

基于采用天牛须搜索算法优化神经网络的可见光室内定位方法

赵黎, 刘海涛*, 陈俊波

(西安工业大学 电子信息工程学院, 西安 710021)

摘要:针对基于神经网络的可见光室内定位技术存在训练速度慢、泛化能力弱而导致定位精度不高的问题,提出采用天牛须搜索(BAS)算法优化神经网络的可见光定位方法,搭建了 $0.8\text{ m} \times 0.8\text{ m} \times 0.8\text{ m}$ 的实测模型。该方法使用BAS算法优化神经网络的连接权重矩阵,拟合了室内无线信道参数,实现室内定位。仿真与实验结果表明:该方法仿真时的平均定位误差不超过 3.42 cm ,比神经网络训练速度提升 40% ;实验时,在高度 $h=0.25\text{ m}$ 的平面测得平均定位误差不超过 4.0 cm 。

关键词:可见光通信;室内定位;神经网络;天牛须搜索算法

中图分类号:TN929.1 **文献标志码:**A **文章编号:**1002-5561(2022)02-0001-07

DOI:10.13921/j.cnki.issn1002-5561.2022.02.001

开放科学(资源服务)标识码(OSID):



Indoor visible light location method based on neural network optimized by beetle antennae search algorithm

ZHAO Li, LIU Haitao*, CHEN Junbo

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

Abstract: Aiming at the problems of slow training speed and weak generalization ability which leads to low positioning accuracy in visible light indoor positioning technology based on neural network, a visible light positioning method based on beetle antennae search (BAS) algorithm is proposed to optimize neural network. A measured model of $0.8\text{ m} \times 0.8\text{ m} \times 0.8\text{ m}$ is built. In this method, the connection weight matrix of the neural network is optimized by using the BAS algorithm and the indoor wireless channel parameters are fitted to achieve indoor location. The simulation results show that the average positioning error of the simulation method is less than 3.42 cm , which is 40% higher than the neural network training speed. In the experiment, the average error measured in the plane of height $h=0.25\text{ m}$ is less than 4.0 cm .

Key words: visible light communication, indoor positioning, neural network, beetle antennae search algorithm

0 引言

随着第五代移动通信技术的大规模普及,无人停车场、全自动化工厂等大型建筑设施中对室内定位服

收稿日期:2021-12-23。

基金项目:国家自然科学基金项目(No.12004292)资助;陕西省科技厅一般项目-工业领域项目(No.2020GY-054)资助;西安市科技计划项目(No.2020KJRC0040)资助。

作者简介:赵黎(1981—),女,博士,教授,硕士生导师,现任西安工业大学电子信息工程学院副院长。主要研究方向为自由空间光通信系统中的信号处理、可见光通信系统中的光源布局、调制技术和室内定位等。负责承担了10多项科研项目,获得国家发明专利3项,国家实用新型专利2项,软件注册权2项,相关研究成果多次获得陕西省科学技术奖。



* **通信作者:**刘海涛(1996—),男,硕士研究生,主要从事可见光室内通信及其衍生的光定位技术方面的研究工作。

务的需求正在快速增长,各类室内定位解决方案成为了当下的研究热点。但是,全球定位系统(GPS)以及北斗定位导航系统受到电磁屏蔽、多径衰落和障碍物阻挡等因素的影响,无法满足高精度、高稳定性的室内定位需求^[1]。目前,常用的室内定位技术(红外定位、超声波定位、蓝牙定位、WiFi定位和Zigbee定位)可以提供几米到几十厘米的定位精度^[2-3]。但是,在电磁环境复杂的室内,大多数基于无线通信的系统受电磁干扰,其稳定性与定位精度得不到保障^[4]。此时,一种利用可见光进行无线通信的技术——可见光通信(VLC)以其绿色环保、抗电磁干扰和频谱资源丰富等优点得到迅速发展,而基于VLC的高精度室内可见光定位(VLP)技术也得到了广泛研究。VLP技术是一种基于VLC技术实现照明和通信相统一的新型室内定位技术,被讨论为下一代移动通信系统的室内接入方式之

赵黎, 刘海涛, 陈俊波: 基于采用天牛须搜索算法优化神经网络的可见光室内定位方法

一, 具有非常广阔的应用前景^[5-6]。

经过近几年的发展, VLP 技术已经具备一定的技术基础。传统的室内 VLP 技术可以大致分为基于接收信号的几何测量方法和基于图像的算法。基于接收信号的几何测量法使用光电检测器(PD)采集信号强度, 再采用到达时间(TOA)法^[7]、到达时间差(TDOA)法^[8]、到达角度(AOA)法^[9]、接收信号强度(RSS)法^[10]和指纹匹配法^[11]等算法进行定位; 基于图像的算法是将 PD 换成高精度摄像头, 通过对摄像头采集到的高清图像进行处理与识别来实现室内定位。随着对 VLP 技术研究的不断深入, 各种具有更高复杂度、性能更好的混合定位算法与基于机器学习的定位算法层出不穷。例如: 文献[12]利用 3 个发光二极管(LED)进行室内光源布局, 同时采用 4 个传感器采集光源发出的光信号, 用线性逼近法进行二维平面定位, 定位误差达到 12.65 cm; 文献[13]提出了一种利用 TDOA 与 RSS 混合的定位算法, 该算法利用两步定位技术, 实现了在高信噪比下较好的定位性能, 但是, TDOA 算法要求设备具有严格的同步时钟周期, 硬件搭建繁琐且稳定性差; 文献[14]利用 K-means 聚类算法实现了一种无监督的 LED 定位, 该算法首次将机器学习的方法应用于室内 VLP 系统, 最终在 4 m×4 m×4 m 场景中接收器的平均定位误差达到 0.31 m, 但是该系统采用的 K-means 聚类算法对 K 值的选取敏感, 很难确定分类的个数和同时具备稳定、高效率、高精度的室内定位。针对非线性问题, 人工神经网络的自学习能力和自适应能力具有较好的拟合性能, 近年来在室内定位领域得到广泛应用。例如: 文献[15]采用遗传-最小均方(GA-LMS)算法优化径向基函数(RBF)神经网络的连接权值矩阵, 实现了定位精度在 0.1 m 内的改进神经模型定位, 但是遗传算法(GA)的实现复杂, 且 3 个算子的参数选择严重影响 GA 的寻优性能。天牛须搜索(BAS)算法具有运算量小、收敛速度快和实现简单等优点, 本文为了提高定位系统的稳定性与精度, 将神经网络与 BAS 算法结合, 对室内可见光信道

参数进行学习, 从而实现稳定、高精度的可见光室内定位。

1 可见光室内定位模型

可见光室内定位模型如图 1 所示。为了满足国际照度标准^[16], 根据光照度补偿原理, 顶部布置 m 个 LED 光源, 其中第 $n(n \leq m)$ 个 LED 光源坐标可以表示为

$$L_n = (x_n, y_n, z_n) \quad (1)$$

若想达到定位的目的, 需要在不同高度平面的不同位置对 LED 光源信号进行解码, 从而获得光强数据来建立初始训练数据集。光源位置信息经过调制与编码后, 经 LED 驱动电路, 把电信号转为光信号, 再通过 PD 采集可见光辐射信息。




图 1 可见光室内定位模型

根据 LED 的特性, 解调后的电信号电流与接收到的光功率的强度成正比, 单个 LED 的光辐射功率为 P_s 。因为光信号的多次室内反射传播对 VLP 的定位精度有着不可忽视的影响^[17], LED 的光辐射功率与接收端 PD 收到电功率 P_r 的关系^[18]为

$$P_r = \{RP_s[H(0) + H(0)_{\text{REF}}]\}^2 + \sigma_n^2 \quad (2)$$

其中, R 为接收端 PD 的响应度; $H(0)$ 为光信道的直流增益; σ_n^2 为总噪声方差, 包含热噪声方差和散粒噪声方差; $H(0)_{\text{REF}}$ 为光信号在漫反射信道中的传输函数, 其表达式^[19]如下:

$$H(0)_{\text{REF}} = \frac{m_s + 1}{2\pi d_1 d_2} dS_f A \rho T(\varphi) G(\varphi) \times \cos\alpha \cos\beta \cos^m(\theta) \cos^{m_r}(\varphi) \quad (3)$$

其中, d_1 、 d_2 分别代表从 LED 光源到反射面的距离和反射面到接收点间的距离; α 、 β 分别为入射角和出射角; dS_f 为反射面的面积微元; m_s 为发射端的朗伯发光阶数, 与所选择的 LED 光源的半功率角有关; A 为光电探测器的有效面积; T 为光滤波器的增益, G 为聚光透镜增益, T 、 G 都与相对于接收轴的入射角有关; θ 为相对于 LED 垂直轴的发射角; φ 为相对于接收轴的入射角; m_r 、 m_t 分别为发射端、接收端的朗伯发光阶数。用接收端检测到的 M 个光源的功率值构建数据库, 将其作为训练数据输入神经网络进行训练, 得到可见光室内位置预测模型, 最后进行测试。

整个算法主要由室内定位神经网络训练和测试室内定位神经网络误差 2 个阶段构成。在室内定位神经网络训练阶段, 将定位区域划分为等大小的小区域, 在不同高度上采集这些小区域坐标上的光强度数据, M 个光源中每个光源为一组就可以得到 M 组 RSS 数据。将采集到的 M 组数据作为 M 个输入神经元输入到待训练网络中, 设置目标误差, 当达到目标误差后, 神经网络训练结束, 保存网络。测试时, 选取坐标输入神经网络, 得到的输出数据通过误差约束模型计算, 最终获得相应的预测坐标。

2 BAS 算法优化神经网络的定位方法

2.1 BAS 算法

BAS 算法是基于天牛觅食原理的元启发式算法^[20], 其原理为: 天牛的 2 条触须会接收到不同的气味强度, 天牛通过判断 2 条触须接收到的气味强度来决定下一步的前进方向。BAS 算法根据该仿生原理, 将三维空间的运动引申到多维空间, 进行多维空间的函数

寻优。该算法中的个体只有一个, 寻优的速度快。为了使 BAS 算法对任意维函数都有效, 本文采用如图 2 所示的简化模型描述天牛。

天牛质心即天牛的当前位置为 m , 天牛左须位置为 m_a , 天牛右须的位置为 m_b , 两须之间的距离为 d_0 。

天牛步长 step 与两须之间距离 d_0 的比是常数 ($\text{step} = c \times d_0$, c 是常数), 同时假设天牛飞到下一步后, 头的朝向是随机的。




图 2 天牛简化模型

2.2 BAS 算法优化神经网络

神经网络在训练开始时的初始权重一般通过随机初始化的方式获得, 并且在训练过程中, 神经网络的各层之间的连接权重也是通过误差反向传递和梯度下降法的方式进行修正的, 则权重的选取会直接影响神经网络的各项性能。而使用 BAS 算法优化神经网络的初始权值和连接权值, 可以提高网络训练阶段的收敛速度和预测阶段模型的稳定性。

在初始化神经网络时, 根据定位需要定义 RBF 神经网络 3 个神经元的输出, 代表 x 、 y 、 z 轴坐标的输出矢量。在神经网络训练过程中, 输出层将定位误差进行反向传播, 神经网络通过不断地修正各层之间的权值与阈值矩阵使预测出来的定位点与实际点之间的误差越来越小, 从而提高定位精度。

在 RBF 神经网络的训练过程中, 采用函数 $\varphi(x_i, c_i)$ 作为其激活函数, 其公式如式 (4) 所示^[21]。

$$\varphi(x_i, c_i) = \exp\left(-\frac{\|x_i - c_i\|^2}{2\sigma^2}\right) \quad (4)$$

其中, c_i 为第 i 个神经元的中心点, σ 为高斯函数的方差, $\|x_i - c_i\|$ 为样本 x_i 到中心点 c_i 的欧氏距离。RBF 神经网络对中心点 c_i 的取值敏感, 一般采用 K -means 算法计算, 其公式为

$$c_i = \frac{1}{D_i} \sum_{x_i \in D_i} x_i \quad (5)$$

其中, D_i 为分类分出的 k 个簇, 计算每个 x_i 与 c_i 的距离, 并根据阈值将数据集分为相应的簇中, 最终得到 c_i 的矩阵就是中心点矩阵。再定义误差函数为均方误差, 当有 P 个样本时, 系统误差为

$$E = \frac{1}{2P} \sum_{p=1}^P \sum_{k=1}^L (d_{pk} - o_{pk})^2 = \sum_{p=1}^P E_p \quad (6)$$

其中, d_{pk} 是第 p 个样本中第 k 个输出的期望值, o_{pk} 是第

赵黎, 刘海涛, 陈俊波: 基于采用天牛须搜索算法优化神经网络的可见光室内定位方法

p 个样本中第 k 个输出的当前值, E_p 是 P 个样本中每个样本的均方误差。位置 w_i 权重采用天牛须生物算法进行计算, 其优化神经网络模型的步骤如下:

① 确定天牛在神经网络的 n 维连接权值空间中的位置为 $w_i=(x_1, x_2, \dots, x_n)$, 天牛左右 2 只触角的位置模型被定义为如式(7)所示。

$$\begin{cases} w_a = w_i + l \times \vec{d} \\ w_b = w_i - l \times \vec{d} \end{cases} \quad (7)$$

其中, l 表示天牛质心与触须的距离; $\vec{d}$ 表示随机单位向量, 是由 n 维空间数据归一化而来, 其表达式为

$$\vec{d} = \frac{\text{rands}(n, 1)}{\|\text{rands}(n, 1)\|^2} \quad (8)$$

② 采用线性递减权重策略设置步长因子 δ 。这样能保证天牛足以覆盖当前的搜索区域, 避免陷入局部极小, 保证搜索的精细化。即

$$\delta = \delta_0 \times u \quad (9)$$

其中, δ_t 表示在第 t 次迭代时的步长, 该变量每次在区间内随机取值, 使得每次天牛的步长都是随机大小的; $t=0, 1, \dots, n; u \in (0, 1)$ 。

③ 使用测试数据的均方误差(MSE)作为自适应评估函数来推进空间区域的搜索。用 $f(w_{at})$ 和 $f(w_{bt})$ 分别代表左右须接收到的气味浓度大小, 根据函数值最小原则, 判断 $f(w_{at})$ 和 $f(w_{bt})$ 的大小, 若 $f(w_{at}) < f(w_{bt})$, 则天牛向左移动, 反之向右移动。天牛位置更新公式如下:

$$m_{t+1} = m_t + \delta_t \times \vec{d} \times \text{sign}[f(w_{at}) - f(w_{bt})] \quad (10)$$

其中, $\text{sign}(\cdot)$ 为符号函数, 其定义式为

$$\text{sign}(x) = \begin{cases} 1, x > 0 \\ \text{保持}, x = 0 \\ -1, \text{otherwise} \end{cases} \quad (11)$$

为防止天牛因为左右两须的气味值相同而导致天牛不动, 将 $\text{sign}(\cdot)$ 函数在 $x=0$ 时设为保持上一步天牛的前进方向。

2.3 创建数据集

首先, 在位置感知区域高度 $h=0.5 \text{ m}$ 、 $h=1.0 \text{ m}$ 和 $h=1.5 \text{ m}$ 平面随机选取 Q 个点作为指纹数据集的参考点, 每个参考点为指纹点接收到的 m 个 LED 光源的辐射功率, 其中第 $n(1 \leq n \leq Q)$ 个指纹点对应的记录信息 S 为

$$S = F_n(n, x_n, y_n, z_n, P_{n1}, P_{n2}, \dots, P_{nm}) \quad (12)$$

其中, (x_n, y_n, z_n) 为数据集的第 $n(1 \leq n \leq Q)$ 个指纹点的真实坐标, P_{nm} 为第 n 个指纹点在 (x_n, y_n, z_n) 处所检测到的功率值。从中选取 L 个样本作为测试集, 剩下的

$N(N=Q-L)$ 个样本为训练集。

神经网络的输入层神经元个数是由室内可见光源的个数 $m(m \geq 4)$ 决定的。在神经网络的训练阶段, 将总计有 m 组、每组 N 个样本的可见光源的光功率作为训练集, 则神经网络输入训练集矩阵 X 可表示为

$$X = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_N \end{bmatrix} = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1m} \\ P_{21} & P_{22} & \dots & P_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ P_{N1} & P_{N2} & \dots & P_{Nm} \end{bmatrix}_{N \times m} \quad (13)$$

其中, $X_d = (P_{d1}, P_{d2}, \dots, P_{dm}), 0 < d \leq N$, X_d 代表训练集数据中在第 d 个位置参考点所能接收到的 m 个光源的光功率值。

L 个测试集数据中包含参考点与对应的 m 个接收光功率矩阵, 将其输入到保存好的神经网络预测模型 $\bar{D}$ 中。

$$\bar{D} = \begin{bmatrix} \bar{D}_1 \\ \bar{D}_2 \\ \vdots \\ \bar{D}_L \end{bmatrix} = \begin{bmatrix} \bar{d}_{11} & \bar{d}_{12} & \dots & \bar{d}_{1m} \\ \bar{d}_{21} & \bar{d}_{22} & \dots & \bar{d}_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ \bar{d}_{L1} & \bar{d}_{L2} & \dots & \bar{d}_{Lm} \end{bmatrix} \quad (14)$$

其中, $\bar{D}_q = (\bar{d}_{q1}, \bar{d}_{q2}, \dots, \bar{d}_{qm})$ 为测试集中第 q 个位置到 m 个 LED 光源之间距离的预测值。最后, 将神经网络输出的位置矩阵进行误差约束, 得

$$X = (D^T D)^{-1} D^T Y \quad (15)$$

矩阵 D 表示为

$$D = \begin{bmatrix} 2(x_m - x_1) & 2(y_m - y_1) & 2(z_m - z_1) \\ \vdots & \vdots & \vdots \\ 2(x_m - x_{m-1}) & 2(y_m - y_{m-1}) & 2(z_m - z_{m-1}) \end{bmatrix} \quad (16)$$

矩阵 Y 表示为

$$Y = \begin{bmatrix} L_1^2 - L_m^2 - (x_1^2 + y_1^2 + z_1^2) + (x_m^2 + y_m^2 + z_m^2) \\ \vdots \\ L_{m-1}^2 - L_m^2 - (x_{m-1}^2 + y_{m-1}^2 + z_{m-1}^2) + (x_m^2 + y_m^2 + z_m^2) \end{bmatrix} \quad (17)$$

3 仿真与实测

本文进行了三维定位仿真与实测定位实验, 验证算法的理论有效性以及实测数据定位可靠性、稳定性。

3.1 模拟三维定位测试分析


本文通过仿真对 BAS 算法优化 RBF 神经网络前后的性能进行对比。在长、宽、高分别为 $L=5 \text{ m}$ 、 $W=5 \text{ m}$ 、 $h=3 \text{ m}$ 的立体空间模型中进行仿真, 4 个 LED 光

源矩阵的坐标分别为 $L_1(1\text{ m}, 1\text{ m}, 3\text{ m})$ 、 $L_2(1\text{ m}, 3\text{ m}, 3\text{ m})$ 、 $L_3(3\text{ m}, 3\text{ m}, 3\text{ m})$ 和 $L_4(3\text{ m}, 1\text{ m}, 3\text{ m})$ 。分别选取 $h=0.5\text{ m}$ 、 $h=1.0\text{ m}$ 和 $h=1.5\text{ m}$ 的 3 个平面, 每个平面划分为 $0.05\text{ m} \times 0.05\text{ m}$ 的若干个网格作为训练集。使用 PD 测得每个参考点上 4 个 LED 光源矩阵的光功率, 构建思维数据向量模型作为训练输入集。仿真参数如表 1 所示。


设置训练数据集的规模为 2930 组数据。2 种网络训练速度对比结果如图 3 所示, 无 BAS 算法优化的 RBF 神经网络迭代到目标误差为 0.04 m 时需要 5×10^4 次迭代, 而有 BAS 算法优化的 RBF 神经网络只需要

表 1 仿真参数

参数	值
LED 功率/W	5
光电探测器接收面积/ cm^2	1
噪声带宽因数 I_f	0.562
系统数据传输速率(R_b)/($\text{Mb} \cdot \text{s}^{-1}$)	10
激活函数	高斯径向基函数
输入层神经节点数/个	4
中心点个数/个	900
输出层神经节点数/个	3



(a) 无 BAS 算法优化的 RBF 神经网络



(b) 有 BAS 算法优化的 RBF 神经网络

图 3 训练速度对比

3×10^4 次迭代, 训练速度提升了近 40%。

当 $h=0.5\text{ m}$ 时, 预测模型预测的定位结果如图 4 所示, 红色三角代表标定参考点的坐标, 绿色三角代表经过 BAS 算法优化的 RBF 神经网络预测出来的位置坐标(简称预测位置坐标), z 轴代表预测点与参考点之间的误差, x 轴和 y 轴是位置坐标轴。经统计, 参考点和预测点之间的最大定位误差为 8.4 cm , 平均定位误差为 2.1 cm 。




图 4 $h=0.5\text{ m}$ 定位误差分布图

当 $h=1.0\text{ m}$ 时, 该预测模型预测的定位误差分布图如图 5 所示。经统计, 参考点和预测点之间的最大误差为 6.4 cm , 平均定位误差不超过 2 cm 。




图 5 $h=1.0\text{ m}$ 定位误差分布图

当 $h=1.5\text{ m}$ 时, 预测定位误差分布图如图 6 所示。经统计, 参考点和预测点之间的最大定位误差为 11.44 cm , 平均定位误差为 3.42 cm 。

计算测试点经过神经网络模型预测出的结果与参考点之间的欧氏距离, 得到定位误差。在每个平面上, 选取测试集中的 120 个点进行误差统计, 绘制定位误差分布图, 其结果如图 7~图 9 所示。这 3 幅图分别显示了在训练集规模相等、高度 h 分别为 0.5 m 、

赵黎, 刘海涛, 陈俊波: 基于采用天牛须搜索算法优化神经网络的可见光室内定位方法




图 6 $h=1.5$ m 定位误差分布图




图 7 $h=0.5$ m 定位误差累积分布




图 8 $h=1.0$ m 定位误差累积分布




图 9 $h=1.5$ m 定位误差累积分布

1.0 m 和 1.5 m 时定位误差小于 4 cm 的概率。可以看出在 $h=0.5$ m 时, 该平面上有 95% 的预测点误差在 4 cm 以内; 在 $h=1.0$ m 平面上, 预测点误差小于 4 cm 的占 96.7%; 在 $h=1.5$ m 的平面上, 预测点误差小于 4 cm 的点占比为 62%。

3.2 实测定位测试与分析

本文在长、宽、高均为 0.8 m 的立方体空间中搭建了如图 10 所示的实验平台, 用以进一步验证 BAS 定位算法在实际应用场景中的可行性及可靠性。在实验平台上, 将底部 $0.8\text{ m}\times 0.8\text{ m}$ 的空间以 0.1 m 为间隔划分为若干个区域, 并在顶部布置 4 个功率为 5 W 的 LED 光源, 以划分的区域为参考定位点多次光源强度值, 并取均值作为 4 组光源在该点的 RSS 数据。各个 LED 灯的位置坐标和对应的光功率值如表 2 所示。




图 10 实际实验平台

表 2 实测实验数据

坐标/m			光功率/W			
x 轴	y 轴	z 轴	LED1	LED2	LED3	LED4
0	0	0.6	144	19.53	7.56	14.22
0	0.05	0.6	194.4	23.76	8.05	15.48
0	0.1	0.6	239.04	28.62	8.68	15.93
0	0.15	0.6	306.72	39.42	9.72	16.29
0	0.2	0.6	310	52.72	9.74	17
0	0.25	0.6	283.36	76.68	11.7	16.2
0	0.3	0.6	223.6	102.52	12.33	15.03
0	0.35	0.6	172.8	141.12	12.23	13.86
0	0.5	0.6	60.84	336.92	16.02	11.52
0.8	0.1	0.35	26.28	16.2	52.54	131.76
0.8	0.15	0.35	25.56	17.91	62.64	141.12
0.8	0.2	0.35	26.64	19.62	74.52	140.4
0.8	0.25	0.35	25.5	21.6	87.12	140.4

将实测的 1000 余组数据输入神经网络进行训练, 再随机在实验平台上测得 30 组数据进行多次的定位测试, 其定位结果如图 11 所示, 平均定位误差为 4.33 cm。与文献[15]中的方法相比, 在相同的定位空间中, 本文算法的定位精度提升了 50%, 神经网络模型的训练速度提升了 40%。




图 11 实测定位误差分布

4 结束语

本文针对传统的基于神经网络算法的室内 VLP 技术稳定性差、性能不理想和神经网络训练速度慢等问题, 将 BAS 算法与神经网络相结合, 提出了一种基于采用 BAS 算法优化神经网络的 VLP 方法。首先, 该方法结合多次反射信道建模, 采用 BAS 算法优化神经网络的初始权值矩阵; 然后, 使用优化的网络对室内可见光信道参数进行学习; 最后, 搭建神经网络训练与测试模型。该模型可以显著提高 VLP 系统的定位精度和速度, 实现高速和高精度的定位。仿真测试时, 该算法在 5 m×5 m×3 m 的室内空间模型的平均定位误差不超过 3.42 cm。在实物测试阶段, 本文搭建了 0.8 m×0.8 m×0.8 m 的实验模型, 平均定位误差为 4.33 cm。在相同规模的数据中, 训练速度比 BP 神经网络提高了 40%, 为室内 VLP 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): 145–154.
- [2] HUANG H Q, YANG A Y, FENG L H, et al. Artificial neural-network-based visible light positioning algorithm with a diffuse optical chan-

nel[J]. Chinese Optics Letters, 2017, 15(5): 20–24.

- [3] 汪明, 许亮, 何小敏. 无线传感器网络精度优选 RSSI 协作定位算法[J]. 计算机应用, 2018, 38(7): 1981–1988.
- [4] 李深安. 基于物联网网关的智能家居系统室内定位技术研究 [D]. 北京: 北京邮电大学, 2015.
- [5] KANG Y, KE X Z. Multidimensional coding in visible light communication [J]. China Laser, 2015, 42 (2): 138–144.
- [6] WANG T Q, SEKERCIOGLU Y A, ARMSTRONG J. Position accuracy of time-of-arrival based ranging using visible light with application in indoor localization systems [J]. Journal of Lightwave Technology, 2013, 31 (20): 3302–3308.
- [7] KESKIN M F, GEZICI S. Comparative theoretical analysis of distance estimation in visible light positioning systems[J]. Journal of Lightwave Technology, 2016, 34(3): 854–865.
- [8] DU P, ZHANG S, CHEN C, et al. Demonstration of a low-complexity indoor visible light positioning system using an enhanced TDOA scheme [J]. IEEE Photonics Journal, 2018, 10(4): 1–10.
- [9] STEENDAM H. A 3-D positioning algorithm for AOA-based VLP with an aperture-based receiver[J]. IEEE Journal on Selected Areas in Communications, 2018, 36(1): 23–33.
- [10] TRONG-HOP D, MYUNGSIK Y. An in-depth survey of visible light communication based positioning systems [EB/OL]. [2021–12–23]. <https://pubmed.ncbi.nlm.nih.gov/27187395/>.
- [11] 徐世武, 吴怡, 王徐芳. 基于稀疏自适应和位置指纹的可见光定位算法[J]. 光学学报, 2020, 40(18): 1806003-1–1806003-9.
- [12] 王鹏飞, 关伟鹏, 文尚胜, 等. 基于免疫算法的高精度室内可见光三维定位系统[J]. 光学学报, 2018, 38(10): 111–121.
- [13] KAZIKLI E, GEZICI S. Hybrid TDOA/RSS based localization for visible light systems[J]. Digital Signal Processing, 2019, 86: 19–28.
- [14] SAADI M, AHMAD T, ZHAO Y, et al. An LED based indoor localization system using k-means clustering [C]//15th IEEE International Conference on Machine Learning and Applications (ICMLA), Dec. 18–20, 2016, Anaheim, USA. New York: IEEE, 2016: 246–252.
- [15] 张慧颖, 于海越, 王凯, 等. 基于 KPCA-K-means++ 和 GA-LMS 模型的改进 RBF 神经网络室内可见光定位[J]. 光学学报, 2021, 41(19): 72–81.
- [16] 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.
- [17] GU W, KASHANI M A, KAVEHRAD M. Indoor visible light positioning system with multipath reflection analysis [EB/OL]. [2021–12–23]. <https://arxiv.org/abs/1504.01192>.
- [18] 徐岩, 王昕昕. 多层 ELM 分区域可见光室内定位算法[J]. 湖南大学学报(自然科学版), 2019, 46(10): 125–132.
- [19] 许毅钦, 陈志涛, 袁涛, 等. 室内可见光通信高精度定位系统设计[J]. 发光学报, 2019, 40(1): 109–117.
- [20] JIANG X, LI S. BAS: Beetle antennae search algorithm for optimization problems[EB/OL]. [2021–12–23]. <https://arxiv.org/abs/1710.10724>.
- [21] 梁光胜, 张安然. 基于优化 RBF 神经网络的体感温度建模[J]. 计算机应用研究, 2020, 37(S2): 161–163.