

基于多源信息融合的 RBF 神经网络室内可见光定位算法

王琪, 孟祥艳, 赵黎*

(西安工业大学 电子信息工程学院, 西安 710021)

摘要: 针对基于接收信号强度(RSS)的定位技术易受环境干扰而导致定位精度不高和稳定性较差的问题, 提出了一种基于多源信息融合的径向基函数(RBF)神经网络室内可见光定位算法。通过将图像的颜色矩特征与 RSS 矩特征融合, 构建指纹库, 并采用 RBF 神经网络进行预测, 实现了图像与 RSS 之间的优势互补, 最后对定位算法进行了验证。实验结果表明, 经过优化的多源信息融合定位算法较单一 RSS 定位算法的定位精度提高了 9.4%。

关键词: 可见光; 室内定位; 多源信息融合; 颜色矩; 神经网络; 径向基函数; 特征提取

中图分类号: TN929.1; TP212 **文献标志码:** A **文章编号:** 1002-5561(2024)02-0030-06

DOI: 10.13921/j.cnki.issn1002-5561.2024.02.006

开放科学(资源服务)标识码(OSID):



RBF neural network indoor visible light positioning algorithm based on multi-source information fusion

WANG Qi, MENG Xiangyan, ZHAO Li*

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

Abstract: Aiming at the problem of low positioning accuracy and poor stability caused by the environmental interference of the positioning technology based on received signal strength (RSS), an radial basis function (RBF) neural network indoor visible light positioning algorithm based on multi-source information fusion is proposed. By fusing the color moment feature of the image with the RSS moment feature, a fingerprint database is constructed, and the RBF neural network is used for prediction to achieve complementary advantages between the image and RSS. Finally, the positioning algorithm is verified. The experimental results show that the optimized multi-source information fusion positioning algorithm improves the positioning accuracy by 9.4% compared with the single RSS positioning algorithm.

Key words: visible light, indoor position, multi-source information fusion, color momentn, neural networks, radial basis function, feature extraction

0 引言

传统的室内可见光定位(VLP)技术^[1]因成本、设备部署等因素存在局限性。因此, 基于多源信息融合^[2]的室内定位技术逐渐受到研究者的关注, 成为室内定位的一个重要方向。文献[3]为解决发光二极管(LED)与光电探测器(PD)之间因辐射角度导致的光强采集问

题, 加入了角度特征融合建立模型, 输入卷积神经网络实现定位, 其平均定位误差为 4.16 cm, 但角度特征的精确采集较为困难。文献[4]结合了无线网络(WiFi)和蓝牙的信号强度数据以增强系统定位精度, 但此方法复杂度较高。文献[5]将信号强度数据与测距数据融合, 提出了基于接收信号强度(RSS)^[6]和到达时间(TOA)^[7]的分布式融合定位系统, 但该系统的光源会受到复杂环境的影响。文献[8]将红外与相机传感器融合, 利用红外和相机独立观测的数据, 通过极大似然估计来确定融合位置。但红外容易受到其它灯光的干扰, 同时红外线的传输距离较短。与此相比, 图像特征^[9]不会因周围环境遮挡光源而影响特征数据的采集。此外, 颜色矩相对于其它图像特征对图像的尺寸、方向、视角变化的依赖性较小, 提取的特征向量维数较少,

收稿日期: 2023-10-08。

基金项目: 陕西省科技厅一般项目-工业领域(No.2020GY-054)资助。

作者简介: 王琪(1999—), 陕西西安人, 女, 硕士研究生, 主要研究方向为无线光通信关键技术、神经网络、室内可见光定位技术、图像处理。曾获得国家级竞赛二等奖 1 项和省部级竞赛二等奖、三等奖各 1 项。

* 通信作者: 赵黎(1981—), 女, 博士, 教授, 硕士生导师, 主要研究方向为无线光通信关键技术。



更便于后续的特征融合。鉴于此,本文提出一种基于多源信息融合的RBF神经网络VLP算法,将RSS与图像的颜色矩特征融合处理,通过径向基函数(RBF)神经网络拟合得到高精度的室内定位结果。

1 室内VLP和LED光强信道模型

1.1 VLP模型

在长、宽、高分别为 l 、 w 、 h 的立体空间中,本文利用PD及图像传感器(IS)在水平地面采集各LED灯对应坐标点的RSS值及图像数据。假设立体空间顶部水平面均匀布设 a 个LED灯,则第 b 个LED灯的坐标($b \leq a$)可表示为

$$f_i = (x_b, y_b, h) \quad (1)$$

1.2 LED光强信道模型

信道模型中,安设在顶部的LED作为信号发射端,LED实际面积相对于测试环境整体面积可忽略不计,即可将LED看作朗伯光源。不同的LED均携带各自不同的身份标识(ID)信息,定位模型通过PD解析所接收的光信号以此获取LED位置与RSS值。

在视距传播(LOS)中,LOS信道增益 $H(0)$ 表达式为

$$H(0) = \frac{(\gamma+1)A}{2\pi d^2} T_l G \cos^\gamma \phi \cos \varphi \quad (2)$$

其中, A 为PD实际的有效面积, d 为LED与PD之间的直线距离, G 为聚光透镜增益, T_l 为光学滤波器的增益, ϕ 为相对于垂直轴的辐射角, φ 为相对于垂直轴的接收角。 γ 为朗伯光源阶数,其表达式为

$$\gamma = \frac{-\ln 2}{\ln(\cos \alpha_{1/2})} \quad (3)$$

其中, $\alpha_{1/2}$ 为发射机半功率角。

非视距传播(NLOS)中存在多径效应,根据反射次数分为一阶NLOS、二阶NLOS等,其中一阶NLOS对系统影响较大,因此本文只考虑一阶NLOS的影响。假设墙面上存在反射点,反射系数为 ρ ,则一阶NLOS对应的直流增益 $H(0)_{\text{NLOS}}$ 为


$$H(0)_{\text{NLOS}} = \frac{\gamma+1}{2\pi d_1 d_2^2} \rho \cos \varphi \cos^\gamma \phi A T_l \cos \alpha \cos \beta d_q \quad (4)$$

其中, d_1 、 d_2 分别为LED到反射点和反射点到接收端的距离, α 、 β 分别为LED到反射点的入射角和出射角, d_q 为反射点反射信号的面积微元。

2 基于多源信息融合的RBF神经网络室内VLP算法

基于多源信息融合的RBF神经网络室内VLP算

法主要分为离线建库训练阶段和在线测试定位阶段,其融合定位原理图如图1所示。



在离线建库训练阶段,首先分别将PD、IS置于实体模型底部的不同坐标处,采集对应图像数据和RSS,并记录采集处坐标 (x, y, z) 。随后,对采集到的图像进行预处理,并提取图像的颜色矩特征,将颜色矩特征数据与RSS融合作为特征输入到RBF神经网络模型中进行训练,利用位置坐标和融合特征数据之间具有的对对应关系完成算法的输入/输出流程,输出三维坐标位置。最后,逐步递增神经网络的训练次数,寻得误差最佳参数并保存该参数,以此得到稳定的算法模型。在在线测试定位阶段,首先在实验环境中实时采集RSS和颜色矩数据,经过处理后得到融合特征数据。然后,将这些数据输入到上一阶段已训练好的神经网络算法模型中,最终得到待测点的预测定位坐标结果。

2.1 融合源数据库构建

本文采用特征向量维数少的颜色矩特征^[10]作为融合源数据来源之一,通过计算低阶矩来描述颜色分布。具体而言,R、G、B颜色通道上分别计算3个颜色矩(一阶矩、二阶矩、三阶矩),共提取九维数据。一阶矩反映图像的明暗程度,二阶矩反映图像颜色分布范围,三阶矩反映图像颜色分布对称性。其中,一阶矩公式为

$$\mu_t = \frac{1}{N} \sum_{j=1}^N p_{t,j} \quad (5)$$

其中, $t=1,2,3$,分别表示R、G、B这3个颜色通道; μ_t 表示第 t 个颜色通道上所有像素的均值(一阶矩), $p_{t,j}$ 表示彩色图像第 t 个颜色通道分量中第 j 个图像像素值, N 表示单通道图像中总的像素数。

σ_t 为第 t 个颜色通道上所有像素的方差(二阶矩),其表达式为

王琪,孟祥艳,赵黎:基于多源信息融合的RBF神经网络室内可见光定位算法

$$\sigma_t = \left(\frac{1}{N} \sum_{j=1}^N (p_{t,j} - \mu_t)^2 \right)^{1/2} \quad (6)$$

s_t 为第 t 个通道上所有像素的斜度的三次方根(三阶矩),其表达式为

$$s_t = \left(\frac{1}{N} \sum_{j=1}^N (p_{t,j} - \mu_t)^3 \right)^{1/3} \quad (7)$$

所提取的颜色矩特征矩阵 W 可表示为

$$W = \begin{bmatrix} \mu_{1,1} & \sigma_{1,1} & s_{1,1} & \cdots & \mu_{3,1} & \sigma_{3,1} & s_{3,1} \\ \mu_{1,2} & \sigma_{1,2} & s_{1,2} & \cdots & \mu_{3,2} & \sigma_{3,2} & s_{3,2} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ \mu_{1,i} & \sigma_{1,i} & s_{1,i} & \cdots & \mu_{3,i} & \sigma_{3,i} & s_{3,i} \end{bmatrix} \quad (8)$$

其中, $\mu_{t,i}$ 、 $\sigma_{t,i}$ 、 $s_{t,i}$ 分别表示第 t 个颜色通道第 i 个采样点的一阶矩、二阶矩、三阶矩。

PD 接收的 RSS(P_{LOS}) 与 LED 光源的发射光功率 P_t 之间的关系为

$$P_{\text{LOS}} = P_t H(0) \quad (9)$$

而 PD 接收到 NLOS 分量中 RSS 为

$$P_{\text{NLOS}} = P_t H_{\text{NLOS}}(0) \quad (10)$$

此外,在可见光系统中,信道中的噪声也会对接收信号造成影响。加性噪声主要包括热噪声与散粒噪声, σ_a^2 、 σ_u^2 滤波器分别为前 2 种噪声对应的方差,则总噪声可表示为

$$\sigma_{\text{noise}}^2 = \sigma_a^2 + \sigma_u^2 \quad (11)$$

综上,同时考虑实际信道传输中所存在的各种因素,接收端 PD 最终接收到的 RSS 应为

$$P_r = P_{\text{LOS}} + P_{\text{NLOS}} + \sigma_{\text{noise}}^2 = R_{i,g} \quad (12)$$

其中, $R_{i,g}$ 表示在第 i 个坐标点所接收到第 g 个 LED 光源的 RSS。

提取的 RSS 特征矩阵 U 表示为

$$U = \begin{bmatrix} R_{1,1} & R_{1,2} & \cdots & R_{1,g} \\ R_{2,1} & R_{2,2} & \cdots & R_{2,g} \\ \vdots & \vdots & \ddots & \vdots \\ R_{i,1} & R_{i,2} & \cdots & R_{i,g} \end{bmatrix} \quad (13)$$

对于顶部安设 n ($n=1,2,3,4$) 个 LED 的实验环境,每条指纹信息由 n 个 RSS 值、经过随机筛选过后的六维颜色矩特征数和三维坐标 (x, y, z) 构成,则第 i 个坐标点所对应的指纹信息可表示为

$$H_i = (x_i, y_i, z_i, R_{i,1}, R_{i,2}, \cdots, R_{i,n}, \mu_{2,i}, \sigma_{2,i}, s_{2,i}, \mu_{3,i}, \sigma_{3,i}, s_{3,i}) \quad (14)$$

其中, x_i 、 y_i 和 z_i 表示第 i 个采样点相应三维坐标值。

2.2 RBF 神经网络训练与预测

基于神经网络的定位系统能够有效地模拟 VLP

系统中源数据与坐标之间的非线性关系。通过将多源信息构建的指纹库与人工神经网络相结合,该系统能够实现高精度的定位功能。在考虑参考点密度与融合源数据库数量的基础上,本文选择了 RBF 神经网络进行数据库的训练和预测工作。RBF 神经网络作为一种 3 层前馈神经网络,其特点是各层之间没有反馈机制,仅接受前一层的输出并传递给下一层。该网络在隐藏层使用了 RBF 作为传递函数,其网络结构如图 2 所示。




图2 基于RBF神经网络结构

在平面内等间隔地采集了 K 个样本后,随机从中选取了 F 个样本作为训练样本集。这个训练样本集被用作神经网络的输入,以训练出最佳定位模型。而未被选为训练样本的剩余 Z 个样本,则构成了测试样本集,用于对训练好的神经网络模型进行测试与性能分析,即训练集与测试集数据互不包含。神经网络的输入训练样本集矩阵 X^T 可表示为

$$X^T = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_F \end{bmatrix} = \begin{bmatrix} R_{1,1}, R_{1,2}, \cdots, R_{1,n}, \mu_{2,1}, \sigma_{2,1}, s_{2,1}, \mu_{3,1}, \sigma_{3,1}, s_{3,1} \\ R_{2,1}, R_{2,2}, \cdots, R_{2,n}, \mu_{2,2}, \sigma_{2,2}, s_{2,2}, \mu_{3,2}, \sigma_{3,2}, s_{3,2} \\ R_{3,1}, R_{3,2}, \cdots, R_{3,n}, \mu_{2,3}, \sigma_{2,3}, s_{2,3}, \mu_{3,3}, \sigma_{3,3}, s_{3,3} \\ \vdots \\ R_{F,1}, R_{F,2}, \cdots, R_{F,n}, \mu_{2,F}, \sigma_{2,F}, s_{2,F}, \mu_{3,F}, \sigma_{3,F}, s_{3,F} \end{bmatrix} \quad (15)$$

其中,每一行数据都代表某个采样点对应的指纹信息。

通过神经网络训练,得到输入矩阵所对应的输出矩阵 Y^T 可表示为

$$Y^T = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_F \end{bmatrix} = \begin{bmatrix} x_1 & y_1 & z_1 \\ x_2 & y_2 & z_2 \\ x_3 & y_3 & z_3 \\ \vdots & \vdots & \vdots \\ x_F & y_F & z_F \end{bmatrix} \quad (16)$$




图3 实验箱示意图

其中,每一行数据表示神经网络所预测的采样点坐标,测试集的输入、输出矩阵与训练集相同。

测试算法模型通过定位误差表示,定位误差为采样点实际位置坐标与神经网络预测坐标之间的欧氏距离,定位误差(处于水平地面情况,即 $h=0$)可表示为

$$e = \sqrt{(x-x')^2 + (y-y')^2} \quad (17)$$

其中, (x,y) 为采样点的实际坐标位置, (x',y') 为算法模型预测坐标位置。

测试算法模型采用迭代循环法,即利用RBF对输入和输出矩阵进行连续拟合训练,直到满足预定的误差要求。

3 实验结果与分析

3.1 实验环境搭建

为了验证所提算法模型的可行性及实际定位效果,本文搭建了如图3(a)所示的实验箱,用于进行算法模型的实验验证。实验中的关键参数如表1所示。在实验箱顶部,安装了4个功率均为5W的LED作为光源发射端,4个LED(LED₁~LED₄)的坐标分别为(0.2m,0.2m,0.8m)、(0.2m,0.6m,0.8m)、(0.6m,0.6m,0.8m)和(0.6m,0.2m,0.8m),其实物图如图3(b)所

表1 关键参数

参数	值
实验箱长/m、宽/m、高/m	0.8、0.8、0.8
光圈	F2.2
相机分辨率	2 532×1 170
LED 功率/W	5
PD 实际接收面积/cm ²	1
激活函数	RBF

示。实验箱底部为采样区域,设计成间隔5cm的网格坐标系,如图3(c)所示。底部采样区域的实际面积为0.8m×0.8m,等间隔划分为224个坐标点,在每个采样点利用PD和IS分别重复采样获取相应数据。在实际采集数据时,由于移动图像采集设备的体积较大,摄像头在采样区域的两侧无法垂直向上采集图像,这导致了一定的空间限制。因此,在实验过程中,需要排除两侧采样点的采集数据,以减小定位误差。

3.2 定位结果与分析

3.2.1 颜色通道选择分析

随机选择2种颜色通道的低阶矩作为图像特征输入,将R、G、B这3种颜色通道随机组合为3组,分别作为最终颜色矩信息构建融合源指纹库,得到定位结果如图4所示。可以看出,GB颜色通道组合在相同环境下的定位表现最为稳定,最大误差为0.0746m,最小误差为0.0368m,平均误差为0.0437m。因此,本文采用G、B这2种颜色通道上的3个低阶颜色矩作为图像特征参与融合源指纹库的构建。




图4 不同颜色通道组合定位对比图

3.2.2 定位精度分析

本文对 21 组测试数据分别采用了 RSS 定位算法和本文所提算法进行定位测试, 定位结果对比图如图 5 所示。根据图 5 中的数据, 采用式(17)计算可得, RSS 定位算法的定位误差为 0.045 6 m, 而所提算法的定位误差为 0.041 7 m。与 RSS 定位算法相比, 本文所提算法的定位精度提高了 9.4%。




图 5 定位结果对比图

采用式(17)的计算方法, 本文不仅得出了该定位算法的误差, 并进一步推导了误差的累积分布(CDF)情况, 如图 6 所示。可以看出, 本文所提算法的误差累积分布在 3.5 cm 内达到了 85.13%, 相比之下, RSS 定位算法在同一误差范围内的累积分布仅为 58.63%。此外, 本文还得到了不同算法误差所占比例的直方图如图 7 所示。可以看出, 本文所提算法的主要误差集中在 0~0.03 m 内, 而 RSS 定位算法的定位误差主要分布在 0.03~0.06 m 内。




图 6 2 种算法累计误差分布图

因此, 采用本文算法后的模型在定位精度上更胜一筹, 验证了所提算法的可行性与高精度定位性能。




图 7 2 种算法误差所占比例直方图

3.2.3 稳定性分析

首先, 在 LED₃ 被遮挡的复杂环境下, 对比了本文所提算法与 RSS 定位算法的定位性能。实验过程中, 本文模拟了实际应用中的遮挡场景, 通过人为遮挡 LED₃ 来构建实验环境。随后, 利用 PD 和 IS 设备分别采集 RSS 数据和图像数据, 构建了单一的 RSS 指纹信息库和融合源指纹信息库。在相同环境下, 得到定位结果对比图如图 8 所示。根据图 8 中的数据, 采用式(17)计算可得, 采用本文所提算法 RSS 定位算法时的平均定位误差分别为 0.053 14m、0.071 49 m。





图 8 2 种算法定位结果对比图(遮挡 LED₃)

接着, 为了进一步测试本文所提算法在更多 LED 遮挡情况下的误差情况, 增加了 LED₂ 的遮挡, 并重复了上述实验, 实验结果如图 9 所示。根据图 9 中的数据, 采用式(17)计算可得, 在遮挡 2 个 LED 后, 本文所提算法的平均定位误差为 0.112 6 m, 而 RSS 定位算法已失去定位能力(定位位置与实际位置相差较远)。

综上所述, 当处于复杂环境中时, RSS 定位算法难以满足定位需求。然而, 通过采用基于多源信息融合

图9 2种算法定位结果对比图(遮挡LED₂、LED₃)

技术的定位算法,则可以有效减轻因单一光强被遮挡时对定位产生的负面影响。

4 结束语

本文基于室内复杂环境结构和障碍物对光强数据采集的干扰情况,结合图像特征本身所具备的特征稳定性,提出了一种基于多源信息融合的RBF神经网络室内VLP算法。该算法旨在利用图像特征来弥补单一光强信息源在定位方面的局限,从而提升定位算法的整体性能。此外,算法还采用RBF神经网络来解决LED光源的非线性问题,并通过将光源视为朗伯模型来进一步优化训练算法模型,进而减少定位误差。在算法实现过程中,本文选择了具有向量维数简洁、数据可视化等优点的颜色矩特征作为图像特征。经过维数筛选后,将最终的颜色矩特征向量与光强数据融合,构建了融合源指纹库,并完成了神经网络算法模型的搭建。在基于0.8 m×0.8 m×0.8 m的立体模型中进行的测试表明,所提算法的平均误差约为4.1 cm,相较于RSS定位算法,其定位精度提升了9.4%。同

时,该算法还具备良好的稳定性,为室内VLP算法提供了更加可行的解决方案。

参考文献:

- [1] ROURAY S K. The changing trends of optical communication [J]. IEEE Potentials, 2014, 33(1): 28–33.
- [2] GUO X, ANSARI N, HU F, et al. A survey on fusion-based indoor positioning[J]. IEEE Communications Surveys & Tutorials, 2019, 22(1): 566–594.
- [3] YIN L, WU X, HAAS H. Indoor visible light positioning with angle diversity transmitter [C]//IEEE. Proceedings of 2015 IEEE 82nd Vehicular Technology Conference (VTC2015-Fall). Boston: IEEE, 2015: 1–5.
- [4] GALVN-TEJADA C E, CARRASCO-JIMNEZ J C, BRENA R F. Bluetooth-WiFi based combined positioning algorithm, implementation and experimental evaluation[J]. Procedia Technology, 2013, 7: 37–45.
- [5] VELDE S V D, ARORA G, VALLOZZI L, et al. Cooperative hybrid localization using Gaussian processes and belief propagation [C]//IEEE. Proceedings of 2015 IEEE International Conference on Communication Workshop (ICCW). London: IEEE, 2015: 785–790.
- [6] 冯越, 冯莉芳, 金建力, 等. 基于区域划分的自适应可见光定位算法研究[J]. 光子学报, 2022, 51(3): 223–235.
- [7] 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.
- [8] MARTIN-GOROSTIZA E, GARCA-GARRIDO M A, PIZARRO D, et al. An indoor positioning approach based on fusion of cameras and infrared sensors[J]. Sensors, 2019, 19(11): 2519–2549.
- [9] 陶建武. 基于单目视觉的静止目标定位方法[J]. 光子学报, 2016 (10): 122–129.
- [10] MALIK F, BAHARUDIN B. Features analysis for content-based image retrieval based on color moments[J]. Research Journal of Applied Sciences, Engineering and Technology, 2012, 4(9): 1215–1224.
- [11] ILIYAS S A, ELSHAFEI M, HABIB M A, et al. RBF neural network inferential sensor for process emission monitoring [J]. Control Engineering Practice, 2013, 21(7): 962–970.
- [12] CHANG C C, HUANG H T. Automatic tuning of the RBF kernel parameter for batch-mode active learning algorithms: a scalable framework[J]. IEEE Transactions on Cybernetics, 2018, 49(12): 4460–4472.