

# 融合迁移特征学习的生物启发网络用于可见光成像室内位置感知方法

孟祥艳, 张欣, 张峰\*, 赵黎, 李帅

西安工业大学电子信息工程学院, 陕西 西安 710021

**摘要** 现行可见光定位技术采用各类传感器以及混合复杂算法实现定位, 操作难度大且易受干扰, 导致系统的定位精度不稳定。为提高可见光室内定位的精度与稳定性, 提出将迁移特征学习与生物启发网络相融合的方法并将其应用于可见光室内定位中, 在可见光环境下采集图像, 利用改进的小波阈值去噪法去除图像噪声对深度特征的影响, 提取可见光图像的深度特征并建立指纹库, 构建天牛须搜索算法优化的神经网络模型, 进行训练与定位测试。结果表明: 在实测定位阶段搭建的  $0.8\text{ m} \times 0.8\text{ m} \times 0.8\text{ m}$  实验环境中, 预测坐标的平均误差为  $4.26\text{ cm}$ , 其中, 误差小于  $4\text{ cm}$  的预测点数量占总坐标点数量的  $63.4\%$ , 误差小于  $6\text{ cm}$  的预测点数量占总坐标点数量的  $78\%$ 。所提方法为室内定位提供了一种稳定可靠的方法。

**关键词** 光通信; 可见光视觉成像; 图像深度特征; 生物启发; 神经网络; 室内位置感知

**中图分类号** TN929.1

**文献标志码** A

**DOI:** 10.3788/CJL221362

## 1 引言

随着当代社会移动通信技术的高速发展, 大型工厂、商场及写字楼等复杂室内环境对定位服务的需求快速增长。目前应用最广泛的定位技术如全球定位系统 (GPS) 和北斗定位在室外环境中表现优异。但是, 在室内环境中, 在厚重障碍物、复杂环境和电磁屏蔽等因素影响下, 常见的室内定位技术如红外定位、蓝牙定位等很难满足用户需求<sup>[1-2]</sup>。可见光定位技术作为一种新型的室内定位技术, 相比于传统射频通信定位技术, 具有兼顾照明和通信且稳定可靠的优点<sup>[3]</sup>。在新一代室内移动通信系统中, 可见光室内定位技术已成为当下热门研究方向之一<sup>[4-5]</sup>。

近年来可见光定位技术已经有了一定的发展。常见的可见光定位系统主要使用光电检测器件采集信号强度值以及使用图像传感器采集图像, 对信号及图像进行相应的处理以实现定位<sup>[6-8]</sup>。随着设备技术的完善和更多算法的使用, 室内定位精度不断提高。例如: 文献[9]提出一种非线性摄像机辅助接收信号强度算法, 利用摄像机和光电二极管, 结合视觉和强度信息实现定位; 文献[10]针对室内光源信号互相叠加导致定位效果差的问题, 提出利用码分多

址对光源信息进行调制处理, 对不同光源的信号进行分离, 克服了码间干扰并提高了信号接收增益, 定位误差达到  $6\text{ cm}$ ; 文献[11]提出了一种改进的隐马尔可夫模型算法, 利用信号强度和节点间距建立模型, 室内停车场的定位平均误差达到  $3.35\text{ m}$ ; 文献[12]提出了一种基于改进混合蝙蝠算法的可见光三维定位方法, 在构造适应度函数时定义权重系数, 并通过引入自适应搜索因子提高定位精度与速度, 在  $1.5\text{ m} \times 1.2\text{ m} \times 2.0\text{ m}$  环境中平均定位误差为  $3.64\text{ cm}$ , 定位时间为  $0.89\text{ s}$ ; 文献[13]利用粒子群算法优化神经网络, 并压缩指纹数据库, 缩短神经网络训练时间, 网络对外部干扰具有很好的鲁棒性, 提高了定位性能和精度; 文献[14]利用图像传感器和加速传感器接受光源信息, 基于两点光源进行粗定位, 再利用 2D 图像坐标重建定位, 在  $5\text{ m} \times 5\text{ m} \times 3\text{ m}$  的室内环境中定位误差和不超过  $2\text{ cm}$ , 但该方法受接收端倾斜角度的影响, 需根据不同环境不断改变内置传感器角度, 实用性较差。

在传统室内定位技术不能满足人们日益增长的多元化定位需求的情况下, 本文提出了一种基于图像的可见光室内定位方法, 图像的深度特征具有平移旋转不变性, 适用场景十分广阔。通过对采集的图像进行去噪处理并提取深度特征, 建立图像深度特征指纹库,

收稿日期: 2022-10-25; 修回日期: 2022-11-21; 录用日期: 2022-12-15; 网络首发日期: 2023-02-07

基金项目: 国家自然科学基金 (12004292)、陕西省科技厅一般项目-工业领域 (2022GY-072)、西安市科技计划项目 (2020KJRC0040)、西安工业大学优秀硕士学位论文培育基金 (YS202210)

通信作者: \*zf\_zx963@163.com

将深度特征融入到生物启发式神经网络模型中,可以更好地优化与筛选特征,实现稳定、高精度的室内定位。

## 2 可见光室内定位模型

为模拟真实的室内场景,本文搭建了  $0.8\text{ m} \times 0.8\text{ m} \times 0.8\text{ m}$  的可见光定位系统实验箱。在实验箱中,按照国际照度标准,基于光照度补偿原理,顶部布置  $M$  个发光二极管(LED)光源<sup>[15]</sup>。其中,第  $m$  ( $m \leq M$ ) 个LED光源坐标可以表示为  $L_m(x_m, y_m, z_m)$ 。

整个系统主要由离线建库、模型建立和实测定位三个部分构成。可见光成像室内定位的实验流程如图 1 所示。

在离线建库阶段,采集图像并进行去噪处理,提取处理之后的图像的深度特征并建立指纹库。在模

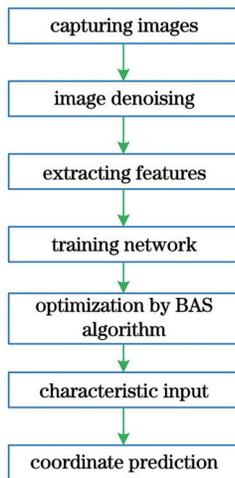


图 1 可见光成像室内定位流程图

Fig. 1 Flow chart of indoor positioning in visible light imaging

型建立阶段,搭建生物启发优化的径向基函数(RBF)神经网络模型,使用天牛须搜索(BAS)算法进行优化。在实测定位阶段,提取待测定位点的图像特征,将其作为输入神经元输入到训练好的定位模型中,设置目标误差,进行位置预测并获得预测坐标。

## 3 可见光成像的数据处理

### 3.1 可见光图像预处理

采集的图像常带有噪声干扰,噪声干扰对图像深度特征的提取有很大影响,特征提取不准确会导致定位精度较差<sup>[16]</sup>。采用的图像是手机摄像头拍摄的三原色(RGB)格式的图像,通常会受到传输设备本身以及外界环境的干扰,从而携带噪声。拍摄及传输过程中电路元器件自身固有的噪声及相互影响产生的噪声属于加性噪声。图像的噪声模型一般可表示为

$$Y_{ij} = X_{ij} \cdot \delta + N, \quad (1)$$

式中:  $X_{ij}$  是二维空间位置坐标点  $(i, j)$  处的图像原始信号;  $Y_{ij}$  为坐标点  $(i, j)$  处含有噪声的图像;  $\delta$  为乘性噪声;  $N$  为加性噪声。针对加性噪声,利用小波变换将含噪图像进行多层分解,可得到小波高频分量和小波低频分量<sup>[17]</sup>。对可见光图像进行预处理时,既要保留图像原本特征,同时要达到良好的去噪效果,所以通过设置合适的阈值将噪声分离出来是图像预处理的关键。小波阈值图像去噪保留了小波低频分量,传统的软阈值和硬阈值去噪都有一定的优劣:前者压缩信号,影响重构图像与原始图像的逼近度;后者处理信号会产生跳跃点,失去了信号的平滑性。针对两者的缺点,对小波变换去噪方法进行优化:

$$\hat{W}_{j,k} = \begin{cases} \text{sign}(W_{j,k}) \cdot [ |W_{j,k}| - T + T/(2e + 1) ], & |W_{j,k}| \geq T \\ \frac{W_{j,k}^{2e+1}}{(2e + 1) \cdot T^{2e}}, & |W_{j,k}| < T \end{cases}, \quad (2)$$

式中:  $\text{sign}(\cdot)$  为符号函数;  $\hat{W}_{j,k}$  为估计的小波高频系数;  $W_{j,k}$  为小波分解后的高频系数;  $j, k$  为系数的位置;  $T$  为小波阈值;  $e$  为设置的调节因子,可自由调节阈值函数。改进的阈值去噪方法很好地解决了阈值函数振荡导致信号缺失的问题,调节函数保证了信号较好的连续性,在图像去噪的基础上最大限度地保留了图像的原始特征。

### 3.2 基于迁移学习的图像特征提取

对图像进行去噪处理之后,就要提取图像深度特征并建立指纹库。训练的深度学习模型具有平移不变性,图像旋转、平移和缩放不会改变图像的深度特征。提取图像的深度特征需要搭建足够深度的网络。传统神经网络在训练过深的网络时,梯

度会反向传到前面的层并不断相乘,产生梯度爆炸或梯度消失等问题,使神经网络的收敛更缓慢,准确率降低。

ResNet 网络使用非常小的卷积滤波器架构来增加深度,相对于传统神经网络有更大的网络层数,同时为了避免网络层数的增加引起的准确度下降问题,增加了残差学习。残差网络在卷积层(conv)中引入了跳跃通道,经过卷积层与池化层(maxpool)的图像特征  $s$  直接跳过一层或多层卷积层,并与经过多次卷积层的输出特征图  $F(s)$  相加,使得神经网络更容易得到恒等映射,提高了神经元的利用率,减少了网络深度对模型的影响。本文使用层数为 50 层的网络即 ResNet50 进行图像特征提取,图像特征提取流程如图 2 所示,其中 FC 为全连接层。

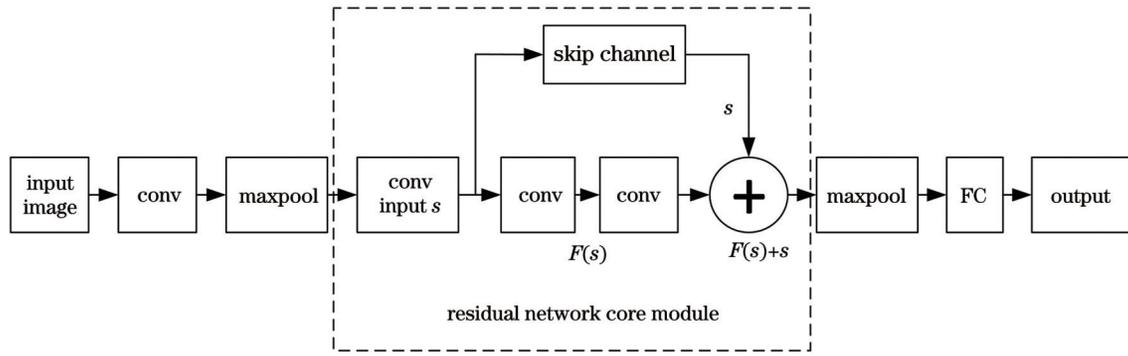


图 2 图像特征提取流程

Fig. 2 Image feature extraction process

## 4 基于生物启发优化神经网络的位置估计

### 4.1 BAS 优化神经网络

BAS 算法来源于天牛捕捉食物时的行为, 仿照其觅食特性, 从而对神经网络算法进行优化。原理是天牛额头上的两根触角对食物的气味具有很强的敏感性, 例如当食物在右前方时, 天牛两个触角会根据气味浓度差不断判断最优寻食路线, 朝着气味浓度较大方向移动, 直到抵达目标<sup>[18]</sup>。

RBF 神经网络是多层前馈神经网络的一个特例, 具有良好的逼近能力、非线性映射能力和分类能力等,

可以从大量的数据中提取关键信息。使用径向基函数作为其激活函数, 其公式为

$$\varphi(\mathbf{x}_i, \mathbf{c}_i) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{c}_i\|^2}{2\sigma^2}\right), \quad (3)$$

式中:  $\mathbf{x}_i$  为神经网络输入层第  $i$  个样本点;  $\mathbf{c}_i$  为输入数据集中选取的中心点向量, 其是 RBF 神经网络隐藏层的神经元;  $\sigma$  为高斯函数的方差;  $\|\mathbf{x}_i - \mathbf{c}_i\|$  为输入神经网络中的图像特征样本到中心点  $\mathbf{c}_i$  的欧氏距离。用 BAS 算法优化 RBF 神经网络模型的框图如图 3 所示, 其中  $d_m$  为坐标点与第  $m$  个 LED 光源之间的直线距离。

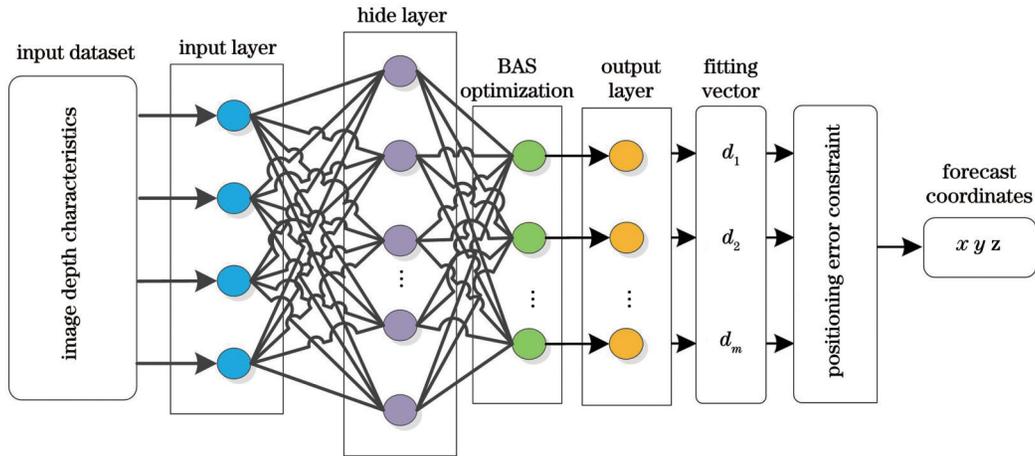


图 3 BAS 优化 RBF 神经网络模型

Fig. 3 BAS optimized RBF neural network model

在输入层输入采集坐标点图像的深度特征并在神经网络中进行训练, 输出层对定位误差进行判断, 使用 BAS 算法优化神经网络各层之间的连接权值矩阵, 提高网络训练速度和稳定性, 通过反向传播寻找网络各层之间的最优权值, 从而提高定位精度。输出值是对三维坐标点的预测, 需要定义三个神经元代表其输出坐标值。

### 4.2 创建数据集

在建立数据库时, 在实验平台以等距间隔拍摄图片, 提取特征建立数据库。假设样本总数为  $Q$ , 其中第  $n$  个位置对应的指纹数据为

$$F_n = \{n, x_n, y_n, z_n, D_{\text{DCNN}, n1}, D_{\text{DCNN}, n2}, \dots, D_{\text{DCNN}, nr}\}, \quad 1 \leq n \leq Q, \quad (4)$$

式中:  $(x_n, y_n, z_n)$  为数据集中第  $n$  个采集图像点的坐标位置;  $D_{\text{DCNN}, nr}$  为其所对应图像的第  $r$  个深度特征。对神经网络进行训练, 每个平面选取  $L$  个点作为测试集, 用来测试训练好的模型的定位性能, 将其余  $K$  ( $K = Q - L$ ) 个点输入到网络中进行训练。将图像的深度特征作为神经网络输入层的神经元, 神经元个数由图像深度特征个数决定。对  $r$  组样本 (每组  $K$  个样本) 的图像深度特征进行训练, 输入训练集矩阵  $\mathbf{X}^T$  为

$$\mathbf{X}^T = \begin{pmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \\ \vdots \\ \mathbf{X}_k \end{pmatrix}^T = \begin{pmatrix} D_{\text{DCNN}, 11} & D_{\text{DCNN}, 12} & \cdots & D_{\text{DCNN}, 1r} \\ D_{\text{DCNN}, 21} & D_{\text{DCNN}, 22} & \cdots & D_{\text{DCNN}, 2r} \\ \vdots & \vdots & & \vdots \\ D_{\text{DCNN}, K1} & D_{\text{DCNN}, K2} & \cdots & D_{\text{DCNN}, Kr} \end{pmatrix}_{K \times r}^T, \quad (5)$$

式中:  $\mathbf{X}_d$  为训练位置  $d$  处的图像深度特征所构成的矩阵,  $\mathbf{X}_d = (D_{\text{DCNN}, d1}, D_{\text{DCNN}, d2}, \dots, D_{\text{DCNN}, dr})$ ,  $0 < d \leq K$ 。神经网络测试数据集输入矩阵可表示为

$$\mathbf{X}^T = \begin{pmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \\ \vdots \\ \mathbf{X}_L \end{pmatrix}^T = \begin{pmatrix} D_{\text{DCNN}, 11} & D_{\text{DCNN}, 12} & \cdots & D_{\text{DCNN}, 1r} \\ D_{\text{DCNN}, 21} & D_{\text{DCNN}, 22} & \cdots & D_{\text{DCNN}, 2r} \\ \vdots & \vdots & & \vdots \\ D_{\text{DCNN}, L1} & D_{\text{DCNN}, L2} & \cdots & D_{\text{DCNN}, Lr} \end{pmatrix}_{L \times r}^T. \quad (6)$$

该矩阵表示  $L$  个测试集数据包包含参考点及对应的  $r$  个深度特征。接下来将其输入到保存好的神经网络预测模型  $\mathbf{D}$  中:

$$\bar{\mathbf{D}}^T = \begin{pmatrix} \bar{\mathbf{D}}_1 \\ \bar{\mathbf{D}}_2 \\ \vdots \\ \bar{\mathbf{D}}_L \end{pmatrix}^T = \begin{pmatrix} \bar{d}_{11} & \bar{d}_{12} & \cdots & \bar{d}_{1r} \\ \bar{d}_{21} & \bar{d}_{22} & \cdots & \bar{d}_{2r} \\ \vdots & \vdots & & \vdots \\ \bar{d}_{L1} & \bar{d}_{L2} & \cdots & \bar{d}_{Lr} \end{pmatrix}_{L \times r}^T, \quad (7)$$

式中:  $\bar{\mathbf{D}}_q$  为输入神经网络的图像深度特征测试集中第  $q$  个图像采集点处所采集的图像与其图像包含的光源之间的预测距离,  $\bar{\mathbf{D}}_q = (\bar{d}_{q1}, \bar{d}_{q2}, \dots, \bar{d}_{qr})$ 。对神经网络输入的测试点位置坐标矩阵进行误差约束并输出, 即

$$\mathbf{X} = (\mathbf{D}^T \mathbf{D})^{-1} \mathbf{D}^T \mathbf{Y}, \quad (8)$$

式中:  $\mathbf{D} = \begin{pmatrix} 2(x_r - x_1) & 2(y_r - y_1) & 2(z_r - z_1) \\ \vdots & \vdots & \vdots \\ 2(x_r - x_{r-1}) & 2(y_r - y_{r-1}) & 2(z_r - z_{r-1}) \end{pmatrix}$ , 其中  $x_r, y_r, z_r$  为第  $r$  个待测点的三维位置坐标;  $\mathbf{Y} = \begin{bmatrix} L_1^2 - L_r^2 - (x_1^2 + y_1^2 + z_1^2) + (x_r^2 + y_r^2 + z_r^2) \\ \vdots \\ L_{r-1}^2 - L_r^2 - (x_{r-1}^2 + y_{r-1}^2 + z_{r-1}^2) + (x_r^2 + y_r^2 + z_r^2) \end{bmatrix}$ 。

## 5 定位实验与数据分析

### 5.1 实验环境及参数设置

论文搭建了图 4 所示的定位实验平台并构造光环

境来模拟真实的室内场景, 以验证算法的适用性和有效性。其中,  $\theta$  代表 LED 射出光与中心光轴的夹角,  $d$  代表发射端与接收端的直线距离,  $\varphi$  代表接收端入射光与接收轴的夹角。

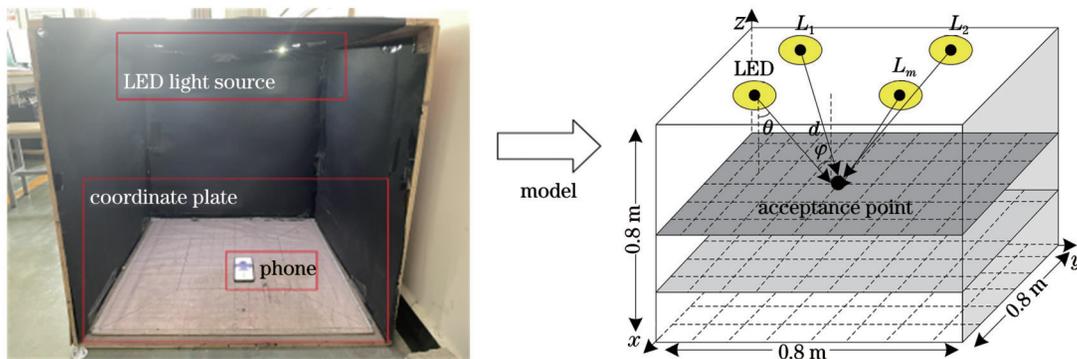


图 4 可见光定位系统实验箱及模型

Fig. 4 Experiment box and model of visible light positioning system

在实验箱底部的坐标板上以 5 cm 为间隔将坐标板划分为大小相等的若干区域, 并在实验箱顶部安装 4 个功率相同的 LED 光源, 用来采集可见光图像并提取深度特征; 通过升降坐标板, 在不同高度 (0、0.11、0.19 m) 处

采集图片, 利用采集的图片的深度特征建立数据库。将实测的 1684 组数据输入到神经网络中进行训练。在划分的区域内采集图像, 提取每个点处采集图像的深度特征并建立数据库。表 1 为实验环境参数。

表 1 实验环境参数

Table 1 Experimental environment parameters

Parameter	Value
Test box size	0.8 m×0.8 m×0.8 m
Number of LEDs	4
Sampling position interval	0.05 m
Noise bandwidth factor	0.752
Data transmission rate	10 Mbit·s <sup>-1</sup>
Camera resolution	1.2×10 <sup>7</sup> pixel

### 5.2 基于BAS的网络训练

将RBF网络训练次数设置为1000,学习速率为0.015,输入层节点数为256,输出层节点数为3,设置训练网络出口,当误差小于0.04 m时,保存神经网络并退出训练。在BAS参数设置中,初始搜索步长为100,步长调整比例为0.5,触须间距为5,变量维数为2。对数据集进行训练,BAS优化后的RBF(BAS-RBF)神经网络与优化前的RBF神经网络的训练速度对比如图5所示。优化前的RBF神经网络达到目标误差的迭代次数为26983,BAS优化后的RBF神经网络的迭代次数为47352,训练速度提升约40%。

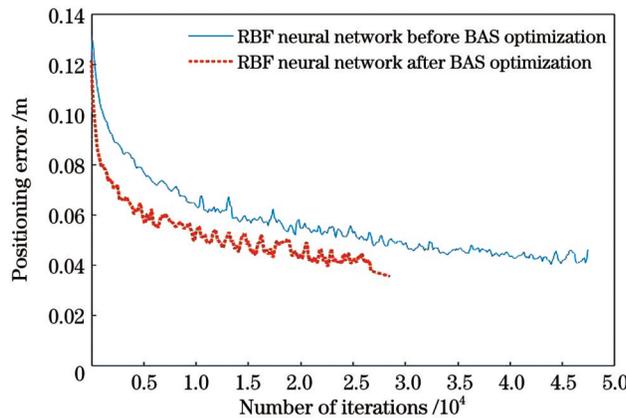


图 5 BAS优化前后RBF神经网络的训练速度

Fig. 5 Training speeds of RBF neural networks before and after BAS optimization

### 5.3 实验结果及分析

随机在实验箱内选取30个不同坐标点,采集对应图像但不对其进行去噪处理,定位测试结果如图6所示。

图6中的星号代表预测位置,圆圈代表真实位置,

图像去噪前得到的平均定位误差为5.02 cm。随后对图6中随机选取的30个点位处的采集图像进行去噪处理,然后提取特征进行训练,得到的定位误差分布如图7所示。

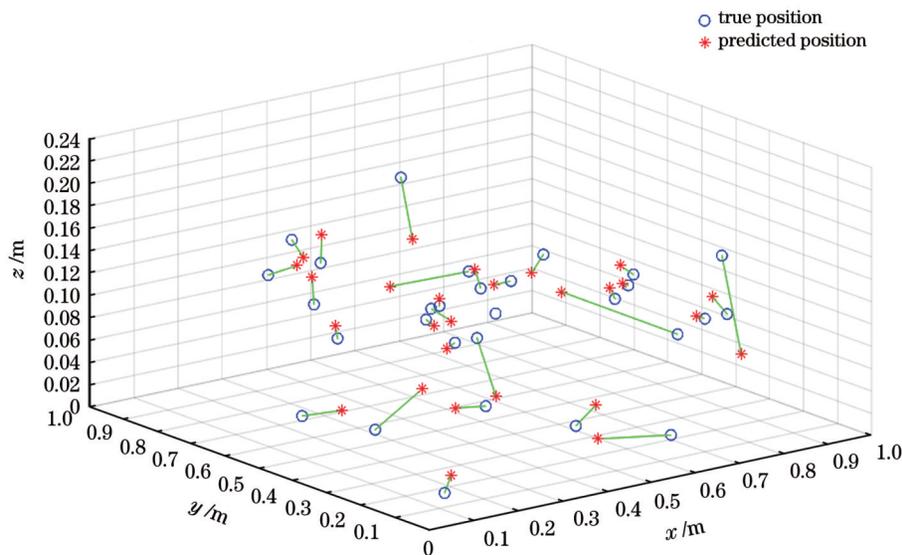


图 6 图像去噪前实测的定位误差分布

Fig. 6 Distribution of measured positioning error before image denoising

图像去噪后得到的平均定位误差为4.26 cm,实验表明,对图像进行去噪能有效地提高定位精度。在图

像去噪后的实测定位误差结果中选取10组位置数据,对真实坐标与预测坐标进行比较,结果如表2所示。

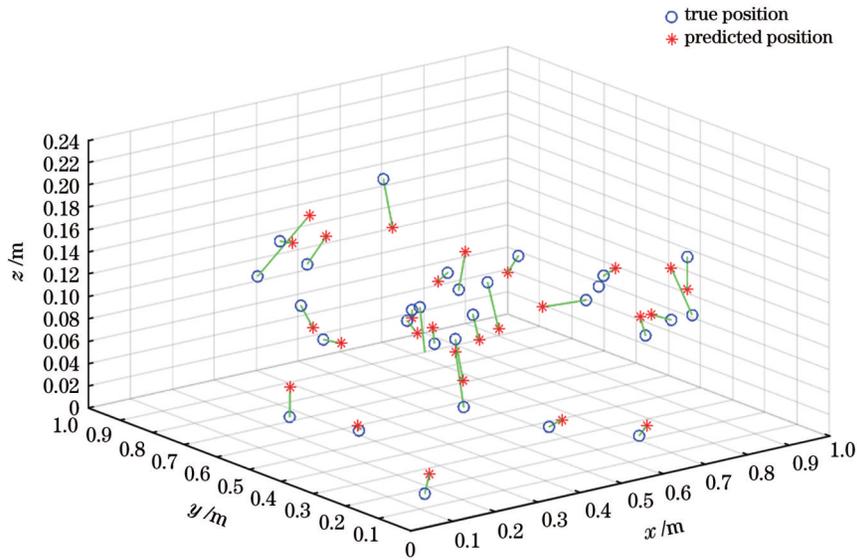


图 7 图像去噪后实测的定位误差分布

Fig. 7 Distribution of measured positioning error after image denoising

表 2 部分位置坐标的比较

Table 2 Comparison of partial position coordinates

True coordinate	Forecast coordinate	True coordinate	Forecast coordinate
(0.50 m, 0.05 m, 0.19 m)	(0.51 m, 0.02 m, 0.18 m)	(0.30 m, 0.40 m, 0.11 m)	(0.30 m, 0.37 m, 0.12 m)
(0.70 m, 0.20 m, 0 m)	(0.70 m, 0.21 m, 0.03 m)	(0.70 m, 0.05 m, 0.19 m)	(0.73 m, 0.07 m, 0.15 m)
(0.25 m, 0.80 m, 0.11 m)	(0.29 m, 0.73 m, 0.16 m)	(0.10 m, 0.10 m, 0.19 m)	(0.08 m, 0.07 m, 0.16 m)
(0.55 m, 0.60 m, 0.11 m)	(0.53 m, 0.58 m, 0.12 m)	(0.25 m, 0.70 m, 0 m)	(0.26 m, 0.73 m, 0.02 m)
(0.15 m, 0 m, 0.19 m)	(0.12 m, 0.01 m, 0.16 m)	(0.70 m, 0.10 m, 0.11 m)	(0.71 m, 0.09 m, 0.09 m)

对 BAS-RBF 神经网络算法、RBF 神经网络算法、反向传播(BP)神经网络算法进行比较,得到的累计误差分布如图 8 所示。

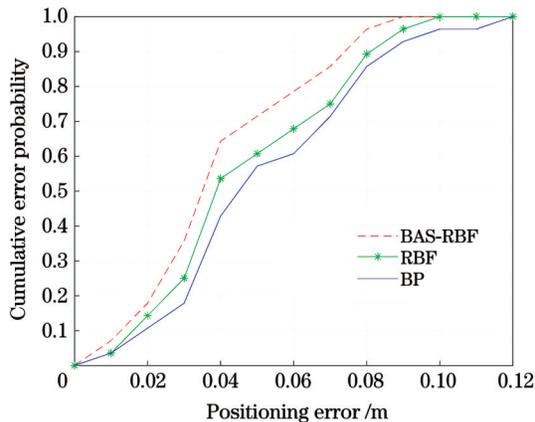


图 8 定位误差的累计分布

Fig. 8 Cumulative distribution of positioning errors

由图 8 可知, BAS-RBF 神经网络算法性能相比 RBF 神经网络算法和 BP 神经网络算法均有明显提升,误差小于 4 cm 的预测点数量占总坐标点数量的 63.4%,误差小于 6 cm 的预测点数量占总坐标点数量的 78%。对比 BP 神经网络算法,定位误差小于 2 cm

的置信概率提高了 9%,定位误差小于 4 cm 的置信概率提高了 11%,定位误差小于 6 cm 的置信概率提高了 10%,定位误差对比如表 3 所示。

表 3 三种算法的定位误差比较

Table 3 Comparison of positioning errors of three algorithms

Location algorithm	Minimum error /cm	Maximum error /cm	Average positioning error /cm
BAS-RBF	0.47	8.92	4.26
RBF	0.59	9.55	4.76
BP	0.62	11.2	5.13

由实验结果可知,经 BAS 优化的 RBF 神经网络算法的性能均高于 RBF 神经网络和 BP 神经网络。本文所提算法的平均定位误差为 4.26 cm,相比 RBF 神经网络定位精度提高了 10.5%,相比 BP 神经网络提高了 16.9%。

## 6 结 论

针对现行室内可见光定位技术受环境影响大、实际操作难度高导致的定位不稳定的问题,提出了视觉成像的可见光定位技术。只需在室内位置采集图像,

再使用迁移特征学习提取去噪处理的图像的深度特征,建立数据库,并将其代入到融合生物算法的神经网络中进行学习训练,搭建神经网络训练与测试模型。在定位精度和训练速度上,该模型相比 RBF 网络和 BP 网络均有提升。在实测定位阶段,搭建了  $0.8\text{ m} \times 0.8\text{ m} \times 0.8\text{ m}$  的实物模型进行验证,预测结果的平均定位误差为  $4.26\text{ cm}$ ,误差小于  $4\text{ cm}$  的预测点数量占总坐标点数量的  $63.4\%$ ,误差小于  $6\text{ cm}$  的预测点数量占总坐标点数量的  $78\%$ 。定位结果稳定可靠,所提方法为可见光室内定位技术提供了新的可行方案。

### 参 考 文 献

- [1] 赵黎, 韩中达, 张峰. 基于神经网络的可见光室内立体定位研究 [J]. 中国激光, 2021, 48(7): 0706004.  
Zhao L, Han Z D, Zhang F. Research on stereo location in visible light room based on neural network [J]. Chinese Journal of Lasers, 2021, 48(7): 0706004.
- [2] Huang H Q, Yang A Y, Feng L H, et al. Artificial neural-network-based visible light positioning algorithm with a diffuse optical channel [J]. Chinese Optics Letters, 2017, 15(5): 050601.
- [3] Wang C Y, Wang L, Chi X F, et al. The research of indoor positioning based on visible light communication [J]. China Communications, 2015, 12(8): 85-92.
- [4] 白勃, 田骅, 李晓波. 基于发光二极管光源的相机定标无线定位算法 [J]. 中国激光, 2015, 42(2): 0205003.  
Bai B, Tian H, Li X B. Wireless positioning algorithm based on light emitting diode lights and camera calibration [J]. Chinese Journal of Lasers, 2015, 42(2): 0205003.
- [5] 亢焯, 柯熙政. 可见光通信中的多维编码 [J]. 中国激光, 2015, 42(2): 0205001.  
Kang Y, Ke X Z. Multi-dimensions encoding scheme for visible light communication system [J]. Chinese Journal of Lasers, 2015, 42(2): 0205001.
- [6] 贾兰芳, 周小芳, 吕丽君. 基于光信号强度检测法的可见光通信定位方法研究 [J]. 激光杂志, 2021, 42(5): 97-101.  
Jia L F, Zhou X F, Lv L J. Research on visible light communication location method based on optical signal intensity detection [J]. Laser Journal, 2021, 42(5): 97-101.
- [7] Li Y W, Ghassemlooy Z, Tang X, et al. A VLC smartphone camera based indoor positioning system [J]. IEEE Photonics Technology Letters, 2018, 30(13): 1171-1174.
- [8] 张志涛, 郭彩丽, 柏琳, 等. PD 辅助的 P3P 可见光定位算法 [J]. 北京邮电大学学报, 2022, 45(1): 75-81.  
Zhang Z T, Guo C L, Bai L, et al. Perspective-three-point visible light localization algorithm assisted by photo-diode [J]. Journal of Beijing University of Posts and Telecommunications, 2022, 45(1): 75-81.
- [9] Bai B, Su B, Chen N, et al. A high precision positioning method based on high speed camera and visible light [C] // 2017 Asia Communications and Photonics Conference (ACP), November 10-13, 2017, Guangzhou, China. New York: IEEE Press, 2017.
- [10] 关伟鹏, 吴玉香, 文尚胜, 等. 基于 CDMA 调制的可见光通信室内定位技术的研究 [J]. 光学学报, 2016, 36(11): 1106006.  
Guan W P, Wu Y X, Wen S S, et al. Indoor positioning technology of visible light communication based on CDMA modulation [J]. Acta Optica Sinica, 2016, 36(11): 1106006.
- [11] 陈勇, 巫杰, 刘焕淋, 等. 基于隐马尔可夫模型的可见光与惯导融合室内定位系统 [J]. 中国激光, 2020, 47(12): 1206001.  
Chen Y, Wu J, Liu H L, et al. Visible light and inertial navigation fusion indoor positioning system based on hidden Markov model [J]. Chinese Journal of Lasers, 2020, 47(12): 1206001.
- [12] Chen Y, Zheng H, Liu H L, et al. Indoor high precision three-dimensional positioning system based on visible light communication using improved hybrid bat algorithm [J]. IEEE Photonics Journal, 2020, 12(5): 6802513.
- [13] Zhang M Q, Li F J, Guan W P, et al. A three-dimensional indoor positioning technique based on visible light communication using chaotic particle swarm optimization algorithm [J]. Optik, 2018, 165: 54-73.
- [14] 车平, 冯莉芳. 基于室内可见光的两点光源定位技术研究 [J]. 光学技术, 2018, 44(3): 257-262.  
Che P, Feng L F. Research on two-point light source positioning technology based on indoor visible light [J]. Optical Technique, 2018, 44(3): 257-262.
- [15] 刘智港, 赵黎, 朱彤, 等. 兼顾照明的室内可见光定位系统研究 [J]. 激光技术, 2018, 42(5): 646-650.  
Liu Z G, Zhao L, Zhu T, et al. Research of indoor positioning and illuminating systems based on visible light [J]. Laser Technology, 2018, 42(5): 646-650.
- [16] 李敏. 基于新阈值函数的小波图像去噪算法研究 [J]. 控制工程, 2021, 28(12): 2360-2365.  
Li M. Research on wavelet image denoising algorithm based on new threshold function [J]. Control Engineering of China, 2021, 28(12): 2360-2365.
- [17] 沙宇洋, 席丽霞, 张晓光, 等. 基于小波阈值去噪的偏振模色散测量 [J]. 中国激光, 2018, 45(11): 1106006.  
Sha Y Y, Xi L X, Zhang X G, et al. Polarization mode dispersion measurement based on wavelet threshold denoising [J]. Chinese Journal of Lasers, 2018, 45(11): 1106006.
- [18] Khan A T, Cao X W, Li S, et al. Fraud detection in publicly traded US firms using Beetle Antennae Search: a machine learning approach [J]. Expert Systems with Applications, 2022, 191: 116148.

## Bioheuristic Network Based on Migration Feature Learning for Indoor Location Awareness in Visible Light Imaging

Meng Xiangyan, Zhang Xin, Zhang Feng\*, Zhao Li, Li Shuai

School of Electronic Information Engineering, Xi'an Technological University, Xi'an 710021, Shaanxi, China

### Abstract

**Objective** With the rapid development of mobile communication technology in modern society, the demand for location services in complex indoor environments, such as large factories, shopping malls, and office buildings, has been growing rapidly. The current visible light positioning technology uses various sensors and hybrid complex algorithms to achieve positioning, which is difficult to operate and vulnerable to interference, resulting in unstable positioning accuracy of the system. The advantages of visible light

communication include both lighting and communication, as well as stability and reliability. On this basis, to improve the accuracy and stability of visible light indoor positioning, a bio-inspired network integrating migration feature learning is proposed to achieve stable and high-precision indoor positioning in visible light imaging.

**Methods** In this study, a visible-light indoor location method based on an image is proposed. The acquired image is first denoised to eliminate noise interference which has a significant impact on the extraction of the image depth features. Inaccurate feature extraction leads to poor positioning accuracy. An improved threshold denoising method is used to address the issue of signal loss caused by the oscillation of the threshold function. The adjustment function ensures good continuity of the signal and retains the original features of the image to the maximum extent based on image denoising. Second, the ResNet network is used to extract image depth features and establish a fingerprint database. The image depth features exhibit translation and rotation invariance. However, the ResNet network has deeper network layers than the traditional neural networks. Thus, residual learning is added to avoid a decrease in accuracy resulting from the increase in network layers. Finally, the BAS algorithm is used to optimize the connection weight matrix between the layers of the RBF neural network, improve the training speed and stability of the network, and determine the optimal weight between the layers of the network through back propagation for enhanced positioning accuracy.

**Results and Discussions** In this study, we first build a positioning experimental platform (Fig. 4) consisting of a light environment that can simulate real indoor scenes to verify the applicability and effectiveness of the algorithm. The coordinate plate at the bottom of the experimental box is divided into several areas of equal size at an interval of 5 cm, and four LED light sources with the same size and power are installed on top of the experimental box to collect visible light images and extract depth features. Pictures are collected at three different heights by lifting and lowering the coordinate plate to establish a depth feature database for the collected pictures. The measured data are input into the neural network for training. The RBF neural network achieves 26983 target error iterations, the BAS optimized RBF neural network achieves 47352 iterations (Fig. 5), and the training speed is increased by approximately 40%. We randomly select 30 different coordinate points in the experimental box and collect the corresponding images without denoising for the positioning test. The average positioning error without denoising is 5.02 cm (Fig. 6), whereas, with denoising applied to the images collected at the same 30 points, the average positioning error is 4.26 cm (Fig. 7). The experiment shows that image denoising can effectively improve positioning accuracy. When compared to the RBF and back-propagation (BP) network algorithms, the BAS-RBF neural network algorithm provides significant improvements (Fig. 8). Compared with the BP network algorithm, the confidence probability of a fixed error of less than 2 cm, 4 cm, and 6 cm increase by 9%, 11%, and 10%, respectively. The experimental results show that the performance of the RBF neural network optimized by BAS is better than those of the RBF and BP neural networks (Table 3). The average positioning error of the algorithm is 4.26 cm, which is 10.5% higher than that of the RBF neural network and 16.9% higher than that of the BP neural network.

**Conclusions** This study proposes a visible light positioning technology for visual imaging that requires only images from indoor locations. Subsequently, the migration feature learning is used to extract the depth features of the denoised images to establish a database, which is brought into a neural network fused with biological algorithms for learning and training, with the goal of building a neural network training and testing model. Compared with the RBF and BP networks, this model can improve the positioning accuracy and training speed. In the actual measurement and positioning stage, 0.8 m × 0.8 m × 0.8 m physical model, the average positioning error of the prediction result is 4.26 cm; the probability of the prediction point error of less than 4 cm is 63.4% and the probability of the prediction point error of less than 6 cm is 78%. The positioning result is stable and reliable, providing a new feasible scheme for visible-light indoor positioning technology.

**Key words** optical communications; visible light visual imaging; image depth characteristics; biological inspiration; neural network; indoor location awareness