

基于 Elman 神经网络的可见光室内定位算法研究

秦岭, 张崇泰, 郭瑛, 徐艳红, 王凤英, 胡晓莉*

内蒙古科技大学信息工程学院, 内蒙古 包头 014010

摘要 近年来,室内定位算法吸引了大量的关注和研究。为了改善现有定位算法的复杂度以及精确度等问题,提出了一种先利用 Elman 神经网络进行室内位置预测,使用加权 K 近邻算法(WKNN)对预测结果进行修正的可见光室内定位算法。该算法应用在由单 LED 灯作为发射器,4 个水平光电探测器(PD)构成接收器的室内定位系统中。4 个水平光电探测器分别位于接收器的 4 个角,待测位置位于接收器的中心。通过两个 Elman 神经网络分别预测待测点的横坐标和纵坐标来确定待测点的初步位置,找出定位误差大于神经网络预测平均误差的待测点,用加权 K 近邻算法进行修正来确定待测点的精确位置,将修正后的精确位置更新到整体待测点的位置中。仿真结果表明,在 $3.6\text{ m}\times 3.6\text{ m}\times 3\text{ m}$ 的室内环境下,本研究算法的平均定位误差为 7.13 cm ,平均定位时间为 0.24 s 。

关键词 光通信; Elman 神经网络; 加权 K 近邻; 室内定位; 误差修正

中图分类号 TN929.12

文献标志码 A

doi: 10.3788/AOS202242.0506002

Research on Visible Light Indoor Localization Algorithm Based on Elman Neural Network

Qin Ling, Zhang Chongtai, Guo Ying, Xu Yanhong, Wang Fengying, Hu Xiaoli*

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

Abstract In recent years, indoor localization algorithms have attracted a great deal of attention and research interest. For the improvement of the complexity as well as the accuracy of existing localization algorithms, this paper proposes a visible light indoor localization algorithm that first uses Elman neural networks for indoor localization prediction and then uses the weighted K-nearest neighbor (WKNN) algorithm to correct the prediction results. The algorithm is applied in an indoor localization system with a single LED as a transmitter and four horizontal photoelectric detectors (PDs) as receivers. The four horizontal PDs are located at the four corners of the receiver and the position to be measured is located at the center of the receiver. The initial position of the point to be measured is first determined by predicting the horizontal and vertical coordinates of the point by two Elman neural networks. Then the point to be measured with a positioning error greater than the average error predicted by the neural network prediction is identified and corrected with the WKNN algorithm to determine the exact position of the point to be measured, and the corrected position is updated into the overall position of the point to be measured. The simulation results show that the average positioning error of this algorithm is 7.13 cm and the average positioning time is 0.24 s in an indoor environment of $3.6\text{ m}\times 3.6\text{ m}\times 3\text{ m}$.

Key words optical communications; Elman neural network; weighted K-nearest neighbor; indoor localization; error correction

收稿日期: 2021-07-19; 修回日期: 2021-08-25; 录用日期: 2021-09-10

基金项目: 国家自然科学基金(62161041, 61661044)、内蒙古自然科学基金(2019LH06005)、内蒙古关键技术攻关项目(2021GG0104)

通信作者: *huxiaoli@imust.edu.cn

1 引言

随着移动互联网的快速普及,对位置信息的获取已经变得必不可少。目前室外位置信息的获取技术已经较为成熟,而由于无线信号的传播特性和室内环境的复杂性,获取精确的室内位置信息还比较困难^[1]。目前,基于红外、超声波、超宽带的室内定位技术实现成本较高,基于无线网络、射频识别的室内定位技术容易受到多径效应和干扰的影响,故定位精度较低^[2-4]。可见光通信技术作为一种新颖的技术逐渐走进人们的视野,它不仅具有通信和照明的功能,还能实现室内定位功能。可见光定位技术具有灵敏度高、无电磁干扰等优点,适用于医院、煤矿井下、机场等对电磁敏感的区域^[5-6]。

传统的定位方法包括基于到达时间(TOA)、到达时间差(TDOA)、到达角度(AOA)、接收信号强度(RSS)等定位方法^[7-10],基于RSS的定位方法实现简单并且不需要复杂的设备,因此成为了可见光室内定位中常用的方法^[11-13]。为了获得更好的定位性能,学术界将机器学习方法引入到可见光室内定位中。目前常用于可见光室内定位的机器学习方法有聚类、人工神经网络和多分类器融合等^[14-16]。徐岩等^[17]提出了一种基于多层极限学习机(ELM)的分区域可见光室内定位算法,该算法根据定位误差大小和分布特征对定位区域进行了分区,建立多层极限学习机有效降低了边界区域的定位误差,但分区过程和建立多层极限学习机的步骤复杂且耗费时间较多。肖佳琳等^[18]先采用遗传算法对反向传播(BP)神经网络进行优化,然后采用优化后的BP神经网络对信道两端的距离进行修正,最后经过计算实现对室内目标的定位。经过遗传算法优化的BP神经网络收敛速度快,不易陷于局部最优,遗传算法参数的选择对优化效果起着重要的作用,但是目前遗传算法的参数选择尚未有定量方法,选择遗传算法最优参数的过程较为繁琐。王正等^[19]设计了一种基于BP神经网络的可见光室内定位系统,利用光照度接收装置采集实验数据,利用BP神经网络处理实验数据。虽然能够在室内实现定位,但利用BP神经网络实现的定位精度不高。目前,人工神经网络在可见光室内定位中的应用较为单一且存在个别点预测精度较低进而影响整体定位误差的问题。

综上所述,本研究提出了一种基于Elman神经网络的可见光室内定位算法。Elman神经网络是一

种典型的局部回归网络,其网络基本结构类似于BP神经网络,不同之处在于Elman神经网络在基本的网络结构上加了一个承接层,从而增加了网络的计算能力和联想记忆功能。Elman神经网络能够以任意精度逼近任意非线性映射,在处理非线性关系问题方面具有较强的能力。因此,本研究先采用Elman神经网络对待测点的坐标进行预测,再采用加权K近邻算法对Elman神经网络预测误差较大的个别点进行修正,从而降低整体的定位误差。

2 室内定位模型

室内定位模型如图1所示,LED灯安放在室内顶部的中心作为发射器,接收器形状为一正方形,4个PD分别位于接收器的4个角,待测位置位于接收器的中心。




图1 可见光室内定位模型

Fig. 1 Visible light indoor positioning model

在不考虑一次反射及多次反射的情况下,接收器 PD_n ($n=1, 2, 3, 4$)的接收功率 P_r 与LED的发射功率 P_t 的关系可表示为

$$P_r = P_t \cdot H, \quad (1)$$

式中, H 为直射链路的信道增益。由于LED的辐射服从朗伯分布, H 可表示为

$$H = \begin{cases} \frac{m+1}{2\pi d^2} A \cos^m \varphi T_s(\psi) g(\psi) \cos \psi, & 0 \leq \psi \leq \psi_c \\ 0, & \psi > \psi_c \end{cases}, \quad (2)$$

式中, d 为LED光源到接收器 PD_n 的直线距离, A 为接收器 PD_n 实际的接收面积, ψ 为接收器 PD_n 的入射角, φ 为LED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 为接收器 PD_n 视场角, m 为朗伯光源阶数, m 可以由(3)式计算得出

$$m = -\frac{\ln 2}{\ln \cos \phi_{1/2}}, \quad (3)$$

式中, $\phi_{1/2}$ 为 LED 发光的半功率半角, 此角度上的 LED 光源辐射功率是中心功率的 1/2。

3 定位准备阶段

3.1 实验数据预处理

Elman 神经网络训练效果依赖于数据的全面性, 故建立指纹数据库时把待测平面等距离划分成 n^2 个网格, 待测平面就形成了 $(n+1)^2$ 个网格点, 取网格点为参考点。分别测量接收器 PD_n ($n=1, 2, 3, 4$) 在每个参考点接收到的光功率, 将每个参考点测量到的光功率数据和对应的 x 轴坐标、 y 轴坐标分别形成的指纹数据存储起来形成两个指纹数据库, 分别用来训练两个 Elman 神经网络。第 f 个参考点的两个指纹数据分别表示为

$$\begin{aligned} \mathbf{G}_{x,f} &= (P_{f1}, P_{f2}, P_{f3}, P_{f4}, x_f) \\ \mathbf{G}_{y,f} &= (P_{f1}, P_{f2}, P_{f3}, P_{f4}, y_f), \end{aligned} \quad (4)$$

式中, P_{fn} ($n=1, 2, 3, 4$) 为接收器 n 在第 f 个参考点接收到的光功率, x_f, y_f 分别为第 f 个参考点的横坐标和纵坐标。平面上 $(n+1)^2$ 个参考点建立起来的两个指纹数据库表示为

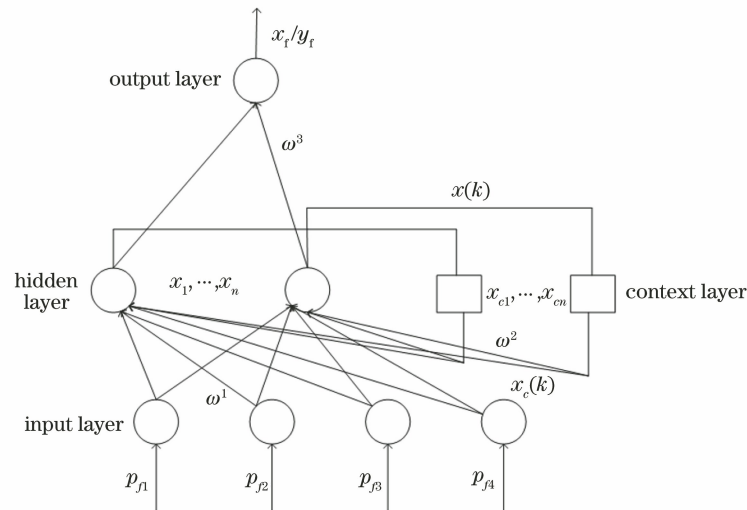


图 2 Elman 神经网络结构图

Fig. 2 Elman neural network structure diagram

在定位准备阶段, 需要建立两个 Elman 神经网络模型, 一个负责预测待测点 x 轴的位置, 一个负责预测待测点 y 轴的位置。如图 2 所示, 将 PD_n 在参考点接收的光功率 $\mathbf{U} = [P_{f1}, P_{f2}, P_{f3}, P_{f4}]^T$ 输入到 Elman 神经网络中去, 用于预测待测点 x 轴位置的 Elman 神经网络输出为 $\mathbf{y} = [x_f]^T$, 用于预测待测点 y 轴位置的 Elman 神经网络输出为 $\mathbf{y} = [y_f]^T$ 。Elman 神经网络的数学表达式为

$$x(k) = f[\omega^2 x_c(k) + \omega^1 u(k-1)], \quad (6)$$

$$\mathbf{H}_{x,f} = [G_{x,1}, G_{x,2}, G_{x,3}, \dots, G_{x,(n+1)^2}]^T \quad (5)$$

$$\mathbf{H}_{y,f} = [G_{y,1}, G_{y,2}, G_{y,3}, \dots, G_{y,(n+1)^2}]^T。$$

3.2 建立 Elman 神经网络模型

神经网络模型分为前向网络和反馈网络。在反馈网络中, 信息在前向传递的同时还要进行反向传递, 这种信息的反馈可以发生在不同网络层的神经元之间, 也可以只局限于某一层神经元上。反馈网络属于动态网络, 只有满足了稳定条件, 网络才能在工作了一段时间之后达到稳定状态。Elman 神经网络是一种典型的反馈网络, 其网络基本结构类似于 BP 神经网络, 相比较于 BP 神经网络多了一个承接层。因为承接层起到一步延时算子的作用, 从而使网络具有记忆的功能, 增加了网络的全局稳定性和计算能力。Elman 神经网络具有强大的学习能力, 能够对任意的非线性关系建模, 在处理非线性关系的问题中有着强大的能力。Elman 神经网络结构如图 2 所示。Elman 神经网络通过输入层单元传输输入信号, 承接层用来存储隐层单元上一时刻的输出值, 隐层的输入输出通过承接层的存储和延迟功能连接在一起, 输出层单元对隐层的输出起到加权作用。

$$x_c(k) = x(k-1), \quad (7)$$

$$y(k) = g[\omega^3 x(k)], \quad (8)$$

(6)~(8) 式中, ω^1 为连接输入层单元、隐含层的权值, ω^2 为连接隐含层、承接层的权值、 ω^3 为连接隐含层、输出层单元的权值, $f(\ast)$ 为隐含层神经元的传递函数, $g(\ast)$ 为输出层神经元的传递函数, $k=2, 3, \dots, (n+1)^2$, $(n+1)^2$ 为参考点数。

Elman 神经网络训练流程如图 3 所示。 $f(\ast)$ 选用 tansig 函数, $g(\ast)$ 选用 pureline 线性传递函

数,将两个指纹库中的数据分别作为训练集,训练得到两个 Elman 神经网络模型。

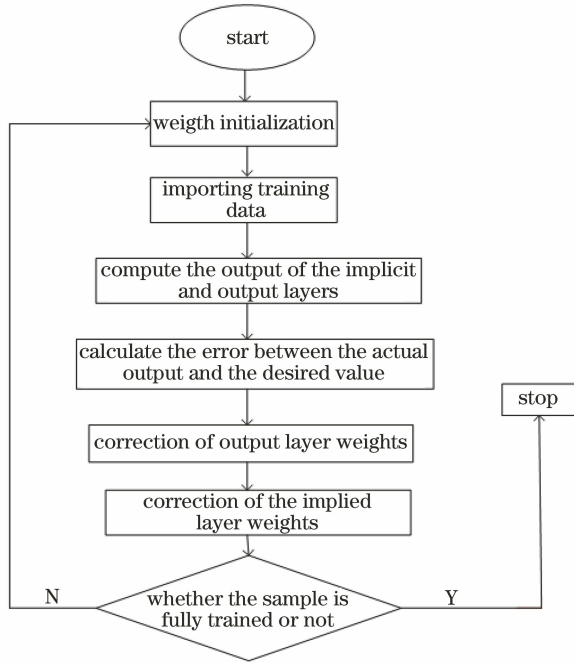


图 3 Elman 神经网络训练流程图

Fig. 3 Elman neural network training flow chart

4 定位过程

4.1 Elman 神经网络进行位置预测

假设待测点 A 测量得到的光功率向量为

$$U_A = [P_{A1}, P_{A2}, P_{A3}, P_{A4}]^T. \quad (9)$$

将其输入到定位准备阶段已经训练好的两个 Elman 神经网络中去,得到与之对应的 x 轴预测位置 x_A , y 轴预测位置 y_A ,待测点 A 的预测位置坐标为

$$Z_A = (x_A, y_A). \quad (10)$$

4.2 预测位置进行修正

本研究采用加权 K 近邻算法对预测位置进行修正。通常,使用 K 近邻(KNN)算法首先需要建立一个样本数据集合,即训练样本集。训练样本集中每个数据都存在标签,并且训练样本集中每一数据与其标签存在一一对应的关系。在本文算法中训练样本集中的数据为每个参考点的位置坐标,标签为每个参考点所对应的光功率向量。输入新数据后,将新数据中的标签与训练样本集中数据对应的标签进行比较,提取出样本集中标签特征最相似的数据。一般来说,只选择样本数据集中前 k 个最相似的数据,然后将前 k 个最相似数据作为新数据分类的依据。

K 近邻算法需要计算当前测量点的指纹数据标

签与数据库中的各个指纹数据标签之间的距离,对这些距离进行排序,找到离当前测量点的指纹数据标签最近的 k 个参考点,通过对 k 个参考点的坐标进行加和求平均得到当前测量点的位置。加权 K 近邻算法在 K 近邻算法的基础上为 k 个参考点的坐标分配权重,并对分配给权重的坐标进行加权求和再求平均,进而得到当前测量点的位置。

根据上面的描述,得到待测点 A 的预测位置坐标 Z_A 后,计算出 Elman 神经网络预测的平均定位误差(RMSE, R_{MSE}),找出所有定位误差大于 RMSE 的待测点 Z_B 。设 Z_B 的光功率指纹为 $U_B = [P_{B1}, P_{B2}, P_{B3}, P_{B4}]^T$,参考点 Z_i 的光功率指纹为 $U_i = [P_{i1}, P_{i2}, P_{i3}, P_{i4}]^T$,计算 Z_B 与所有参考点 (x_i, y_i) 光功率指纹的欧式距离 d_i 为

$$d_i = \sqrt{(U_B - U_i)^2}, i = 1, 2, 3, \dots, (n + 1)^2. \quad (11)$$

把距离值 d_i 按升序排列,按权重为 $1/(d_i + \epsilon)$ 的加权规则为前 k 个参考点的坐标分配权重, ϵ 为一个常量,由(12)式求得待测点 Z_B 的最终坐标,此时获得的坐标值为待测点 Z_B 的最终坐标。

$$(x_{B1}, y_{B1}) = \frac{\sum_{i=1}^k [1/(d_i + \epsilon)](x_i, y_i)}{\sum_{i=1}^k 1/(d_i + \epsilon)}. \quad (12)$$

5 仿真与结果分析

室内环境大小为 $3.6 \text{ m} \times 3.6 \text{ m} \times 3 \text{ m}$,LED 灯安装在房间顶部,坐标为 $(1.8 \text{ m}, 1.8 \text{ m}, 3 \text{ m})$ 。把待测平面均匀划分成 20×20 个小网格,得到了 21×21 个网格点,把这些网格点作为参考点,用接收器测量参考点上的光功率,接收器上的 4 个水平 PD 与接收器中心位置上的参考点距离为 10 cm 。仿真的主要参数如表 1 所示。

表 1 仿真参数

Table 1 Simulation parameters

Simulation parameter	Simulation value
LED emission power P_i	15 W
Actual receiving area of a single PD	1 cm^2
Receiver field of view ψ_c	90°
Half power angle of LED $\varphi_{1/2}$	45°
Refractive index of the lens n	1.5
Optical concentrator gain $g(\psi)$	1.5^2
Optical filter gain $T_s(\psi)$	1

先把接收器在参考点接收到的光功率和对应参考点的横、纵坐标形成的指纹数据分别存储到指纹

库中,将指纹库中的数据作为训练集,通过训练得到两个 Elman 神经网络模型,神经网络训练的参数设置如表 2 所示。为了验证本算法的有效性,在待测平面均匀选取了 256 个与训练集参考点不同的位置点作为测试集。将测试集中的待测点的光功率向量作为两个训练好的 Elman 神经网络的输入,获得相应的预测位置坐标 (x_A, y_A) 。假设待测点的真实坐标为 (x_{A1}, y_{A1}) ,求得待测点的定位误差后根据(13)式计算出 Elman 神经网络预测的平均定位误差 RMSE

$$R_{MSE} = \frac{\sum_{A=1}^{256} \sqrt{(x_A - x_{A1})^2 + (y_A - y_{A1})^2}}{256} \quad (13)$$

找出所有定位误差大于 RMSE 的待测点 Z_B , 使用加权 K 近邻算法对其进行修正, k 的取值将会影响修正效果,故本算法中 k 值待定。

表 2 神经网络训练参数

Table 2 Neural network training parameters

Training parameters	Settings
Elman neural network training algorithm	Gradient descent method
Number of iterations	15000
Target error	1×10^{-7}

使用加权 K 近邻算法进行对 Z_B 的预测位置坐标修正后,得到其最终坐标 (x_{B1}, y_{B1}) ,将最终修正的坐标更新为待测点的全局位置。假设待测点最终定位坐标为 (x_{A2}, y_{A2}) ,则定位误差 E_A 表示为

$$E_A = \sqrt{(x_{A1} - x_{A2})^2 + (y_{A1} - y_{A2})^2} \quad (14)$$

仿真发现,隐含层的神经元数量可以直接影响 Elman 神经网络的预测精度,进而影响最终定位结果。为了确定最佳的隐含层神经元个数,本研究仿真了不同神经元个数下 Elman 神经网络的 RMSE。图 4 为 Elman 神经网络隐含层神经元个数为 4~12 时平均定位误差的变化情况。

从图 4 中可以看出,当隐含层中的神经元数量增加时,平均定位误差也相应减小。隐含层的神经元数量越多,神经网络的学习时间就越长。由于隐含层的神经元数量增加到 10 个后,平均定位误差变化不大,所以本研究将 Elman 神经网络隐含层的神经元数量选为 10。为了选择合适的 k 值,本研究仿真了 k 取值为 0~6 时本文算法 RMSE 和最大定位误差的变化情况。

从图 5 可以看出,与 k 取 0 (即没有使用

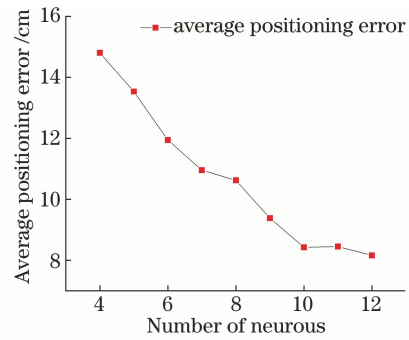


图 4 不同神经元个数时的 RMSE

Fig. 4 RMSE at different number of neurons

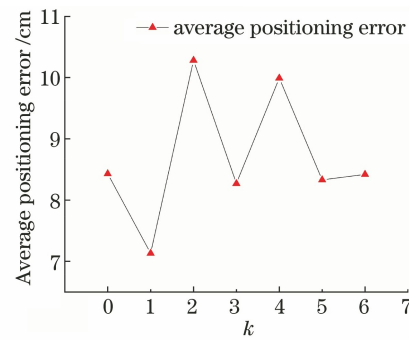


图 5 不同 k 值时的 RMSE

Fig. 5 RMSE at different k values

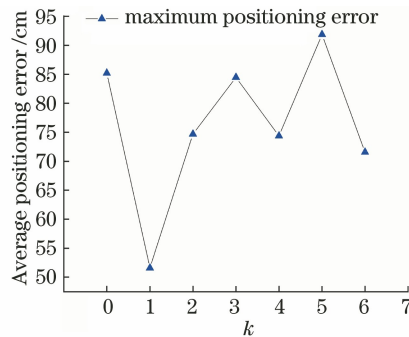


图 6 不同 k 值时的最大定位误差

Fig. 6 Maximum positioning error at different k values

WKNN 算法进行修正)相比,当 k 取 1 时, WKNN 算法对平均定位误差的修正效果最好;从图 6 可以看出,与 k 取 0 相比,当 k 取 1 时, WKNN 算法对最大定位误差的修正效果最好。综合对平均定位误差、最大定位误差的修正效果考虑,本文算法中 k 的取值选择为 1。当隐含层神经元个数设置为 10, k 取 1 时,修正前后的定位误差分布图如图 7 所示,修正前后位置坐标对比图如图 8 所示。

从图 7 可以看出,修正前的最大定位误差为 85.20 cm,修正后的最大定位误差为 51.61 cm。从图 8 可以看出,修正前定位平面四角的个别点与实际位置差别较大,修正后分布在定位平面四

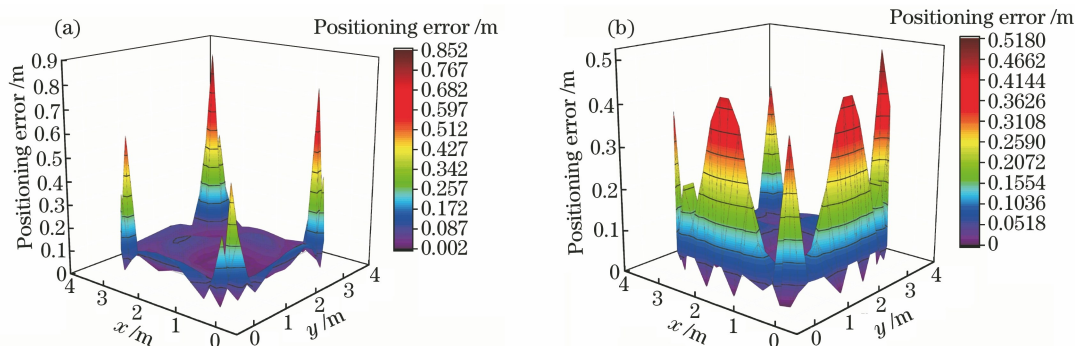


图 7 修正前后的定位误差分布图。(a)未修正的定位误差分布;(b)已修正的定位误差分布

Fig. 7 Positioning error distribution before and after correction. (a) Uncorrected positioning error distribution; (b) corrected positioning error distribution

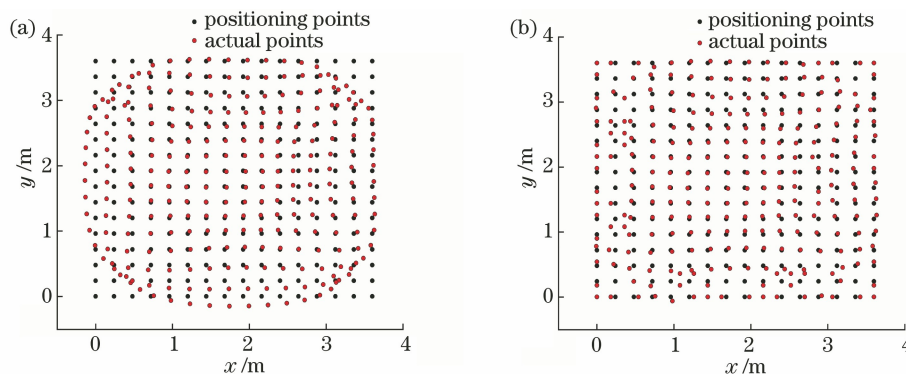


图 8 修正前后的对比图。(a)修正前的对比图;(b)修正后的对比图

Fig. 8 Comparison chart before and after correction. (a) Comparison chart before correction; (b) comparison chart after correction

角定位误差较大的个别点得到了有效修正,修正前平均定位误差为 8.43 cm,修正后平均定位误差为 7.13 cm。为了证明本文算法的有效性,仿真对比了本文算法、BP 神经网络和单个 Elman 神经网络(用一个 Elman 神经网络预测定位点的纵横坐标),对比结果如表 3 所示。从表 3 可以看出,与 BP 神经网络和单个 Elman 神经网络相比,本算法的定位精度显著提高。与 BP 神经网络相比,本文算法的定位精度提高了 55.35%,与单个 Elman 神经网络相比,本文算法的定位精度提高了 48.89%。另外,与 BP 神经网络、单个 Elman 神经网络相比,本文算法平均定位时间略长,但本文算法平均定位时间控制在 1 s 以内,不会对日常的使用造成影响。

本研究比较了三种算法定位误差的累积分布,比较结果如图 9 所示。由图 9 可知,本文算法 90% 的定位误差小于 8.38 cm, BP 神经网络 90% 的定位误差小于 23.74 cm, 单个 Elman 神经网络 90% 的定位误差小于 20.50 cm。

表 3 不同算法的定位性能对比

Table 3 Comparison of positioning performance of different algorithms

Positioning algorithm	Average positioning error /cm	Average positioning time /s
BP neural network	15.97	0.176588
Elman neural network	13.95	0.218410
Elman neural Network+WKNN	7.13	0.243774

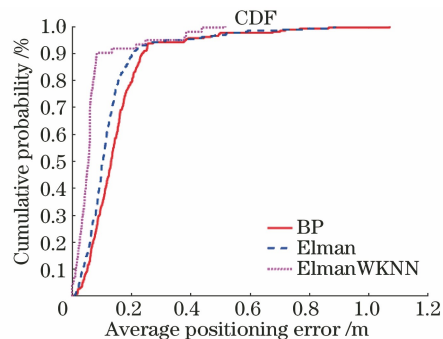


图 9 定位误差累积分布图

Fig. 9 Cumulative distribution of positioning errors

6 结 论

本研究提出了用 Elman 神经网络进行室内定位,用加权 K 近邻算法对定位结果进行修正的可见光室内定位算法。通过两个 Elman 神经网络分别预测待测目标的横坐标和纵坐标来确定待测目标的初步位置,得到待测目标的初步位置后,找出定位误差大于神经网络预测平均误差的待测点,用加权 K 近邻算法进行修正并更新,进而得到待测点的最终位置。仿真结果表明,在 $3.6\text{ m}\times 3.6\text{ m}\times 3\text{ m}$ 的室内环境下,本算法的平均定位误差为 7.13 cm ,平均定位时间为 0.24 s ,符合绝大多数室内应用场景的定位服务要求。

参 考 文 献

- [1] Yuan C L, Lu H M, Huang J C, et al. Energy self-sustaining visible light positioning algorithm based on clustering[J]. *Acta Optica Sinica*, 2021, 41(10): 1006001.
原程林, 路慧敏, 黄嘉成, 等. 基于聚类的能量自持续可见光定位算法[J]. *光学学报*, 2021, 41(10): 1006001.
- [2] Zhao C H, Zhang H M, Song J. Fingerprint based visible light indoor localization method[J]. *Chinese Journal of Lasers*, 2018, 45(8): 0806002.
赵楚韩, 张洪明, 宋健. 基于指纹的室内可见光定位方法[J]. *中国激光*, 2018, 45(8): 0806002.
- [3] Cao Y, Dang Y C, Peng X F, et al. Indoor visible light localization method using TOA/RSS hybrid information[J]. *Chinese Journal of Lasers*, 2021, 48(1): 0100001.
曹阳, 党宇超, 彭小峰, 等. TOA/RSS 混合信息室内可见光定位方法[J]. *中国激光*, 2021, 48(1): 0100001.
- [4] Dong W J, Wang X D, Wu N. A hybrid RSS/AOA algorithm for indoor visible light positioning [J]. *Laser & Optoelectronics Progress*, 2018, 55(5): 050603.
董文杰, 王旭东, 吴楠. 基于 RSS/AOA 混合的室内可见光定位算法[J]. *激光与光电子学进展*, 2018, 55(5): 050603.
- [5] Yang Z C, Wang Z Y, Zhang J S, et al. Polarization-based visible light positioning[J]. *IEEE Transactions on Mobile Computing*, 2019, 18(3): 715-727.
- [6] Almadani Y, Ijaz M, Adebisi B, et al. An experimental evaluation of a 3D visible light positioning system in an industrial environment with receiver tilt and multipath reflections [J]. *Optics Communications*, 2021, 483: 126654.
- [7] Wang W G, Zhang Y W, Tian L B. TOA-based NLOS error mitigation algorithm for 3D indoor localization [J]. *China Communications*, 2020, 17(1): 63-72.
- [8] Liu C F, Yang J, Wang F S. Joint TDOA and AOA location algorithm [J]. *Journal of Systems Engineering and Electronics*, 2013, 24(2): 183-188.
- [9] Li S P, Yang X Y, Zhao R, et al. An indoor positioning method based on RSSI probability distribution [J]. *IOP Conference Series: Materials Science and Engineering*, 2019, 490: 042054.
- [10] Gao L, Yang X M. An improved trilateration positioning algorithm [J]. *Industry and Mine Automation*, 2020, 46(2): 78-81.
高莉, 杨雪苗. 一种改进的三边定位算法[J]. *工矿自动化*, 2020, 46(2): 78-81.
- [11] Xie C Y, Guan W P, Wu Y X, et al. The LED-ID detection and recognition method based on visible light positioning using proximity method [J]. *IEEE Photonics Journal*, 2018, 10(2): 1-16.
- [12] Wang Y F, Gao J X, Li Z K, et al. Robust and accurate Wi-Fi fingerprint location recognition method based on deep neural network[J]. *Applied Sciences*, 2020, 10(1): 321.
- [13] Zhang H Y, Yu H Y, Chen L L. Indoor visible light location using adaptive pollination receiving signal strength indication based on reverse learning strategy [J]. *Chinese Journal of Lasers*, 2021, 48(1): 0106001.
张慧颖, 于海越, 陈玲玲. 基于反向学习策略的自适应花粉接收信号强度指示室内可见光定位[J]. *中国激光*, 2021, 48(1): 0106001.
- [14] Tran H, Ha C. Improved visible light-based indoor positioning system using machine learning classification and regression [J]. *Applied Sciences*, 2019, 9(6): 1048.
- [15] Raes W, Knudde N, De Bruycker J, et al. Experimental evaluation of machine learning methods for robust received signal strength-based visible light positioning[J]. *Sensors*, 2020, 20(21): 6109.
- [16] Şahin A, Eroğlu Y S, Güvenç i, et al. Hybrid 3-D localization for visible light communication systems [J]. *Journal of Lightwave Technology*, 2015, 33(22): 4589-4599.
- [17] Xu Y, Wang X X. Indoor positioning algorithm of subregional visible light based on multilayer ELM [J]. *Journal of Hunan University (Natural Sciences)*, 2019, 46(10): 125-132.
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.

- [18] Xiao J L, Yue D W, Zhao Z D, et al. A visible light localization algorithm based on BP neural network optimized by genetic algorithm [J]. Journal of Optoelectronics • Laser, 2019, 30(8): 810-816.
肖佳琳, 岳殿武, 赵政铎, 等. 基于遗传算法优化 BP 神经网络的可见光定位 [J]. 光电子 • 激光, 2019, 30(8): 810-816.
- [19] Wang Z, Zhu Y Y, Zhang Z C. Indoor visible light location system based on BP neural network [J]. Science & Technology Information, 2021, 19(1): 81-84.
王正, 朱玉业, 张中成. 基于 BP 神经网络的室内可见光定位系统 [J]. 科技资讯, 2021, 19(1): 81-84.