

DOI:10.19651/j.cnki.emt.2212007

## 基于误差校正和自适应算子的 SVR-PSO 定位算法\*

路畅<sup>1,2</sup> 崔英花<sup>1,2</sup>

(1.北京信息科技大学信息与通信工程学院 北京 100101;

2.北京信息科技大学信息与通信系统信息产业部重点实验室 北京 100101)

**摘要:** 针对室内复杂环境易受多径效应和非视距影响,导致 RSSI 值不可靠,影响 SVR 模型预测性能和系统定位精度的问题,提出一种基于误差校正和自适应算子的 SVR-PSO 算法。该算法提出利用近邻参考标签的预测误差对待测标签的预测距离进行误差校正,从而弥补 SVR 模型因 RSSI 值不可靠而预测不准确的问题。然后构建求解待测标签位置坐标的非线性方程组,利用 PSO 算法迭代求解。针对标准 PSO 算法存在的易陷入局部最优且收敛速度慢的问题,设计了一种自适应算子,分别对 PSO 算法的惯性权重和学习因子进行改进。仿真结果表明,误差校正和自适应算子对提升室内定位精度均有一定的作用。与 SVR-PSO 相比,系统平均定位精度提升了 31.6%。在相同定位精度下,该算法使用的参考标签数量更少。

**关键词:** 室内定位;射频识别;支持向量回归;误差校正;粒子群优化算法;自适应算子

**中图分类号:** TP391;TN911 **文献标识码:** A **国家标准学科分类代码:** 510.99

## SVR-PSO localization algorithm based on error correction and adaptive operator

Lu Chang<sup>1,2</sup> Cui Yinghua<sup>1,2</sup>

(1. School of Information and Communication Engineering, Beijing Information Science and Technology University, Beijing 100101, China; 2. Key Laboratory of Information and Communication Systems, Ministry of Information Industry, Beijing Information Science and Technology University, Beijing 100101, China)

**Abstract:** The complex indoor environment is easily affected by the multipath effect and non-line-of-sight, which leads to the unreliable RSSI value and affects the prediction performance of SVR model and positioning accuracy of the system. To solve the problem, a SVR-PSO algorithm based on error correction and adaptive operator is proposed. This algorithm proposes to use the prediction error of the nearest neighbor reference labels to correct the prediction distance of the measured label, so as to make up for the inaccurate prediction of SVR model due to the unreliable RSSI value. Then, the nonlinear equations of the measured label's position coordinates is constructed and solved iteratively by PSO algorithm. Aiming at the problem that the standard PSO algorithm is easy to fall into local optimum and the convergence speed is slow, an adaptive operator is designed to improve the inertia weight and learning factor of PSO algorithm respectively. The simulation results show that both error correction and adaptive operator have certain effects on improving the indoor positioning accuracy. Compared with SVR-PSO, the average positioning accuracy of the system is improved by 31.6%. With the same positioning accuracy, the algorithm uses fewer reference tags.

**Keywords:** indoor positioning; radio frequency identification; support vector regression; error correction; particle swarm optimization algorithm; adaptive operator

## 0 引言

随着物联网的快速发展,人们对实时获取人和重要物品位置信息的需求越来越大,定位技术受到人们的广泛关

注<sup>[1-2]</sup>。基于接收信号强度值(received signal strength indicator, RSSI)的 LANDMARC 算法是射频识别(radio frequency identification, RFID)定位技术<sup>[3]</sup>的主流算法,通过引入参考标签大大降低了定位成本。其基本原理是当待

收稿日期:2022-11-09

\* 基金项目:北京市自然科学基金面上项目(4202024)、促进内涵发展科研水平提高项目重点研究培育项目(2020KYNH213)资助

测标签和参考标签距离相近时,则阅读器接收到的 RSSI 值也是接近的,从而利用质心权重算法求出待测标签的位置。但是传统的 LANDMARC 算法存在易受多径效应和参考标签数量影响、系统定位精度低等问题,为提高其定位精度,许多学者提出了改进方法。邹承明等<sup>[4]</sup>提出改进 LANDMARC 邻近标签的选择方法和参考标签权重公式,提高了系统的定位精度和稳定性。张平等<sup>[5]</sup>提出一种基于自适应递归校正的 LANDMARC 算法,自适应选取  $K$  值,增强了系统对环境的适应性。Li 等<sup>[6]</sup>提出通过相邻标签的误差修正待测标签的位置,改进参考标签权重公式,消除了欧氏距离为 0 时的系统异常值,提高了定位系统的稳定性。以上改进方法虽然一定程度上提高了 LANDMARC 的定位精度,但无法满足一些对精度要求更高的场景。近年来,一些学者将支持向量回归(support vector regression, SVR)的方法引入到室内定位中,使定位精度有了显著提高。尹强等<sup>[7]</sup>提出一种基于 SVR 的定位算法,利用 SVR 构建 RSSI 和距离的映射关系,通过最小二乘法求解非线性方程组得到目标标签的位置,有效提高了定位精度,但 SVR 的参数没有进行优化,非线性方程组的求解问题也有待进一步研究。Liu 等<sup>[8]</sup>提出一种基于遗传算法(genetic algorithm, GA)优化 SVR 的室内定位算法(GA-SVR),利用 GA 优化 SVR 的参数,相比其他算法定位精度得到明显提高。但由于构建位置坐标与 RSSI 时的单输出,导致位置坐标信息之间关联性降低,从而定位不准确。Yang 等<sup>[9]</sup>基于 SVR 和粒子群优化算法(particle swarm optimization, PSO)提出一种 SVR-PSO 算法,相比上述尹强等<sup>[7]</sup>所提算法对边界标签的定位更精确,系统定位精度也得到了有效提升。但通常在实际环境下, RSSI 值会受多径效应和非视距的影响波动十分剧烈,从而影响 SVR 模型的性能,增大系统的平均定位误差。

鉴于此,本文基于误差校正 SVR 模型(error correction support vector regression, ECSVR)和改进 PSO 算法(improved particle swarm optimization, IPSO)提出一种室内定位算法(ECSVR-IPSO)。将参考标签的 RSSI 值作为输入,参考标签与阅读器对应的距离作为输出,利用 SVR 模型进行训练。然后根据近邻参考标签的预测误差计算校正误差,用来校正待测标签与阅读器的预测距离,提升 SVR 模型的预测性能。最后构建求解位置坐标的非线性方程组,利用基于自适应算子的 PSO 算法迭代求解,实现高精度室内定位。

## 1 传统 SVR 定位算法

SVR 是研究小样本、非线性问题的一种有效监督学习方法<sup>[10]</sup>。设有训练集  $T = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)\}$ ,  $\mathbf{x}_i \in R^n, y_i \in R, i = 1, 2, \dots, m$ , 通过 SVR 训练,期望得到如下回归模型:

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b \quad (1)$$

式中:  $b$  为偏置,  $\mathbf{w}$  为权重系数。

依据结构风险最小化原则<sup>[11]</sup>,将回归问题转化为如下凸优化问题:

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m \ell_\epsilon(f(\mathbf{x}_i) - y_i) \quad (2)$$

其中,  $C$  为正则化常数,  $\ell_\epsilon$  是  $\epsilon$ -不敏感损失函数:

$$\ell_\epsilon(z) = \begin{cases} 0, & |z| \leq \epsilon \\ |z| - \epsilon, & \text{其他} \end{cases} \quad (3)$$

引入松弛变量  $\xi_i$  和  $\hat{\xi}_i$ , 可将式(2)重写为:

$$\min_{\mathbf{w}, b, \xi_i, \hat{\xi}_i} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m (\xi_i + \hat{\xi}_i) \quad (4)$$

$$\text{s. t. } f(\mathbf{x}_i) - y_i \leq \epsilon + \xi_i,$$

$$y_i - f(\mathbf{x}_i) \leq \epsilon + \hat{\xi}_i, \quad (5)$$

$$\xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, 2, \dots, m$$

对于以上凸优化问题,引入拉格朗日乘子,转化为对偶问题,得到 SVR 模型:

$$f(\mathbf{x}) = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) \mathbf{x}_i^T \mathbf{x} + b \quad (6)$$

为求解非线性问题,引入核函数,最终的 SVR 模型可表示为:

$$f(\mathbf{x}) = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) k(\mathbf{x}, \mathbf{x}_i) + b \quad (7)$$

其中,  $k(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$  为核函数。通常选择径向基函数作为核函数:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right) \quad (8)$$

其中,  $\sigma$  为高斯核的带宽。

假设有  $m$  个参考标签,  $n$  个阅读器,可以得到参考标签的 RSSI 矩阵  $\mathbf{S}_{mn}$ :

$$\mathbf{S}_{mn} = \begin{bmatrix} S_{11} & S_{12} & \cdots & S_{1n} \\ S_{21} & S_{22} & \cdots & S_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ S_{m1} & S_{m2} & \cdots & S_{mn} \end{bmatrix} \quad (9)$$

其中,  $\mathbf{S}_{mn}$  表示第  $m$  个参考标签在第  $n$  个阅读器上的 RSSI 值。因为参考标签和阅读器的位置已知,故可以得到参考标签与阅读器的距离矩阵  $\mathbf{d}_{mn}$ :

$$\mathbf{d}_{mn} = \begin{bmatrix} d_{11} & d_{12} & \cdots & d_{1n} \\ d_{21} & d_{22} & \cdots & d_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ d_{m1} & d_{m2} & \cdots & d_{mn} \end{bmatrix} \quad (10)$$

其中,  $\mathbf{d}_{mn}$  表示第  $m$  个参考标签与第  $n$  个阅读器之间的物理距离。则在离线阶段可得到指纹数据库  $\mathbf{F}_{mn}$ :

$$\mathbf{F}_{mn} = [(S_{m1}, d_{m1}), (S_{m2}, d_{m2}), \dots, (S_{mn}, d_{mn})] \quad (11)$$

将  $\mathbf{S}_{mn}$  和  $\mathbf{d}_{mn}$  输入 SVR 模型进行训练,建立参考标签的 RSSI 值和对应的距离之间的非线性映射关系。设有  $n$  个待测标签,同理可得到待测标签的 RSSI 矩阵  $\mathbf{E}_{qn}$ :

$$\mathbf{E}_{qn} = \begin{bmatrix} E_{11} & E_{12} & \cdots & E_{1n} \\ E_{21} & E_{22} & \cdots & E_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ E_{q1} & E_{q2} & \cdots & E_{qn} \end{bmatrix} \quad (12)$$

在线阶段将  $\mathbf{E}_{qn}$  输入到 SVR 模型中得到待测标签与阅读器的预测距离矩阵  $\mathbf{h}_{qn}$ 。设  $n$  个阅读器的坐标分别为  $(X_2, Y_2), (X_n, Y_n), \dots, (X_n, Y_n)$ , 待测标签  $q$  的坐标为  $(x_q, y_q)$ , 可得到求解待测标签位置的非线性方程组, 如式(13)所示。通过最小二乘法或 PSO 算法求解该方程组便可得到待测标签的位置坐标。

$$\begin{cases} (x_q - X_1)^2 + (y_q - Y_1)^2 = h_{q1}^2 \\ (x_q - X_2)^2 + (y_q - Y_2)^2 = h_{q2}^2 \\ \vdots \\ (x_q - X_n)^2 + (y_q - Y_n)^2 = h_{qn}^2 \end{cases} \quad (13)$$

## 2 基于误差校正和自适应算子的 SVR-PSO

### 2.1 基于误差校正的 SVR 模型(ECSVR)

在实际环境中, 标签的 RSSI 值容易受多径效应和非视距的影响发生巨大波动, 或者出现标签和阅读器的距离近但 RSSI 值反而小的情况<sup>[12]</sup>, 影响 SVR 的预测性能, 导致待测标签的距离预测误差变大, 从而降低系统定位精度。

本文采用对数路径损耗模型<sup>[13]</sup>模拟室内环境下无线信号的传播过程, 公式如下:

$$\text{RSSI}(d) = \text{RSSI}(d_0) - 10n \lg \frac{d}{d_0} + X_\sigma \quad (14)$$

式中:  $d_0$  是参考距离,  $n$  是对数路径损耗因子。  $X_\sigma$  是均值为 0, 标准差为  $\sigma_1$  的正态随机变量。

为提升 SVR 模型的预测性能, 提出一种基于近邻参考标签的误差校正的方法。其基本思想是在 SVR 模型中, 假设参考标签的预测误差是已知的, 然后求出待测标签的近邻参考标签, 根据这些近邻参考标签的预测误差对待测标签的预测距离进行校正。具体步骤如下:

1) 将  $\mathbf{S}_{mn}$  输入到训练好的 SVR 模型得到参考标与阅读器的预测距离  $\mathbf{u}_{mn}$ , 计算参考标签的预测误差  $\mathbf{e}_{mn}$ :

$$\mathbf{u}_{mn} = \begin{bmatrix} u_{11} & u_{12} & \cdots & u_{1n} \\ u_{21} & u_{22} & \cdots & u_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ u_{m1} & u_{m2} & \cdots & u_{mn} \end{bmatrix} \quad (15)$$

$$\mathbf{e}_{mn} = \mathbf{u}_{mn} - \mathbf{d}_{mn} \quad (16)$$

2) 计算待测标签和参考标签的欧氏距离  $\mathbf{L}_{qm}$ :

$$\mathbf{L}_{qm} = \begin{bmatrix} L_{11} & L_{21} & \cdots & L_{q1} \\ L_{12} & L_{22} & \cdots & L_{q2} \\ \vdots & \vdots & \ddots & \vdots \\ L_{1m} & L_{2m} & \cdots & L_{qm} \end{bmatrix} \quad (17)$$

其中, 每列为一个待测标签与  $m$  个参考标签的欧氏距离。欧氏距离具体计算公式如下:

$$L_{qm} = \sqrt{\sum_{i=1}^n (\mathbf{S}_{mi} - \mathbf{E}_{qi})^2} \quad (18)$$

3) 将  $\mathbf{L}_{qm}$  的每列按升序排序, 并记录每个欧氏距离所对应的参考标签的序号。取每列的前  $K$  个参考标签作为该待测标签的近邻标签。

4) 找到待测标签对应的前  $K$  个参考标签所对应的预测误差  $\mathbf{e}_{kn}, k \in [1, K]$ , 计算待测标签的校正误差  $\mathbf{e}'_{qn}$ :

$$\mathbf{e}'_{qn} = \frac{1}{K} \sum_{k=1}^K \mathbf{e}_{kn} \quad (19)$$

5) 将  $\mathbf{E}_{qn}$  输入到模型中得到待测标签的距离矩阵  $\mathbf{h}_{qn}$ , 根据校正误差  $\mathbf{e}'_{qn}$  对  $\mathbf{h}_{qn}$  进行校正, 得到校正后的待测标签与阅读器的距离矩阵  $\mathbf{h}'_{qn}$ :

$$\mathbf{h}'_{qn} = \mathbf{h}_{qn} - \mathbf{e}'_{qn} \quad (20)$$

故可构建出新的求解待测标签位置的方程组, 如式(21)所示。

$$\begin{cases} (x_q - X_1)^2 + (y_q - Y_1)^2 = h'_{q1}{}^2 \\ (x_q - X_2)^2 + (y_q - Y_2)^2 = h'_{q2}{}^2 \\ \vdots \\ (x_q - X_n)^2 + (y_q - Y_n)^2 = h'_{qn}{}^2 \end{cases} \quad (21)$$

### 2.2 基于自适应算子的 PSO 算法(IPSO)

PSO 算法是一种启发式智能优化算法, 常被用于求解目标最优值问题<sup>[14]</sup>。基本 PSO 算法的惯性权重为常数, 易陷入局部最优且寻优精度不高。目前大多采用线性递减策略, 该算法通常被视为标准 PSO 算法, 公式如下:

$$\begin{cases} \mathbf{V}_i^{k+1} = \omega \times \mathbf{V}_i^k + c_1 \times r_1 \times (\mathbf{P}_{best\ i}^k - \mathbf{X}_i^k) + c_2 \times r_2 \times (\mathbf{G}_{best}^k - \mathbf{X}_i^k) \\ \mathbf{X}_i^{k+1} = \mathbf{X}_i^k + \mathbf{V}_i^{k+1} \end{cases} \quad (22)$$

$$\omega = (\omega_{start} - \omega_{end}) \left( \frac{Q - k}{Q} \right) + \omega_{end} \quad (23)$$

其中,  $\omega$  为惯性权重,  $k$  为当前迭代次数,  $Q$  为最大迭代次数。  $c_1$  为自我认知因子,  $c_2$  为社会学习因子。  $r_1, r_2$  为  $(0, 1)$  之间的随机数。  $\mathbf{V}_i^k, \mathbf{X}_i^k$  为粒子  $i$  当前的速度和位置,  $\mathbf{V}_i^{k+1}, \mathbf{X}_i^{k+1}$  为粒子  $i$  下一时刻的速度和位置,  $\mathbf{P}_{best\ i}^k, \mathbf{G}_{best}^k$  为粒子  $i$  第  $k$  次迭代找到的个体最优和群体最优。

PSO 算法迭代初期应扩大粒子的搜索区域, 避免陷入局部最优; 后期应注重提升收敛速度和准确性。研究表明, 当  $c_1 > c_2$  时, 算法具有较强的全局搜索能力; 当  $c_1 < c_2$  时, 算法具有较强的局部搜索能力<sup>[15]</sup>。基于以上分析,  $c_1, c_2$  应动态变化且分别呈现递减和递增的趋势, 标准 PSO 算法的学习因子均为固定值无法满足上述要求。本文采用异步学习的方法设计学习因子  $c_1, c_2$ , 公式如下:

$$c_1 = c_{1start} + \frac{c_{1end} - c_{1start}}{Q^2} k^2 \quad (24)$$

$$c_2 = c_{2start} + \frac{c_{2end} - c_{2start}}{Q^2} k^2 \quad (25)$$

式中:  $c_{1start} = 2.5, c_{1end} = 0.5, c_{2start} = 0.5, c_{2end} = 2.5$ 。

由上式可知,在粒子迭代初期阶段,  $c_1$  较大,  $c_2$  较小, 算法注重全局搜索,可避免发生早熟现象。随着迭代的进行,  $c_1$  逐渐变小,  $c_2$  逐渐变大,算法注重局部寻优,能够加速粒子收敛,迅速达到种群的最优位置。

此外,线性递减策略权重相比固定权重来说取得了不错的效果,但是并非对所有问题来说都是最有效的<sup>[16]</sup>。研究表明加快  $w$  的递减速度使算法较快进入局部搜索,能够提高算法的收敛速度<sup>[17]</sup>。为保证粒子在搜索过程中能更好地平衡个体和群体的关系,本文在采用异步学习因子的基础上,提出利用凹函数递减策略动态调整  $w$  的取值,改进的惯性权重公式如下:

$$w' = w_{end} (w_{start} / w_{end})^{1/(C_3 k/Q)} \quad (26)$$

其中,  $w'$  为基于凹函数递减策略的惯性权重。本文取  $w_{start} = 0.9, w_{end} = 0.4, C_3 = 10$ 。

假设粒子  $i$  的坐标为  $z_i = (x_i, y_i), i \in (1, q)$ , 则其适应度函数为:

$$fitness(z_i) = \sum_{j=1}^n \left| \sqrt{(x_i - X_j)^2 + (y_i - Y_j)^2} - h'_{ij} \right| \quad (27)$$

故可将式(21)的求解转化为目标函数的优化问题,利用 IPSO 算法迭代找到使式(27)最小的粒子,该粒子的位置即为待测标签的坐标。

ECSVR-IPSO 算法流程如图 1 所示。

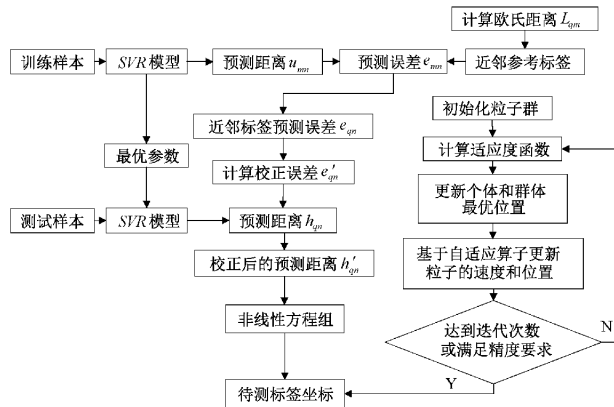


图 1 ECSVR-IPSO 算法流程

### 3 仿真结果及分析

采用 MATLAB R2018b 调用林智仁教授的 Libsvm 工具箱,实现室内定位仿真实验。假设室内定位实验场景为  $8\text{ m} \times 8\text{ m}$  的会议室区域,区域内均匀放置 16 个参考标签,间隔为  $2\text{ m}$ ,阅读器放置在 4 个顶角。在定位区域内随机产生 10 个待测标签,系统定位模型如图 2 所示。信道模型中  $n = 2.4, \sigma_1 = 0.25, d_0 = 1\text{ m}$ 。PSO 算法初始种群为 50,最大迭代次数为 100。仿真主机操作系统为 Windows10 64 bit,硬件配置为 AMD R5 5600H 处理器,主频  $3.3\text{ GHz}$ ,运行内存  $8\text{ GB}$ 。利用式(28)、(29)计算系统

的定位误差和平均误差。

$$rmse = \sqrt{\frac{1}{k} \sum_{i=1}^k (x - x_i)^2 + (y - y_i)^2} \quad (28)$$

$$\overline{rmse} = \frac{1}{q} \sum_{i=1}^q rmse_i \quad (29)$$

式中:  $(x, y)$  为待测标签的实际坐标,  $(x_i, y_i)$  为第  $i$  次仿真估计的待测标签的位置,  $k$  为仿真次数,本文中  $k = 10$ 。 $rmse$  代表待测标签的定位误差,  $\overline{rmse}$  代表区域内所有待测标签的平均定位误差。




图 2 系统定位模型

#### 3.1 验证误差校正的优越性

比较 ECSVR 和 SVR 模型预测性能,并以预测误差  $d_{rmse}$  和平均预测误差  $\overline{d_{rmse}}$  作为评价标准,用如下公式表示:

$$d_{rmse} = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - d_i^*)^2} \quad (30)$$

$$\overline{d_{rmse}} = \frac{1}{q} \sum_{i=1}^q d_{rmse} \quad (31)$$

式中:  $d_i$  为待测标签与第  $i$  个阅读器的估计距离,  $d_i^*$  为待测标签与第  $i$  个阅读器的真实距离,  $n$  为阅读器的个数,  $q$  为待测标签的个数。

表 1 为 ECSVR 和 SVR 模型的预测精度的比较,可以看出,经过误差校正后,ECSVR 模型得到的待测标签和阅读器之间的距离更准确,平均预测误差只有  $0.054\text{ m}$ ,而 SVR 模型的平均预测误差为  $0.17\text{ m}$ ,预测精度提高了  $68.2\%$ 。

表 1 ECSVR 和 SVR 模型预测误差比较

待测标签编号	ECSVR 预测误差/m	SVR 预测误差/m
1	0.052 4	0.406 5
2	0.059 8	0.068 6
3	0.037 6	0.051 4
4	0.042 9	0.730 3
5	0.051 9	0.165 7
6	0.056 3	0.058 8
7	0.061 9	0.048 6
8	0.087 7	0.105 1
9	0.021 0	0.041 8
10	0.071 8	0.052 9

表 2 为 ECSVR-PSO 和 SVR-PSO 算法定位误差的比较。可以看出经误差校正后大多数待测标签的定位误差有了明显提高。ECSVR-PSO 算法的平均定位误差为 0.620 m, 而 SVR-PSO 算法为 0.828 m, 误差校正的引入使 SVR-PSO 算法的定位精度提高了 25.1%。

表 2 ECSVR-PSO 和 SVR-PSO 定位误差比较

待测标签 编号	ECSVR-PSO 定位误差/m	SVR-PSO 定位误差/m
1	0.074 9	0.060 4
2	0.063 7	0.101 5
3	0.037 2	0.087 2
4	0.029 5	0.067 8
5	0.047 4	0.076 8
6	0.079 9	0.096 8
7	0.078 5	0.076 5
8	0.080 4	0.125 4
9	0.033 0	0.062 8
10	0.064 6	0.073 2

### 3.2 验证自适应算子的优越性

为验证 IPSO 算法的有效性,将其与基于 levy 飞行的 PSO 算法<sup>[18]</sup>以及标准 PSO 算法进行比较。将这 3 种 PSO 算法分别用于室内定位算法,并比较它们的定位误差,结果如图 3 所示。可以看出,使用本文的 IPSO 算法求解的效果最好,80%的定位误差在 0.067 m 以下,其次为 levy-PSO,80%的定位误差在 0.082 m 以下,标准 PSO 算法效果最差,80%的定位误差在 0.097 m 以下。3 种算法的平均定位误差分别为 0.068 9、0.077 4、0.082 8 m,平均运行时间为 3.9、11.8、4.5 s。综合定位精度和时间来看,IPSO 算法能较快地收敛到最优解附近,且有较高的寻优精度。




图 3 基于不同 PSO 算法的定位误差比较

### 3.3 验证 ECSVR-IPSO 算法的优越性

将 ECSVR-IPSO 算法与现有的 SVR-PSO 算法<sup>[9]</sup>、GA-SVR 算法<sup>[8]</sup>进行比较,为方便比较,同时给出了 SVR 算法的定位精度,如图 4 所示。

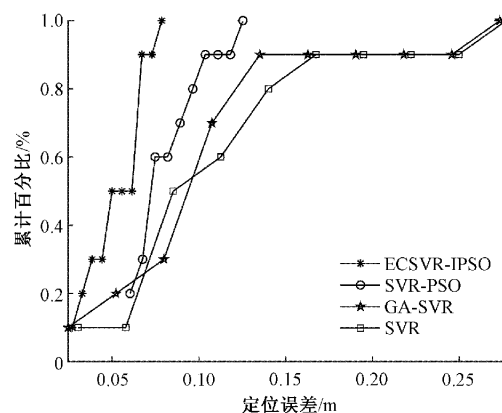


图 4 ECSVR-IPSO 算法与不同定位算法比较

由图 4 可以看出,ECSVR-IPSO 算法明显优于其他算法,可以将定位误差控制在 0.1 m 以内,平均定位误差为 0.056 6 m。比 SVR-PSO 算法定位精度提高 31.6%。GA-SVR 和 SVR 算法的平均定位误差分别为 0.112 5 和 0.134 6 m。相比这两种算法,本文算法的定位精度分别提高 49.7%和 57.9%。

### 3.4 ECSVR-IPSO 算法定位性能分析

首先研究  $K$  值对 ECSVR-IPSO 算法定位性能的影响,结果如图 5 所示。可以看出,当  $K=1$  时,算法的定位效果最好。随着  $K$  值的增大,平均定位误差开始增大且在 0.07 m 附近波动。




图 5 不同  $K$  值下 ECSVR-IPSO 算法平均定位误差

其次研究不同参考标签数下本文算法与 SVR-PSO 算法的性能比较。待测标签数为 10,保持不变,分别将参考标签数设为 9、16、49,参考标签间隔设为 2、2、1 m,结果如表 3 所示。

由表 3 可以看出,随着参考标签数量的增大,两种算法的平均定位误差逐渐减小,且 ECSVR-IPSO 算法总是优于 SVR-PSO 算法。当区域内参考标签密度  $\geq 0.77$  时 ECSVR-IPSO 算法的定位精度不再有明显提升。比较 16 个参考标签下的 ECSVR-IPSO 算法和 49 个参考标签下的 SVR-PSO 算法可知,两者具有相同的定位精度,但 ECSVR-IPSO 算法使用的参考标签数量更少,证明了该算法的优越性。

表 3 不同参考标签数下两种算法比较

算法	参考标签数/ 区域面积	参考标签 个数	平均定位 误差/m
SVR-PSO	0.14	9	0.191 7
ECSVR-IPSO	0.14	9	0.153 6
SVR-PSO	0.25	16	0.082 8
ECSVR-IPSO	0.25	16	0.056 6
SVR-PSO	0.77	49	0.058 6
ECSVR-IPSO	0.77	49	0.053 7

#### 4 结 论

本文提出了一种 ECSVR-IPSO 室内定位算法,主要创新性工作包括:一是根据 RFID 室内定位的特点,对 SVR 模型提出误差校正的方法,从而得到更为准确的待测标签和阅读器的预测距离。二是针对标准 PSO 算法存在的易陷入局部最优且收敛速度慢的问题,采用凹函数递减策略和异步学习方式设计了一种自适应算子,分别改进了惯性权重和学习因子,使 PSO 算法在寻优过程中自适应地平衡局部与全局的关系。实验结果表明,ECSVR-IPSO 算法比 SVR-PSO 算法定位精度提高了 31.6%,在相同精度下,使用的参考标签数更少,能够有效节约定位成本、提高定位效率。

#### 参考文献

- [1] 薛伟莲,赵娣,张颖超. 室内定位研究综述[J]. 计算机与现代化, 2020, 297(5): 80-88.
- [2] MOTRONI A, BUFFI A, NEPA P. A survey on indoor vehicle localization through RFID technology[J]. IEEE Access, 2021, 9: 17921-17942.
- [3] LI C, MO L, ZHANG D. Review on UHF RFID localization methods [J]. IEEE Journal of Radio Frequency Identification, 2019, 3(4): 205-215.
- [4] 邹承明,黄明凯. LANDMARC 室内定位改进算法[J]. 计算机工程与设计, 2019, 40(11): 3111-3117.
- [5] 张平均,胡鹏军,罗玲. 自适应递归校正的 LANDMARC 室内定位算法[J]. 电子测量技术, 2020, 43(21): 149-153.
- [6] LI Y, XU H, LI P. RFID-based WIMEC-LANDMARC indoor location algorithm [C]. 2020 International Conferences on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, IEEE, 2020.
- [7] 尹强,佐磊,何怡刚,等. 基于支持向量回归机的 RFID 室内定位研究[J]. 计算机工程与科学, 2017, 39(12): 2340-2344.
- [8] LIU X, WANG W, GUO Z, et al. Research on adaptive

SVR indoor location based on GA optimization [J]. Wireless Personal Communications, 2019, 109(2): 1095-1120.

- [9] YANG L, LIU Q, XU J, et al. An indoor RFID location algorithm based on support vector regression and particle swarm optimization[C]. 2018 IEEE 88th Vehicular Technology Conference (VTC-Fall), IEEE, 2018, DOI: 10.1109/VTCFall.2018.8690994.
- [10] HSIA J Y, LIN C J. Parameter selection for linear support vector regression [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(12): 5639-5644.
- [11] XU H, WU M, LI P, et al. An RFID indoor positioning algorithm based on support vector regression[J]. Sensors, 2018, DOI: 10.3390/s18051504.
- [12] 高思远,冯秀芳. 基于 RSSI 信号特征的室内分区指纹定位算法[J]. 计算机工程与设计, 2020, 41(4): 1093-1098.
- [13] ZHANG Y, LI B. Improvement of LANDMARC algorithm based on ZigBee technology [C]. 2020 International Conference on Microwave and Millimeter Wave Technology (ICMMT), IEEE, 2020, DOI: 10.1109/ICMMT49418.2020.9386383.
- [14] SAMIGULINA G, MASSIMKANOVA Z. Development of modified cooperative particle swarm optimization with inertia weight for feature selection [J]. Cogent Engineering, 2020, 7(1): 1788876.
- [15] TRELEA I C. The particle swarm optimization algorithm: Convergence analysis and parameter selection [J]. Information Processing Letters, 2003, 85(6): 317-325.
- [16] 陈贵敏,贾建援,韩琪,等. 粒子群优化算法的惯性权重递减策略研究[J]. 西安交通大学学报, 2006, 40(1): 53-56.
- [17] 郭丽丽,刘勇,王卫西. 粒子群优化算法之惯性权重递减策略的改进[J]. 黑龙江大学工程学报, 2019, 10(1): 67-71.
- [18] 范伟,孟江,杜永飞,等. 基于改进粒子群算法的精密隔振系统 LQR 控制 [J]. 电子测量技术, 2022, 45(2): 104-109.

#### 作者简介

路畅(通信作者),硕士研究生,主要研究方向为室内定位技术。

E-mail: luchang@bistu.edu.cn

崔英花,博士,教授,主要研究方向为射频识别技术、室内定位技术。

E-mail: cui\_ying\_hua@sina.com