

doi:10.3969/j.issn.1001-4616.2017.02.006

# 基于果蝇—广义回归神经网络优化的 WSN 节点定位算法

陈 璟<sup>1</sup>, 虞继敏<sup>2</sup>

(1. 广西科技师范学院数学与计算机科学学院, 广西 来宾 546199)

(2. 重庆邮电大学工业物联网与网络化控制教育部重点实验室, 重庆 400065)

[摘要] 针对无线传感器网络(WSN)基于测距的定位算法中,利用节点坐标计算方法获得的节点坐标位置存在较大误差的问题,提出一种无需进行坐标计算的果蝇—广义回归神经网络(FOA-GRNN)优化的 WSN 节点定位算法. 该算法利用广义回归神经网络(GRNN)较快的学习速度和较强的逼近能力建立 WSN 节点定位模型,通过果蝇优化算法(FOA)调整广义回归神经网络的平滑参数,降低调整平滑参数时人为因素的影响,由神经网络直接输出未知节点坐标. 仿真实验表明,通过果蝇算法优化的 FOA-GRNN 模型的节点定位精度比未经优化的 GRNN 模型的节点定位精度高. 同时,比较了 FOA-GRNN 模型与 BP 神经网络模型、虚拟节点 BP 网络模型(VNBP)在 WSN 节点定位中效果,表明 FOA-GRNN 模型在 WSN 节点定位精确性方面具有明显优势.

[关键词] 无线传感器网络,节点定位,广义回归神经网络,果蝇优化算法

[中图分类号] TP391.9 [文献标志码] A [文章编号] 1001-4616(2017)02-0031-08

## Node Localization Algorithm of WSN Based on Fruit Flies Optimization and Generalized Regression Neural Network

Chen Jing<sup>1</sup>, Yu Jimin<sup>2</sup>

(1. College of Mathematics and Computer Science, Guangxi Science & Technology Normal University, Laibin 546199, China)

(2. Key Laboratory of Industrial Internet of Things & Network Control, MOE, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

**Abstract:** In order to improve the accuracy of WSN node location and avoid the deficiency of the distance measurement based localization algorithm using node coordinates to calculate the location of unknown nodes, a new WSN node localization algorithm of Fruit Flies Optimization-Generalized Regression Neural Network(FOA-GRNN) was presented. The proposed FOA-GRNN algorithm builds WSN positioning model by the fast learning speed and strong approximation ability of Generalized Regression Neural Network(GRNN) and adjusts GRNN's smoothing parameter by using Fruit Flies Optimization Algorithm(FOA) to reduce the impact of human factors on selecting GRNN smoothing parameter to minimum. Finally, the coordinates of unknown nodes in WSN can be directly obtained from the output of FOA-GRNN model. Simulating results show that the localization accuracy of FOA-GRNN optimized by FOA is better than that of GRNN model. In addition, the FOA-GRNN algorithm was compared with BP algorithm and VNBP algorithm in WSN nodes localization. Simulating results further show the FOA-GRNN algorithm has obvious advantages in the accuracy of WSN node localization.

**Key words:** wireless sensor networks, node localization, generalized regression neural networks, fruit fly optimization algorithm

无线传感器网络技术(wireless sensor networks, WSN)是一种对客观世界状态感知和目标信息采集处理技术,它通过监测区域内分布的大量传感器节点自组织形成无线网络,其应用领域非常广泛,如环境监测、军事国防、工农业控制、生物医疗等. 节点定位技术是无线传感器网络广泛应用的基础,没有准确的位置信息就无法准确判断特定事件的发生区域,因此准确地获取节点位置信息是无线传感器网络应用研究

收稿日期:2016-05-18.

基金项目:2014 年度广西高校科学技术研究项目(LX2014489)、2016 年广西高校重点实验室建设项目、重庆市自然科学基金(cstc2013jcyjC0013).

通讯联系人:陈璟,副教授,研究方向:控制理论、智能算法. E-mail:lzszej@163.com

中的关键技术之一<sup>[1-2]</sup>.

目前 GPS 是应用较为广泛成熟的定位服务,但该技术受到成本、功耗、环境等关键问题的制约<sup>[3]</sup>,应用范围较为有限.国内外学者提出多种无线传感器网络节点定位技术,利用少量的信标节点通过定位算法尽可能准确估算未知节点的坐标位置.近年来,为了取得更准确的位置信息,人工神经网络、遗传算法等人工智能算法被应用到 WSN 节点定位领域.Prince Singh 等<sup>[4]</sup>为了克服最小二乘法在到达时间差(time difference of arrival, TDOA)模型定位算法的缺陷,提出了基于径向基(radial basis function, RBF)网络的 TDOA 定位算法,利用 RBF 网络的反复训练网络,调整参数,实现对未知节点的准确定位,但该算法需要大量的样本数据,定位准确度与样本数据的多少有很大关系.Ashish Payal 等<sup>[5]</sup>提出了基于多层感知器的反向传播神经网络的定位模型,将贝叶斯正则化和 Levenberg-Marquardt 算法相结合训练网络,提高 WSN 节点定位精度,有效地减小定位误差.但该算法复杂度较高,优化参数较多,较难应用在大规模网络中.Runjie LIU 等<sup>[6]</sup>提出了基于次锚节点和 BP 网络结合的定位算法.该算法利用反向传播神经网络(BP 网络)的并行性和节点的多跳性,在对硬件环境要求不高的情况下准确定位未知节点坐标信息,虽然算法节省了硬件开销,降低了运算复杂度,但定位精度较低,误差较大.

广义回归神经网络(generalized regression neural network, GRNN)是 RBF 网络的一种改进模型,由美国学者 Donald F Spetch 于 1992 年提出. GRNN 具有较强的非线性映射能力和柔性网络结构,以及高度的容错性和鲁棒性,已在各领域得到广泛应用<sup>[7]</sup>.然而,目前 GRNN 网络的平滑参数因子  $\sigma$  的选择主要依靠主观经验,手动设置,还存在学习效率低、人为主观影响较大等问题<sup>[8]</sup>.果蝇优化算法(fruit fly optimization algorithm, FOA)是一种基于果蝇觅食行为推演出寻求全局优化的新方法,具有随机搜索特性和快速收敛性,可实现变量的全局寻优<sup>[9-10]</sup>.FOA 算法自产生以来就受到相关领域的广泛关注,目前已被广泛应用于交通事件、原油含水率<sup>[11]</sup>、企业经营绩效<sup>[12]</sup>、光纤传感系统<sup>[13]</sup>以及卫星预测<sup>[14]</sup>等优化问题.因此,本文提出一种基于果蝇优化算法与广义回归神经网络有机结合的果蝇-广义回归神经网络优化(FOA-GRNN)的 WSN 节点定位算法,利用 FOA 算法的随机搜索特性和快速收敛性,优化 GRNN 网络的平滑参数因子  $\sigma$  的选择,降低算法复杂度,提高 GRNN 回归预测效果,准确定位 WSN 未知节点坐标位置.

## 1 GRNN 算法与 FOA 算法

### 1.1 广义回归神经网络模型

如图 1 所示,GRNN 由输入层、模式层、求和层、输出层构成.

输入层的神经元数目与学习样本中输入向量的维数  $n$  相等,每个神经元都是一个简单的分布单元,这些神经元直接将输入变量传递到模式层中.

模式层的神经元数目即为学习样本的数目  $n$ ,每个神经元分别对应一个学习样本,模式层中第  $i$  个神经元的传递函数为:

$$P_i = \exp\left[-\frac{(\mathbf{X}-X_i)^T(\mathbf{X}-X_i)}{2\sigma^2}\right], \quad i=1,2,\dots,n. \quad (1)$$

式中,  $P_i$  是各模式层的神经元输出,  $\sigma$  为平滑因子,  $X_i$  为第  $i$  个神经元对应的学习样本.

求和层中包含了分母求和单元与分子求和单元.分母求和单元对所有模式层神经元的输出进行算术求和,模式层中各个神经元与该神经元的连接权值为 1,传递函数为:

$$S_D = \sum_{i=1}^n P_i. \quad (2)$$

分子求和单元是对神经元输出加权求和,其连接权值是模式层中神经元的输出  $y_i$  值,其传递函数为:

$$S_N = \sum_{i=1}^n y_i P_i. \quad (3)$$

输出层  $\hat{Y}$  是由求和层中的分子求和单元、分母求和单元的输出相除得到,即:

$$\hat{Y} = S_N / S_D. \quad (4)$$

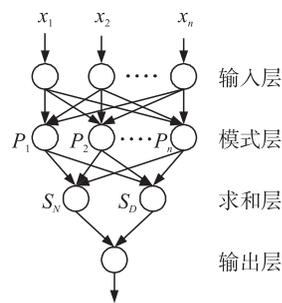


图 1 GRNN 的原理图

Fig. 1 Schematic diagram of GRNN

GRNN 模型结构简单、运算复杂度较低、执行效率高,在网络中只需确定参数  $\sigma$  即可获得准确输出,因此极大简化了网络运算的性能,增加了网络模型的鲁棒性. 但目前平滑参数  $\sigma$  的选择还具有较大主观随机性,限制了 GRNN 模型的应用效果. 因此,本文运用果蝇优化算法优化参数  $\sigma$  的选择,实现参数  $\sigma$  的自适应寻优. 由于在本文仿真工具 MATLAB 中, $\sigma$  用 spread 参数值来表示,因此,文中用 spread 表示平滑参数  $\sigma$  值.

### 1.2 果蝇优化算法

果蝇优化算法是一种基于果蝇觅食行为推演出寻求全局优化的新方法. 果蝇本身在感官知觉上优于其他物种,尤其是其嗅觉器官比较发达,能够很好地搜集到漂浮在空中的各种气味,食物味道越浓,果蝇对其感知能力就越强. 对于果蝇来说,食物的味道浓度与果蝇和食物的位置有关,距离越近,其味道浓度就越浓,距离越远,其味道浓度就越小,果蝇搜索食物的过程就是不断地从味道浓度小的地方到达味道更浓的地方的过程. 当果蝇飞近食物位置后利用其敏锐的视觉发现食物并与同伴聚集到食物位置<sup>[15]</sup>. 图 2 给出了果蝇群体迭代搜索食物的示意图. 其中  $n$  只果蝇从果蝇群体初始位置沿随机方向飞出,然后所有果蝇再飞往味道浓度最高的果蝇位置,形成新的果蝇群体位置,不断循环往复,直到找到食物源.

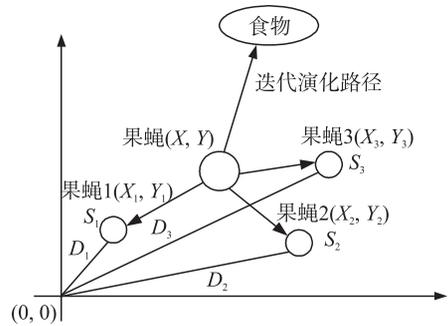


图 2 果蝇群体迭代搜索食物的示意图  
Fig. 2 The fruit fly group iterate to search food

根据果蝇搜寻食物的特点,果蝇优化算法主要有以下几个步骤<sup>[16]</sup>:

- (1) 随机产生果蝇的初始位置 ( $IntX\_axis, IntY\_axis$ ), 确定种群个体数量  $sizepop$  和最大迭代次数  $max\ gen$ .
- (2) 赋予果蝇个体利用嗅觉搜寻食物的随机方向和距离 ( $X(i), Y(i)$ ).
- (3) 估计与原点的距离  $D(i)$ , 计算味道浓度判定值  $S(i)$ , 其中  $S(i) = 1/D(i)$ .
- (4) 将味道浓度的判定值  $S(i)$  代入味道浓度判定函数 ( $Fitness\ function$ ) 求出该果蝇个体位置的味道浓度  $Smell(i)$ , 其中  $Smell(i) = function(S(i))$ .
- (5) 找出此果蝇群体当中味道浓度最高的果蝇 (求最大值).
- (6) 保留最佳味道浓度值  $S(i)$  与 ( $X(i), Y(i)$ ) 的坐标, 此时果蝇群体利用视觉向该位置飞去.
- (7) 迭代寻优, 充分执行步骤 2-5, 并判断当前味道浓度是否优于前一迭代味道浓度, 若是则执行步骤 6.

## 2 FOA-GRNN 定位算法

### 2.1 FOA-GRNN 定位的基本方案

建立神经网络的 WSN 节点定位模型, 首先根据现场环境特征通过样本训练网络建立 FOA-GRNN 网络定位模型, 然后输入未知节点信息计算节点坐标. 因此, 建立 FOA-GRNN 定位模型概括为两个阶段:

(1) 训练网络模型阶段: 本阶段包括场景建模和训练预测两个部分. 首先需要搭建实验环境, 建立数学模型. 其次需要进行大量的实验以获取足够多的样本数据, 将获取的样本用于 FOA-GRNN 模型训练, 以得到节点预测模型. 在训练过程中, 必须采用合适的样本数据, 否则将影响未知节点的定位精度.

(2) 测试节点位置阶段: 本阶段利用训练所得到的 FOA-GRNN 网络模型, 将计算出的未知节点到各个信标节点的距离输入至神经网络模型, 即可计算出未知节点的位置坐标.

方案流程如图 3 所示.

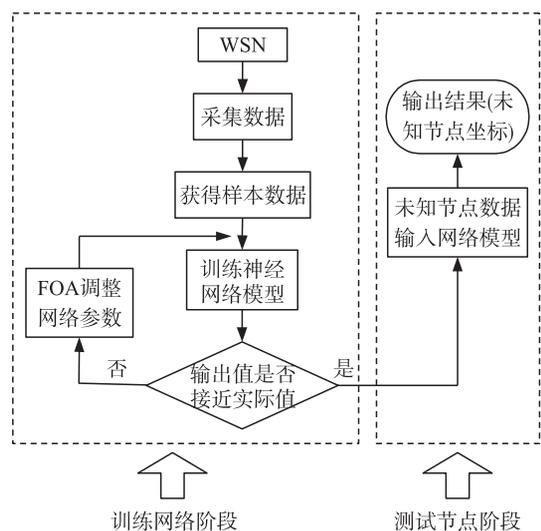


图 3 FOA-GRNN 方案流程图

Fig. 3 The process of scheme

### 2.2 FOA-GRNN 算法实现

本文 FOA-GRNN 定位模型利用 MATLAB 中自带的神经网络函数  $net = newgrnn(P, T, spread)$ , 其中  $newgrnn$  是构造广义回归神经网络,  $P$  为神经网络输入,  $T$  神经网络输出,  $spread$  ( $spread \leq 1$ ) 为平滑参数,  $spread$  的值越小, 对函数的逼近就越精确,  $spread$  值越大, 逼近误差会比较大. 测试输出利用函数  $Y = sim(net, P)$ , 其中  $net$  为训练形成的网络架构,  $P$  为测试输入,  $Y$  为测试输出.

以信标节点与未知节点之间的距离  $D$  作为模型的  $n$  个输入, 则第  $i$  个待测节点  $(x_i, y_i)$  到各信标节点  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  的距离表示为:

$$D = [d_1, d_2, d_3, \dots, d_n].$$

其中,

$$\begin{cases} d_1 = \sqrt{(x_1 - x_i)^2 + (y_1 - y_i)^2}, \\ d_2 = \sqrt{(x_2 - x_i)^2 + (y_2 - y_i)^2}, \\ \vdots \\ d_n = \sqrt{(x_n - x_i)^2 + (y_n - y_i)^2}. \end{cases} \quad (5)$$

以未知节点的坐标作为模型输出, 则第  $i$  个节点坐标表示为  $O_i = (x_{oi}, y_{oi}), i = 1, 2, 3, \dots$ . 通常情况下, 参数  $spread$  主要采取手动调整寻找最优值, 但该方式有较大的主观因素, 效率较低, 精度较差. 从数学方面讲,  $spread$  的选取实质就是一个优化问题, 即通过寻找一个最优的  $spread$ , 使得训练样本的 GRNN 输出值与实际值的均方差最小. 因此, 本文采用具有随机搜索和快速收敛特性的 FOA 全局寻优算法对  $\sigma$  进行优化调整, 可最大限度地减少调整  $\sigma$  时人为因素影响.

FOA-GRNN 定位算法的具体步骤为:

- (1) 确定种群个体数量  $sizepop = 10$ , 和最大迭代次数  $max\ gen = 50$ , 在  $[0, 10]$  范围内随机生成果蝇初始位置.
- (2) 赋予果蝇个体利用嗅觉搜寻食物的随机方向和距离区间  $[-1, 1]$ .
- (3) 估计与原点的距离  $D(i)$ , 并且计算味道浓度判定值  $S(i)$ .
- (4) 用  $p$  表示广义回归神经网络的平滑参数  $spread$ , 令  $spread$  等于味道浓度的判定值  $S(i)$ , 即  $p = spread = S(i)$ . 为了防止网络模型陷入局部最小值, 设置条件若  $p \leq 0.001$  时, 令  $p = 1$ .
- (5) 样本数据代入  $net = newgrnn(D, O_i, p)$ , 进行网络模型训练. 再把测试数据代入测试函数  $Y = sim(net, D)$ .
- (6) 将测试输出  $Y_c$  的坐标与实际坐标做差, 记录出误差小于 0.1 的节点的个数  $Smellnum$ , 并且记录误差小于 0.1 的节点的误差总和  $Smellsum$ .
- (7) 找出误差小于 0.5 的节点个数最多, 且误差总和最小的一组  $bestSmell$ .
- (8) 迭代比较, 重复执行步骤 2-7, 直至迭代结束, 寻找到最优一组  $Smellbest$ .

### 3 实验及结果分析

为测试算法的准确度与精确度, 在 MATLAB7.12 环境下采集数据和测试定位算法的性能. 如图 4 所示, 在  $10\ m \times 10\ m$  的区域内任意布置数个传感器节点, 以左下角为坐标原点,  $x \in [0, 10], y \in [0, 10]$ . 任取 5 个信标节点为参考节点, 分别为  $P_1(0, 0), P_2(0, 10), P_3(10, 10), P_4(10, 0), P_5(5, 5)$ , 在图中用“o”标记, 该区域均匀的划分为 441 个区域, 在图中用“\*”标记, 使未知节点处于这 441 个区域. 对于任意节点坐标  $(x_0, y_0)$  可以利用信号往返传播时间计算出其与 5 个信标节点之间的距离  $d_1, d_2, d_3, d_4, d_5$ , 如表 1 所示. 以 5 个距离作为 FOA-GRNN 网络模型的输入, 以节点的坐标作为输出, 训练神经网络. 通过 441 组样本数据, 50 次的迭代训练, 可获得

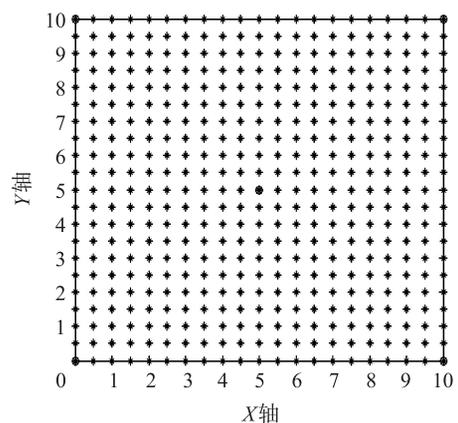


图 4 样本数据采集点  
Fig. 4 Sample data to collect

稳定的网络输出. 再用 20 组数据作为测试数据, 测试比较网络的输出结果是否与实际值相符.

表 1 441 组传感器节点坐标及与 5 个信标节点间的距离

Table 1 441 sets of coordinates and distances between these nodes to five anchor nodes

$(x_0, y_0)$	$d_1$	$d_2$	$d_3$	$d_4$	$d_5$
(0,0)	0.000 0	10.000 0	14.142 1	10.000 0	7.071 07
(0,0.5)	0.500 0	9.500 0	13.791 3	10.012 5	6.726 81
(0,1)	1.000 0	9.000 0	13.453 6	10.049 9	6.403 12
(0,1.5)	1.500 0	8.500 0	13.124 4	10.111 9	6.103 28
(0,2)	2.000 0	8.000 0	12.806 2	10.198 0	5.830 95
(0,2.5)	2.500 0	7.500 0	12.500 0	10.307 8	5.590 17
(0,3)	3.000 0	7.000 0	12.206 6	10.440 3	5.385 16
(0,3.5)	3.500 0	6.500 0	6.500 0	11.926 9	10.594 80
(0,4)	4.000 0	6.000 0	11.661 9	10.770 3	5.099 02
(0,4.5)	4.500 0	5.500 0	11.412 7	10.965 9	5.024 94
...	...	...	...	...	...
(10,5.5)	11.412 7	10.965 9	4.500 0	5.400 0	5.024 94
(10,6)	11.661 9	10.770 3	4.000 0	6.000 0	5.099 02
(10,6.5)	11.926 9	10.594 8	3.500 0	6.500 0	5.220 15
(10,7)	10.307 8	10.440 3	3.000 0	7.000 0	5.385 16
(10,7.5)	12.500 0	10.307 8	2.500 0	7.500 0	5.590 17
(10,8)	12.086 2	10.198 0	2.000 0	8.000 0	5.830 95
(10,8.5)	13.124 4	10.111 9	1.500 0	8.500 0	6.103 28
(10,9)	13.453 6	10.049 9	1.000 0	9.000 0	6.403 28
(10,9.5)	13.793 1	10.012 5	0.500 0	9.500 0	6.726 81
(10,10)	14.142 1	10.000 0	0.000 0	10.000 0	7.071 07

### 3.1 spread 误差收敛与果蝇寻优分析

图 5 为寻优轨迹图, 由图可知, 果蝇在寻优的飞行过程中, 通过迭代不断寻找最优位置点. 图 6 为果蝇寻优过程收敛图, 由图 6 可见, 在果蝇寻优演化过程中, 均方误差值随迭代次数的增加而快速衰减, 在第三次迭代后, 均方误差值为  $0.1 \times 10^{-9}$ . 由图 7 (spread 在程序中表示为 bestS) 的结果运行窗口展示的运行结果可知, 在取得最小均方误差时, spread 值为 0.031 2. 故迭代次数选择 50 次足够满足定位误差要求, 同时也说明了果蝇优化算法的收敛速度很快.

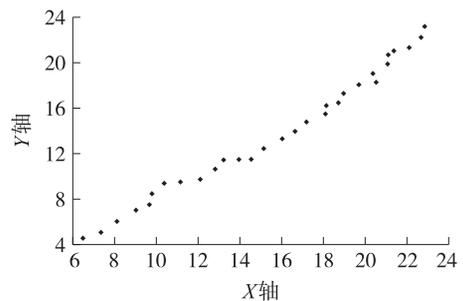


图 5 果蝇寻优轨迹图  
Fig. 5 Fruit fly flying route

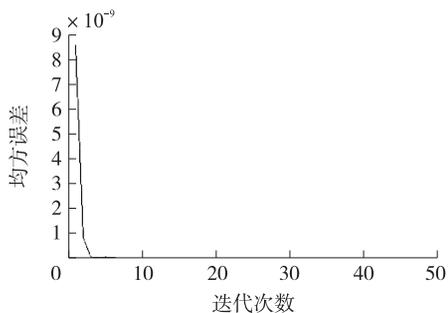


图 6 果蝇寻优过程收敛图  
Fig. 6 Optimization process



图 7 果蝇寻优过程收敛图  
Fig. 7 Fruit optimization process function

### 3.2 FOA-GRNN 与 GRNN 的定位效果比较

图 8 为广义回归神经网络 GRNN 的 WSN 节点定位图, 图 9 为果蝇—广义回归神经网络优化 FOA-GRNN 的定位图. 图中“o”为节点的实际坐标点, “\*”为节点定位坐标. 针对未优化的 GRNN 定位算法和 FOA-GRNN 定位算法的比较, 本文选取 3 组数据作比较, 分别为: 算法执行时间 ( $T$ , 单位为 s)、定位节点的坐标误差小于 0.5 m 的个数 ( $N$ )、定位节点的坐标与实际坐标接近度为 99% 的节点的个数占定位节点总

数的百分比( $P$ ).

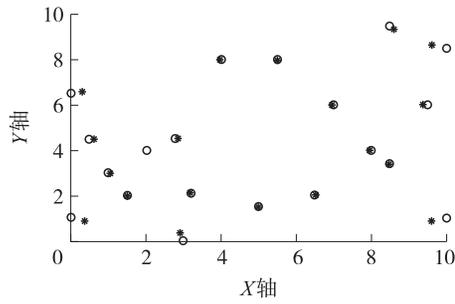


图 8 GRNN 定位图

Fig. 8 Localization results of GRNN

由表 2 中的数据可知,FOA-GRNN 算法的精确度较 GRNN 高出近两倍,说明果蝇优化算法在解决优化问题方面具有很大优势. 由于在节点选取方面的任意性,以及计入调整 spread 所用的时间,使得 FOA-GRNN 算法的执行时间比 GRNN 算法的执行时间要长,GRNN 默认 spread 为 1,无需训练.

进一步由表 3 对 20 组节点进行了实际坐标与预测坐标的比较,在优化参数 spread 之前,部分节点的误差较大,最大偏差为 7.76%,最小的偏差为 0.21%,标准差为 3.97%;在果蝇算法优化参数 spread 之后,节点的定位坐标与实际坐标基本重合,最大偏差为 3.53%,最小的偏差为 0,标准差为 0.75%. 比较可见,通过果蝇优化算法对 spread 的优化,网络定位效果具有明显提高.

表 3 20 组测试节点实际坐标与预测坐标

Table 3 The coordinates of 20 sets test data and their actual coordinates

算法	实际坐标	测定坐标	相对误差/%	标准偏差/%	算法	实际坐标	测定坐标	相对误差/%	标准偏差/%
GRNN 定位 坐标	(0.00,6.50)	(0.310 5,6.558 7)	0.45	3.97	FOA- GRNN 定位 坐标	(0.00,6.50)	(0.000 0,6.500 0)	0	0.75
	(0.00,1.00)	(0.374 9,0.855 2)	0.72			(0.00,1.00)	(0.000 0,1.000 0)	0	
	(0.50,4.50)	(0.597 8,4.490 6)	1.89			(0.50,4.50)	(0.500 0,4.500 0)	0	
	(1.00,3.00)	(1.044 8,2.972 4)	0.70			(1.00,3.00)	(1.000 0,3.000 0)	0	
	(1.50,2.00)	(1.511 4,1.980 6)	0.87			(1.50,2.00)	(1.500 0,2.000 0)	0	
	(2.00,4.00)	(2.025 8,3.989 6)	0.78			(2.00,4.00)	(2.000 0,4.000 0)	0	
	(2.50,4.50)	(2.420 9,4.424 0)	3.02			(2.50,4.50)	(2.500 0,4.500 0)	0	
	(3.20,2.00)	(3.189 0,2.120 9)	0.67			(3.20,2.00)	(3.000 0,2.000 0)	3.53	
	(3.00,0.00)	(2.920 9,0.324 0)	1.32			(3.00,0.00)	(3.000 0,0.000 0)	0	
	(4.00,8.00)	(3.989 6,7.974 2)	0.29			(4.00,8.00)	(4.000 0,8.000 0)	0	
	(5.00,1.50)	(5.000 0,1.523 4)	0.78			(5.00,1.50)	(5.000 0,1.500 0)	0	
	(5.50,8.00)	(6.512 5,2.024 2)	0.70			(5.50,8.00)	(5.500 0,8.000 0)	0	
	(6.50,2.00)	(6.512 5,2.024 2)	0.70			(6.50,2.00)	(6.500 0,2.000 0)	0	
	(7.00,6.00)	(6.971 3,5.999 0)	0.21			(7.00,6.00)	(7.000 0,6.000 0)	0	
	(8.00,4.00)	(7.974 2,3.989 6)	0.29			(8.00,4.00)	(8.000 0,4.000 0)	0	
	(8.50,9.50)	(8.589 4,9.347 9)	1.33			(8.50,9.50)	(8.500 0,9.500 0)	0	
	(8.50,3.40)	(8.473 1,3.382 3)	0.42			(8.50,3.40)	(8.500 0,3.500 0)	0.27	
	(9.50,6.00)	(9.937 0,6.655 2)	7.76			(9.50,6.00)	(9.500 0,6.000 0)	0	
	(10.00,8.50)	(9.825 1,8.565 2)	1.21			(10.00,8.50)	(10.000 0,8.500 0)	0	
	(10.00,1.00)	(9.625 1,0.855 2)	7.11			(10.00,1.00)	(10.000 0,1.000 0)	0	

### 3.3 FOA-GRNN 与 BP 网络和 VN-BP 网络的性能比较

为了说明 FOA-GRNN 算法在节点定位中的优越性与准确性,将 FOA-GRNN 算法与 BP 算法和 VN-BP 算法<sup>[6]</sup>进行比较. 在 50 m×50 m 的空间随机布置节点,采用 3 种训练好的算法模型对 50 个节点进行定

位,每个节点进行 10 次定位,取其平均值作为该点的坐标值,再通过 3 个不同的方面进行算法比较. 由于 FOA-GRNN 算法充分利用了 FOA 算法的随机搜索特性和快速收敛性,快速寻找到 GRNN 最适合的平滑参数  $\sigma$ ,从而提高了 GRNN 网络的定位效果,从 3 个比较结果可体现出 FOA-GRNN 的优势. 平均误差计算公式如式(6)

$$ALE = \frac{1}{10} \sum_{i=1}^{10} [\sqrt{(x-x_i)^2 + (y-y_i)^2}], i = 1, 2, \dots, 10. \quad (6)$$

#### (1) 平均定位误差与通信距离关系

图 10 为平均定位误差与通信距离的变化曲线. 由图 10 可以看出,3 种算法的定位误差在 30 m 以内随通信距离的增加略微下降. 在大于 30 m 以后随通信距离的增加略微上升. BP 算法的定位误差始终在 12% 以上, VN-BP 算法的定位误差在 10% 左右,而 FOA-GRNN 算法的定位误差低于 10%. 增大通信距离,FOA-GRNN 算法的定位误差始终小于 BP 算法和 VN-BP 算法的定位误差.

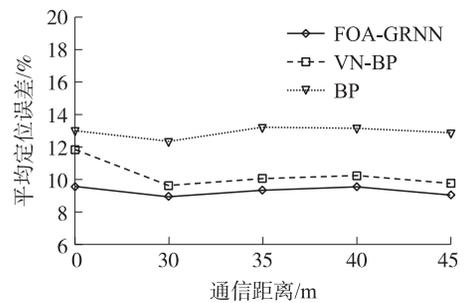


图 10 平均定位误差与通信距离关系图

Fig. 10 ALE and communication range

#### (2) 平均定位误差与信标节点比例关系

图 11 为平均定位误差与信标节点比例的变化曲线. 由图 11 可以看出,随着信标节点数量的不断增加,3 种算法的定位误差均有下降. 当信标节点分布密度 25% 时,3 种算法的定位误差都较小. 而在相同信标节点数的前提下,FOA-GRNN 算法要比 BP 算法及 VN-BP 算法的定位误差要小.

#### (3) 平均定位误差与测距误差关系

图 12 为平均定位误差随测距误差的变化曲线. 由图 12 可以看出,3 种算法的平均定位误差随测距误差的增大而增加. 在 30% 以内,3 种算法的平均定位误差的增加幅度较小;大于 30% 时,3 种算法的定位误差迅速增加,但无论测距误差如何变化,FOA-GRNN 算法的定位误差始终小于 BP 算法和 VN-BP 算法的定位误差.

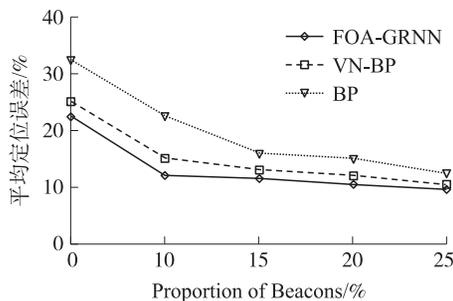


图 11 平均定位误差与信标节点比例关系图

Fig. 11 ALE and proportion of beacons

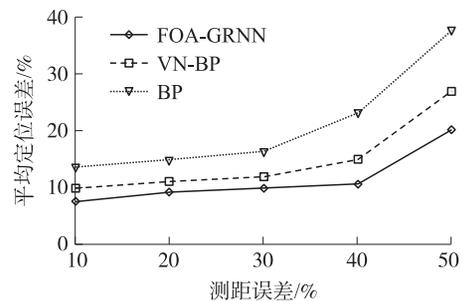


图 12 平均定位误差与测距误差关系图

Fig. 12 ALE and ranging error

## 4 结语

果蝇优化算法(FOA)是 2011 年提出的新兴智能算法. 本文提出的基于果蝇—广义回归神经网络优化的 WSN 节点定位算法(FOA-GRNN),通过果蝇优化算法(FOA)来调整广义回归神经网络(GRNN)的平滑参数  $\sigma$ ,提高了网络模型输出未知节点坐标的精度. 仿真实验表明,通过 FOA 优化  $\sigma$  参数的 FOA-GRNN 网络模型比没有优化的 GRNN 网络模型定位精度要高,收敛速度快. 而且,本文进一步从影响 WSN 平均定位误差的不同通信距离、不同信标节点数和不同测距误差等方面对 FOA-GRNN 模型、经典 BP 网络模型和 VN-BP 网络的 WSN 节点定位性能进行了对比分析,仿真结果表明 FOA-GRNN 较 BP 网络和 VN-BP 网络的节点定位精度更高,整体性能更好,为解决相关领域实际优化问题提供了一定借鉴思路与方法.

### [参考文献]

[1] 陈龙,张可,罗配明. 改进的 Elman 神经网络在 WSNs 距离预测中的应用[J]. 传感器与微系统,2013,32(1):149-152.

- [2] 田莹,张淑芳. 基于SOM的WSN节点定位算法与仿真实现[J]. 系统仿真学报,2011,23(6):1166-1172.
- [3] 李牧东,熊伟,梁青. 基于人工蜂群改进算法的无线传感器网络定位算法[J]. 传感技术学报,2013,26(3):241-245.
- [4] PRINCE S,SUNIL A. TDOA based node localization in WSN using neural network[C]//2013 International Conference on Communication Systems and Network Technologies(CSNT). Hainan,China,2013:400-404.
- [5] ASHISH P,RAI C S,REDDY B V R. Comparative analysis of Bayesian regularization and levenberg-marquardt training algorithm for localization in wireless sensor network[C]//2013 15th International Conference on Advanced Communication Technology. Adelaide,South Australia,2013:191-194.
- [6] LIU R J,SUN K,SHEN J Y. BP localization algorithm based on virtual nodes in wireless sensor network[C]//2010 6th International Conference on Wireless Communications,Networking and Mobile Computing. Chengdu,China,2010:1-4.
- [7] PAN W T. Using fruit fly optimization algorithm optimized general regression neural network to construct the operating performance of enterprises model[J]. Journal of Taiyuan university of technology,2011,29(4):1-4.
- [8] 贾义鹏,吕庆,尚岳全. 基于粒子群算法和广义回归神经网络的岩爆预测[J]. 岩石力学与工程学报,2013,32(2):343-348.
- [9] LIU C L,ZHANG L L,WANG J Q. Application of FOA-GRNN to prediction of moisture content in crude oil of wellheat metering[J]. Computer-simulation,2012,29(11):243-246.
- [10] 王海军,涂凯,闫晓荣. 基于果蝇优化算法的GRNN模型在边坡稳定预测中的应用[J]. 水电能源科学,2015(1):24-27.
- [11] PAN W T. A new fruit fly optimization algorithm:taking the financial distress model as an example[J]. Knowledge-based systems,2012,26:69-74.
- [12] SHI D Y,LU J,LU L J. A judge model of the impact of lane closure incident on individual vehicles on freeways based on RFID technology and FOA-GRNN method[J]. Journal of Wuhan university of technology,2012,34(3):63-68.
- [13] 张燕君,刘文哲,付兴虎,等. 基于自适应变异果蝇优化算法和广义回归神经网络的布里渊散射谱特征提取[J]. 光谱学与光谱分析,2015(10):2916-2923.
- [14] 邹兵,陈西宏,薛伦生,等. 果蝇优化算法优化灰色神经网络的卫星钟差预报[J]. 测绘科学,2014(9):44-48.
- [15] LI H Z,GUO S,LI C J. A hybrid annual power load forecasting model based on generalized regression neural network with fruit fly optimization algorithm[J]. Knowledge-based systems,2013,37:378-387.
- [16] PAN W T. A new evolutionary computation approach:fruit fly optimization algorithm[C]//2011 Conference of Digital Technology and Innovation Management. Taipei,2011.

[责任编辑:陆炳新]