

基于 Bi-LSTM 神经网络的室内可见光定位方法

王乐乐, 秦岭*, 胡晓莉, 赵德胜

(内蒙古科技大学 信息工程学院, 内蒙古 包头 014010)

摘要: 双向长短期记忆(Bi-LSTM)神经网络由于超参数众多, 难以获得最优系统模型。同时, 考虑到灰狼优化(GWO)算法可能过早收敛的情况, 提出了一种采用 GWO 结合粒子群(GWO-PSO)算法优化 Bi-LSTM 神经网络的单灯定位方法。通过优化网络中的学习率、隐藏神经元个数等超参数, 提高系统的稳定性和定位精度。最后, 采用加权 K 邻近(WKNN)算法对误差较大的点进行优化, 以获得更精确的定位位置。仿真结果表明, 在 $3\text{ m} \times 3.6\text{ m} \times 3\text{ m}$ 的室内环境中, 所提定位方法的平均定位误差为 3.57 cm, 其中 90% 的定位误差在 6 cm 内。

关键词: 可见光定位; 双向长短期记忆; 灰狼结合粒子群; 加权 K 近邻

中图分类号: TN929.1 **文献标志码:** A **文章编号:** 1002-5561(2024)02-0036-06

DOI: 10.13921/j.cnki.issn1002-5561.2024.02.007

开放科学(资源服务)标识码(OSID):

Indoor visible light positioning
method based on Bi-LSTM neural network

WANG Lele, QIN Ling*, HU Xiaoli, ZHAO Desheng

(School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou Inner Mongolia 014010, China)

Abstract: Due to the large number of hyperparameters, it is difficult to obtain the optimal system model for the bidirectional long short-term memory (Bi-LSTM) neural network. At the same time, considering the possibility of premature convergence in the Grey Wolf optimizer (GWO) algorithm, a single-lamp localization method using the GWO combined with particle swarm optimization (GWO-PSO) algorithm to optimize the Bi-LSTM neural network is proposed. By optimizing hyperparameters such as the learning rate and the number of hidden neurons in the network, the stability and positioning accuracy of the system are improved. Finally, the weighted K-nearest neighbors (WKNN) algorithm is used to optimize points with large errors to obtain more accurate positioning locations. The simulation results show that in an indoor environment of $3\text{ m} \times 3.6\text{ m} \times 3\text{ m}$, the average positioning error of the proposed localization method is 3.57 cm, with 90% of the positioning errors within 6 cm.

Key words: visible light positioning, bidirectional long short term memory, Grey Wolf combined with particle swarm optimization algorithm, weighted K-nearest neighbor

0 引言

随着人们对室内定位需求的日益增加, 研究人员

收稿日期: 2023-03-11。

基金项目: 国家自然科学基金项目(62161041)资助; 内蒙古自治区应用技术与开发资金项目(2021GG0104)资助。

作者简介: 王乐乐(1999—), 女, 汉族, 硕士研究生, 现就读于内蒙古科技大学信息工程学院电子信息(电子与通信工程)专业, 主要研究方向为基于人工智能的定位算法和室内可见光定位。

* **通信作者:** 秦岭(1979—), 女, 汉族, 博士, 教授, 硕士生导师, 主要研究方向为光通信技术、光定位系统、基于人工智能的定位算法和光信息处理。



开发出了一些常见的定位技术, 如红外、无线网络通信(WiFi)、射频识别(RFID)、蓝牙等。然而, 这些技术存在成本较高、定位误差较大和易受到其它信号干扰的问题。相比之下, 可见光具有保密性高、成本低、高精度定位等特点, 已成为现阶段的研究热点^[1-2]。近年来, 随着人工智能技术的日益成熟, 结合人工智能的室内定位研究不仅成为了热点, 还取得了显著的进展。2019 年, 史明泉等人^[3]基于粒子群优化(PSO)算法设计了一种单发光二极管(LED)灯的室内定位系统。该系统通过使用单个 LED 灯作为光源, 避免了多个 LED 光源信号之间可能产生的相互干扰, 不仅部署简

单,而且定位精度高达 13.67 cm。2020 年, HAN W 等人^[4]提出了一种基于 M5 模型树(M5Tree)的迭代算法,该算法利用单个 LED 和多个光电探测器(PD)实现室内定位,并评估了树的最大深度和迭代次数对定位精度的影响,在单个 LED 定位系统中具有良好的定位性能。2021 年, HASAN A B 等人^[5]提出了使用加权 K 近邻(WKNN)算法进行基于接收信号强度(RSS)的指纹识别定位,并发现使用少于 3 个 LED 灯即可实现定位,且 WKNN 算法的定位精度优于多层感知器(MLP)。然而,这些文献中的方法均采用单一算法进行定位,因此可能面临定位精度和稳定性不高的问题。为了解决这个问题,本文提出一种基于双向长短时记忆(Bi-LSTM)神经网络的室内可见光定位方法,使用灰狼优化结合粒子群(GWO-PSO)算法^[6-9]对 Bi-LSTM 神经网络进行优化,利用 WKNN 算法对定位误差较大的点进行修正,以降低系统的最大定位误差和平均定位误差,从而实现更精准的定位。

1 室内可见光定位系统

针对单 LED 场景,本文使用的室内可见光定位系统如图 1 所示。LED 作为发射器,被放置在空间天花板的中心,接收器包括 3 个倾斜 PD 和 1 个水平 PD,倾斜 PD 的方位角分别为 90° 、 180° 、 270° ,摆放角 ω_1 、 ω_2 、 ω_3 分别为 0° 、 90° 、 180° ,倾斜角 α 为 25° ,水平 PD 与倾斜 PD 之间的距离 r 为 5.3 cm。待测点位于水平 PD 处,具体如图 2 所示。




图 1 室内可见光定位系统

由于光源辐射分布满足朗伯辐射模型,所以可见光视距传播(LOS)链路的信道增益^[10]可表示为

$$H_{\text{LOS}} = \begin{cases} \frac{A_r(m+1)}{2\pi L^2} \cos^m(\varphi) T_s(\psi) g(\psi) \cos\psi, & 0 \leq \psi \leq \psi_c \\ 0, & \psi > \psi_c \end{cases} \quad (1)$$

其中, L 为 LED 光源到 PD 的距离, A_r 为 PD 实际的接收面积, ψ 为 PD 的入射角, φ 为 LED 的发射角, $T_s(\psi)$ 为光学滤波器增益, $g(\psi)$ 为光学聚光器增益, ψ_c 为 PD 的接收视场角 FOV。定位系统参数如表 1 所示。




图 2 接收器摆放示意图

表 1 室内可见光定位系统参数

参数名称	参数值
LED 发射功率 P/W	10
PD 接收面积 A_r/mm^2	3
视场角 $\psi_c/(\circ)$	90
LED 的半功率半角 $\varphi_{1/2}/(\circ)$	45
光学滤波增益 $T_s(\psi)$	1
透镜的折射率 n	1.5

2 基于 Bi-LSTM 神经网络的室内可见光定位方法

2.1 Bi-LSTM 神经网络

递归神经网络(RNN)的输出结果不仅依赖于当前的输入,还与过去的输入紧密相关,且还存在梯度消失^[11]问题。为了解决这一问题,长短时记忆(LSTM)神经网络^[12-13]应运而生,它通过增加门控单元来筛选并保留有用信息,从而确保这些信息在序列中得以保留。这样,LSTM 就能有效避免长期依赖和早期有用信息丢失的问题。进一步地,Bi-LSTM 神经网络结合了前向和后向的 LSTM,使其能够更全面地捕捉数据的双向特征,从而利用过去的特征来预测未来的特征^[14]。

为了比较 LSTM 和 Bi-LSTM 这 2 种神经网络的定位精度,本文在 $3\text{ m} \times 3.6\text{ m} \times 3\text{ m}$ 的仿真环境下进行了实验。实验中使用 PD 采集单个 LED 发出的可见光信号。每组测得的数据包括 4 个 PD 接收到的光功率值和 1 个坐标点。这些数据被分为训练集和测试集。训练集在横坐标上以 0.15 m 为间隔,纵坐标上以 0.12 m 为间隔进行划分,共形成 21×31 组数据。测试集在横坐标上以 0.28 m 为间隔,纵坐标上以 0.15 m 为间隔进行划分,共形成 11×25 组数据。整个实验共获得了 926 组数据。为了公平比较,2 种神经网络的参数设置

王乐乐, 秦岭, 胡晓莉, 等: 基于 Bi-LSTM 神经网络的室内可见光定位方法

相同: 迭代次数为 500, 学习率为 0.005, 隐藏神经元 m_1 、 m_2 分别为 250、95。随后, 利用训练集分别训练了 2 个 LSTM 神经网络和 2 个 Bi-LSTM 神经网络。接着, 将测试集的数据输入到训练好的 LSTM 和 Bi-LSTM 神经网络中, 输出预测坐标点。最终, 得到了 2 种神经网络预测位置和真实位置的对比图分别如图 3、图 4 所示。




图 3 LSTM 神经网络预测位置和真实位置对比图




图 4 Bi-LSTM 神经网络预测位置和真实位置对比图

从图 3、图 4 可以看出, Bi-LSTM 神经网络的四周区域定位误差相较 LSTM 神经网络下降较为明显, 中心区域误差更小。因此, Bi-LSTM 神经网络的定位性能优于 LSTM 神经网络。

2.2 GWO-PSO 算法

GWO 算法通过模拟大自然中灰狼的等级制度与狩猎行为来实现参数寻优。首先, 算法初始化一定数量的灰狼群体, 并随机分布在搜索空间内; 接着, 计算每个灰狼的适应度值, 以确定它们的优劣; 然后, 选出适

应度最高的灰狼作为当前群体的“领袖”, 计算其它灰狼在某种程度上“受领袖的影响”, 即通过某种函数变换来更新其位置和适应度值; 最后, 判断是否满足停止准则, 若不满足则重新选择适应度最高的灰狼。在 GWO 算法中, 灰狼的社会等级制度按照降序排列, 依次为 α 、 β 、 δ 和 ω 。这些不同等级的灰狼在参数寻优过程中发挥着重要作用, 其中 α 、 β 、 δ 狼起着主导作用。通过这种等级制度, GWO 算法能够有效地在搜索空间内寻找最优参数^[15-17]。为了防止 GWO 算法过早收敛, 文献[16]提出了将 GWO 算法与 PSO 算法相结合的策略, 即将 PSO 算法中的位置更新方法引入到 GWO 算法中, 以此替代原有的灰狼位置更新方式。根据式(2), 可以得到经过这种改进后的灰狼新位置为

$$X_i^d(t+1) = \frac{1}{3} \left[\sum_{j=\alpha, \beta, \delta} X_{i,j}^d + v_i^d(t) \right] \quad (2)$$

其中, t 、 d 分别为当前迭代次数和在 D 维搜索空间中第 d 维的灰狼, $k < D$; $i=1, 2, 3, \dots, N$, $v_i^d(t)$ 为灰狼个体速度。

本文通过对 GWO-PSO、GWO 和 PSO 这 3 种算法的性能进行对比, 得到了它们的误差累积分布函数 (CDF) 图, 如图 5 所示。可以看出, GWO-PSO 算法中有 90% 的定位误差小于 8 cm, 最大定位误差为 20.59 cm; PSO 算法中有 90% 的定位误差小于 1.12 cm, 最大定位误差为 28.69 cm; 而 GWO 算法中有 90% 的定位误差小于 12.26 cm, 最大定位误差为 50.13 cm。由此可见, GWO-PSO 算法的性能优于 PSO 算法和 GWO 算法。




图 5 3 种算法定位误差累积分布图

2.3 WKNN 算法

WKNN 算法是在 K 近邻 (KNN) 算法^[18]的基础上对 k 个参考点进行加权处理。本文采用欧式距离作为计算依据, 首先计算参考点和测量点之间的距离, 以此

来表征近邻程度^[6]。通过 Bi-LSTM 神经网络预测定位误差后, 为了修正个别较大的误差点, 本文进一步找出误差大于 0.095 m 的点 Z_B 。设 Z_B 的光功率指纹为 $U_B = [P_{B,1}, P_{B,2}, P_{B,3}, P_{B,4}]^T$, 其中, $P_{B,1}, P_{B,2}, P_{B,3}, P_{B,4}$ 为第 B 个采样点 4 个 PD 的光功率; 参考点 Z_i 的光功率指纹为 $U_i = [P_{i,1}, P_{i,2}, P_{i,3}, P_{i,4}]^T$, 其中, $P_{i,1}, P_{i,2}, P_{i,3}, P_{i,4}$ 为第 i 个采样点 4 个 PD 的光功率。计算 Z_B 与所有参考点光功率的欧式距离 L_i 为

$$L_i = \sqrt{(U_B - U_i)^2} \quad (3)$$

然后, 按照距离 L_i 升序排列, 为前 k 个参考点分配权重, 权重为 $1/(L_i + \varepsilon)$, ε 为常量。

最后, 利用式(4)来计算修正后的坐标^[17]。

$$(x_{B,1}, y_{B,1}) = \frac{\sum_{i=1}^k [1/(L_i + \varepsilon)] (x_i, y_i)}{\sum_{i=1}^k 1/(L_i + \varepsilon)} \quad (4)$$

其中, (x_i, y_i) 为第 i 个参考点坐标。

本文针对角落与 y 轴两侧区域的部分误差较大的点使用 WKNN 算法对其进行优化。为比较不同 k 值对结果的影响, 将 k 从 0~5 取值并对平均定位误差和最大误差进行对比, 图 6 为不同 k 值的平均定位误差图和最大误差图。其中, $k=0$ 表示未使用 WKNN 算法的平均定位误差和最大定位误差。可以看出, $k=1$ 时系统的平均定位误差、最大定位误差均最小, 分别为 3.57、20 cm。因此, 考虑不同 k 值对平均定位误差和最大误差的影响时, 本文选择 k 值为 1。




图 6 不同 k 值的平均定位误差和最大定位误差图

为降低最大定位误差, 本文采用 WKNN 算法对误差较大点进行修正, 得到不同待修正点的最大定位误差和平均定位误差对比图如图 7 所示。可以看出, 当选择待修正点大于 0.08 m 时, 系统的平均定位误差最小为 0.034 7 m, 最大定位误差为 0.143 m; 当选择待修正点大于 0.095 m 时, 系统的平均定位误差、最大定位误差的最小值分别为 0.035 7、0.095 m。修正结果表明,




图 7 不同待修正点的最大定位误差和平均定位误差对比图

当待修正点大于 0.095 m 时, 最大定位误差较待修正点大于 0.08 m 时降低了 4.8 cm, 而两者的平均定位误差相差 1 mm。综合考虑, 本文将定位误差大于 9.5 cm 的点视为拖累点, 并对其进行修正。

2.4 GWO-PSO-Bi-LSTM-WKNN 算法流程

为了提高室内可见光定位系统的精度, 本文首先在离线阶段采用了 GWO-PSO 算法^[15-17]对 Bi-LSTM 神经网络进行优化, 将最优超参数引入 Bi-LSTM 神经网络中, 并采用位置指纹数据训练优化后的神经网络; 然后, 在线阶段, 将采集到的测试集位置指纹数据引入训练好的神经网络进行预测, 得到预测坐标; 最后, 再利用 WKNN 算法^[18,6-7]对误差较大的点进行位置修正, 将修正好的点更新到预测坐标中, 从而降低整体误差, 提高定位精度。GWO-PSO-Bi-LSTM-WKNN 算法流程如图 8 所示。

3 算法性能仿真结果与分析

本文以表 1 的参数值为依据, 基于 Bi-LSTM 神经网络的 GWO-PSO 算法 (GWO-PSO-Bi-LSTM), 对采用 WKNN 算法修正 (GWO-PSO-Bi-LSTM-WKNN) 前后的系统性能进行了仿真。

图 9 为采用 WKNN 算法修正前后的误差累计分布对比图。可以看出, 经过 WKNN 算法修正后, 90% 的定位误差小于 6 cm, 而未经修正的定位误差则有 90% 在 8 cm 以内。大部分原本较大的误差点被修正到了 6 cm 以内, 修正后系统的定位精度得到了显著提升。

图 10、图 11 分别为 GWO-PSO-Bi-LSTM、GWO-PSO-Bi-LSTM-WKNN 预测的 3D 定位误差图。

从图 10、图 11 可以看出, 最大误差由 0.206 m 降到 0.094 5 m; 误差较大的一侧下降, 与较小一侧误差基本相同, 甚至有的点误差更小。

为了更清晰地观察 WKNN 算法对定位性能的改

王乐乐, 秦岭, 胡晓莉, 等: 基于 Bi-LSTM 神经网络的室内可见光定位方法




图8 GWO-PSO-Bi-LSTM-WKNN 算法流程图




图9 进行位置修正前后的误差累计分布对比图




图10 GWO-PSO-Bi-LSTM 预测的 3D 定位误差图




图11 GWO-PSO-Bi-LSTM-WKNN 预测的 3D 定位误差图




图12 GWO-PSO-Bi-LSTM 预测的位置对比图

进, 本文绘制了使用 WKNN 算法前后的位置对比图, 如图 12、图 13 所示。

从图 12 可知, 经 GWO-PSO 算法优化后的 Bi-LSTM 神经网络较单一 Bi-LSTM 神经网络(图 5)整体及四周区域的定位误差明显降低, 部分点经优化后甚至与真实位置坐标完全重合, 仅角落与 Y 轴两侧区域

王乐乐,秦岭,胡晓莉,等:基于 Bi-LSTM 神经网络的室内可见光定位方法




图 13 GWO-PSO-Bi-LSTM-WKNN 预测的位置对比图

部分点误差较大。从图 13 可以看出, WKNN 算法的修正效果明显, 角落与 Y 轴两侧误差较大的点得到了修正, 角落和房间边界误差明显降低。优化算法对四周区域优化效果明显, 而中心区域优化效果不明显。因此, 优化后的神经网络预测误差最小点不在空间中心区域。

为验证本文所提定位方法的优越性, 与其它 3 种不同定位方法进行了对比, 结果如表 2 所示。

表 2 不同方法的定位性能对比

定位方法	90%的定位误差/cm	平均定位误差/cm
Elman 神经网络 结合 WKNN ^[18]	<8.38	7.13
深度神经网络 结合 WKNN ^[19]	<8.98	—
改进的加权 K 最近邻算法 ^[20]	<30	16.3
GWO-PSO-Bi-LSTM-WKNN	<6.00	3.57

从表 2 可知, 本文所提的定位方法的平均定位误差为 3.57 cm, 其中 90% 的定位误差在 6 cm 内。对比结果表明, 本文提出的定位方法的精度要优于其它定位算法。

4 结束语

本文提出了一种利用 GWO-PSO 算法优化 Bi-LSTM 神经网络的超参数, 并用 WKNN 算法对误差较大的点进行修正的室内定位方法。仿真结果表明: 本文所提定位方法的平均定位误差为 3.57 cm, 其中

90% 的定位误差在 6 cm 内, 与其它室内可见光定位算法相比, 本文所提定位方法的定位误差更小, 更具有鲁棒性。

参考文献:

- [1] 秦岭, 王东星, 史明泉, 等. 基于遗传算法优化 ELM 神经网络的室内可见光定位系统[J]. 中国激光, 2022, 49(21): 151-160.
- [2] 王皓. 面向会话数据的推荐算法研究[D]. 济南: 齐鲁工业大学, 2022.
- [3] 史明泉, 崔丽珍, 秦岭, 等. 基于粒子群优化的单 LED 室内可见光定位系统[J]. 激光杂志, 2020, 41(5): 31-34.
- [4] HAN W, WANG J, PKLUH M K, et al. Visible light indoor positioning via an iterative algorithm based on an M5 model tree [J]. Applied Optics 2020, 59(32): 10194-10200.
- [5] HASAN A B K, TYREL G, YAN T H. Accurate visible light positioning using multiple-photodiode receiver and machine learning [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-12.
- [6] 毕京学, 汪云甲, 纪冬华, 等. RSS 最小值动态补偿的室内 WKNN 指纹定位方法[J]. 测绘科学, 2020, 45(12): 22-27.
- [7] 秦岭, 张崇泰, 郭瑛, 等. 基于 Elman 神经网络的可见光室内定位算法研究[J]. 光学学报, 2022, 42(5): 24-31.
- [8] 于海越. 高精度室内可见光定位技术研究[D]. 吉林: 吉林化工学院, 2022.
- [9] 陈亮, 王震, 王刚. 深度学习框架下 LSTM 网络在短期电力负荷预测中的应用[J]. 电力信息与通信技术, 2017, 15(5): 8-11.
- [10] 王辉. 基于位置指纹的室内可见光定位方法研究[D]. 西安: 西安电子科技大学, 2018.
- [11] 陈文星. 基于智能优化算法的室内可见光定位技术研究 [D]. 北京: 北京邮电大学, 2020.
- [12] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(S2): 1-6, 26.
- [13] 段中兴, 温情, 周孟, 等. 基于改进蝙蝠算法优化 LSTM 网络的短时客流预测[J]. 铁道科学与工程学报, 2021, 18(11): 2833-2840.
- [14] 马夫花. 基于机器学习的室内定位技术研究[D]. 哈尔滨: 黑龙江大学, 2021.
- [15] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69(3): 46-61.
- [16] 李真, 王帆, 王冉珺. 一种结合灰狼算法的粒子群优化算法[J]. 计算机测量与控制, 2021, 29(10): 217-222.
- [17] 杨寒石, 吴皓月, 孔德贵. 一种优化的灰狼算法[J]. 黑龙江大学自然科学学报, 2022, 39(2): 238-245.
- [18] 赵万祥, 张远进, 李晓荣. 基于 LSTM 神经网络的缺失数据随机功率谱估计 [J]. 武汉理工大学学报 (信息与管理工程版), 2022, 44(6): 993-998.
- [19] SH O H, KIM J G. AI-based positioning with input parameter optimization in indoor VLC environments [J]. Sensors, 2022, 22 (21): 8125-8138.
- [20] 梁哲豪, 石磊, 唐杰, 等. 室内可见光指纹定位系统中改进的加权 K 最近邻算法[J]. 激光与光电子学进展, 2022, 59(17): 123-127.