

6-2-2020

Indoor Positioning Algorithm for RFID Based on Newton Interpolation and Support Vector Regression Optimized by Hybridizing Grey Wolf Optimization

Yangjie Xu

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Wang Yan

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Dahu Yan

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Zhicheng Ji

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Indoor Positioning Algorithm for RFID Based on Newton Interpolation and Support Vector Regression Optimized by Hybridizing Grey Wolf Optimization

Abstract

Abstract: Since the traditional LANDMARC location algorithms have poor positioning accuracy and cost laborious efforts to decorate reference tags in the RFID positioning system, a novel positioning algorithm proposed is based on the Newton interpolation method and support vector regression optimized by hybridizing grey wolf optimization with differential evolution (HGWOSVR). *By using the proposed algorithm, Gaussian filter was used to deal with the sampling data of the reference tags. Newton interpolation method was adopted to estimate the RSS value of other reference tags to expand database. The HGWOSVR algorithm was employed to build the nonlinear relationship between the RSS value of reference tags and their locations to predict the positioned tags.* Simulation results show that the proposed algorithm performs better in terms of positioning accuracy, and reduces the workload of decorating reference tags, which improves working efficiency of the indoor location positioning method.

Keywords

RFID, Newton interpolation, DE algorithm, GWO algorithm, SVR algorithm

Recommended Citation

Xu Yangjie, Wang Yan, Yan Dahu, Ji Zhicheng. Indoor Positioning Algorithm for RFID Based on Newton Interpolation and Support Vector Regression Optimized by Hybridizing Grey Wolf Optimization[J]. Journal of System Simulation, 2017, 29(9): 1921-1929.

基于 Newton 插值与混合灰狼优化 SVR 的 RFID 定位算法

徐杨杰, 王艳, 严大虎, 纪志成

(江南大学物联网技术应用教育部工程研究中心, 江苏 无锡 214122)

摘要: 针对 RFID 定位系统中, 传统的 LANDMARC 定位算法定位精度不高且需要布置大量参考标签的问题, 提出了一种基于牛顿插值和差分进化改进灰狼优化支持向量回归机(Newton-HGWOSVR)的定位算法。该算法采用高斯滤波对参考标签的采样数据进行预处理; 通过牛顿插值法对其它位置的信号强度进行估值来扩充信号数据库; 通过 HGWOSVR 构建物理位置和信号接收强度值之间的非线性关系来完成定位。实验结果表明, 该算法提升了室内定位的精度, 并且能减少布置参考标签的工作量, 提高了室内定位方法的工作效率。

关键词: RFID; Newton 插值; DE 算法; GWO 算法; SVR 算法

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X (2017) 09-1921-09

DOI: 10.16182/j.issn1004731x.joss.201709007

Indoor Positioning Algorithm for RFID Based on Newton Interpolation and Support Vector Regression Optimized by Hybridizing Grey Wolf Optimization

Xu Yangjie, Wang Yan, Yan Dahu, Ji Zhicheng

(Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China)

Abstract: Since the traditional LANDMARC location algorithms have poor positioning accuracy and cost laborious efforts to decorate reference tags in the RFID positioning system, a novel positioning algorithm proposed is based on the Newton interpolation method and support vector regression optimized by hybridizing grey wolf optimization with differential evolution (HGWOSVR). By using the proposed algorithm, Gaussian filter was used to deal with the sampling data of the reference tags. Newton interpolation method was adopted to estimate the RSS value of other reference tags to expand database. The HGWOSVR algorithm was employed to build the nonlinear relationship between the RSS value of reference tags and their locations to predict the positioned tags. Simulation results show that the proposed algorithm performs better in terms of positioning accuracy, and reduces the workload of decorating reference tags, which improves working efficiency of the indoor location positioning method.

Keywords: RFID; Newton interpolation; DE algorithm; GWO algorithm; SVR algorithm

引言

近年来, 人们对室内位置信息服务如个性化信



收稿日期: 2017-05-17 修回日期: 2017-07-10;
基金项目: 国家自然科学基金(61572238), 江苏省杰出青年基金(BK20160001), 江苏省产学研联合创新资金-前瞻性联合研究项目(201602224);
作者简介: 徐杨杰(1992-), 男, 江苏盐城, 硕士生, 研究方向为基于 RFID 的室内定位算法。

息传递、医疗服务、目标发现等的需求与日俱增^[1], 无论室外还是室内的位置信息都是不可或缺的。传统的基于卫星的定位技术, 如全球定位系统(Global Positioning System, GPS), 能够很好地满足室外定位的需求, 但是用于室内定位时, 由于建筑物对卫星信号的影响, 定位能力受到很大的限制^[2]。

目前被广泛研究的定位技术包括红外技术、视

觉定位技术、超声波技术、超宽带(Ultra Wide Band, UWB)技术、无线传感器网络(Wireless Sensing Networks, WSN)、射频识别(Radio Frequency Identification, RFID)、ZigBee 和无线局域网(Wireless Local Area Networks, WLAN)定位技术等。其中,射频识别定位技术以其非接触、非视距、高灵敏度和低成本的优点,成为室内定位系统的热门技术,受到人们越来越多的关注。

射频识别定位技术使用的定位方法可以分为测距算法和非测距算法。测距算法的实质是根据测量阅读器与标签的方位或距离进行定位,主要包括信号到达时间(Time of Arrival, TOA)、信号到达时间差(Time Difference of Arrival, TDOA)、信号到达角(Angle of Arrival, AOA)和信号传播模型测距等方法。其中 TOA、TDOA 以及 AOA 算法能取得较高的精度,但需要添加昂贵的测量设备,因此不适合在现实环境大规模部署。传播模型法利用经验公式将信号接收强度(Received Signal Strength, RSS)转化为距离进行定位,优点是低功率、低成本、简单易行。但是容易受到室内复杂环境的影响,定位精度低。

典型的基于非测距算法的 RFID 定位系统就是 LANDMARC 系统。LANDMARC 系统^[3]是由 Ni 等提出的一种有源 RFID 室内定位系统,它在定位区域引入参考标签代替 RFID 阅读器,通过分析待定位标签和参考标签的 RSS,利用 K 近邻算法估计位置坐标,节约了成本但需要密集的参考标签辅助定位,增加了室内信号传播的干扰性,以及布置参考标签的工作量。针对 LANDMARC 算法存在的问题,文献[4]将 LANDMARC 与三边算法结合在一起,利用参考标签校正待测标签来提高精度,但是增加了算法复杂度;文献[5]结合路径损耗模型,提出了非视距环境下的改进策略,但是缺少一个能适用于各种复杂环境的损耗模型;文献[6]提出利用多天线控制阅读器的功率来改善定位精度,该方法不需要参考标签,减小了系统的复杂度,不过需要对阅读器硬件进行改造,增加硬件成本;文献[7]

引入线性插值技术,通过采用虚拟网格坐标和小概率位置排除法来达到更准确的定位结果。与 LANDMARC 相比,其主要优点是节省了成本并减少了室内信号传播的干扰;其次,相比于传统的以检测到的 RSS 值估计测量距离进行定位,该方法以虚拟标签作为辅助,能有效提高定位精度。但是,实际环境中信号强度值与距离并非简单的线性关系,采用线性插值法来估计虚拟参考标签的信号强度值将导致其估计值与实际值偏差较大,影响最终的定位准确率。

针对上述方法的缺陷,本文提出了一种 Newton-HGWOSVR 定位算法。该算法通过 Newton 插值法取代线性插值法能更好的满足实际信号传播损耗情况,同时在构建物理位置与 RSS 值函数关系时通过差分进化改进灰狼优化算法(Hybridizing Gray Wolf Optimization with Differential Evolution, HGWO)对支持向量回归机(Support Vector Regression, SVR)的参数进行寻优来提高定位算法的精度。

1 Newton-HGWOSVR 定位系统描述

基于 Newton 插值与 HGWOSVR 匹配算法的定位系统框图如图 1 所示,主要包括离线和在线两个阶段。离线阶段主要负责扩充 RSS 数据库及构建信号位置匹配模型,首先对定位区域的参考标签进行 RSS 数据采集,对采集的数据预处理后通过 Newton 插值算法扩充信号数据库,最后通过 HGWOSVR 算法训练样本构建 RSS-位置模型。在线位置估计阶段,阅读器读取待测标签的 RSS 值,去噪后即可通过构建好的 RSS-位置模型求解目标位置。

2 Newton-HGWOSVR 算法原理

2.1 高斯滤波

选取一定的参考标签进行 RSS 值采集时,为确保数据的准确性需要进行多组次采集,以更好的

获取受到室内环境的各种因素影响的信号强度的真实数据。然而 RSS 测距会受到很多因素的干扰, 在不同环境下外界的干扰因素也不同, 使得同一 RSS 值会对应多个不同的位置, 这些现象破坏了距离和信号强度值之间的对应关系, 给测得的距离造成很大的误差。假设每次测量是独立的, RSS 值可以看作是一种正态分布, 通过高斯滤波将一些突变的小概率干扰项滤除^[8], 最终获取一个能平稳真实反映采样点属性的 RSS 值, 从而为下一阶段的估计插值及数据库的扩充提供精确的数据支持。其拟合处理函数如公式(1)~(3)所示:

$$f(x) = \frac{1}{\sigma\sqrt{\pi/2}} e^{-2(x-\mu)^2/\sigma^2} \quad (1)$$

$$\mu = \frac{\sum_{i=1}^k RSSI_i}{k} \quad (2)$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^k (RSSI_i - \mu)^2}{k-1}} \quad (3)$$

式中: μ 表示该位置接收到的信号 RSS 值的均值; σ 表示该位置接收的信号 RSS 值的标准差; $f(x)$ 表示该位置测量结果的密度函数。将该位置接收到的信号 RSS 值代入公式(1)中, 当 $0.6 \leq f(x) \leq 1$ 时, 求取满足要求的信号强度值加权平均作为参考标签最终的信号强度值。

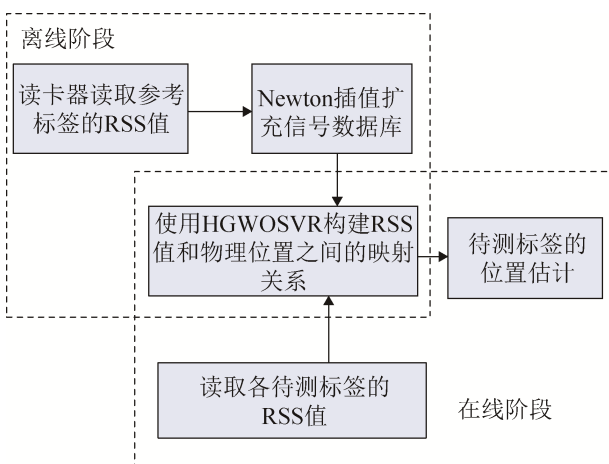


图 1 LWR-ABCSVR 系统框图
Fig. 1 System chart of LWR-ABCSVR

2.2 Newton 插值扩充信号数据库

针对 LANDMARC 需要密集的参考标签辅助定位, 增加了室内信号传播的干扰性的问题, 文献[7]采用线性插值的技术引入虚拟参考标签来减少信号传播的干扰, 同时减少了实体参考标签的数量。但是 RSS 值和距离之间是复杂的传播损耗模型关系, 因此对 RSS 值按线性插值计算就会产生不可忽略的误差。采用恰当的插值算法在扩建信号数据库, 将使定位精度进一步提高。

经典的多项式插值算法主要有 Lagrange 插值法、Newton 插值法等。Lagrange 插值法方式具有对称性, 易编程实现的特点。但是其中的插值多项式随着插值节点的增加, 所有插值基函数必须重新计算。Newton 插值多项式的使用比较灵活, 并具有承袭性。插值节点增加后, 只需在原有基础上增加部分计算, 且插值余项也较容易估计。因此, 用 Newton 插值方式求得的 RSS 值更符合实际环境, 也会提高整个算法的精度。本文采用 Newton 插值算法扩充信号数据库。

Newton 插值多项式:

$$N_n(x) = f(x_0) + f[x_0, x_1](x - x_0) + (x - x_0)(x - x_1)f[x_0, x_1, x_2] + \dots + f[x_0, x_1, \dots, x_n](x - x_0)(x - x_1)(x - x_{n-1}) \quad (4)$$

其中: $f[x_0, x_1, \dots, x_k] =$

$$\frac{f[x_1, x_2, \dots, x_k] - f[x_0, x_1, \dots, x_{k-1}]}{x_k - x_0}$$

由于阅读器读取标签的 RSS 值时, 在各个方向上存在差异, 因此计算时以阅读器为圆心, 将每个 90°区域平均分为 6 等分, 即每 15°作为一个计算单元。插值过程如下:

步骤 1 把感应区域分成 6 等分, 若某个参考标签处于两个区域的界线上, 那么标签同属这两个区域。

步骤 2 根据阅读器和参考标签的距离 $D_i (1 \leq i \leq n, n$ 为参考标签的数目)对 RSS 值 $RS_0, RS_1, RS_2, \dots, RS_n$ 按升序排列, 其中 RS_0 表示当 D_i 最小时对应的 RSS 值。

步骤 3 以 D_i 为自变量, RS_i 为因变量, 那么插值节点即 RSS 值。

步骤 4 将每个区域的虚拟参考坐标的 RSS 值都按步骤 3 算出, 即可求出所有虚拟参考坐标的 RSS 值。

2.3 支持向量回归方法

构建好信号数据库后, 解决定位问题的关键就是获取物理位置与信号强度之间的函数关系, 在实际室内定位环境中, 由于多径、阴影效应, RF 阅读器上来自参考标签的 RSS 值呈现非线性的特征。目前主流的方法是使用神经网络和支持向量机等机器学习方法对位置和信号强度之间的非线性关系进行拟合^[9-10]。人工神经网络作为典型的学习算法, 环境适应性较强、复杂度低, 但泛化能力差、定位精度不高。本文采用支持向量机回归算法构建信号 RSS 值与物理位置的非线性映射关系, 以较低的算法复杂度有效提高定位算法的精度。

支持向量机来源于统计学习理论, 是一种能够有效解决小样本学习问题的通用学习算法^[11], 与传统学习方法不同, 支持向量机依据结构风险最小化原则, 通过 VC 维大小控制置信范围, 从而使得实际期望风险最小。因此拥有比传统学习方法更优异的泛化能力。在 RFID 定位算法中, 采用带 ε 不敏感损失函数的支持向量回归机来拟合 RSS 值和物理位置之间的关系^[12]。

假设 $s = [s_1, s_2, \dots, s_n]^T$ 为参考标签在位置 (x, y) 处接收到来自 n 个 RF 阅读器的信号强度所构成的向量。RSS 信号与物理位置呈非线性映射关系, 假设物理坐标与 RSS 的关系如式(5)所示:

$$\begin{aligned} x &= f(s) \\ y &= g(s) \end{aligned} \quad (5)$$

其中: $f(\cdot)$ 和 $g(\cdot)$ 均为非线性函数, 以 y 轴坐标为例。通过一个非线性映射 $\phi(s)$ 将输入样本空间的数据映射到一个高维特征空间, 此时可以将非线性函数转为线性关系, 在高维特征空间构造回归估计函数:

$$y = \phi(s)^T \mathbf{w} + b \quad (6)$$

式中: \mathbf{w} 为权重向量, 其维数与 $\phi(s)$ 相同, b 为偏置常数。训练目标就是求得 \mathbf{w} 与 b 的最优值, 以使得 SVR 的泛化性能最好。回归学习函数的泛化性能通过回归学习的期望风险函数 $R(\mathbf{w})$ 评估。

$$R(\mathbf{w}) = \int L(y, f(s, \mathbf{w})) dF(s, y) \quad (7)$$

$$L(y, f(s, \mathbf{w})) = \text{Max}(0, |f(s, \mathbf{w}) - y| - \varepsilon) \quad (8)$$

$$\varepsilon > 0$$

式(8)中: $\{f(s, \mathbf{w})\}$ 是预测函数集, 可以表示任何函数集; $L(y, f(s, \mathbf{w}))$ 是由于用 $\{f(s, \mathbf{w})\}$ 对输出 y 进行预测而产生的差别, 即为损失函数。引入 ε 不敏感 SVR 修正损失函数; 当预测值与实际值相差 ε 小于损失函数的值等于 0, 一定程度上提高了回归估计的稀疏性; $F(s, y)$ 为信号强度与 y 坐标之间的联合概率密度分布。我们可采用结构风险最小化原则求取期望风险函数的最优值, 引入松弛因子 ξ_i 和 ξ_i^* , 最优目标转化为:

$$\begin{aligned} \min J(\mathbf{w}) &= \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s.t.} &\begin{cases} (\phi(s_i)^T \mathbf{w} + b) - y_i \leq \varepsilon + \xi_i \\ y_i - (\phi(s_i)^T \mathbf{w} + b) \leq \varepsilon + \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0, C \geq 0 \end{cases} \end{aligned} \quad (9)$$

式中: $\|\mathbf{w}\|$ 控制置信范围的大小, $\sum_{i=1}^l (\xi_i + \xi_i^*)$ 控制经验风险, 即训练误差, C 为惩罚因子, 是用于平衡置信范围和经验风险的参数。根据对偶原理和 Karush-Kuhn-Tucker(KKT)^[13]条件, \mathbf{w} 可以被一定数量的支持向量线性表示, 即 $\mathbf{w} = \sum_{i=1}^{NSV} \alpha_i \phi(s_i)$,

则式(6)可转化为:

$$y = \sum_{i=1}^{NSV} \alpha_i \phi(s)^T \phi(s_i) + b \quad (10)$$

式中: NSV 表示 ε -带边界上的样本 x_i , 即标准支持向量集合; α_i 为朗格朗日乘子。 $\phi(s)^T \phi(s_i)$ 可以不用显式计算, 而是通过计算核函数得出。高斯核具有良好的局部特征提取能力, 从而准确描述 RSS 与物理位置之间的关系, 因此本文选择高斯核作为 SVR 的核函数。

$$\phi(s)^T \phi(s_i) = K(s, s_i) = \exp(-g \|s - s_i\|^2) \quad (11)$$

式中: $K(\cdot, \cdot)$ 和 g 分别是核函数和相应的核参数。式(10)即可转化为:

$$y = \sum_{i=1}^{NSF} \alpha_i K(s, s_i) + b \quad (12)$$

给定参数 C, g, ε 对(9)式进行凸二次优化, 即可得到支持向量机权重 w 的全局最优解。 x 坐标的求解过程与上述方法类似。

2.4 基于 HGWO 算法的 SVR 参数优化

在 SVR 建模过程中, 其惩罚参数 C 、核函数参数 g 和不敏感系数 ε 是影响 SVR 性能的主要因素^[14]。所谓 SVR 参数优化选择是指寻找最优的参数组合 (C, g, ε) , 使 SVR 具有最好的回归性能, 提高 SVR 的学习和泛化能力。文献[15]中使用了网格搜索选取 SVR 的最优参数, 然而网格搜索法的寻优精度不高^[16]。针对 SVR 参数寻优问题, 本文使用差分进化改进灰狼算法优化 SVR 参数。

GWO^[17]优化算法是由 Mirjalili 等人于 2014 年提出的一种模仿狼群狩猎行为过程新型群体智能优化算法。该算法具有结构简单、需要调节的参数少等特点, 同时在收敛精度和收敛速度也优于其他群智能算法。在 GWO 算法中, 灰狼主要分为 $\alpha, \beta, \delta, \omega$ 四级, 其中 α 狼等级最高, 负责寻优过程中的控制决策。该算法主要通过狼群跟踪、包围、追捕、攻击猎物等过程实现优化的目的。

狼群在狩猎过程中首先对目标进行包围, 该过程的数学模型为:

$$D = |C \cdot X_p(t) - X(t)| \quad (13)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (14)$$

式中: A 和 C 表示系数; t 为当前的迭代次数; X_p 代表猎物位置; X 代表灰狼位置。 A 和 C 的数学计算公式如下:

$$a = 2 \left(1 - \frac{t}{Iter_{max}} \right) \quad (15)$$

$$A = 2ar_1 - a \quad (16)$$

$$C = 2 \cdot r_2 \quad (17)$$

其中: $Iter_{max}$ 为最大迭代次数, a 的值从 2 线性递减到 0; r_1 和 r_2 为区间[0, 1]的随机向量。

在对猎物进行包围后, 灰狼实行追捕行为, 为了能够更好地搜寻到猎物的位置, 该过程通常是由 α, β 和 δ 来引导, 该阶段狼群位置更新表达式为:

$$\begin{cases} D_\alpha = |C_1 \cdot X_\alpha - X|, D_\beta = |C_2 \cdot X_\beta - X| \\ D_\delta = |C_3 \cdot X_\delta - X| \end{cases} \quad (18)$$

$$\begin{cases} X_1 = X_\alpha - A_1 D_\alpha, X_2 = X_\beta - A_2 D_\beta \\ X_3 = X_\delta - A_3 D_\delta \end{cases} \quad (19)$$

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (20)$$

式中: $D_\alpha, D_\beta, D_\delta$ 为其他灰狼与 α, β, δ 的距离; $X(t+1)$ 为更新后灰狼的位置。

灰狼在攻击猎物时, 通过不断线性减小参数 a 的值, A 也相应的在区间[-2a, 2a]取任意值, 当 $|A| \leq 1$ 时, 狼群则集中攻击猎物, 当 $|A| > 1$ 时, 灰狼则抛弃此猎物寻找其他的猎物即局部最优解。

由于灰狼算法在寻优到一定阶段后, 部分灰狼在局部极值附近聚集, 从而导致寻优进展缓慢, 难以跳出局部最优。因此, 本文引入差分进化算法的差分策略^[18], 通过该算法中的变异、交叉和选择过程, 使得算法能跳出局部最优, 同时充分利用差分进化算法在局部寻优方面的优点, 提高算法的寻优精度。DE 算法的变异操作为:

$$v_{i,G+1} = x_{r_1,G} + F(x_{r_2,G} - x_{r_3,G}) \quad (21)$$

式中: $v_{i,G+1}$ 为第 G 代个体变异得到的新个体; F 为缩放因子, 它对差分向量进行放大缩小控制。

为了提高种群的多样性, 交叉操作方式为:

$$u_{j,G+1} = \begin{cases} v_{j,G+1} & \text{rand}(j) \leq CR \\ x_{j,G+1} & \text{rand}(j) > CR \end{cases} \quad (22)$$

式中: $u_{i,G+1}$ 为第 G 代灰狼变异体与第 $G+1$ 代灰狼交叉产生的新个体; $\text{rand}(j)$ 是[0, 1]之间的一个随机数; CR 表示在[0, 1]的交叉概率因子, CR 越大有利于局部搜索和加快收敛; CR 越小有利于全局搜索和保持种群多样性。

HGWO 的参数优化过程如下:

步骤 1 归一化处理已经采集到的位置指纹数据训练样本集 $\{y_i, s_i\}$ 。

步骤 2 初始化 SVR 的参数 $[C, g, \varepsilon]$ 的取值范

围, 并设置 HGWO 算法的相关参数。

步骤 3 在设定的范围初始化灰狼个体位置 $X_i(i=1,2,\dots,n)$ 并根据式(15)~(17)初始化 a, A, C 。

步骤 4 计算种群中每个灰狼个体的适应度值并排列, 取最优 3 位的灰狼个体位置分别记为 $X_\alpha, X_\beta, X_\delta$ 。

步骤 5 根据式(18)计算其他个体与 α, β, δ 的距离, 并根据式(19)~(20)更新各灰狼个体的位置, 同时根据式(13)~(15)更新 a, A, C 等参数的值。

步骤 6 引入 DE 算法, 根据式(21)~(22)产生灰狼变异子个体。

步骤 7 比较变异子个体与父代灰狼的适应度值, 如果子灰狼个体的适应度函数值比上一代更好则取代之, 从而进一步对父代种群进行更新。

步骤 8 判断是否达到最大迭代次数, 输出适应度最佳的灰狼 X_α 进行 SVR 参数训练。在线阶段将 RSS 值输入 SVR 模型中即可得到对应的位置预测值。

3 仿真实验与结果分析

3.1 仿真环境

为了验证本文提出的 Newton-HGWOSVR 定位算法的性能, 在主频分别为 2.50 GHz 和 2.49 GHz 的 Intel i5 双核 CPU 及 3.89GB 内存的 PC 机上利用 MATLAB 进行定位仿真实验。仿真布局如图 2 所示: 在 $8\text{m}\times 8\text{m}$ 的空间布设 4 个阅读器, 16 个参考标签, 相邻参考标签均匀间距 2 m, 并放置 16 个待定位标签, 4 个阅读器分布在室内环境的边界, 并假设能够检测到所有标签。阅读器对每个参考标签和待定位标签分别测量其 RSS 值进行实验仿真。

3.2 结果分析

为了验证本文提出算法的定位性能, 同时采用传统的 LANDMARC 算法以及 VIRE 算法进行了定位仿真。其中 HGWO 算法中种群个数设置为 50、最大迭代次数为 200、缩放因子 F 区间为 $[0.2, 0.8]$ 、交叉概率 CR 为 0.2。LANDMARC 邻近参考标签

数 K 设置为 4, VIRE 算法中 N 设置为 3。实验中使用了 LIBSVM 工具箱^[19]。




图 2 仿真布局图
Fig. 2 Simulation layout

图 3~5 分别为经典的 LANDMARC 算法、VIRE 算法以及本文提出的 Newton-HGWOSVR 算法的定位仿真结果图。结果表明, LANDMARC 算法对于那些位于边缘的待测标签定位结果不是很理想, 这是因为边缘没有设置参考标签, 导致定位精度低。而本文提出的 Newton-HGWOSVR 算法对于边缘标签的定位精度提升比较明显, 估计结果和真实值最接近, 这得益于本文提出的方法采用 HGWOSVR 算法对支持向量回归机参数优化以及采用 Newton 插值进行 RSS 数据库扩充的结果。以下分别从这两方面进行分析。




图 3 LANDMARC 仿真结果图
Fig. 3 Simulation result chart of LANDMARC

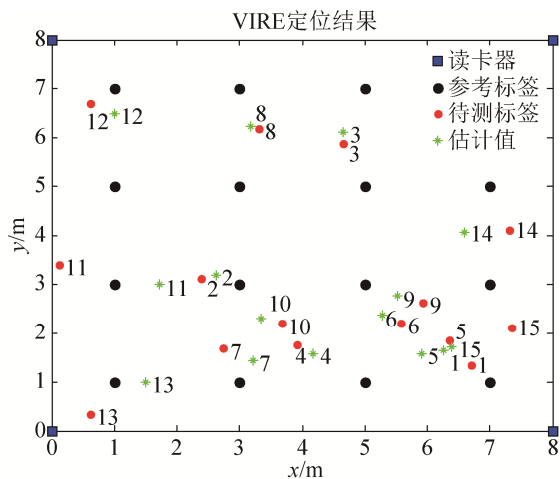


图 4 VIRE 仿真结果图
Fig. 4 Simulation result chart of VIRE

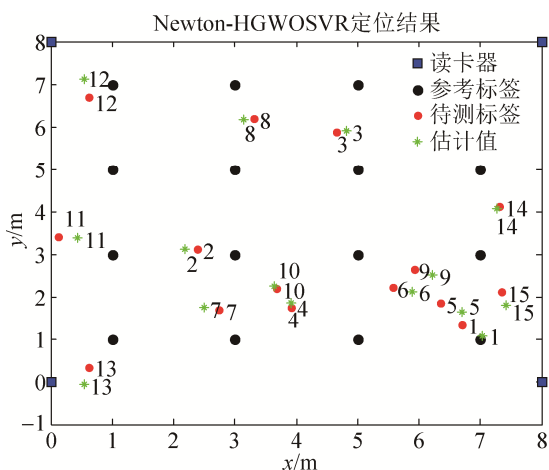


图 5 Newton-HGWOSVR 仿真结果图
Fig. 5 Simulation result chart of Newton-HGWOSVR

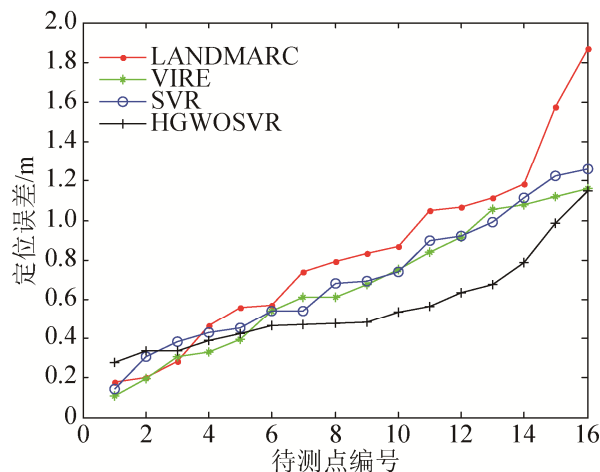


图 6 定位误差比较图
Fig. 6 Schematic diagram of position error

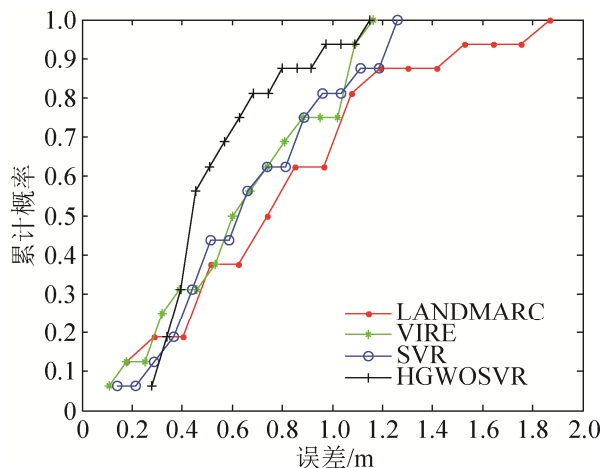


图 7 定位精确度对比图
Fig. 7 Schematic diagram of position accuracy

图 6 所示为各待测标签的定位误差由小到大排序的定位误差图。从图 6 可以看出, 几种算法相比较 LANDMARC 算法都有较大提升。其中 HGWOSVR 算法的定位误差最小, 相比于用网格搜索 SVR 算法定位误差有明显的改善。说明采用 DE 改进 GWO 方法优化 SVR 参数可有效减少定位误差。然而, 由于离线训练的参考标签数量有限。导致网格搜索 SVR 方法的精度没有 VIRE 算法高。

图 7 为各算法的定位误差累计概率曲线图。当平均误差在 0.8 m 以内时 HGWOSVR 算法的累积概率约为 80%, 而网格搜索 SVR, VIRE, LANDMARC 算法的累积概率分别为 60%, 65%, 50%。说明 HGWOSVR 算法定位性能好。

图 8~9 分别为针对 LANDMARC 算法以及 HGWOSVR 算法采用 Newton 插值算法进行扩充 RSS 数据库前后的误差以及定位准确度对比。从图 8 可以看出采用 Newton 插值扩充数据库后定位误差都有减少, 其中 Newton-HGWOSVR 算法较 HGWOSVR 误差有明显减少。图 9 中, 本文提出的算法在 0.4 m 误差以内就能达到 95% 以上, 而 Newton-LANDMARC、HGWOSVR、LANDMARC 3 种算法的定位准确度分别为 40%, 30%, 15%。说明采用 Newton 扩充数据库可以提升定位算法的定位性能, 意味着在保证定位精度的前提下可以通过 Newton 插值的方式减少布置参考标签的个数。

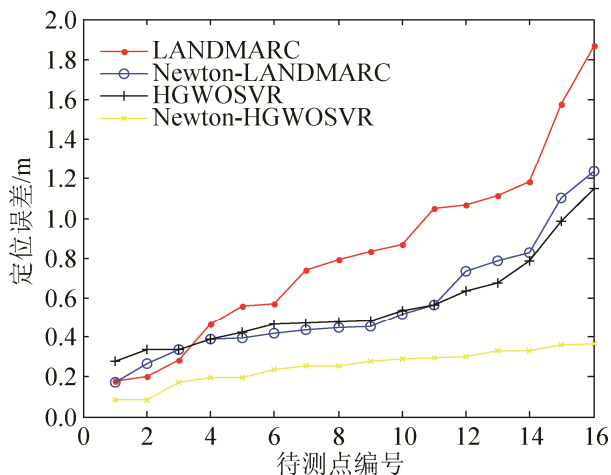


图 8 扩充数据库前后定位误差对比

Fig. 8 Comparison of location error with expanded database

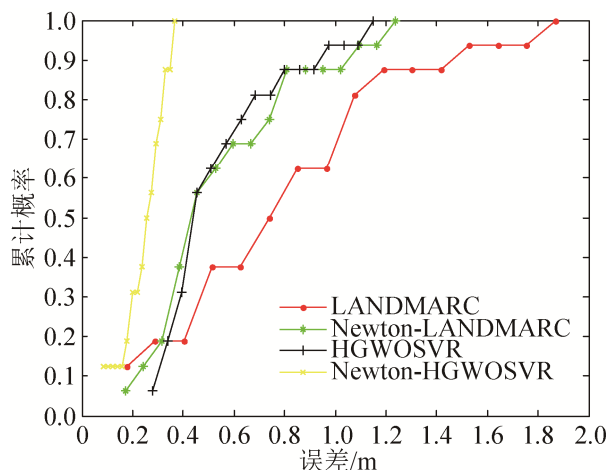


图 9 扩充数据库前后准确度对比

Fig. 9 Comparison of accuracy with expanded database

为了比较算法的综合性能,表 1 列出了几种算法的最大误差、平均误差、训练时间以及预测时间等指标。可以看到本文提出的 Newton-HGWOSVR 算法的定位误差远小于其他几种算法。定位准确度也优于本文其他的算法。但是采用本方法需要在离线阶段训练采集的样本数据来构建合理的 RSS-位置模型,因此消耗了部分的计算开销,但是其预测时间相比其余算法并不算长。虽然实时性略有降低,但是对提升定位精度和减少布置密集参考标签的工作量的效果是很好的。综上所述,本文提出的 Newton-HGWOSVR 算法具有更好的定位性能。

表 1 算法综合性能比较

Tab. 1 Comparison of algorithm combination property				
算法名称	最大误差/m	平均误差/m	训练时间/s	预测时间/s
LANDMARC	1.866	0.833	0	0.035
VIRE	1.616	0.668	0	0.291
网格搜索 SVR	1.259	0.707	1.121	0.469
HGWOSVR	1.149	0.561	12.432	0.667
Newton-HGWOSVR	0.366	0.252	21.160	0.705

4 结论

本文针对在 RFID 环境下,传统的 LANDMARC 算法定位精度不高且需要布置大量参考标签等问题,提出了一种 Newton-HGWOSVR 定位算法。该算法首先通过 Newton 插值算法在离线阶段对预处理之后的 RSS 值进行插值扩充;然后利用 HGWOSVR 构建物理位置和 RSS 之间的非线性预测关系,并通过构建的预测模型完成定位。实验结果表明,本文提出的 Newton-HGWOSVR 定位算法的定位精度高于传统的 LANDMARC, VIRE 算法及网格搜索 SVR 定位算法。既提升了定位精度也能在一定程度上减少需要布置的参考标签的数量,具有更好的定位性能。

参考文献:

- [1] 钱志鸿, 王义君. 面向物联网的无线传感器网络综述 [J]. 电子与信息学报, 2013, 35(1): 215-227. (Qian Zhi-hong, Wang Yi-jun. Internet of Things-oriented Wireless Sensor Networks Review [J]. Journal of Electronics & Information Technology, 2013, 35(1): 215-217.)
- [2] 石雪军, 纪志成. 基于射频识别的室内定位系统算法研究 [J]. 系统仿真学报, 2015, 27(6): 1294-1300. (Shi Xue-jun, Ji Zhi-cheng. Indoor Positioning System Algorithm Based on RFID [J]. Journal of System Simulation (S1004-731X), 2015, 27(6): 1294-1300.)
- [3] M N Lionel, Y Liu, Y C Lau, et al. LANDMARC: Indoor location sensing using active RFID [J]. Wireless Networks (S1022-0038), 2004, 10(6): 701-710.
- [4] Jin G Y, Lu X Y, Park M S. An indoor localization mechanism using active RFID tag [C]// Proceedings of the IEEE International Conference on Sensor Networks,

- Ubiquitous, and Trustworthy Computing, Taiwan, China. USA: IEEE, 2008: 511-514.
- [5] Zhao J, Zhao C, Yang W. An improved location algorithm for RFID system in NLOS environment [C]// Wireless and Optical Communications Conference. USA: IEEE, 2010: 1-5.
- [6] Li X, Yan L, Pan W, et al. Improved Accuracy of RFID Localization Assisted by Output Power Adjustment of the Reader [M]// Internet of Things. Germany: Springer Berlin Heidelberg, 2012: 220-225.
- [7] Y Zhao, L M Ni. VIRE: Active RFID-based Localization Using Virtual Reference Elimination [C]// The 2007 International Conference on Parallel Processing. USA: IEEE, 2007: 56.
- [8] 张明华, 张申生, 曹健. 基于无线局域网定位的误差关键因素分析与仿真 [J]. 系统仿真学报, 2009, 21(15): 4866-4869. (Zhang Ming-hua, Zhang Shen-sheng, Cao Jian. Analysis and Simulation of Key Factors for Errors in WLAN-based Location Estimation [J]. Journal of System Simulation (S1004-731X), 2009, 21(15): 4866-4869.)
- [9] Mok E, Cheung B K S. An Improved Neural Network Training Algorithm for Wi-Fi Fingerprinting Positioning [J]. ISPRS International Journal of Geo-Information (S2220-9964), 2013, 2(3): 854-868.
- [10] 邓志安, 徐玉滨. 基于支持向量机回归算法的 WLAN 室内定位系统 [J]. 仪器仪表学报, 2009, 30(6): 578-582. (Deng Zhi-an, Xu Yu-bin. A Support Vector Regression Algorithm for Indoor Positioning in Wireless Local Area Networks [J]. Chinese Journal of Scientific Instrument, 2009, 30(6): 578-582.)
- [11] 张学工. 关于统计学习理论与支持向量机 [J]. 自动化学报, 2000, 26(1): 32-42. (Zhang Xue-gong. Introduction to Statistical Learning Theory and Support Vector Machines [J]. Acta Automatica Sinica, 2000, 26(1): 32-42.)
- [12] 邓志安. 基于学习算法的 WLAN 室内定位技术研究 [D]. 哈尔滨: 哈尔滨工业大学, 2012. (Deng Zhi-an. Research on Learning Based WLAN Indoor Positioning Techniques [D]. Harbin, China: Harbin Institute of Technology, 2012.)
- [13] 黄秋钧. 基于 SVR 的 GSM 网络侧定位技术的研究与实现 [D]. 北京: 北京邮电大学, 2013. (Huang Qiu-jun. Research and Implementation of Location Technology in GSM Networks Based on SVR [D]. Beijing, China: Beijing University of Posts and Telecommunications, 2013.)
- [14] 刘路, 王太勇. 基于人工蜂群算法的支持向量机优化 [J]. 天津大学学报(自然科学与工程技术版), 2011, 44(9): 803-809. (Liu Lu, Wang Tai-yong. Support Vector Machine Optimization Based on Artificial Bee Colony Algorithm [J]. Journal of Tianjin University (Science and Technology), 2011, 44(9): 803-809.)
- [15] 张勇, 黄杰, 徐科宇. 基于 PCA-LSSVR 算法的 WLAN 室内定位方法 [J]. 仪器仪表学报, 2015, 36(2): 408-414. (Zhang Yong, Huang Jie, Xu Ke-yu. Indoor positioning algorithm for WLAN based on principal component analysis and least square support vector regression [J]. Chinese Journal of Scientific Instrument, 2015, 36(2): 408-414.)
- [16] 纪昌明, 周婷, 向腾飞, 等. 基于网格搜索和交叉验证的支持向量机在梯级水电系统随机调度中的应用 [J]. 电力自动化设备, 2014, 34(3): 125-131. (Ji Chang-ming, Zhou Ting, Xiang Teng-fei, et al. Application of support vector machine based on grid search and cross validation in implicit stochastic dispatch of cascaded hydropower stations [J]. Electric Power Automation Equipment, 2014, 34(3): 125-131.)
- [17] Mirjalili S, Mirjalili S M, Lewis A. Grey Wolf Optimizer [J]. Advances in Engineering Software (S0965-9978), 2014, 69(3): 46-61.
- [18] 陈涛. 基于差分进化算法的支持向量回归机参数优化 [J]. 计算机仿真, 2011, 28(6): 198-201. (Chen Tao. Parameters Optimization of Support Vector Regression Based on Differential Evolution [J]. Computer Simulation (S1006-9348), 2011, 28(6): 198-201.)
- [19] Chang C C, Lin C J. LIBSVM: A library for support vector machines [J]. ACM Transactions on Intelligent Systems & Technology (S2231-1961), 2011, 2(3): 389-396.