

基于稀疏训练点和指纹重构的室内可见光三维定位算法

刘开华, 鄢书丹*, 官霄霖**

天津大学微电子学院, 天津 300072

摘要 目前构建基于机器学习的室内可见光定位模型主要依赖于光电二极管和指纹数量, 为了降低指纹采集的复杂度, 提高定位精度, 提出一种基于指纹矩阵稀疏重构的室内三维可见光定位算法。该算法利用极限学习机训练稀疏采样点, 采用奇异值分解和交替方向乘法求解稀疏指纹矩阵的重构问题。该算法可以有效降低指纹的采样率, 同时可以基于极限学习机算法较强的泛化能力提高定位速度和定位精度。在此基础上, 由于可见光的多径反射等因素的影响, 定位区域的边界定位误差大于内部定位误差, 通过引入一种边界修正定位算法, 可以有效降低边界定位误差。仿真和实验结果表明, 与传统的机器学习算法相比, 该算法在减少其所需指纹数量的同时, 具有更高的定位速度和精度。

关键词 光通信; 可见光定位; 极限学习机; 奇异值分解; 边界修正

中图分类号 TN929.12

文献标志码 A

doi: 10.3788/CJL202148.0306003

1 引言

近年来, 随着人们对室内人和物位置服务需求的不断增加, 室内定位逐渐成为研究热点。

目前提出了多种室内定位技术: 无线网络、超宽带网络、超声波、可见光、ZigBee、射频识别 (RFID)、蓝牙等^[1-3]。其中可见光对人体是无害的, 不会干扰其他电子设备, 且大多数室内场所都有光, 可见光信号受多径反射的影响较小, 可以用作室内定位系统的信息载体, 故可见光室内定位技术极具潜力。其中发光二极管 (LED) 灯以其高性价比、高宽带、长寿命等优点引起了研究人员的广泛关注。

基于可见光室内定位的研究现状, 文献[4]利用光传动的被动多目标定位算法, 通过扇形环模型和自适应定位算法减少伪目标定位, 实现了更高的定位精度和计数率, 不足之处在于对节点密度敏感。文献[5]基于奇异值分解 (SVD) 技术推导出了确定接收机位置和方向的近似表达式, 加快了定位过程, 增强了鲁棒性, 避免了初始猜测误差可能导致的定

位失败。文献[6]提出了一种基于 SVD 的方法, 解决了奇异突发事件下接收信号强度 (RSS) 矩阵预测的数值稳定性问题。文献[7]提出了一种利用 SVD 的多重定位方法, 实现了室内三维定位。Zhang 等^[8]提出了一种人工神经网络 (ANN) 方法, 以精确建模和定位现场数据, 利用到达相位差和 RSS 测量值的选择策略, 缓解了基于 RSS 的 VLP (可见光定位) 系统建模不准确和可见光强度变化的问题, 提高了鲁棒性。文献[9]提出了一种利用 RSS 的室内可见光三维定位系统, 该系统借助深度学习技术极大地降低了三边计算的复杂性, 计算速度较快。Chen 等^[10]提出了一种基于指纹识别和极值学习机 (ELM) 的室内实时三维可见光定位系统, 增加了抗干扰性, 缩短了定位时间。Keskin 等^[11]研究了同步和异步 VLP 系统的直接定位和两步定位方法。Park 等^[12]提出一种将 adhama 矩阵用于多输入多输出 (MIMO) 系统的光信号和多路复用技术。Konings 等^[13]使用卷积神经网络 (CNN) 无线定位开发了用于光学定位和机载网络定位融合应用的

收稿日期: 2020-08-14; 修回日期: 2020-08-27; 录用日期: 2020-09-07

* E-mail: 2018232071@tju.edu.cn; ** E-mail: gxl@tju.edu.cn

VLP 系统。

文献[14]先采用支持向量机回归(SVR)算法学习模型进行粗定位,再结合指纹定位算法实现更精确的定位。文献[15]提出了一种基于隐马尔科夫模型的可见光与惯导融合定位算法,其中利用改进的维特比算法进行用户轨迹匹配定位。文献[16]提出一种低复杂度、稀疏度自适应的压缩感知算法,实现了可见光室内定位。研究表明基于指纹的机器学习算法具有实现简单、成本低、精度高等优点,但存在学习速度慢、指纹采样对定位敏感的问题。为此,本文提出一个基于指纹矩阵稀疏重构(SRoFM)的室内可见光三维定位方法,用于减少指纹数量,提高定位速度和精度,其次通过一种边界修正定位算法(LwBC)有效地减小了边界定位误差。

2 基本原理

可见光通信(VLC)是一种新型的绿色低碳的无线数据传输技术,VLP技术是基于可见光通信的技术。可见光定位系统的实现过程如下:首先,在发射端对LED(发光二极管)灯的位置信息进行编码和调制;然后通过接收端(RX)的光集中器、光滤波器和光电转换器将光信号转换为电信号;最后,通过解调和解码得到光电探测器接收到的功率,再通过本文提出的算法得到估计的位置。本文提出的算法用于定位阶段。

图1为基于4个发射机的可见光定位系统模型,接收机为光电探测器。利用LED灯的位置信息和光电探测器接收到的电功率对接收端进行定位。

假设LED灯光的空间传播遵循Lambertian模

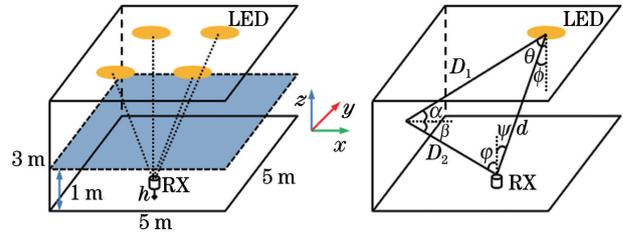


图1 定位系统模型

Fig. 1 Positioning system model

型,由于视距传播的影响远大于反射传播的影响,且二阶反射在光通道中的脉冲响应较低,可以忽略^[17],因此本文只考虑光的视距传播和一阶反射。接收端在光信道视距(LOS)传播下的直流(DC)增益 $H(0)$ 可表示为

$$H(0)_{\text{LOS}} = \begin{cases} \frac{m+1}{2\pi d^2} A_s \cos^m \phi \cos \psi T(\psi) g(\psi), & 0 \leq \psi \leq \psi_c \\ 0 & \text{otherwise} \end{cases}, \quad (1)$$

式中: A_s 是PD(光电二极管)的面积; ϕ 是发射机相对于定位终端的辐射角; ψ 是接收机的光入射角; d 为LED灯与接收机的距离; ψ_c 为接收端的视场角; m 为Lambertian阶数; $T(\psi)$ 是光滤波器增益; $g(\psi)$ 为光集中器增益。 m 和 $g(\psi)$ 的表达式为

$$g(\psi) = \begin{cases} \frac{n^2}{\sin^2 \psi_c}, & 0 \leq \psi \leq \psi_c \\ 0, & \psi > \psi_c \end{cases}, \quad (2)$$

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

式中: $\phi_{1/2}$ 是发射机的半功率角, n 是光集中器的折射率,通常在1~2之间。可见光信道一阶反射增益 $H_{\text{ref}}(0)$ 为

$$H_{\text{ref}}(0) = \begin{cases} \frac{(m+1)A_s}{2\pi^2 D_1^2 D_2^2} \rho A_{\text{wall}} \cos^m \theta \cos \alpha \cos \beta g(\varphi) T(\varphi) \cos \varphi, & 0 \leq \varphi \leq \psi_c \\ 0, & \varphi > \psi_c \end{cases}, \quad (4)$$

式中: D_1 为发送端到反射点的距离; D_2 为反射点到接收端的距离; ρ 为反射因子; A_{wall} 为反射区域的面积; θ 和 α 分别为反射点的辐射角和入射角; β 和 φ 分别为接收端的辐射角和入射角。

当光电传感器接收到光信号时,将光功率转换为电功率,电功率 P_r 可以表示为

$$P_r = \{RP_t [H(0)_{\text{LOS}} + H_{\text{ref}}(0)]\}^2 + \delta_{\text{noise}}^2, \quad (5)$$

式中: P_t 为LED灯的发射功率; R 为接收端传感

器的响应度,是描述器件光电转换能力的物理量; δ_{noise}^2 为总噪声方差,包含热噪声方差和散粒噪声方差。本研究将这两项噪声均假设为加性高斯白噪声(AWGN)^[18],故系统信噪比 R_{SN} 可以表示为

$$R_{\text{SN}} = 10 \lg \frac{\{RP_t [H(0)_{\text{LOS}} + H_{\text{ref}}(0)]\}^2}{\delta_{\text{noise}}^2}. \quad (6)$$

3 算 法

3.1 指纹矩阵稀疏重构(SRoFM)算法

由于光反射和环境噪声等因素的影响,接收端接收信号强度和位置的非线性映射非常复杂,本研究采用神经网络回归分析方法学习接收信号强度与接收端位置的映射关系。ELM 是一种基于单层前馈神经网络(SLFN)的机器学习方法,具有较强的泛化能力^[19]。它由输入层、隐含层和输出层组成。本研究利用该算法建立了一个回归预测模型,该模型的输入为 PD 所接收到的电功率,输出为 PD 所处的位置。

假设极限学习机由 N 个训练样本, p 个输入层节点, L 个隐层节点和 q 个输出层节点组成, $\{C_i = (x_i, y_i, z_i)\}_{i=1}^N$ 为 N 个采样节点的位置坐标, $\{P_{ri} = (P_{1,i}, P_{2,i}, \dots, P_{v,i})\}_{i=1}^N$ 为对应的采样节点处 PD 接收到的来自 v 个 LED 灯的功率,其中 v 代表 LED 灯光源个数。相应的标准 SLFNs 表达式为

$$\sum_{j=1}^L \beta_j h(\mathbf{w}_j P_{ri} + b_j) = C_i, i = 1, 2, \dots, N, \quad (7)$$

式中: $h(\cdot)$ 为 s 型激活函数; β_j 为隐藏层第 j 个神经元与输出层间的连接权值矩阵; $\mathbf{w}_j = (w_{j1}, w_{j2}, \dots, w_{jp})$ 为表示输入层与隐藏层间的连接权值矩阵, b_j 为第 j 个隐藏层神经元的偏置矩阵,其中 \mathbf{w}_j 和 b_j 随机产生,且在训练过程中保持不变,因此只需求解 β 。(7)式可简化为

$$\mathbf{H}\beta = \mathbf{C}, \quad (8)$$

式中: \mathbf{H} 为隐藏层输出矩阵; \mathbf{C} 为期望输出矩阵。最优输出权重 β 需满足

$$\tilde{\beta} = \min_{\beta} \|\mathbf{H}\beta - \mathbf{C}\|, \quad (9)$$

式中: $\|\cdot\|$ 为范数,其解为

$$\tilde{\beta} = \mathbf{H}^{\dagger} \mathbf{C}, \quad (10)$$

其中 \mathbf{H}^{\dagger} 为隐藏层输出矩阵 \mathbf{H} 的伪逆。ELM 神经网络用于回归预测时,测试定位误差表示为

$$e_{rr} = |\tilde{\mathbf{C}}_T - \mathbf{C}_T| = \sqrt{(\tilde{x}_i - x_i)^2 + (\tilde{y}_i - y_i)^2 + (\tilde{z}_i - z_i)^2}, \quad (11)$$

式中: $|\cdot|$ 为绝对值; $\tilde{\mathbf{C}}_T = \{(\tilde{x}_i, \tilde{y}_i, \tilde{z}_i)\}_{i=1}^t$ 为测试目标估计位置; $\mathbf{C}_T = \{(x_i, y_i, z_i)\}_{i=1}^t$ 为测试目标真实位置; t 为测试目标数。

本研究均匀设置采样节点,在采样节点上采集接收端电功率和 LED 灯的位置信息。为了降低节点的采样密度、限制指纹的数量,采用奇异值分解法来重构指纹矩阵。具体算法流程如下。

令 $\mathbf{Q} = \mathbf{Q}_1 = \mathbf{Q}_2 = \mathbf{Q}_3 = \mathbf{Q}_4 \in \mathbf{R}^{l \times l}$ 为定位场景下 PD 接收的来自 4 个 LED 灯的电功率的部分观测采样值指纹矩阵,其中 $l \times l$ 为指纹矩阵的尺寸。将观测元素的索引集记作 Ω ,再令

$$|P_{\Omega}(\mathbf{Q}_k)|_{ij} = \begin{cases} q_{ij}, & \text{if } (i, j) \in \Omega \\ 0, & \text{otherwise} \end{cases}, \quad (12)$$

式中: $P_{\Omega}(\cdot)$ 表示一个作用于 Ω 上的正交映射。假设部分采样矩阵 \mathbf{Q} 为一个近似低秩矩阵,则上述问题采样值矩阵重构问题可以转化为凸优化模型,令 $\mathbf{X} \in \mathbf{R}^{l \times l}$ 表示重构后的指纹矩阵,则有

$$\min_{\mathbf{X}} \|\mathbf{X}\|_*, \quad \text{s. t. } P_{\Omega}(\mathbf{X}) = P_{\Omega}(\mathbf{Q}), \quad (13)$$

式中: $\|\cdot\|_*$ 为核范数,用交替方向乘子法(ADMM)和奇异值分解法求解核范数最小化问题。ADMM 是一种广泛应用于机器学习的约束问题优化方法,它采用块坐标下行方法对无约束优化的部分分别进行优化^[20]。若给定任意矩阵 $\mathbf{f} \in \mathbf{R}^{m' \times n'}$,其奇异值分解表达式为 $\mathbf{f} = \mathbf{U}\mathbf{S}\mathbf{V}^T$,其中 $\mathbf{U} \in \mathbf{R}^{m' \times r}$ 和 $\mathbf{V} \in \mathbf{R}^{n' \times r}$ 由正交的奇异向量构成, $\mathbf{S} \in \mathbf{R}^{r \times r}$ 是由奇异值 $\sigma_1, \sigma_2, \dots, \sigma_r$, 构成 $r = \min\{m', n'\}$,且分布在矩阵对角线上。

为了解决(13)式的优化问题,引入中间变量 $\mathbf{M} \in \mathbf{R}^{l \times l}$,问题转换为

$$\min_{\mathbf{X}} \|\mathbf{M}\|_*, \quad \text{s. t. } \begin{cases} P_{\Omega}(\mathbf{X}) = P_{\Omega}(\mathbf{Q}) \\ \mathbf{X} = \mathbf{M} \end{cases}, \quad (14)$$

整个优化问题的增广拉格朗日函数为

$$l(\mathbf{X}, \mathbf{M}, \mathbf{T}) =$$

$$\|\mathbf{M}\|_* + \langle \mathbf{X} - \mathbf{M}, \mathbf{T} \rangle + \frac{\mu}{2} \|\mathbf{X} - \mathbf{M}\|_F^2, \quad (15)$$

式中: $\mathbf{T} \in \mathbf{R}^{l \times l}$ 为辅助矩阵; μ 为常数,其值设为 0.005; $\langle \cdot \rangle$ 为内积符号; $\|\cdot\|_F$ 为 F 范数。对矩阵 $\mathbf{X}, \mathbf{M}, \mathbf{T}$ 不断迭代更新即可实现矩阵重构,各个更新公式为

$$\begin{cases} \mathbf{M}^{k+1} = \mathbf{D}_{1/\mu} \left(\mathbf{X}^k + \frac{1}{\mu} \mathbf{T}^k \right) \\ \mathbf{X}^{k+1} = P_{1/\Omega} \left(\mathbf{M}^{k+1} - \frac{1}{\mu} \mathbf{T}^k \right) + P_{\Omega}(\mathbf{Q}) \\ \mathbf{T}^{k+1} = \mathbf{T}^k - \mu(\mathbf{M}^{k+1} - \mathbf{X}^{k+1}) \end{cases}, \quad (16)$$

式中: k 表示当前迭代代数;符号 $P_{1/\Omega}(\cdot)$ 表示作用于补集的正交映射; $\mathbf{D}_{\lambda}(\cdot)$ 表示软阈值算子, $\mathbf{D}_{\lambda}(\mathbf{f}) = \mathbf{U}\mathbf{S}_{\lambda}\mathbf{V}^T$,其中 $\mathbf{S}_{\lambda} = \text{diag}(\max\{\sigma - \lambda, 0\})$, $\sigma = (\sigma_1, \sigma_2, \dots, \sigma_r)^T$, $\lambda = (\lambda, \dots, \lambda)^T \in \mathbf{R}^r$ 。由此, \mathbf{X} 由部分采样矩阵 \mathbf{Q} 重构。误差定义为

$$d_{ev} = |\mathbf{X} - \mathbf{P}_r|. \quad (17)$$

3.2 边界修正定位算法

边界修正定位算法(LwBC)通过引入边界虚拟

节点来提高定位区域边界的 ELM 训练权重,从而增加指纹的数量、减少边界目标的泛化误差。假设引入节点的坐标为 $\{C_d = (x_i, y_i, z_i)\}_{i=1}^{\eta}$, η 为虚拟节点的数量,通过仿真得到相应的电功率可以实现更精确的定位。经过边界校正的具体布局如图 2

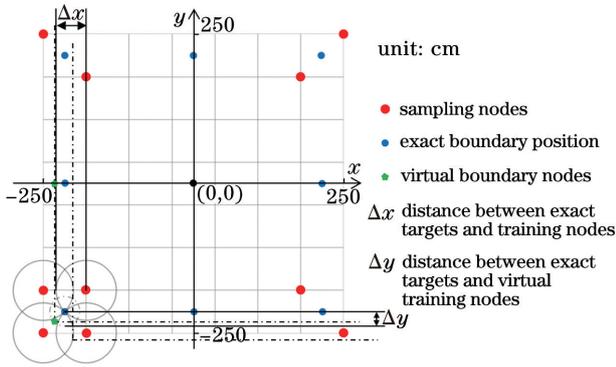


图 2 边界校正的具体布局
Fig. 2 Specific layout with boundary correction

所示,通过图中的虚拟边界节点,把训练节点与真实目标的距离从 Δx 降低为 Δy 。

4 设计与仿真

为了验证本文算法的定位性能,首先对 LED 灯的各自位置信息进行编码,再由频分复用对 LED 灯进行调制^[21]。仿真在 5 m×5 m×3 m 场景下室内环境进行,LED 灯坐标分别为 (1.25, 1.25, 3)、(-1.25, 1.25, 3)、(1.25, -1.25, 3)、(-1.25, -1.25, 3),地面中心坐标为(0,0,0),上述灯的坐标和地面中心坐标的单位为 m,下同。每个 LED 灯由 120 颗发射功率为 500 mW 的 LED 灯珠组成,其半功率角为 70°。仿真采用 S1337-1010BR PD 参数,其中光电转换效率设置为 0.62 A/W,视场角为 70°,PD 的有效面积为 1 cm²。仿真参数如表 1 所示。

表 1 仿真参数

Table 1 Simulation parameters

Parameter	Value
Interior room size / (m×m×m)	5×5×3
Power of LED lights / W	60
Locations of LED lights / m	(1.25, 1.25, 3), (-1.25, 1.25, 3), (-1.25, -1.25, 3), (1.25, -1.25, 3)
Effective area of PD / cm ²	1
Ha Half power angle of transmitters / (°)	70
Field of view angle of receivers / (°)	70
Responsivity / (A·W ⁻¹)	0.62
Refractive index	1.5
Reflection coefficient of the wall	0.8

4.1 ELM 回归预测仿真

在模拟场景 5 m×5 m×3 m 区域下,光电探测器在离地面不同高度平面内进行三维移动,在 0, 0.3, 0.6, 0.9 m 的不同高度平面内均匀设置 8×8 个采样节点,室内环境仿真结果如图 3 所示。因此,在每个高度平面内得到 64 个训练指纹样本,并设置 21 个测试指纹样本。图 3 给出了在 0, 0.3, 0.6, 0.9 m 高度处 ELM 回归预测仿真时估计目标和真实目标的坐标分布。仿真结果表明:当高度为 0 m 时,定位平均误差为 3.145 cm,最小平均误差为 0.191 cm。

当高度为 0.30 m 时,平均误差为 4.62 cm,最小平均误差为 0.068 cm;当高度为 0.60 m 时,平均误差为 5.577 cm,最小平均误差为 0.224 cm;当高度为 0.90 m 时,平均误差为 6.704 cm,最小平均误

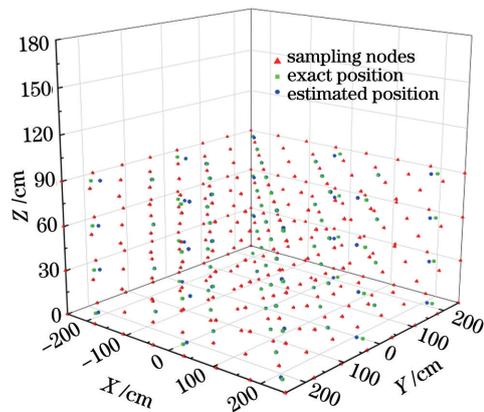


图 3 ELM 三维定位的分布

Fig. 3 Distribution of three-dimensional positioning with ELM

差为 0.228 cm。图 4 为 0, 0.3, 0.6, 0.9 m 高度的定位误差累积分布函数(CDF)。由图 3 和图 4 可

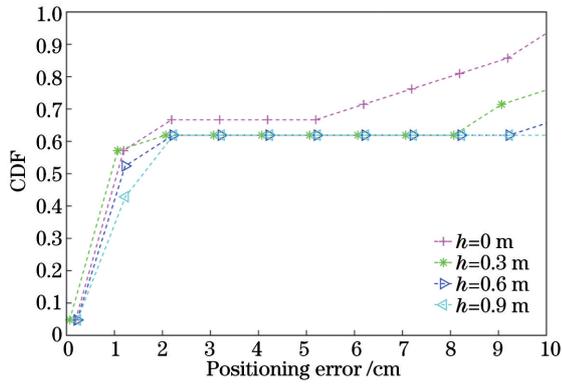


图 4 在 0, 0.3, 0.6, 0.9 m 高度下的定位误差 CDF
Fig. 4 CDF of positioning error at the heights of 0, 0.3, 0.6, 0.9 m

知,随着定位目标高度的升高,定位误差增大,且基于 ELM 算法的定位效果较好。图 5 为在不同信噪比下高度为 0 m 时的定位误差 CDF 曲线,设置信噪比 R_{SN} 大小分别为 10、20、30,可以看出,随着信噪比降低,定位误差有所增加,其中信噪比为 10 时的定位误差大于信噪比为 20、30 时的定位误差。

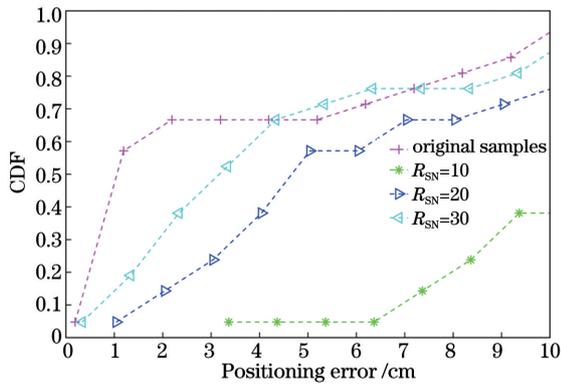


图 5 不同信噪比下的定位误差 CDF
Fig. 5 CDF of positioning error under different signal-to-noise ratios

4.2 SRoFM 算法的仿真

为了验证 SRoFM 的定位性能,大大减少了传统机器学习算法所需指纹的数量,在上述仿真的基础上,通过对 0 m 高度的样本进行多次仿真选择,从以上 64 个采样节点中得到较好的稀疏样本,然后,利用奇异值分解对指纹矩阵进行稀疏重构,最后利用 ELM 对目标进行定位。SRoFM 仿真结果如图 6 所示,分别给出 32、40、48、56、64 个稀疏样本下的定位误差 CDF 曲线。通过稀疏重构,可以看出 48、56 个稀疏样本下的定位效果较好。

4.3 引入 LwBC 算法的仿真

边界修正定位算法(LwBC)通过增加虚拟边界节点的数量来提高定位区域边界的 ELM 训练权

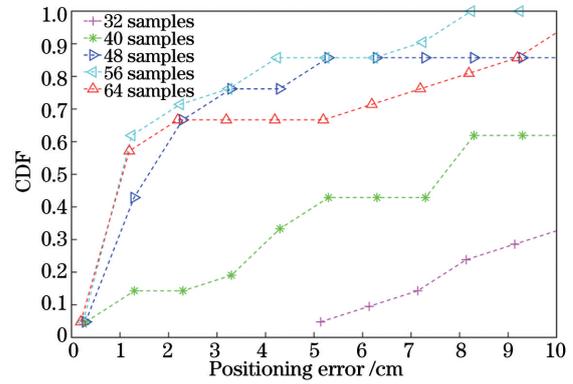


图 6 稀疏样本数为 32, 40, 48, 56, 64 时仿真定位误差 CDF
Fig. 6 CDF of simulation positioning error under the sparse samples with the number of 32, 40, 48, 56, 64

重,从而降低边界定位误差。图 7 为添加 4 个虚拟边界节点时定位误差的 CDF 曲线。图 8 为添加 8 个虚拟边界节点时定位误差的 CDF 曲线。通过引入 LwBC,可以得出基于 48、56 个稀疏样本的 VLP 系统性能更好。可以看出,随着样本数量的增加,定位平均误差减小。当增加虚拟边界节点时,误差进一步减小,由此证实了所提算法的有效性。

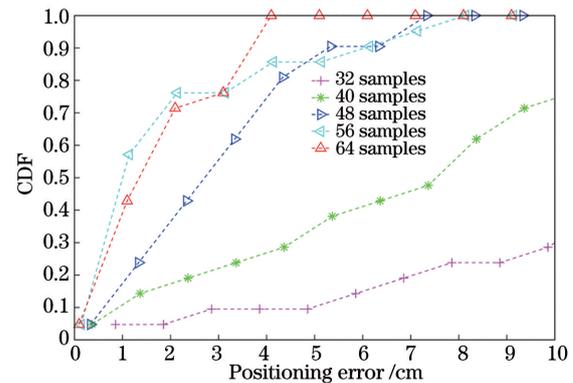


图 7 加入 4 个虚拟节点的仿真定位误差 CDF
Fig. 7 CDF of simulation positioning error with adding 4 virtual nodes

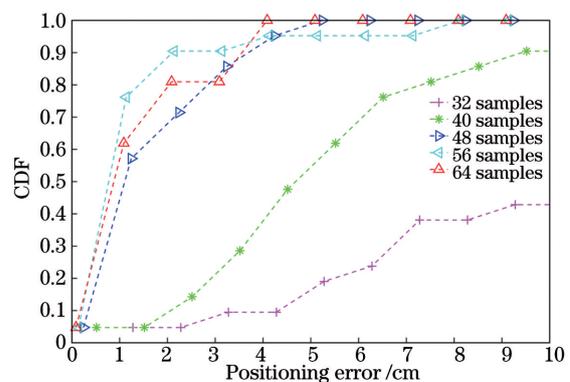


图 8 加入 8 个虚拟节点的仿真定位误差 CDF
Fig. 8 CDF of simulation positioning error with adding 8 virtual nodes

图 9 为不同训练样本数下各坐标轴定位误差分布图。其中:当 48 个样本时, x 轴误差少于 1 cm 的概率为 85.7%,平均定位误差为 0.62 cm, y 轴误差少于 3 cm 的概率为 85.7%,平均定位误差为

1.32 cm;当 56 个样本时, x 轴误差少于 5 cm 的概率为 95%,平均定位误差为 0.84 cm, y 轴误差少于 5 cm 的概率为 95%,平均定位误差为 0.8 cm, z 轴误差少于 3 cm 的概率为 99.6%。

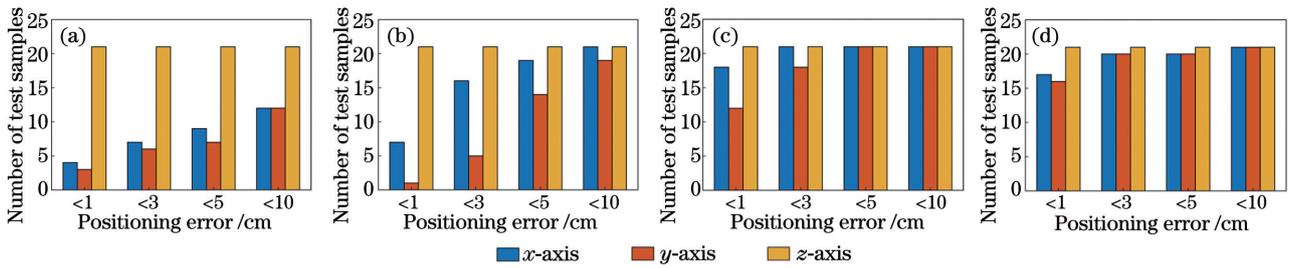


图 9 x, y, z 轴定位误差分布图。(a)32 个样本;(b)40 个样本;(c)48 个样本;(d)56 个样本

Fig. 9 Positioning error distribution with x, y, z axes. (a) 32 samples; (b) 40 samples; (c) 48 samples; (d) 56 samples

为了验证算法相比传统机器学习算法在可见光定位方面的优越性,对随机森林(RF)、K 近邻(KNN)、反向传播(BP)神经网络、ELM、SRoFM-LwBC 算法的定位精度进行了仿真实验。在高度平面下,64 个均匀采样节点用于进行 RF、KNN、BP 和 ELM 训练,使用 48 个稀疏采样节点进行 SRoFM-LwBC 训练。图 10 为采用 ELM、KNN、BP、RF 和 SRoFM-LwBC 算法的定位误差 CDF,可以看出本文提出算法的定位效果优于其他传统机器

学习算法。如表 2 所示,本文算法的定位时间最短,定位误差最小。平均定位时间为 0.0205 s,平均定位误差为 1.593 cm,平均最小误差为 0.243 cm。虽然所提出的平均最小定位误差算法不是最低的,但其优良的定位时间和定位精度使其比传统算法更适用于 VLP 系统。图 11 为使用 ELM 和 SRoFM-LwBC 估计目标的位置分布,可以看出 SRoFM-LwBC 很好地降低了指纹数量和边界定位误差。

表 2 算法的计算资源和定位误差比较

Table 2 Computing resource and positioning error comparison of algorithms

Parameter	RF	KNN	BP	Only ELM	SRoFM-LwBC
Average positioning time / s	0.493	0.049	0.239	0.0324	0.0205
Average positioning error / cm	16.122	12.426	11.352	3.145	1.593
Average minimum error / cm	0.0476	0	0.3156	0.1912	0.2430

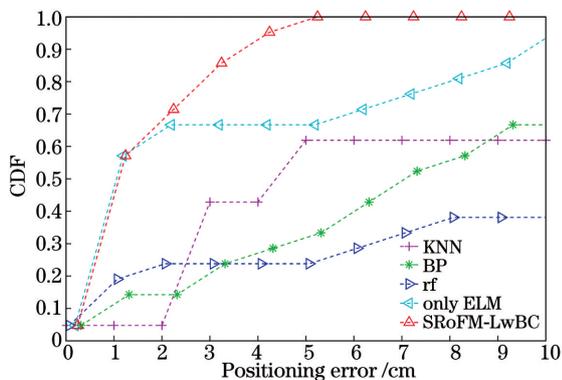


图 10 RF, KNN, BP, ELM and SRoFM-LwBC 仿真定位误差 CDF

Fig. 10 CDF of simulation positioning error with RF, KNN, BP, ELM, and SRoFM-LwBC, respectively

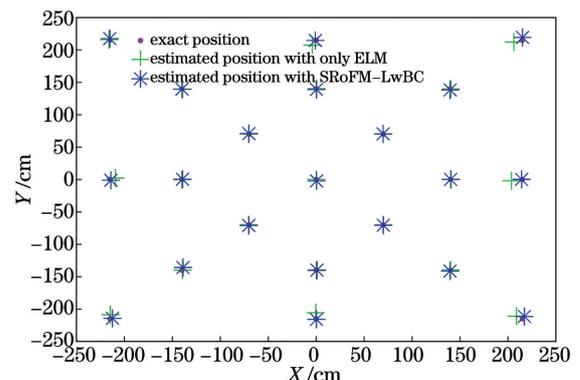


图 11 基于 ELM 和 SRoFM-LwBC 的各自估计目标位置分布

Fig. 11 Location distribution of estimated targets with ELM and SRoFM-LwBC, respectively

5 设计与实验

为了进一步验证所提算法的性能,在上述仿真

的基础上,采用内置光电探测器的 Anristu 光功率计 ML94A、欧思韵 60 W 正白光 6500K LED 灯进行实验,其中灯的尺寸为 20 cm×12 cm。实验数据

采集分为两部分:第一部分是对 64 个采样节点进行离线采样;第二部分是收集实时目标接收到的电功率。实验场景大小为 5 m×5 m,将其划分为 7×7 个平方网格,得到 8×8 个交叉采样节点。场景高度为 3 m,场景中心为(0,0,0),图 12 显示了可见光场景下的具体实验布局,实验使用一个 LED 灯,灯的位置为(1.25,1.25,3),三个镜像灯位置分别为(-1.25,1.25,3)、(-1.25,-1.25,3)、(1.25,-1.25,3),实验采集一个灯的指纹数据,依据 4 个灯位置的镜像对称性可以得到 4 组指纹数据用于实验分析。

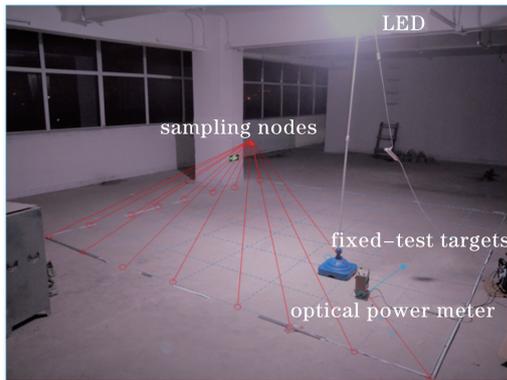


图 12 可见光场景下的具体实验布局

Fig. 12 Specific experimental layout under the visible light scene

图 13 为在稀疏样本下定位误差的 CDF 曲线对比图,可以看出,在指纹数量减少的情况下,SRoFM 的定位效果良好。图 14 为引入 LwBC 在稀疏样本下定位误差的 CDF 对比图。实验结果表明,该算法能较好地降低定位误差和指纹数量,且引入 LwBC 的 SRoFM 算法可以获得更准确的定位结果。从图中可以看出,实验相比仿真结果,其总体定位误差增加。图 15 给出了稀疏样本下 x, y, z 轴的定位误差分布图。其中:当 48 个样本时, x 轴少于 3 cm 的概率为 85.7%,平均定位误差为 1.27 cm, y 轴误差少

于 3 cm 的概率为 61.9%,平均定位误差为 2.52 cm;当 56 个样本时, x 轴误差少于 5 cm 的概率为 90.5%,平均定位误差为 1.73 cm, y 轴误差少于 3 cm 的概率为 90.5%,平均定位误差为 1.4 cm, z 轴误差少于 3 cm 的概率为 98%。

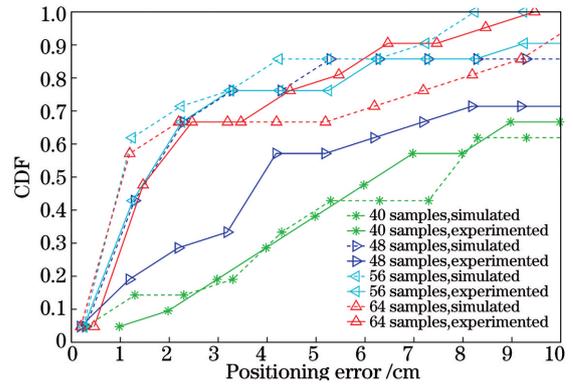


图 13 SRoFM 在稀疏样本下的定位误差 CDF 对比 (其中虚线为仿真结果,实线为实验结果)

Fig. 13 CDF comparison of experimental positioning error under sparse samples with SRoFM (The dotted lines are the simulation results, the solid lines are the experimental results)

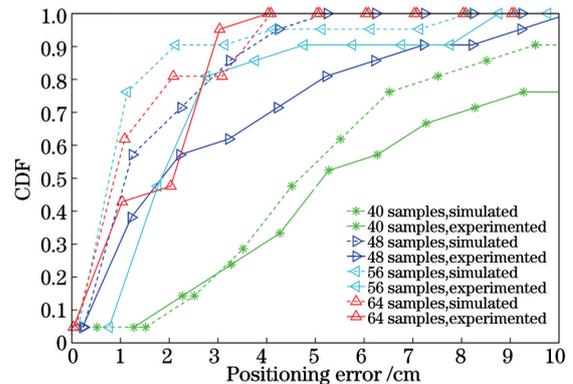


图 14 引入 LwBC 在稀疏样本下的定位误差 CDF 对比 (其中虚线为仿真结果,实线为实验结果)

Fig. 14 CDF comparison of experimental positioning error under sparse samples by introducing LwBC

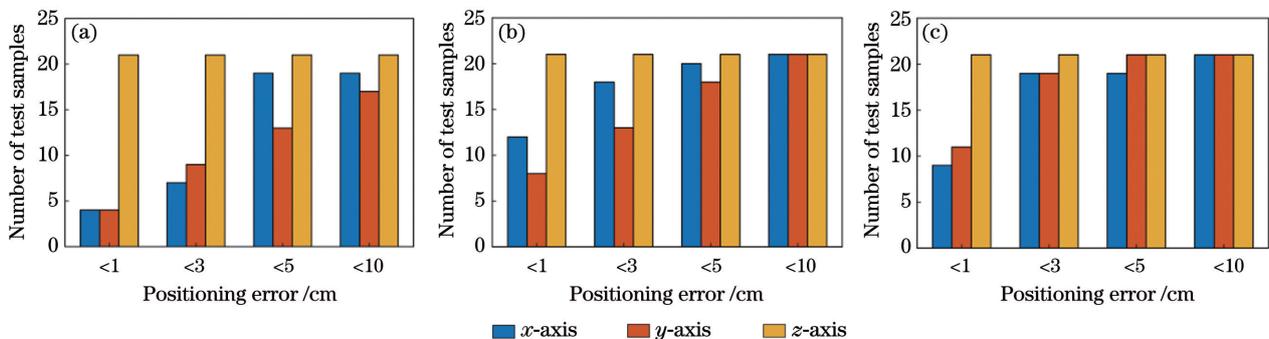


图 15 x, y, z 轴定位误差分布。(a)40 个样本;(b)48 个样本;(c)56 个样本

Fig. 15 Positioning error distribution of x, y, z axes. (a) 40 samples; (b) 48 samples; (c) 56 samples

6 结 论

提出一种基于稀疏重建指纹矩阵的室内三维可见光定位方法。该算法显著地减少了传统机器学习训练所需的指纹数量,且与 KNN、BP、RF、ELM 相比,提高了平均定位误差和定位速度。此外,通过边界修正定位算法降低了定位区域的边界定位误差。在 $5\text{ m} \times 5\text{ m} \times 3\text{ m}$ 定位场景下:仿真结果表明,本文所提算法的平均定位时间为 0.0205 s ,平均定位误差为 1.593 cm ,平均最小误差为 0.243 cm ;其中当样本个数为 48 时,实验结果表明,定位平均误差为 2.95 cm ,最小平均误差为 0.22 cm 。

参 考 文 献

- [1] Yassin A, Nasser Y, Awad M, et al. Recent advances in indoor localization: a survey on theoretical approaches and applications [J]. *IEEE Communications Surveys & Tutorials*, 2017, 19(2): 1327-1346.
- [2] Hassan N U, Naeem A, Pasha M A, et al. Indoor positioning using visible LED lights: a survey [J]. *ACM Computing Surveys*, 2015, 48(2): 1-32.
- [3] Swook H, Kim J H, Jung S Y, et al. White LED ceiling lights positioning systems for optical wireless indoor applications [C] // 36th European Conference and Exhibition on Optical Communication, September 19-23, 2010, Torino, Italy. New York: IEEE Press, 2010: 11636889.
- [4] Zhang S, Liu K H, Ma Y T, et al. An accurate geometrical multi-target device-free localization method using light sensors [J]. *IEEE Sensors Journal*, 2018, 18(18): 7619-7632.
- [5] Zhang R, Zhong W D, Qian K M, et al. Image sensor based visible light positioning system with improved positioning algorithm [J]. *IEEE Access*, 2017, 5: 6087-6094.
- [6] Yang J, Lee H, Moessner K. Multilateration localization based on singular value decomposition for 3D indoor positioning [C] // 2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN), October 4-7, 2016, Alcalá de Henares, Spain. New York: IEEE Press, 2016: 1-8.
- [7] Guo X S, Shao S H, Ansari N, et al. Indoor localization using visible light via fusion of multiple classifiers [J]. *IEEE Photonics Journal*, 2017, 9(6): 1-16.
- [8] Zhang S, Du P F, Chen C, et al. Robust 3D indoor VLP system based on ANN using hybrid RSS/PDOA [J]. *IEEE Access*, 2019, 7: 47769-47780.
- [9] Du P F, Zhang S, Chen C, et al. Experimental demonstration of 3D visible light positioning using received signal strength with low-complexity trilateration assisted by deep learning technique [J]. *IEEE Access*, 2019, 7: 93986-93997.
- [10] Chen Y R, Guan W P, Li J Y, et al. Indoor real-time 3-D visible light positioning system using fingerprinting and extreme learning machine [J]. *IEEE Access*, 2019, 8: 13875-13886.
- [11] Keskin M F, Gezici S, Arikan O. Direct and two-step positioning in visible light systems [J]. *IEEE Transactions on Communications*, 2018, 66(1): 239-254.
- [12] Park J K, Woo T G, Kim M, et al. Hadamard matrix design for a low-cost indoor positioning system in visible light communication [J]. *IEEE Photonics Journal*, 2017, 9(2): 1-10.
- [13] Konings D, Parr B, Alam F, et al. Falcon: fused application of light based positioning coupled with onboard network localization [J]. *IEEE Access*, 2018, 6: 36155-36167.
- [14] Xu S W, Wu Y, Wang X F. Visible light positioning algorithm based on sparsity adaptive and location fingerprinting [J]. *Acta Optica Sinica*, 2020, 40(18): 38-46.
徐世武, 吴怡, 王徐芳. 基于稀疏度自适应和位置指纹的可见光定位算法 [J]. *光学学报*, 2020, 40(18): 38-46.
- [15] Cao Y P, Li X J, Hu Y Y. Visible light fingerprint-based high-accuracy indoor positioning method [J]. *Laser & Optoelectronics Progress*, 2019, 56(16): 160601.
曹燕平, 李晓记, 胡云云. 基于可见光指纹的室内高精度定位方法 [J]. *激光与光电子学进展*, 2019, 56(16): 160601.
- [16] 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.
陈勇, 巫杰, 刘焕淋, 等. 基于隐马尔科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.
- [17] Komine T, Nakagawa M. Fundamental analysis for visible-light communication system using LED lights [J]. *IEEE Transactions on Consumer Electronics*, 2004, 50(1): 100-107.
- [18] Gu W J, Aminikashani M, Deng P, et al. Impact of multipath reflections on the performance of indoor visible light positioning systems [J]. *Journal of Lightwave Technology*, 2016, 34(10): 2578-2587.
- [19] Huang G B, Zhou H M, Ding X J, et al. Extreme

- learning machine for regression and multiclass classification [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2012, 42(2): 513-529.
- [20] Stephen B, Neal P, Eric C, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers [J]. *Distributed Optimization and Statistical Learning via the Alternating Direction Method of Multipliers*, 2011, 3(1): 1-122.
- [21] Lin B J, Tang X, Ghassemlooy Z, et al. Experimental demonstration of an indoor VLC positioning system based on OFDMA [J]. *IEEE Photonics Journal*, 2017, 9(2): 1-9.

Indoor 3D Visible Light Positioning Algorithm Based on Fingerprint Reconstruction and Sparse Training Nodes

Liu Kaihua, Yan Shudan*, Gong Xiaolin**

School of Microelectronics, Tianjin University, Tianjin 300072, China

Abstract

Objective With increasing demand for indoor localization services, indoor positioning technologies have gradually become a research hotspot. Visible light is harmless to the human body and can not interfere with electronic devices. In addition, the visible light signal is less affected by multi-path reflection; thus, it can be used as an information carrier for an indoor positioning system. Therefore, visible light has become an important indoor positioning technology. LED lights are often used in indoor positioning research due to their advantages, such as high cost performance, high broadband, long life. Model building of machine learning-based indoor visible light positioning currently relies on the photodiode and the number of fingerprints. To reduce the complexity of fingerprint acquisition and increase positioning accuracy, an indoor three-dimensional visible light positioning algorithm based on sparse reconstruction of fingerprint matrixes is proposed, and a localization algorithm with boundary correction is introduced. The proposed algorithm can effectively reduce the sampling rate of fingerprints and improve the global positioning speed and precision. We hope that our concepts and algorithms will facilitate the design of fingerprint acquisition and understanding of the relationship between singular value decomposition and fingerprint reconstruction.

Methods First, the proposed algorithm uses extreme learning machine to train sparse sampling nodes and is applied to learn the nonlinear mapping relationships between the received signal strength and location at the receiving end, which only considers the line-of-sight propagation and first-order reflection of visible light. In addition, singular value decomposition and the alternating direction multiplier method are combined to solve the reconstruction problem of sparse fingerprint matrixes, and we get the good sparse samples from the 64 sampling nodes through multiple simulation selection of samples. Second, due to the impact of multi-path reflection of visible light and other factors, the boundary positioning error of the positioning area is greater than the internal positioning error. A localization algorithm with boundary correction is introduced. This algorithm improves the extreme learning machine training weight of the positioning regional boundary by adding virtual boundary nodes to increase the number of fingerprints, reduce the generalization error of boundary targets, and reduce boundary positioning error significantly.

Results and Discussions At heights of 0 m, 0.3 m, 0.6 m, and 0.9 m, the average positioning error of less than 7 cm can be obtained. As the height of positioning targets increases, which leads to increased multi-path reflection gain of visible light, the boundary positioning error and overall positioning error increases (**Fig. 4**). It is observed that using 48 or 56 sparse samples for positioning provides good performance with sparse reconstruction. Here, the average positioning error is 2.74 cm with 48 sparse samples and 1.88 cm under 56 sparse samples by adding four virtual nodes (**Fig. 7**). By adding eight virtual nodes, the average positioning error is 1.59 cm with 48 sparse samples and 1.2 cm with 56 sparse samples (**Fig. 8**). The extreme learning machine has better positioning effect than the k -nearest neighbor, backpropagation, random forest algorithms (**Fig. 10**). The proposed algorithm has the shortest positioning time and lowest positioning error. The average positioning time is 0.0205 s, the average positioning error is 1.593 cm, and the average minimum error is 0.243 cm (**Table 2**). It is found that 48 and 56 sparse samples demonstrate good performance with sparse reconstruction, and the average positioning error is

7.29 cm with 48 sparse samples and 3.3 cm with 56 sparse samples (**Fig. 13**). By introducing the localization algorithm with boundary correction into an experimental scene with 48 and 56 sparse samples, we conclude that the proposed algorithm works well relative to reducing the positioning error and number of fingerprints. By adding eight virtual nodes, the average positioning error is 2.95 cm with 48 sparse samples and 2.49 cm with 56 sparse samples (**Fig. 14**).

Conclusions An indoor three-dimensional visible light localization algorithm based on sparse reconstruction of fingerprint matrixes is proposed. The proposed algorithm reduces the number of fingerprints required by traditional machine learning training significantly and improves the average positioning error and positioning speed compared to the KNN, BP, RF, and ELM algorithms. In addition, a localization algorithm with boundary correction is introduced to reduce the boundary positioning error of the positioning area. The simulation results demonstrate that the proposed algorithm has an average positioning time of 0.0205 s, average positioning error of 1.593 cm, and average minimum positioning error of 0.243 cm. With 48 samples, the experimental results demonstrate that the average positioning error is 2.95 cm, and the minimum average positioning error is 0.22 cm. With 64 sparse training nodes, the number of fingerprints can be reduced further using the singular value algorithm, and the global positioning speed and precision can be improved. Simulation and experimental results demonstrate that the proposed algorithm has better localization speed and accuracy while reducing the number of fingerprints compared to traditional machine learning algorithms.

Key words optical communications; visible light positioning; extreme learning machine; singular value decomposition; boundary correction

OCIS codes 060.2605; 060.4510; 200.4560; 040.5160