excluding different sensors

表 1 不同传感节点数量的实验结果

Table 1 Average classification results of different number of sensors

传感节点数量	检测精度%	检测标准差	平均误差
6	82.23	0.002 1	0.37
5	71.99	0.046 4	0.73
4	52.90	0.059 1	1.53
3	44.60	0.105 1	1.55

## 2.7 不同算法的对比分析

本文提出的基于交错矩阵的 WiFi 感知数据也适用于其他机器学习算法进行建模。为了进一步检验本文基于 BN 层的 DNN 感知模型在人员检测方面的优越性,在实验中采用相同的训练数据和测试数据,选取神经网络(ANN)、极限学习机(ELM)以及 K 最近邻(KNN)模型进行训练,并将实验结果进行对比。其中 ANN 的激活函数为“sigmoid”,隐含层节点数在 200 个时,检测精度最高;而 ELM 模型同样采用“sigmoid”激活函数并且在隐层节点数调为 3 000 个时达到最优值;在 KNN 中的参数 K 值为 9 时,效果最佳。

实验结果如表 2 所示。在训练过程中上 ANN、KNN 和 ELM 3 种机器学习方法精度都在 80% 以上,ANN 与 ELM 更是达到了 99% 以上的正确率,在测试精度上,ANN、KNN 和 ELM 分别仅有 77.33%、75.23% 与 64.65%,而 DNN 模型在测试精度上相对以上 3 种模型分别提高了 4.9%、7% 与 17.58%。可见,ANN、KNN 以及 ELM 方法对信号特征较为复杂的 RSSI 信号的特征提取能力有限,不能很好地区分出不同人数的信号特征,泛

化能力较差。而本文的 DNN 算法通过深层网络结构,各层之间采用全连接方式,对 RSSI 信号特征进行自动提取,该网络在复杂环境下提取高层特征的能力更强,所提取的特征更加易于分类,模型具有更好的泛化能力和鲁棒性,比 ANN、KNN 和 ELM 算法获得了更好的检测性能。

表 2 不同算法实验结果

Table 2 Results of different algorithms %

	ANN	KNN	ELM	本文算法
训练精度	99.36	81.28	99.29	99.64
测试精度	77.33	75.23	64.65	82.23

### 3 结 论

本文提出了一种基于深度学习的室内人群数量检测方法,通过基于 DNN 网络感知模型对不同人员数量下对应 RSSI 交错信号矩阵进行特征提取和分类估计,实现了 82.23% 的人数检测精度。该方法是一种无需被检测人员携带设备的方法,仅通过室内环境中部署的普通 WiFi 设备就可以实现对人员数量的准确估计。通过实验讨论了不同网络参数、不同传感节点布局以及不同传感节点数量对检测精度的影响,并进行了不同机器学习算法的对比性实验。实验结果表明,基于 DNN 网络的 WiFi 感知模型相对其他机器学习算法,自动提取到的 RSSI 信号数据特征更加显著,实现了较高的人员数量检测精度。

### 参考文献

- [1] 刘安, 李金宝, 黎玲利. 基于子信道信息融合的室内定位方法的研究[J]. 仪器仪表学报, 2018, 39(3): 242-249.  
LIU AN, LI J B, LI L L. Study on indoor positioning method based on subchannel information fusion [J]. Chinese Journal of Scientific Instrument, 2018, 39(3): 242-249.
- [2] 李贤阳, 阳建中, 杨竣辉, 等. 深度运动图耦合正则化表示的行为识别算法[J]. 电子测量与仪器学报, 2018, 32(1): 119-128.  
LI X Y, YANG J ZH, YANG J H, et al. Action recognition algorithm based on depth motion maps and regularized representation [J]. Journal of Electronic Measurement and Instrument, 2018, 32(1): 119-128.
- [3] SHAMI M, MAQBOOL S, SAJID H, et al. People counting in dense crowd images using sparse head detections [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2018, 8215: 1-10.
- [4] PIZZO L D, FOGGIA P, GRECO A, et al. Counting people by RGB or depth overhead cameras [J]. Pattern Recognition Letters, 2016, 81: 41-50.
- [5] 蒋留兵, 李骢, 车俐. 超宽带雷达人体动作识别[J]. 电子测量与仪器学报, 2018, 32(1): 129-134.  
JIANG L B, LI C, CHE L. Human motion recognition by ultra-wide band radar [J]. Journal of Electronic Measurement and Instrument, 2018, 32(1): 129-134.
- [6] ZHANG Y Y, ZHOU D S, CHEN S Q, et al. Single-image crowd counting via multi-column convolutional neural network [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 589-597.
- [7] CHOI J W, QUAN X J, CHO S H. Bi-directional passing people counting system based on IR-UWB radar sensors [J]. IEEE Internet of Things Journal, 2018, 5(2): 512-522.
- [8] WU H F, GAO CH Y, CUI Y R, et al. Multipoint infrared laser-based detection and tracking for people counting [J]. Neural Computing and Applications, 2018, 29(5): 1405-1416.
- [9] MADDALENA L, PETROSINO A, RUSSO F. People counting by learning their appearance in a multi-view camera environment [J]. Pattern Recognition Letters, 2014, 36: 125-134.
- [10] CHEN ZH H, ZHU Q CH, SOH Y C. Smartphone inertial sensor-based indoor localization and tracking with iBeacon corrections [J]. IEEE Transactions on Industrial Informatics, 2016, 12(4): 1540-1549.
- [11] ZOU H, CHEN ZH H, JIANG H, et al. Accurate indoor localization and tracking using mobile phone inertial sensors, WiFi and iBeacon [C]. IEEE International Symposium on Inertial Sensors and Systems, 2017: 1-4.
- [12] 姚英彪, 毛伟勇, 姚瑞丽, 等. 基于改进支持向量回归的室内定位算法 [J]. 仪器仪表学报, 2017, 38(9): 2112-2119.  
YAO Y B, MAO W Y, YAO R L, et al. Indoor positioning algorithm based on improved support vector regression [J]. Chinese Journal of Scientific Instrument, 2017, 38(9): 2112-2119.
- [13] 石琴琴, 徐强, 张建平, 等. 基于 RSSI 测距的室内目标定位方法 [J]. 电子测量与仪器学报, 2018, 32(2): 86-91.  
SHI Q Q, XU Q, ZHANG J P, et al. Indoor targeting method based on RSSI ranging [J]. Journal of Electronic Measurement and Instrument, 2018, 32(2): 86-91.
- [14] 兰庆庆, 肖本贤. 基于网格的密度峰值聚类算法的 RFID 定位 [J]. 电子测量与仪器学报, 2018, 32(10): 73-78.

- LAN Q Q, XIAO B X. Grid-based density peak clustering algorithm for RFID positioning[J]. Journal of Electronic Measurement and Instrument, 2018, 32(10): 73-78.
- [15] 何静, 刘冉, 肖宇峰, 等. 融合 RFID 相位差和激光扫描的动态目标定位[J]. 仪器仪表学报, 2018, 39(2): 81-88.
- HE J, LIU R, XIAO Y F, et al. Moving object localization by fusing RFID phase difference and laser scanning[J]. Chinese Journal of Scientific Instrument, 2018, 39(2): 81-88.
- [16] ZOU H, XIE L H, JIA Q SH, et al. Platform and algorithm development for a RFID-based indoor positioning system [J]. Unmanned Systems, 2014, 2(3): 279-291.
- [17] WEPPNER J, LUKOWICZ P. Bluetooth based collaborative crowd density estimation with mobile phones[C]. IEEE International Conference on Pervasive Computing and Communications, 2013: 193-200.
- [18] ZHANG D, LU K ZH, MAO R, et al. Fine-grained localization for multiple transceiver-free objects by using RF-based technologies[J]. IEEE Transactions on Parallel and Distributed Systems, 2014, 25(6): 1464-1475.
- [19] 郑学理, 付敬奇. 基于 PDR 和 RSSI 的室内定位算法研究[J]. 仪器仪表学报, 2015, 36(5): 1177-1185.
- ZHENG X L, FU J Q. Study on PDR and RSSI based indoor localization algorithm [J]. Chinese Journal of Scientific Instrument, 2015, 36(5): 1177-1185.
- [20] WANG X Y, GAO L J, MAO SH W, et al. CSI-based fingerprinting for indoor localization: a deep learning approach [J]. IEEE Transactions on Vehicular Technology, 2017, 66(1): 763-776.
- [21] WU K SH, XIAO J, YI Y W, et al. CSI-based indoor localization [J]. IEEE Transactions on Parallel and Distributed Systems, 2013, 24(7): 1300-1309.
- [22] ZOU H, ZHOU Y X, YANG J F, et al. FreeCount: device-free crowd counting with commodity WiFi [C]. GLOBECOM 2017- 2017 IEEE Global Communications Conference, 2017: 1-6.
- [23] 石泽森, 常强, 陈伟, 等. 基于 Wi-Fi 信号强度的设备无关被动室内定位与活动识别研究[C]. 第七届中国卫星导航学术年会, 2016: 132-137.
- SHI Z S, CHANG Q, CHEN W, et al. Device-free passive indoor localization and activity recognition based on Wi-Fi RSSI [C]. 7th China Satellite Navigation Conference, 2016: 132-137.
- [24] DEPATLA S, MURALIDHARAN A, MOSTOFI Y. Occupancy estimation using only WiFi power measurements[J]. IEEE Journal on Selected Areas in Communications, 2015, 33(7): 1381-1393.
- [25] ZHANG X, WANG J, GAO Q H, et al. Device-free wireless localization and activity recognition with deep learning[C]. IEEE International Conference on Pervasive Computing and Communication Workshops, 2016: 1-5.
- [26] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]. 32nd International Conference on Machine Learning, 2015: 448-456.
- [27] CLEVERT D, UNTERTHINER T, HOCHREITER S. Fast and accurate deep network learning by exponential linear units (ELUs) [C]. 4th International Conference on Learning Representations, 2016.
- [28] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality [C]. 26th International Conference on Neural Information Processing Systems, 2013, 2: 3111-3119.

### 作者简介



陈丹, 2000 年于福州大学获得学士学位, 2003 年于福州大学获得硕士学位, 2011 年于中国科学院沈阳自动化研究所获得博士学位, 现为福州大学副教授, 主要研究方向为无线传感网络、智能感知系统、机器视觉、预测控制和机器人遥操作。

E-mail: fzuchd@163.com

**Chen Dan** received her B. Sc. degree and M. Sc. degree both from Fuzhou university in 2000 and 2003, and received her Ph. D. degree from Shenyang Institute of Automation in 2011. She is currently an associate professor at Fuzhou University. Her main research interests include wireless sensor network, intelligent sensing systems, machine vision, predictive control and robot teleoperation.



江灏 (通信作者), 2008 年于厦门大学获得学士学位, 2011 年于厦门大学获得硕士学位, 2013 年于厦门大学获得博士学位, 2013~2015 年新加坡南洋理工大学博士后研究员, 现为福州大学副教授, 主要研究方向为无线传感网络、室内定位技术、智能感知系统、光传感网络和机器学习。

E-mail: jiangh@fzu.edu.cn

**Jiang Hao** received his B. Sc. degree, M. Sc. degree and Ph. D. degree all from Xiamen university in 2008, 2011 and 2013, respectively. He was a postdoctoral researcher at Nanyang Technological University from 2013 to 2015. He is currently an associate professor at Fuzhou university. His main research interests include wireless sensor network, indoor positioning technology, intelligent sensing systems, optical sensor networks and machine learning.