

面向农业温室环境的 ICDO-RBFNN 多传感器数据融合算法

罗焕芝, 王 骥*

(1. 广东海洋大学电子与信息工程学院, 湛江 524088; 2. 广东省智慧海洋传感网及其装备工程技术研究中心, 湛江 524088)

摘要: 为改善农业环境传感器测量数据精度低、可靠性差的问题, 该研究提出一种改进的切诺贝利灾难优化器 (improved Chernobyl disaster optimizer, ICDO) 优化径向基函数神经网络 (radial basis function neural network, RBFNN) 多传感器数据融合算法。首先引入佳点集、拉普拉斯交叉算子和修改位置更新方程改进切诺贝利灾难优化器 (Chernobyl disaster optimizer, CDO), 增强算法的寻优能力; 再利用 ICDO 优化 RBFNN 模型, 提升模型的稳定性, 最后通过 RBFNN 模型的非线性映射能力实现多传感器数据融合方法, 提高数据融合精度。仿真试验结果表明, 大气环境质量预测的拟合优度达到 0.999, 均方误差低至 0.348, 平均绝对百分比误差降到 0.729%; 现场试验结果表明, 温室环境等级划分的准确率高达 99.21%, 精准率为 99.91%。研究提出的多传感器数据融合算法精度高, 相对误差低, 稳健性好。

关键词: 温室; 多传感器; 数据融合; ICDO; RBF 神经网络

doi: 10.11975/j.issn.1002-6819.202402013

中图分类号: S625.5+1; TP183

文献标志码: A

文章编号: 1002-6819(2024)-21-0184-08

罗焕芝, 王骥. 面向农业温室环境的 ICDO-RBFNN 多传感器数据融合算法[J]. 农业工程学报, 2024, 40(21): 184-191.

doi: 10.11975/j.issn.1002-6819.202402013 <http://www.tcsae.org>

LUO Huanzhi, WANG Ji. ICDO-RBFNN multi-sensor data fusion for agricultural greenhouse environment[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(21): 184-191. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202402013 <http://www.tcsae.org>

0 引言

多传感器数据融合技术就是将多个传感器收集的信息整合处理和融合加工, 削弱数据源中存在的不确定成份, 最终得到一个有决策意义的数据结果。该技术已经在智慧农业信息处理、空间探测、目标跟踪和识别等领域应用, 极大提高了系统测量、探测与识别能力^[1-4]。但目前农业温室专用传感器测量精度较低, 而农业环境感知数据量大, 冗余数据多, 因此设计一个好的多传感器数据融合方法对于提高农业物联网的感知精度尤为重要^[5]。目前多传感器数据融合方法可以分为两类^[6-10]: 1) 非智能的融合方法, 包含卡尔曼滤波法、贝叶斯估计法、Dempster-Shafer 证据推理法、参数模板法、物理模型法、熵法、品质因素法、聚类分析法、估计理论法和专家系统法等; 2) 智能的融合方法, 主要包括模糊集合理论、神经网络、粗集理论、小波分析理论、支持向量机和深度学习等。两类方法在农业温室环境场景感知的大量的数据融合方面都取得了较好的效果, 但算法复杂度高, 数据处理速度慢, 容易陷入局部最优, 导致传感器数据融合精度不高。ANNARITA 等^[11]利用贝叶斯方法进行多传感器数据融合, 有效地利用了先验信息, 取得了较好的融合效果, 但该方法要求基于参数的先验分布进行

推理, 要找到合适的先验分布难度大。LIU 等^[12]在数据融合前引入了最优比例权重的概念, 使用二次加权方法, 解决了不合适权重导致的算法性能不稳定问题, 但融合精度仍有提升空间。WU 等^[13]提出了一种基于反向传播神经网络的多传感器数据融合算法, 取得良好的融合结果, 但收敛速度较慢, 且容易陷入局部最优。吴晟等^[14]通过 FA-BP 神经网络模型构建数据融合算法, 但是融合结果稳定性受制于 FA 算法初始种群质量影响; IMANE 等^[15]提出了一种改进的 DS 证据理论的数据融合算法, 加强了可靠证据的融合效果获得较好精度, 但算法稳定性稍差。

上述文献关于多传感器数据融合方法一定程度上改善了设施农业环境下多传感器数据融合的速度和精度, 但感知数据精准度与融合效率仍然很难满足目前智慧农业, 特别是设施农业的温室环境精准感知要求。所以本文提出了面向农业温室环境的改进的切诺贝利灾难优化器 (improved Chernobyl disaster optimizer, ICDO) 优化径向基函数神经网络 (radial basis function neural network, RBFNN) 多传感器数据融合算法, 拟利用群智能算法 ICDO 的精准搜索能力和 RBFNN 收敛速度较快、全局逼近能力强的特点设计高精度的多传感器数据融合算法, 兼顾运行速度的同时避免 RBFNN 的网络参数随机设置的缺陷, 进一步提高数据融合的精度。

1 RBF 神经网络和 CDO 算法

1.1 RBF 神经网络

RBF 神经网络^[16]基本结构如图 1 所示。主要由输入层、隐含层与输出层构成。


收稿日期: 2024-02-03 修订日期: 2024-08-19

基金项目: 广东省普通高校重点领域新一代信息技术专项 (2020ZDZX3008)

作者简介: 罗焕芝, 研究方向为智能检测与传感技术。

Email: 987299174@qq.com

*通信作者: 王骥, 硕士生导师, 研究方向为无线传感器网络、海洋物联网与人工智能。Email: 13902576499@163.com



注：x 是输入变量；R 是隐含层输出；ω 是隐含层到输出层的连接权值；y 是实际输出。

Note: x is the input variable; R is the output of hidden layer; ω is the weight from hidden layer to output layer; y is the actual output.

图 1 RBF 神经网络结构图

Fig.1 RBF neural network structure

神经网络模型激活函数的高斯函数为

$$R(\mathbf{x}_p - c_i) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x}_p - c_i\|^2\right) \quad (1)$$

式中 $\mathbf{x}_p = (x_p^1, x_p^2, \dots, x_p^n)^T$ 为第 p 个输入样本； $p=1,2,3,\dots,P$ ， P 为样本的总数； c_i 为高斯函数的中心； $i=1,2,3,\dots,h$ ， h 为隐含层节点数； $\|\mathbf{x}_p - c_i\|$ 为欧式范数， σ 为高斯函数的方差。由此得到网络输出结果为

$$y_j = \sum_{i=1}^h \omega_{ij} \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x}_p - c_i\|^2\right) \quad (2)$$

式中 ω_{ij} 为隐含层到输出层的连接权值； y_j 为输入样本对应的网络的第 j 个输出结点的实际输出结果， $j=1,2,3,\dots,m$ 。假设 d 是样本的期望输出值，可得基函数的方差为

$$\sigma = \frac{1}{p} \sum_j^m \|d_j - y_j c_i\|^2 \quad (3)$$

1.2 标准 CDO 算法

切诺贝利灾难优化器 CDO^[17] 是 Shehadeh 于 2023 年受到切尔诺贝利核反应堆堆芯爆炸的启发提出的群智能优化算法。在 CDO 方法中，放射性的发生是由于核的不稳定性。核爆炸会发出不同类型的辐射。CDO 在模拟核爆炸后放射性粒子附着人体的同时，也模拟了核辐射的过程，涉及到 α 、 β 和 γ 粒子。

在 CDO 算法中，每个粒子代表种群中 1 个候选解，其中群体中最优解称为 α ，次优解称为 β ，第三优解称为 γ 。粒子群中其他粒子个体根据 α 、 β 、 γ 的位置来更新各自的位置：

$$V_\alpha = 0.25(X_\alpha(t) - \left(\frac{\pi r^2}{0.25S_\alpha} - W_{sh} \cdot \text{rand}() \cdot |A_\alpha \cdot X_\alpha(t) - X_T(t)|\right)) \quad (4)$$

$$V_\beta = 0.5(X_\beta(t) - \left(\frac{\pi r^2}{0.5S_\beta} - W_{sh} \cdot \text{rand}() \cdot |A_\beta \cdot X_\beta(t) - X_T(t)|\right)) \quad (5)$$

$$V_\gamma = (X_\gamma(t) - \left(\frac{\pi r^2}{S_\gamma} - W_{sh} \cdot \text{rand}() \cdot |A_\gamma \cdot X_\gamma(t) - X_T(t)|\right)) \quad (6)$$

$$x_T = \frac{V_\alpha + V_\beta + V_\gamma}{3} \quad (7)$$

式中 r 为 $[0, 1]$ 间的随机数； W_{sh} 为人的户外步行速度； α 、 β 、 γ 的传播面积分别为 A_α 、 A_β 和 A_γ ，当前位置分别为 $X_\alpha(t)$ 、 $X_\beta(t)$ 和 $X_\gamma(t)$ ，粒子速度分别为 S_α 、 S_β 和 S_γ ，粒子攻击人类时的梯度下降因子分别为 V_α 、 V_β 和 V_γ ； $X_T(t)$ 为其他粒子总位置的平均值， x_T 为其他粒子总速度的平均值。

2 ICDO-RBF 多传感器数据融合算法过程

2.1 ICDO 算法

2.1.1 佳点集初始化种群

在 CDO 算法中，粒子种群的初始位置是通过随机分布来确定的，这使得种群布局具有不确定性，增大了算法陷入局部最优解的风险。本文引入佳点集理论改善 CDO 初始种群的质量，提高求解精度和速度。采用佳点集使初始种群具有遍历性，达到全局最优的目的^[18]。佳点集定义：设 G_s 是 s 维欧氏空间中的单位立方体，如果 $r \in G_s$ ，则有：

$$P_n(k) = \left\{ \left\{ r_1^{(n)} \cdot k \right\}, \left\{ r_2^{(n)} \cdot k \right\}, \dots, \left\{ r_s^{(n)} \cdot k \right\} \right\}, 1 \leq k \leq n \quad (8)$$

$P_n(k)$ 为佳点集， r 为佳点， n 为点数，其偏差为

$$\varphi(n) = C(r, \varepsilon) n^{-1+\varepsilon} \quad (9)$$

$C(r, \varepsilon)$ 是只与 r 、 ε (ε 是任意的正整数) 有关的常数。

$$r_k = \left\{ 2 \cos\left(\frac{2\pi k}{p}\right), 1 \leq k \leq s \right\} \quad (10)$$

p 满足 $(p-\varepsilon)/2 \geq s$ 的最小素数。

首先构建佳点集 $X = \{x_1, x_2, x_3, \dots, x_N\}$ ，其中 N 为种群大小，其次通过式 (11) 生成任意维度分量。

$$x'_{ij} = i \cdot 2 \cos\left(\frac{2j\pi}{p}\right) \quad (11)$$

其中 j 的取值范围为 ($j=1,2,\dots,D$)， D 为搜索空间维度。最后将佳点集映射到所求优化问题的搜索空间。具体计算式如下：

$$x_{ij} = \text{mod}(x'_{ij}, 1)(U_b - L_b) + L_b \quad (12)$$

式中 U_b 、 L_b 是搜索空间的中相应维度上下界。

分别采用随机法和佳点集在二维搜索空间内生成 100 个粒子的初始种群，种群位置上下界分别为 1 和 0。由图 2 可见，在相同的初始条件下，相比随机生成的初始种群，佳点集分布更均匀，增加了初始种群的多样性，有利于避免陷入局部最优。

2.1.2 修改位置更新方程

从式 (4) ~ (7) 看出，CDO 算法在个体位置迭代更新过程中只考虑了个体当前位置信息和群体历史最优位置信息，因此该位置更新方程具有良好的局部探索能力但全局探索能力较弱。为进一步增强 CDO 算法的全局探索能力和加快收敛速度，受差分进化^[19] 以及粒子群算法的启发，从群体中随机选取个体与当前个体进行差分搜索，同时将粒子群算法中对粒子自身运动历史最优解

进行记忆保存的思想引入到 CDO 算法中, 提升个体的记忆功能。从而得到新的位置更新方程:

$$x_T = \frac{(V_\alpha + V_\beta + V_\gamma)}{3} + b_1 r_1 (P_{i,best}^d(t) - x_i^d(t)) + b_2 r_2 (x_j^d(t) - x_i^d(t)) \quad (13)$$

式中 $b_1 \in [0, 1]$ 为个体学习因子, $b_2 \in [0, 1]$ 为群体交流因子, r_1 、 r_2 为 $[0, 1]$ 间均匀分布的随机数, $P_{i,best}^d$ 表示粒子在第 t 次迭代后, 第 i 个粒子 (个体) 搜索得到的最优解; x_j 和 x_i 为群体中随机选择的个体 ($j \neq i$), 通过调节因子 b_1 和 b_2 的值, 可以协调群体和个体记忆对 CDO 算法搜索的影响。

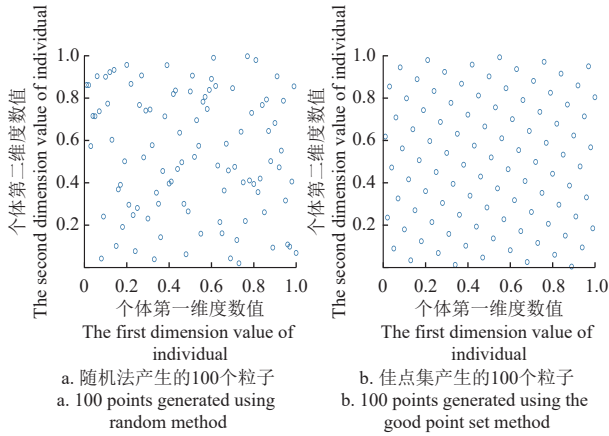


图2 不同方法初始化种群对比

Fig.2 Comparison of different methods to initialize population

2.1.3 拉普拉斯交叉

原 CDO 算法在局部开发阶段缺乏有效的变异策略, 容易陷入局部最优。而拉普拉斯交叉算子具有良好的自适应行为, 有效提高搜索性能^[20]。为此本文在局部开发阶段动态地引入拉普拉斯交叉算子使个体在搜索范围内更仔细地搜索, 从而提高找到全局最优解的可能性, 加快算法的收敛速度。拉普拉斯的密度函数和分布函数如下:

$$f(x) = \frac{1}{2b} \exp\left(-\frac{|x-a|}{b}\right), -\infty < x < \infty \quad (14)$$

$$F(x) = \begin{cases} \frac{1}{2} \exp\left(\frac{|x-a|}{b}\right), x \leq a \\ 1 - \frac{1}{2} \exp\left(-\frac{|x-a|}{b}\right), x > a \end{cases} \quad (15)$$

式中 $a \in \mathbb{R}$ 为位置参数, $b > 0$ 为比例参数。由 $x^{(1)} = (x_1^{(1)}, x_2^{(1)}, \dots, x_n^{(1)})$ 和 $x^{(2)} = (x_1^{(2)}, x_2^{(2)}, \dots, x_n^{(2)})$ 生成两个后代 $y^{(1)} = (y_1^{(1)}, y_2^{(1)}, \dots, y_n^{(1)})$ 和 $y^{(2)} = (y_1^{(2)}, y_2^{(2)}, \dots, y_n^{(2)})$ 的过程为

$$\beta = \begin{cases} a - b \ln u, u \leq \frac{1}{2} \\ a + b \ln u, u > \frac{1}{2} \end{cases} \quad (16)$$

后代生成的计算式为

$$y_i^{(1)} = x_i^{(1)} + \beta |x_i^{(1)} - x_i^{(2)}| \quad (17)$$

$$y_i^{(2)} = x_i^{(2)} + \beta |x_i^{(1)} - x_i^{(2)}| \quad (18)$$

经试验, 当 $a=0$, $b=1$ 时算法在局部搜索的前期进行拉普拉斯交叉, 以大步长探索求解, 能更好地摆脱局部最优问题。而后期选择 $b=0.5$, 以小步长游走, 在最优解附近精细搜索最优区域, 提高寻找全局最优的概率。拉普拉斯交叉密度函数曲线如图3所示。


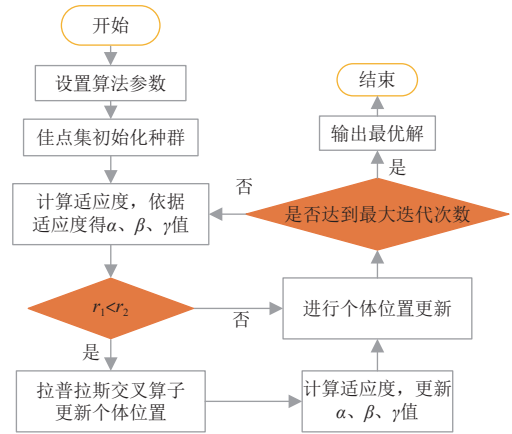


图3 拉普拉斯交叉密度函数 ($f(x)$) 曲线

Fig.3 Laplace density function curve

2.1.4 算法流程

为进一步增强 CDO 算法的全局探索能力和加快收敛速度, 减小陷入局部最优的概率, 提出 ICDO 算法。ICDO 算法流程如图4所示。



注: α 、 β 和 γ 分别表示群体中最优解、次优解和第三优解; r_1 、 r_2 为采用不同方式进行位置更新的随机数。

Note: α , β and γ represent the optimal solution, sub-optimal solution and the third optimal solution in the population, respectively. r_1 and r_2 are random numbers that are updated in different ways.

图4 ICDO 算法流程图

Fig.4 ICDO algorithm flow chart

2.1.5 算法复杂度分析

CDO 算法的时间复杂度主要体现在种群初始化、适应度评价和位置更新 3 个过程。在 CDO 算法中, 假设种群规模为 N , 最大迭代次数为 I_{\max} , 自变量的维度为 D , 其时间复杂度为 $O(N \cdot I_{\max} \cdot D)$, 本文提出的 ICDO 算法主要的各环节时间复杂度分析如下:

1) 采用佳点集初始化种群复杂度为 $O(N \cdot D)$, 则该阶段复杂度为 $O((N+1) \cdot I_{\max} \cdot D) = O(N \cdot I_{\max} \cdot D)$ 。

2) 在修改位置更新方程中, 设加入个体学习因子和群体交流因子所需的时间分别为 t_1 、 t_2 , 则该阶段时间复

杂度为 $O(N \cdot I_{\max} \cdot D + t_1 + t_2) = O(N \cdot I_{\max} \cdot D)$ 。

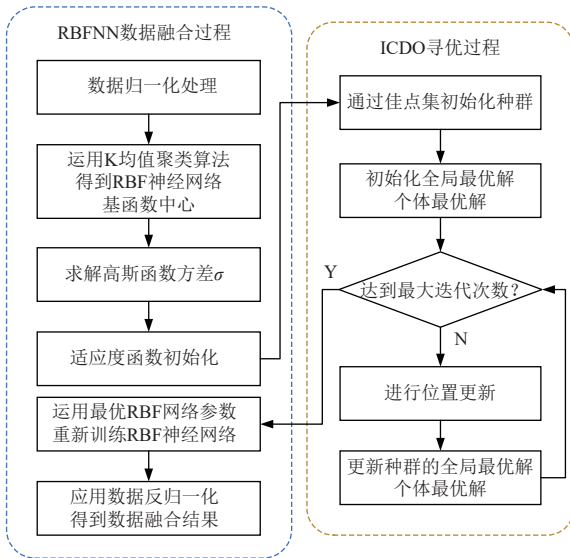
3) 引入拉普拉斯交叉算子的复杂度为 $O(N \cdot D)$ ，则该阶段的复杂度为 $O(N \cdot (I_{\max} + 4) \cdot D) = O(N \cdot I_{\max} \cdot D)$ 。

由上可知，ICDO 算法在 CDO 算法的基础上并没有增加额外的时间复杂度，其时间复杂度为 $O(N \cdot I_{\max} \cdot D)$ 。

2.2 ICDO 优化 RBF 神经网络

构建良好的 RBF 神经网络模型的难点在于确定基函数中心及扩展常数。扩展常数会影响对应高维空间中的点分布。如扩展常数过小，点的分布将过于集中；扩展常数过大，则点的分布会过于分散^[21]。本研究结合 ICDO 算法与 K 均值聚类算法搜索 RBF 神经网络的扩展常数和最优基函数中心。ICDO-RBFNN 数据融合模型如图 5 所示，其实现步骤如下：

- 1) 数据归一化处理，随机选择 h 个样本作为聚类中心 c_i 。
- 2) 将训练样本集合按最近邻规则分组，按照 x_p 与 c_i 之间的欧式距离将 x_p 分配到输入样本的各个聚类集合中。
- 3) 重新调整聚类中心：计算各个聚类集合中训练样本的均值，得到最新的聚类的中心 c_i 。如聚类中心不再发生变化，则所得 c_i 为 RBF 神经网络为最终的基函数中心，否则重复步骤 2)，进入下一轮中心求解。
- 4) 根据式 (3) 求解高斯函数方差 σ 。
- 5) 运用 RBF 模型准确率指标进行适应度函数初始化。
- 6) 通过 ICDO 搜索 RBF 网络最优网络参数。
- 7) 运用最优网络参数重新训练 RBF 神经网络。
- 8) 通过数据反归一化得到数据融合结果。



注：ICDO 为改进的切诺贝利灾难优化器；RBFNN 为径向基函数神经网络。

Note: ICDO is improved Chernobyl disaster optimizer; RBFNN is radial basis function neural network.

图 5 ICDO-RBFNN 数据融合模型
Fig.5 ICDO-RBFNN data fusion model

3 试验与结果分析

本文设置了 3 类试验，从 3 个不同的方面来验证本文算法的有效性。第 1 个为 ICDO 算法验证，与比较流

行的算法进行基准函数测试。第 2 个为大气环境质量判断的仿真，其数据为真气网 2022 年 9 月 1 日至 2023 年 9 月 30 日的南亚热带植物园所在地 24 h 大气数据，传感器为 $PM_{2.5}$ 、 PM_{10} 、 SO_2 、 NO_2 、 O_3 、 CO 空气质量传感器，并在 Matlab R2022a 软件下实现算法验证。第 3 个是温室环境等级划分，将南亚热带植物园温室（东经 $110^{\circ}16'57.144''$ ，北纬 $21^{\circ}10'14.664''$ ）采集的数据进行环境等级划分。

3.1 ICDO 算法验证

为充分验证 ICDO 的寻优性能和跳出局部最优的能力，选择了 5 个经典的算法进行比较，粒子群优化算法（particle swarm optimization, PSO）^[22]、灰狼优化算法（grey wolf optimization, GWO）^[23]、萤火虫算法（firefly algorithm, FA）^[24]、蜣螂优化器算法（dung beetle optimizer, DBO）^[25]、减法优化器（subtraction average based optimizer, SABO）^[26]。本研究从 23 个基准函数^[27]选取了 3 个高维单峰函数、3 个高维多峰函数和 3 个固定维多峰函数进行比较，分别是 F1、F3、F5、F8、F10、F12、F14、F21、F23，如表 1 所示。本文中种群的数量统一设置为 30，最大迭代次数为 80，每个算法独立运行 100 次，选取平均值、方差和最优解作为算法性能的度量标准。所有算法在迭代时的收敛过程如图 6 所示；在不同维度下的测试结果见表 2。

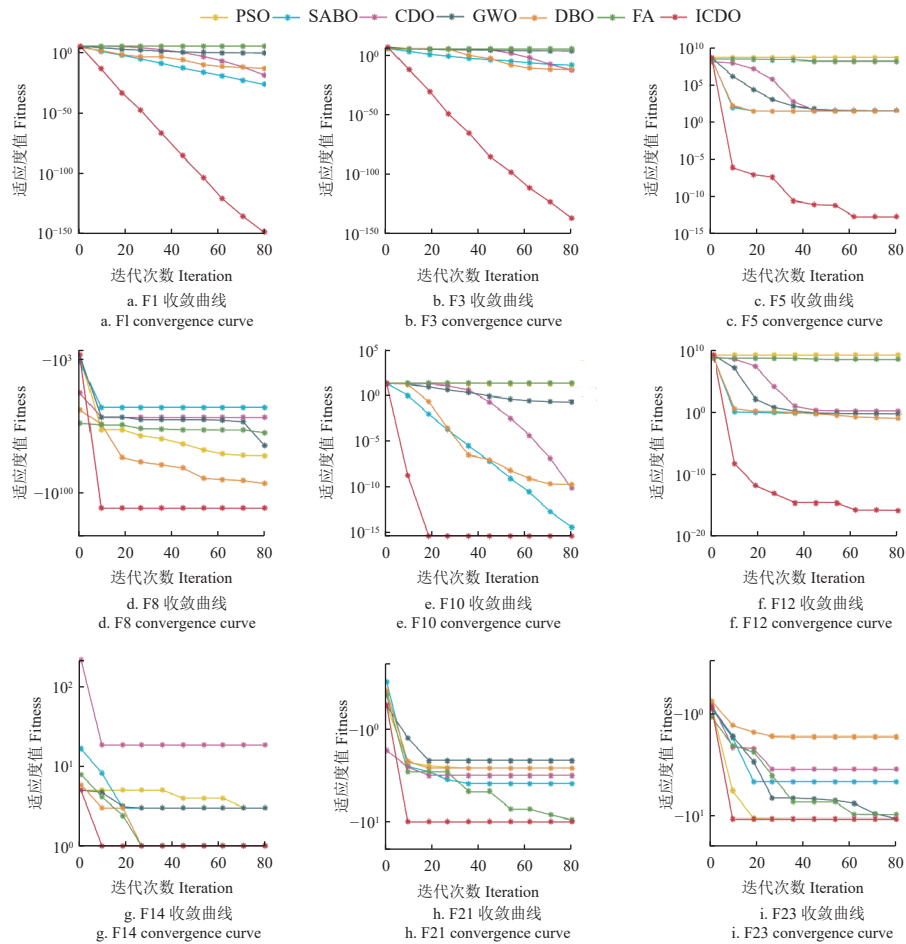
表 1 基准函数

Table 1 Benchmark functions

函数 Function	维度 Dimensional	范围 Range	最优值 Optimal value
F1	30	$[-100, 100]$	0
F3	30	$[-100, 100]$	0
F5	30	$[-100, 100]$	0
F8	30	$[-500, 500]$	-418.982 9×维度
F10	30	$[-32, 32]$	0
F12	30	$[-50, 50]$	0
F14	2	$[-65, 65]$	1
F21	4	$[0, 10]$	-10.152 3
F23	4	$[0, 10]$	-10.536 3

从图 6 中可以看出，在高维单峰函数 F1、F3、F5 中，ICDO 算法有效降低了陷入局部最优的概率，收敛速度非常快，远超其他 6 种算法；对于具有多个极值的高维多峰函数 F8、F10 和 F12，ICDO 算法收敛速度快，在迭代次数为 20 以前能准确找到最优解；对于固定维多峰函数 F14、F21、F23，ICDO 算法收敛快速。无论是在单峰函数还是多峰函数中，ICDO 算法都有非常优秀的表现。

从表 2 的数据可以看出，对于高维单峰函数 F1、F3、F5，ICDO 求解精度和寻优稳定性都有较大的提升，相较于其他 6 种算法多次寻优的平均值和方差均提升了 15 个数量级以上，求解精度提升 16 个数量级以上；对于高维多峰函数 F8、F10 和 F12，ICDO 可以快速找到最优值进行深入开发，有效跳出局部最优，稳定找到全局最优解；对于固定维多峰函数 F14、F21、F23，ICDO 也能精确找到最优解，但稳定性稍显不足。在各种维度的多峰函数中，ICDO 算法都有非常优秀的表现，能够快速搜索收敛，在全局探索和局部开发中自适应转换。



注：CDO 为切诺贝利灾难优化器；PSO 为粒子群优化算法；GWO 为灰狼优化算法；FA 为萤火虫算法；DBO 为蜣螂优化器算法；SABO 为减法优化器。
 Note: CDO is Chernobyl disaster optimizer; PSO is particle swarm optimization; GWO is grey wolf optimization; FA is firefly algorithm; DBO is dung beetle optimizer; SABO is subtraction average based optimizer.

图 6 不同算法的收敛过程

Fig.6 Convergence curve of different algorithms

表 2 不同算法基准函数试验结果

Table 2 Benchmark functions experimental result

函数 Function	指标 Index	PSO	SABO	GWO	DBO	FA	CDO	ICDO
F1	方差	1.05E+00	1.68E-55	7.20E-03	7.22E-19	1.91E+07	1.04E-37	8.44E-263
	均值	6.00E+04	4.07E-28	1.29E-01	8.98E-11	4.88E+04	1.65E-19	9.80E-133
	最优值	6.00E+04	4.18E-30	1.60E-02	6.04E-34	3.56E+04	2.19E-20	3.48E-153
F3	方差	2.55E+06	3.88E-14	1.75E+04	3.57E-32	1.19E+08	2.42E-20	2.01E-269
	均值	3.74E+04	8.11E-07	4.29E+02	1.34E-16	5.59E+04	1.11E-10	3.18E-135
	最优值	3.63E+04	6.72E-07	3.35E+02	1.97E-20	4.82E+04	1.37E-12	7.09E-138
F5	方差	5.36E+08	1.28E-02	7.31E+00	2.68E-05	2.33E+14	2.27E-02	4.30E-27
	均值	4.00E+08	2.88E+01	3.12E+01	2.81E+01	1.35E+08	2.86E+01	4.93E-14
	最优值	4.00E+08	2.87E+01	2.93E+01	2.81E+01	1.24E+08	2.85E+01	2.96E-15
F8	方差	6.50E+05	1.13E+05	1.12E+06	4.19E+05	9.45E+04	2.33E+05	4.21E+05
	均值	-8.40E+03	-2.80E+03	-5.29E+03	-6.85E+03	-4.16E+03	-3.25E+03	-1.25E+04
	最优值	-9.69E+03	-3.45E+03	-4.51E+03	-6.82E+03	-8.69E+03	-4.86E+03	-1.26E+04
F10	方差	6.42E-07	1.10E-29	8.03E-01	2.57E-13	3.99E-02	2.22E-21	0.00E+00
	均值	1.90E+01	5.98E-15	5.70E-01	1.35E-07	2.01E+01	9.66E-11	8.88E-16
	最优值	1.90E+01	4.44E-15	6.83E-02	7.99E-15	1.95E+01	4.57E-11	8.88E-16
F12	方差	4.84E+00	1.39E-02	1.89E-01	1.40E-03	2.91E+15	1.02E-02	4.83E-30
	均值	1.54E+09	4.20E-01	5.00E-01	9.62E-02	2.54E+08	1.65E+00	1.19E-15
	最优值	1.54E+09	2.58E-01	6.93E-02	3.62E-02	1.41E+08	1.12E+00	1.09E-20
F14	方差	6.49E-01	7.97E+00	1.25E+00	1.26E+00	1.68E-01	2.01E+01	2.89E+00
	均值	2.59E+00	3.98E+00	3.01E+00	1.96E+00	1.26E+00	1.50E+01	4.03E+00
	最优值	9.98E-01	9.98E-01	9.98E-01	9.98E-01	9.98E-01	2.02E+00	9.98E-01
F21	方差	1.39E+01	1.11E+00	7.08E+00	8.06E+00	2.02E+00	1.04E+00	4.81E+00
	均值	-7.17E+00	-3.84E+00	-8.93E+00	-6.24E+00	-8.99E+00	-3.81E+00	-8.96E+00
	最优值	-1.02E+01	-5.04E+00	-6.07E+00	-1.01E+01	-1.02E+01	-1.01E+01	-1.02E+01
F23	方差	9.73E+00	1.19E+00	3.28E+00	1.30E+01	1.08E-01	1.58E+00	6.72E+00
	均值	-9.00E+00	-3.70E+00	-9.99E+00	-6.96E+00	-9.80E+00	-4.43E+00	-8.73E+00
	最优值	-1.05E+01	-8.27E+00	-8.71E+00	-1.05E+01	-1.05E+01	-1.04E+01	-1.05E+01

3.2 AQI 仿真

本次试验将构建的 ICDO-RBFNN 多传感器数据融合模型应用于温室外大气环境质量预测，将大气参数 PM_{2.5}、PM₁₀、SO₂、NO₂、O₃、CO 按照《环境空气质量指数（AQI）技术规定（试行）》中空气质量分指数及对应的污染物项目浓度限值表格与计算公式算出各自的空气质量分指数（individual air quality index，IAQI），AQI 是六项污染物空气质量分指数中的最大值。在相同迭代次数和初始种群的前提下，分别用 CDO-RBFNN 模型和 ICDO-RBFNN 模型对 400 个样本进行训练，将剩余 66 条数据作为测试样本。为以可靠的方式呈现试验结果，本研究通过对 20 个随机独立样本进行试验得到 AQI 融合值和 AQI 融合相对误差如图 7 所示。




图 7 不同模型 AQI 融合的相对误差对比
Fig.7 Relative error comparison diagram of AQI fusion of different models

从图 7 中可看出，CDO-RBFNN 融合算法和 RBFNN 融合算法的相对误差分别不超过 7% 和 9%，而本文算法融合的相对误差最高不超过 5%，更接近真实值。由此得出本算法融合精度更高。

为了更好的验证本文数据融合算法的有效性，与其他 5 种模型从拟合优度（coefficient of determination, R^2 ）、均方误差（mean square error, MSE）、平均绝对百分比误差（mean absolute percentage error, MAPE）和平均耗时进行了评估。当 MSE 和 MAPE 越接近 0, R^2 越接近 1 时，表示模型的拟合效果越佳，准确性越高。模型评价指标 R^2 、MSE、MAPE 见式（19）～（21）。对比结果见表 3。

$$R^2 = \frac{\sum_{n=1}^N (\hat{y}_n - \bar{y}_n)(\hat{y}'_n - \bar{y}'_n)}{\sqrt{\sum_{n=1}^N (\hat{y}_n - \bar{y}_n)^2 \sum_{n=1}^N (\hat{y}'_n - \bar{y}'_n)^2}} \quad (19)$$

$$MSE = \frac{1}{N} \sum_{n=1}^N (\hat{y}_n - y_n)^2 \quad (20)$$

$$MAPE = \frac{1}{N} \sum_{n=1}^N \frac{|\hat{y}_n - y_n|}{y_n} \quad (21)$$

从表 3 可以得出 ICDO-RBFNN 融合算法模型在 3 种性能指标上均优于 CDO-RBFNN 融合算法，其 R^2

提升了 0.1 个百分点、MSE 和 MAPE 分别降低了 45.5 个百分点和 0.3 个百分点，平均耗时只增加了 0.4 s。与其他模型相比 R^2 提升 1 个百分点以上，MSE 和 MAPE 分别降低 525 和 1.3 个百分点以上。这表明本算法 AQI 融合效果好，误差小，更稳定，有很好的优化效果。

表 3 AQI 融合对比分析
Table 3 AQI fusion comparative analysis

模型 Model	R^2	均方误差 Mean square error	平均绝对百分比误差 Mean absolute percentage error/%	平均耗时 Average time consumption/s
BPNN 融合算法	0.936	49.133	9.562	0.75
GA-BPNN 融合算法	0.948	25.635	10.096	4.75
Elman 神经网络融合算法	0.910	41.282	8.042	0.13
RBFNN 融合算法	0.988	5.598	2.060	0.04
COD-RBFNN 融合算法	0.998	0.803	1.029	8.60
ICOD-RBFNN 融合算法	0.999	0.348	0.729	8.99

3.3 温室环境等级划分试验

热带气候地区虽冬无严寒，夏无酷暑，但冬季最低温能达 5.1 ℃，且夏季高温持续时间长，空气相对湿度高。由于温度、相对湿度对植物的生长具有重要的影响，特别是兰花、中药材等植物，对生长环境要求非常苛刻。本文取亚热带植物园温室环境数据将温室的环境舒适等级分为 4 个等级，级别越高说明所处的环境越适宜。等级划分如表 4 所示。

表 4 农业温室环境等级划分
Table 4 Greenhouse environment classification

温度 Temperature (t) /℃	湿度 Relative humidity(RH)/%	等级 Level
26≤t≤28	50≤RH≤70	4（最佳生长环境）
20≤t<26; 28<t≤30	40≤RH<50; 70<RH≤80	3（生长环境）
5≤t<20; 30<t≤35	40≤RH<50; 70<RH≤80	2（存活环境）
t<5; t>35	40>RH; RH>80	1（恶劣环境）

在相同迭代次数和初始种群的前提下，分别用 CDO 优化的 RBFNN 模型和 ICDO 优化的 RBFNN 模型对温室采集的 210 个样本进行训练，将剩下的 52 条数据作为测试样本。为了以可靠的方式呈现试验结果，本研究通过对 20 个随机独立样本进行试验得到融合结果如图 8 所示。




图 8 温室环境等级融合对比
Fig.8 Comparison of greenhouse environment grade fusion

通过图 8 对比分析可以看出，在 20 个采样点中，ICDO-RBFNN 融合算法有 1 个采样点与真实值有偏差。

CDO-RBFNN 融合算法有 2 个采样点未融合准确; 而 RBFNN 融合算法有 3 个没有和真实值重叠。这表明, ICDO-RBFNN 融合算法比 CDO-RBFNN 融合算法和传统的 RBFNN 融合算法能够更有效地识别和区分不同的温室环境状态。

为了进一步分析与评估温室环境等级融合时本文算法的融合性能, 以准确率和精确率、平均耗时作为评价标准。在此, 选择了 5 类神经网络融合算法进行对比分析, 如表 5 所示。

表 5 温室环境等级融合对比分析

Table 5 Comparative analysis of greenhouse environment grade fusion

模型 Model	准确率 Accuracy/%	精确率 Precision/%	平均耗时 Average time consumption/s
BPNN 融合算法	46.46	63.44	0.04
GA-BPNN 融合算法	99.20	98.93	7.75
Elman 神经网络融合算法	76.37	95.59	0.25
RBFNN 融合算法	94.49	92.93	0.22
COD-RBFNN 融合算法	96.85	96.81	4.65
ICOD-RBFNN 融合算法	99.21	99.91	4.86

从表 5 可以得出 ICDO-RBFNN 融合算法模型的准确率和精确率指标上均优于其他融合算法。ICDO-RBFNN 融合算法在温室环境等级融合的准确率高达 99.21%, 精确率为 99.91%。与 CDO-RBFNN 融合算法相比, 准确率提升 2.36 个百分点, 精确率提升 3.1 个百分点, 平均耗时多 0.21 s。和 GA-BPNN 融合算法相比, 准确率相差不大, 精确率提升 0.98 个百分点, 但平均耗时多 2.89s; 与其他融合算法比, 准确率和精确率提升 5 个百分点以上。总之, 仿真测试和现场工程试验都验证了本算法的有效性。

4 结 论

为平衡算法的求解精度和速度, 实现多维数据的准确高效融合, 改善传感器测量数据精度低的问题。本文面向农业温室环境提出了一种 ICDO-RBFNN 多传感器数据融合算法。该算法通过引入佳点集、拉普拉斯交叉算子和修改位置更新方程改进 CDO 以提高求解精度和速度, 再与 RBFNN 建立了多维数据融合算法。试验结果表明, 大气环境质量预测的拟合优度达到 0.999, 均方误差低至 0.348, 平均绝对百分比误差降到 0.729%; 温室环境等级划分的准确率高达 99.21%, 精确率为 99.91%; 本融合算法对室内外环境的数据均能得到高精度的融合值, 具有较好的适应能力及准确性。

团队下一步将考虑复杂条件下, 进一步优化算法模型, 提高算法运行速度和鲁棒性, 并将算法应用温室农作物病害预警和温室环境检测等领域, 为智慧温室农业提供坚实的理论与实践根基。

【参 考 文 献】

- [1] WANG J, WU Z, LIANG Y, et al. Perception methods for adverse weather based on vehicle infrastructure cooperation system: a review[J]. *Sensors*, 2024, 24(2): 374.
- [2] 张柏, 凌彩金, 李露青, 等. 基于数据融合策略的红茶发酵程度判别[J]. *农业工程学报*, 2022, 38(15): 339-347.
- [3] ZHANG Bai, LING Caijin, LI Luqing, et al. Discrimination of black tea fermentation degrees based on data fusion strategy[J]. *Transactions of the Chinese Society of Agricultural Engineering(Transactions of the CSAE)*, 2022, 38(15): 339-347. (in Chinese with English abstract)
- [4] 匡亮, 施珮, 季云峰, 等. 改进型支持度函数的 WSN 水质监测数据融合方法[J]. *农业工程学报*, 2020, 36(16): 192-200.
- [5] KUANG Liang, SHI Pei, JI Yunfeng, et al. Data fusion method for water quality monitoring using WSN based on improved support function[J]. *Transactions of the Chinese Society of Agricultural Engineering(Transactions of the CSAE)*, 2020, 36(16): 192-200. (in Chinese with English abstract)
- [6] SONG J H, SHI X Y, WANG H J, et al. Combination of feature selection and geographical stratification increases the soil total nitrogen estimation[J]. *Computers and Electronics in Agriculture*, 2024, 218: 108636.
- [7] 杜肖鹏, 李恺, 王春辉, 等. 国内温室空气温湿度检测及传输技术研究进展[J]. *农业工程技术*, 2022, 42(34): 28-34.
- [8] 曾喆昭, 王耀南. 基于正交基神经网络算法的多传感器数据融合方法[J]. *传感技术学报*, 2007(6): 1368-1370.
- [9] ZENG Zhezhaohao, WANG Yaonan. Multi-sensor information fusion approach based on the basis neural network algorithm with orthogonal basis functions[J]. *Chinese Journal of Sensors and Actuators*, 2007(6): 1368-1370. (in Chinese with English abstract)
- [10] 杜昭, 张文榕, 朱兴一. 基于网联车辆数据融合的路面平整度评估方法[J]. *中国公路学报*, 2024, 37(6): 302-316.
- [11] DU Zhao, ZHANG Wenrong, ZHU Xingyi. Road roughness assessment based on fusion of connected-vehicles data[J]. *China Journal of Highway and Transport*, 2024, 37(6): 302-316. (in Chinese with English abstract)
- [12] 杨华, 陈树生, 高正红, 等. 基于贝叶斯框架的旋翼气动力数据融合[J]. *航空学报*, 2024, 45(8): 138-150.
- [13] YANG Hua, CHEN Shusheng, GAO Zhenghong, et al. Research on rotor aerodynamic data fusion based on bayesian frame-work[J]. *Acta Aeronautica et Astronautica Sinica*, 2024, 45(8): 138-150. (in Chinese with English abstract)
- [14] XIAO H. Computer technology of multisensor data fusion based on FWA-BP network[J]. *Journal of Intelligent Systems*, 2023, 32(1): 6099-6108.
- [15] DONG Y, LIU P X, YUE X J, et al. Data fusion algorithm based on classification adaptive estimation weighted fusion in WSN[J]. *Wireless Personal Communications*, 2022, 127(4): 2859-2871.
- [16] ANNARITA D, ALBERTO R, FRANCESCO P L, et al. DAFNE: A matlab toolbox for Bayesian multi-source remote sensing and ancillary data fusion, with application to flood mapping[J]. *Computers & Geosciences*, 2018, 112: 64-75.
- [17] LIU H B, FANG S Y, JI J H. An improved weighted fusion algorithm of multi-sensor[J]. *Journal of Physics: Conference Series*, 2020, 1453(1): 012009.
- [18] WU L S, CHEN L, HAO X R. Multi-sensor data fusion algorithm for indoor fire early warning based on BP neural network[J]. *Information*, 2021, 12(2): 59-59.
- [19] 吴晟, 闫娇娇, 张晶. 基于启发式萤火虫的 BP 神经网络数据融合算法[J]. *传感器与微系统*, 2021, 40(4): 146-149, 156.
- [20] WU Sheng, YAN Jiaojiao, ZHANG Jing. BPNN data fusion algorithm based on heuristic firefly[J]. *Transducer and Microsystem Technologies*, 2021, 40(4): 146-149, 156. (in Chinese with English abstract)
- [21] IMANE E N H, ALLEL H, MOHAND L. Multisensor data fusion in IoT environments in dempster-shafer theory setting: An improved evidence distance-based approach[J]. *Sensors*

- (Basel, Switzerland), 2023, 23(11): 5141.
- [16] 张志勇, 路小娟, 孔令刚, 等. K-means 结合 RBF 神经网络预测线性菲涅尔集热回路出口熔盐温度[J]. 农业工程学报, 2021, 37(3): 213-222.
ZHANG Zhiyong, LU Xiaojuan, KONG Linggang, et al. Predicting molten salt temperature at the circuit outlet of Linear Fresnelheat collector using K-means combined with RBF neural network[J]. Transactions of the Chinese Society of Agricultural Engineering(Transactions of the CSAE), 2021, 37(3): 213-222. (in Chinese with English abstract)
- [17] A. H. S. Chernobyl disaster optimizer (CDO): A novel meta-heuristic method for global optimization[J]. Neural Computing and Applications, 2023, 35(15): 10733-10749.
- [18] 闫少强, 杨萍, 朱东林, 等. 基于佳点集的改进麻雀搜索算法[J]. 北京航空航天大学学报, 2023, 49(10): 2790-2798.
YAN Shaoqiang, YANG Ping, ZHU Donglin, et al. Improved sparrow search algorithm based on good point set[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(10): 2790-2798. (in Chinese with English abstract)
- [19] WANG M H, MA Y J. A differential evolution algorithm based on accompanying population and piecewise evolution strategy[J]. Applied Soft Computing Journal, 2023, 143: 110390.
- [20] YU H L, QIAO S M, ALI A H, et al. Laplace crossover and random replacement strategy boosted Harris hawks optimization: Performance optimization and analysis[J]. Journal of Computational Design and Engineering, 2022, 9(5): 1879-1916.
- [21] YANG Z L, MOURSHED M, LIU K L, et al. A novel competitive swarm optimized RBF neural network model for short-term solar power generation forecasting[J]. Neurocomputing, 2020, 397: 415-421.
- [22] ZHENG X P, NIE B, CHEN J D, et al. An improved particle swarm optimization combined with double-chaos search[J]. Mathematical Biosciences and Engineering: MBE, 2023, 20(9): 15737-15764.
- [23] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [24] TILAHUN L S, NGNOTCHOUYE T M J. Firefly algorithm for discrete optimization problems: A survey[J]. KSCE Journal of Civil Engineering, 2017, 21(2): 535-545.
- [25] XUE J, SHEN B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [26] PAVEL T, MOHAMMAD D. Subtraction-average-based optimizer: A new swarm-inspired metaheuristic algorithm for solving optimization problems[J]. Biomimetics (Basel, Switzerland), 2023, 8(2): 2313-7673.
- [27] 潘劲成, 李少波, 周鹏, 等. 改进正弦算法引导的蜣螂优化算法[J]. 计算机工程与应用, 2023, 59(22): 92-110.
PAN Jincheng, LI Shaobo, ZHOU Peng, et al. Dung beetle optimization algorithm guided by improved sine algorithm[J]. Computer Engineering and Applications, 2023, 59(22): 92-110. (in Chinese with English abstract)

ICDO-RBFNN multi-sensor data fusion for agricultural greenhouse environment

LUO Huanzhi, WANG Ji^{*}

(1. School of Electronics and Information Engineering, Guangdong Ocean University, Zhanjiang 524088, China; 2. Guangdong Engineering Technology Research Center of Intelligent Ocean Sensor Network and Equipment, Zhanjiang 524088, China)

Abstract: Agricultural sensors can greatly contribute to future technologies and systemic innovation in smart agriculture. However, the types and precision of sensors are limited to monitoring the agricultural environment with complex and diverse objects. The large and redundant monitoring data has also resulted in the low reliability of information perception. In this study, an improved radial basis function neural network (RBFNN) and Chernobyl disaster optimizer (ICDO) multi-sensor data fusion was proposed to improve the accuracy and reliability of single-sensor measurement. Firstly, an improved Chernobyl catastrophe optimization was performed on the neural network model. The good-point set theory was introduced to improve the initial population quality of the CDO, particularly for accuracy and speed. The adaptive Laplacian crossover operator was added to enhance the search performance. The better adaptive behavior was achieved in the high convergence speed. And then, the individual learning and differential evolution strategy were used to redefine the location update equation, in order to balance the local and global exploration. Secondly, the RBF neural network model was optimized by ICDO, in order to improve the stability of the model. Finally, the nonlinear mapping of the RBF neural network model was used to realize the multi-sensor data fusion with high accuracy. Three experiments were conducted to verify the improved model. The first one was to verify the ICDO. A large improvement was obtained in the solution accuracy and optimization stability, compared with particle swarm optimization (PSO), gray wolf optimization (GWO), firefly algorithm (FA), dung beetle optimizer (DBO), and subtraction average-based optimizer (SABO). The second one was to evaluate the quality of the atmospheric environment. Specifically, the atmospheric data was collected outside the South Subtropical Botanical Garden in Mazhang District, Zhanjiang City, Guangdong Province, China, from September 1, 2022, to September 30, 2023. The goodness of fit reached 0.999 for the prediction of atmospheric environmental quality, the mean square error was as low as 0.348, and the mean absolute percentage error was reduced to 0.729%. The third one was to classify the greenhouse environment. The data was collected in the greenhouses of the South Asian Tropical Botanical Garden. The accuracy rate of greenhouse environment classification was 99.21% with a precision rate of 99.91%. The data fusion was suitable for both indoor and outdoor environments, indicating better adaptability and high accuracy. This finding can also provide solid technical support to agricultural sensor data fusion in the field of precision agriculture.

Keywords: greenhouse; multi-sensor; data fusion; improved Chernobyl disaster optimizer; RBF neural network