

孙立辉, 周洁, 徐金鸣. 基于改进 PSO 优化的 RBF 火灾预测系统[J]. 智能计算机与应用, 2024, 14(7): 216–221. DOI: 10.20169/j.issn.2095-2163.240734

基于改进 PSO 优化的 RBF 火灾预测系统

孙立辉, 周洁, 徐金鸣

(吉林化工学院 信息与控制工程学院, 吉林 吉林 132022)

摘要: 针对系统预测火灾状态不准确, 导致火情变大造成人民群众生命和财产损失的问题, 本文提出了一种基于改进粒子群优化的径向基神经网络多传感器数据融合算法的火灾状态预测系统。以温度、烟雾浓度、一氧化碳浓度为输入, 以无火、阴燃火、明火的概率为输出, 为了避免输出产生偏差, 模糊推理系统对神经网络系统的输出做补偿。由于粒子群算法存在容易陷入局部最优的缺陷, 采用一种非线性动态自适应惯性权重的改进粒子群优化算法 (IPSO)。仿真实验表明, 改进后的系统, 以明火为例的平均绝对百分比误差达到 0.169、均方根误差达到 0.002 1、平均绝对误差达到 0.031。

关键词: 改进粒子群优化算法; 径向基神经网络; 模糊推理系统; 预测火灾状态; 多传感器数据融合算法

中图分类号: TP183

文献标志码: A

文章编号: 2095-2163(2024)07-0216-06

RBF fire prediction model based on improved PSO optimization

SUN Lihui, ZHOU Jie, XU Jinming

(College of Information and Control Engineering, Jilin Institute of Chemical Technology, Jilin 132022, Jilin, China)

Abstract: Aiming at the problem is that the system predicts the fire state inaccurately, which leads to the fire becoming bigger and causing the loss of people's lives and property. A fire state prediction system based on the radial basis neural network multi-sensor data fusion algorithm with improved particle swarm optimization is proposed, taking the temperature, smoke concentration, and carbon monoxide concentration as the inputs. The probability of no fire, shaded fire, and open fire are the outputs, and to avoid the outputs from bias, the fuzzy inference system compensates the outputs of the neural network system. Due to the defects of the particle swarm optimization algorithm which is easy to fall into local optimum, an improved nonlinear dynamic adaptive inertia weights particle swarm optimization algorithm (IPSO) is used. After simulation experiments, it is found that the improved system, for example, the average absolute percentage error reaches 0.169, the root mean square error reaches 0.002 1, and the average absolute error reaches 0.031 in the case of open fire.

Key words: improved particle swarm optimization algorithm; radial basis neural network; fuzzy inference system; predicting fire state; multi-sensor data fusion algorithm

0 引言

火灾预测研究是国内外消防的一个热点问题, 由于传感器采集信息时容易受到干扰, 会使得系统对火情状态的判断准确性降低, 提高系统预测火灾状态的精度和准确性是解决这个问题的重点。因为单源传感器信息融合检测方法误报率较高, 所以本文系统采取多源传感器信息融合方法。目前, 多源传感器信息融合有神经网络、模糊算法、时间序列等算法。

神经网络有较强的自学习和容错能力, 而模糊

逻辑具有较强处理随机多变信号的能力, Okayama^[1]和 Nakanishi^[2]分别把神经网络和模糊逻辑应用到火灾探测报警系统中, 大大提升了火灾探测报警系统的性能; 李军等^[3]采用长短期记忆网络和径向基前馈神经网络, 构建集成网络学习不同的火灾特征, 模糊逻辑输出火灾报警等级, 该模型的平均绝对百分比误差 (MAPE) 达到 3.52; 许春芳等^[4]提出了一种基于长短期记忆神经网络 (LSTM) 和径向基神经网络 (RBF) 深度学习模型的多源信息融合火灾预测模型, 该模型的平均绝对误差 (RMSE) 达到 0.022; 刘永立等^[5]通过调整 LSTM 模型时间步长

作者简介: 周洁 (1997-), 女, 硕士研究生, 主要研究方向: 人工智能。

通讯作者: 孙立辉 (1976-), 男, 硕士, 教授, 主要研究方向: 人工智能。Email: sunlihui2000@126.com

收稿日期: 2024-01-03

和迭代次数,运用 LSTM、门控循环神经网络 (GRU) 和循环神经网络 (RNN) 多模型预测分析, *MAPE* 达到 3.843%, *RMSE* 达到 0.029; 韩丙光等^[6] 提出基于 D-S 证据理论多传感器融合的电缆火灾预警系统, 用于解决传感器预警的抗干扰能力和决策准确性不足的问题; 张冉等^[7] 采用麻雀搜索算法优化极限学习机的预测精度和准确度从而输出各火情概率, 系统的 *RMSE* 达到 0.187 32; 朱菊香等^[8] 提出了一种基于粒子群优化算法 (PSO) 优化 BP (Back Propagation) 神经网络多传感器数据融合算法, 该算法的甲醛、PM2.5、挥发性有机化合物 (Volatile Organic Compounds, VOC) 的 *MAPE* 分别达到 4.13%、3.41%、3.25%; 孙苗等^[9] 提出了一种基于 PSO-Nadam 算法优化 BP 神经网络的多传感器火灾检测算法, 明火 *RMSE* 达到 0.019 1; 王坤等^[10] 提出了基于粒子群算法优化长短期记忆网络的算法去提高辅助动力装置排气温度的预测精度, 该算法的 *MAPE* 达到 0.296 4、*RMSE* 达到 0.960 6、平均绝对误差 (Mean Absolute Error, MAE) 达到 0.891 7; 李卫高等^[11] 将神经网络与模糊逻辑串并联模型应用于火灾探测报警系统中, 解决火灾探测对准确度和灵敏度的矛盾, 该系统的 *RMSE* 达到 0.002 4; 赵月爱等^[12] 提出了一种基于 TensorFlow 智能学习系统的 LSTM 神经网络电气火灾预测算法, 提高电气火灾的预测精度, 该算法的 *RMSE* 达到 0.002 5; 黄翰鹏等^[13] 提出了一种结合模糊神经网络模型和温度时序模型的火灾预警算法, 用于解决传统火灾监测器误报率高的问题; 田东平等^[14] 提出了于 sigmoid 惯性权值的自适应粒子群优化算法, 用于改善粒子群的缺陷; 刘伟等^[15] 提出了惯性权重函数使算法的全局与局部搜索能力得到良好平衡, 以达到快速收敛; 丁承君^[16] 提出一种基于惯性粒子群优化的核极限学习机的火灾预警算法, 提高火灾预警分类精度和稳定性。刘洋等^[17] 提出一种改进的粒子群算法优化支持向量机的气温预测模型, 提高粒子群的搜索能力。

相对于单一的神经网络模型, 集成神经网络具有可靠性高以及泛化性强的特点, 因此, 本文在分析火灾特征参数的基础上改进现有的集成神经网络模型, 并提出了一种基于改进 PSO 优化的 RBF 火灾预测模型, 用非线性方法来动态的调整权重因子, 改善粒子群优化算法前期容易过早熟后期收敛慢的问题; 本文提出以改进粒子群优化径向基神经网络算法 (IPSO-RBF) 作为特征层, 模糊推理系统作为决

策层的智能火灾识别检测系统。

1 RBF 神经网络

径向基函数 (Radial Basis Function, 简称 RBF) 神经网络模型是 1988 年由 Moody 和 Darken 提出的一种神经网络结构。RBF 属于一种前向神经网络, 常用于解决分类问题, 包括输入层、隐含层、输出层, RBF 结构图如图 1 所示, 其中 X_1 、 X_2 、 X_3 分别为温度、烟雾浓度和一氧化碳浓度构成的输入层; 隐含层采用的高斯函数作为激活函数, 高斯函数将输入数据映射到高维特征空间中, 使得样本在高维空间中更容易被区分; Y_1 、 Y_2 、 Y_3 分别为明火概率、阴燃火概率、无火概率且构成输出层。RBF 神经网络的激活函数的表达式如式 (1) 所示:

$$h(\mathbf{x}) = \exp\left(-\frac{1}{2\sigma_j^2} \|\mathbf{x} - \mathbf{c}_j\|^2\right) \quad (1)$$

其中, \mathbf{x} 是 n 维的输入样本向量 (本模型 $n = 3$); \mathbf{c}_j 是第 j 个隐层节点的中心矢量, 决定了基函数的位置; σ_j 是第 j 个隐层节点的基函数的扩展系数或者宽度, 决定了基函数对输入样本的响应程度。

当 σ 较大时, 基函数的响应范围更广, 反之则更窄。




图 1 RBF 结构图

Fig. 1 RBF structure diagram

2 粒子群优化算法

标准粒子群算法是 1995 年由美国学者 Eberhart 和 Kennedy 提出的一种模拟自然界鸟群捕食和鱼群捕食的过程, 通过群体中的协作与竞争得到的全局最优解^[18]。首先, 生成初始种群; 其次, 在可行解的空间中初始化“粒子群”, 在此空间内每个粒子是一个解, 解的优劣程度需要将解带到适应度函数中求出适应值得知, 而适应度函数由寻优目标决定。

假设有一个 N 维空间, 存在一个由 n 个粒子构成的粒子群:

第 i 个粒子的位置: $x_i = (x_{i1}, x_{i2}, \dots, x_{iN})$; 第 i 个粒子的速度: $v_i = (v_{i1}, v_{i2}, \dots, v_{iN})$ 。

进化过程中,会记录到目前为止粒子的个体最优位置 $p_i = [p_{i1}, p_{i2}, \dots, p_{iN}]$ 和所有粒子中到目前为止的全局最优位置 $g_i = [g_{i1}, g_{i2}, \dots, g_{iN}]$, 粒子会跟踪已知的历史个体最优位置 p_{best} 和全局最优位置 g_{best} , 对比自己前一刻的状态来更新自己现在的状态, 并且在奔赴的过程中不断的挖掘其他可行解。

粒子 i 的 j 维速度变化方程, 式(2):

$$v_{ij}(t+1) = v_{ij}(t) + c_1 r_1(t) [p_{ij}(t) - x_{ij}(t)] + c_2 r_2(t) [p_{gj}(t) - x_{ij}(t)] \quad (2)$$

粒子 i 的 j 维位置变化方程, 式(3):

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (3)$$

其中, t 表示当前迭代到第 t 代; c_1 和 c_2 是学习因子, 取值范围是 $[0.1, 2]$; p_{ij} 是粒子 i 的 j 维个体最优位置; p_{gj} 是粒子 i 的 j 维全局最优位置; r_1 和 r_2 是两个相互独立的随机数, 取值范围是 $[0 - 1]$; 粒子的速度 v 由最大速度 v_{max} 限制, 取值范围是 $[v_{\text{min}}, v_{\text{max}}]$; 粒子的位置 x 受边界限制, 取值范围是 $[x_{\text{min}}, x_{\text{max}}]$ 。

如果粒子的位置或者速度出界, 采用边界吸取政策, 则下一次进化粒子落在可行解空间边界上。

粒子的速度由粒子的惯性速度、粒子自我认知和全局信息共享构成。Shi 和 Eberhart^[19] 于 1998 年提出线性递减权重策略 (Linearly Decreasing Weight, LDW), 提出惯性权重因子的概念。权重因子 w 可以改变算法全局搜索能力和局部寻优能力, 当 w 变大时, 全局搜索能力变强, 算法的收敛速度变快, 按照线性函数进行动态递减, 即随着迭代次数的增加, 惯性权重因子逐渐减小。这个递减过程是渐进性的, 因此可以有效地平衡了全局搜索和局部搜索能力, 使算法更加鲁棒和有效。

速度更新公式(4):

$$v_{ij}(t+1) = wv_{ij}(t) + c_1 r_1(t) [p_{ij}(t) - x_{ij}(t)] + c_2 r_2(t) [p_{gj}(t) - x_{ij}(t)] \quad (4)$$

此策略的权重因子 w 计算公式(5):

$$w(t) = w_{\text{max}} - \frac{(w_{\text{max}} - w_{\text{min}}) \times t}{T_{\text{max}}} \quad (5)$$

其中, w_{max} 是最大的权重因子, 取值 0.95; w_{min} 为最小的权重因子, 取值 0.4; T_{max} 是最大迭代次数; t 为当前的迭代次数。

实验表明 LDWP 算法很好的优化了迭代次数跟权重因子 w 变化线性相关的寻优情况, 但对于一些复杂的、非线性变化的优化问题适应度不佳。

3 改进粒子群优化算法

进化初期, 粒子更新速度主要由 $w \times v$ 决定, 若权重因子 w 小, 则粒子更新速度慢, 不易于在可行解的空间内全盘“探索”; 到了后期, 个体飞行经验优先转化为集体飞行经验时, 权重小导致的速度低, 会使整体种群的“开发”能力下降, 易早熟和陷入局部最优。因此, 权重因子对于粒子的更新速度有重要的影响, 对算法的寻优强弱有所影响, 本文从自适应的惯性权重角度出发, 避免容易陷入局部最优的缺陷。

本文采用平均适应度变化率 $\beta(x)$ 来调整 w , 公式(6):

$$\beta(x) = \frac{F_{\text{avg}}(t)}{F_{\text{avg}}(t-1)} \quad (6)$$

其中, $F_{\text{avg}}(t)$ 是粒子当前的平均适应值, $F_{\text{avg}}(t-1)$ 是粒子前一刻的平均适应值。

如果前一时刻的平均适应值比当前时刻的平均适应值小, 则认为粒子群已经找到了一个更优的位置, 此时可以适当增加惯性权重以加速搜索; 如果前一时刻的平均适应值比当前时刻的平均适应值大, 则意味着当前位置可能更优, 此时可以适当减小惯性权重以避免跳出更优的位置。

田东平^[14] 对于难优化的复杂高维函数, 提出一个惯性权重函数来平衡全局和局部搜索能力, 公式(7):

$$w = w_{\text{min}} + (w_{\text{max}} - w_{\text{min}}) \times (\exp(-20 \times \text{iter}/\text{iter}_{\text{max}}))^6 \quad (7)$$

其中, w_{max} 是权重因子的最大值; w_{min} 为权重因子最小值; iter_{max} 是最大迭代次数; iter 是当前迭代次数。

刘伟^[15] 考虑到神经网络中最常用的 sigmoid 激活函数在线性与非线性行为之间表现出极好的平衡, 提出了基于 sigmoid 函数的非线性递减惯性权值法, 其 sigmoid 函数如表达式(8):

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (8)$$

由此提出的惯性权重 w , 式(9):

$$w = \frac{1}{1 + \exp\left(\frac{(\ln 1.5 + \ln 19) \times t}{t_m} - \ln 19\right)} \quad (9)$$

其中, t_m 是最大迭代次数, t 是当前迭代次数。

考虑到 sigmoid 在线性与非线性的平滑性, 提出了改进的自适应权重动态调整的粒子群优化算法,

公式(10):

$$w = w_{\max} - (w_{\max} - w_{\min}) \times \frac{1}{1 + \exp\left(\frac{2 \times (2.5 + \ln 1.5) \times t}{t_m \beta(x)} - 2.5\right)} \quad (10)$$

其中, t 为当前迭代次数; t_m 为迭代次数的最大值; w_{\max} 和 w_{\min} 分别是最大、最小权重因子取值。

当前迭代次数为 1 时, w_{\max} 取值 0.9; 当前迭代次数大于 1 时, w_{\min} 取值 0.4。

本文系统结合径向神经网络算法和改进粒子群算法, 采用改进的粒子群优化算法帮助 RBF 找到最优的网络构建参数: 隐层中心点、方差、输出层到结果的权值, 从而提高预测精度。改进 PSO 优化的 RBF 火灾预测系统流程图如图 2 所示。

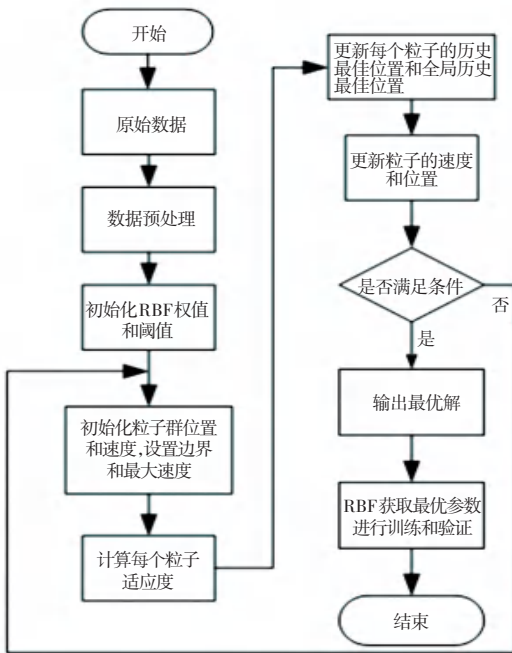


图 2 改进 PSO 优化的 RBF 火灾预测系统流程图

Fig. 2 Flow of RBF fire prediction model with improved PSO optimization

4 决策层数据融合

本文系统采用 matlab 的模糊逻辑工具箱建立模糊逻辑推理系统, 实现决策层对火情状态的判断。

本文模糊推理系统的输入输出变量的论域是 $[0, 1]$; 对每个输入变量的模糊集合建立 sigmoid 型隶属度函数, 输出变量模糊集合则构造三角形函数。输入变量为: 明火概率、阴燃火概率、无火概率和参量信号持续时间。输出变量为报警等级: PN (无火)、PL (警戒)、PM (报警)、PH (严重报警)。参量信号持续时间的计算方式(11):

$$T_n = \begin{cases} a, & T_{(n-1)} \geq 1 \\ [T(n-1 + 0.1 \times k)]a, & T_{(n-1)} < 1 \end{cases} \quad (11)$$

其中, a 为检测器答复信号的火灾异常标志位, 调整系数 k 是由火灾检测系统的火灾实验和巡检周期共同决定的。

应用模糊理论算法, 建立图 3 所示模糊推理决策模型。

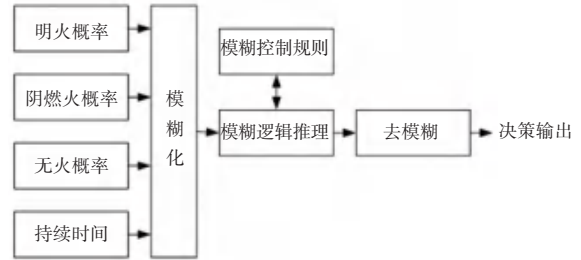


图 3 模糊推理决策模型

Fig. 3 Fuzzy reasoning decision model

5 实验仿真与结果

5.1 数据预处理

传感器采集到的数据混有测量噪声和各种干扰信号。为了有效控制噪声对数据融合的影响, 本文采用小波分析对数据样本进行去噪处理。小波降噪的过程是先对信号进行小波变换, 将信号分解成不同尺度的小波基函数; 通过阈值处理, 将小波系数中的低幅值部分过滤掉, 只保留高幅值的系数; 最后将处理后的小波系数重构成清晰的信号, 将预处理后的数据送到模型的输入端。

本文数据样本符合中国标准阴燃火 SH1、标准明火 SH4 和欧洲 6 种标准火要求, 共 39 组样本数据, 每组数据有 3 列, 随机选取 30 组数据作为训练集, 剩下的 9 组数据作为测试集。

5.2 性能评估指标

为了更加直观的评价不同模型的性能差异, 本文以明火为示例选取平均绝对百分比误差 (MAPE)、平均绝对误差 (MAE)、均方根误差 (RMSE) 这 3 个性能指标对不同模型进行评估。

平均绝对百分比误差 (MAPE) 公式(12):

$$MAPE = \frac{1}{N} \sum_{k=1}^N \left| \frac{F_s - F_f}{F_s} \right| \times 100\% \quad (12)$$

平均绝对误差 (Mean Absolute Error, MAE) 公式(13):

$$MAE = \frac{1}{N} \sum_{k=1}^N F_f - F_s \quad (13)$$

均方根误差 (Root Mean Square Error, RMSE)

公式(14):

$$RMSE = \sqrt{\frac{1}{N} + \sum_{k=1}^N (F_f - F_s)^2} \quad (14)$$

其中, N 表示测试样本数目; F_f 表示模型预测值; F_s 表示真实值。

5.3 实验仿真

为了验证本文提出改进 PSO 优化的 RBF 火灾预测系统的有效性,将本文提出的改进 PSO-RBF 模型与 PSO-RBF 模型、RBF 模型进行对比实验,在同一测试集下 3 种模型的神经网络部分样本数据的测试结果和仿真判断结果对比见表 1, RBF、PSO-RBF、改进 PSO-RBF 在同一数据集预测的各项性能指标见表 2。

表 1 3 种算法的神经网络部分样本数据的测试结果和仿真判断结果对比表

Table 1 Comparison of test results and simulation judgment results of partial sample data of the three algorithms

序号	原始数据	RBF 预测	PSO-RBF 预测	改进 PSO-RBF 预测
1	0.53	0.51	0.52	0.53
2	0.47	0.48	0.46	0.46
3	0.24	0.25	0.28	0.24
4	0	0.21	0.15	0.11
5	0.88	0.83	0.84	0.89

表 2 各模型的评价指标对比

Table 2 Comparison of evaluation indicators of each model

模型	MAPE	MAE	RMSE
RBF	0.190	0.054	0.006 3
PSO-RBF	0.176	0.047	0.003 8
改进 PSO-RBF	0.169	0.031	0.002 1

由表 1 可知,本文改进 PSO-RBF 模型的预测偏差远小于 PSO-RBF 模型、RBF 模型,且精度远高于两个模型。由表 2 可知,改进 PSO-RBF 模型的误差趋于 0,误差更小,精度更高;并且在算法性能上,改进 PSO-RBF 的模型较 RBF 模型提高了 6.0%,较 PSO-RBF 模型提高了 2.4%,预测精度高。

改进 PSO-RBF 模型误差曲线图如图 4 所示,纵轴表示误差平方根,横轴表示迭代的次数,可以看出 PSO-RBF 模型的预测误差低、精准,达到了预期的效果。

3 种算法预测对比如图 5 所示,可见改进 PSO-RBF 模型仿真图的预测曲线比其他两种算法更接近与原始的数据曲线,明显优于其他两种模型,在预测上更加精确。




图 4 改进 PSO-RBF 模型误差曲线图

Fig. 4 Error curve of the improved PSO-RBF model

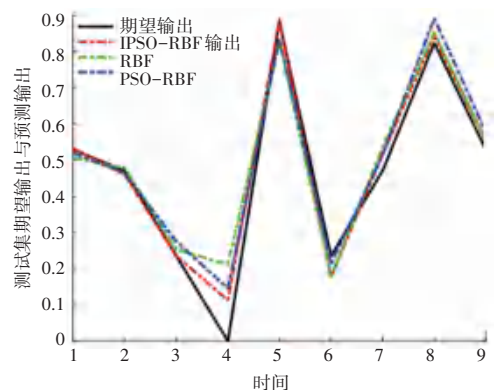


图 5 3 种算法预测对比图

Fig. 5 Prediction comparison of the three algorithms

本文利用 matlab 的模糊逻辑工具箱建立模糊逻辑推理系统。将本文改进的 PSO-RBF 模型预测的明火概率、阴燃火概率、无火概率和持续时间作为输入信号,对输入信号模糊集合建立 Sigmoid 型隶属函数,对输出信号模糊集合构建三角形函数;输入模糊推理规则并生成相应的规则图,模糊推理规则图可以通过改变输入量得到输出值。模糊逻辑控制算法对本文改进的 PSO-RBF 模型输出的测试数据进行仿真结果见表 3。

表 3 模糊逻辑控制算法对 IPSO-RBF 输出的测试数据进行仿真

Table 3 Simulation of IPSO-RBF output test data by fuzzy logic control algorithm

序号	明火预测	阴燃预测	无火预测	持续时间	输出
1	0.53	0.37	0.36	0.98	0.64
2	0.46	0.52	0.21	0.98	0.79
3	0.24	0.79	0.19	0.98	0.54
4	0.11	0.34	0.61	0.98	0.27
5	0.89	0.15	0.03	0.15	0.63

由表 3 可以看出,模糊逻辑推理系统根据不同的火情概率分析 3 种着火状态的联系,做出相应的判断。本文将 [0-1] 的输出分为 4 个层次,对决策

层得到的输出结果做出判断,如式(15)所示:

$$\text{判断结果} = \begin{cases} \text{无警,} & \text{output} \leq 0.25 \\ \text{警戒,} & 0.25 \leq \text{output} \leq 0.50 \\ \text{报警,} & 0.50 \leq \text{output} \leq 0.75 \\ \text{严重报警,} & \text{output} \geq 0.75 \end{cases} \quad (15)$$

6 结束语

本文针对传统火灾检测方式的不足,研究了将神经网络与模糊推理先结合应用于火灾检测的方法,改进了粒子群优化算法的不足点,提出改进的自适应权重动态调整的粒子群优化算法,对改进 PSO-RBF、PSO-RBF、RBF 3 种算法的优化结果进行了比较,结果表明本文提出的改进 PSO-RBF 算法全局收敛性较好、寻优效率较高,一定程度上解决了全局寻优与收敛速度之间的矛盾。模糊推理根据不同情况数据判断出火情等级,帮助更好的判断火情情况。

参考文献

- [1] OKAYAMA Y. A primitive study of a fire detection method controlled by artificial neural net [J]. *Fire Safety Journal*, 1991, 17(6): 535-553.
- [2] NAKANISHI S. In telligent fire warning system using fuzzy technology [C]//Proceedings of 10th Internationale Konferenz über Automatische Brandentdeckung. Duisburg, Germany: IEEE, 1995: 203-212.
- [3] 李军,张志东,乔元健,等. 基于自适应集成神经网络的火灾预测方法[J]. *消防科学与技术*, 2020, 39(12): 1727-1731.
- [4] 许春芳,乔元健,李军. 基于 LSTM 和 RBF-BP 深度学习模型的火灾预测方法[J]. *齐鲁工业大学学报*, 2020, 34(3): 53-59.
- [5] 刘永立,刘晓伟,王海涛. 基于 LSTM 神经网络的煤矿火灾预测[J]. *黑龙江科技大学学报*, 2023, 33(1): 1-5.
- [6] 韩丙光,赵子源,刘建,等. 基于多传感器信息融合的电缆火灾预警建模与仿真[J]. *电子设计工程*, 2022, 30(10): 150-154.
- [7] 张冉,吴云韬,于宝成,等. 基于多传感器数据融合的机房火灾检测算法[J]. *武汉工程大学学报*, 2024, 46(1): 79-84. DOI: 10.19843/j.cnki.CN42-1779/TQ.202303028
- [8] 朱菊香,谷卫,罗丹悦,等. 基于 PSO 优化 BP 神经网络的多传感器数据融合[J]. *中国测试*, 2022, 48(8): 94-100.
- [9] 孙苗,张雪凡,林阳,等. 基于 PSO-Nadam-BP 神经网络的多传感器火灾检测算法[J]. *工业控制计算机*, 2022, 35(6): 1-3, 7.
- [10] 王坤,侯树贤. 基于改进 PSO-LSTM 的 APU 排气温度预测研究[J]. *计算机仿真*, 2022, 39(11): 32-37.
- [11] 李卫高,赵望达. 神经网络与模糊逻辑在火灾探测报警系统中的应用[J]. *湖南文理学院学报(自然科学版)*, 2018, 30(2): 39-43, 62.
- [12] 赵月爱,秦佳宁. 基于 TensorFlow 的 LSTM 神经网络智能电气火灾预测研究[J]. *太原师范学院学报(自然科学版)*, 2019, 18(2): 44-48.
- [13] 黄翰鹏,李柏林,欧阳,等. 融合模糊神经网络与时序模型的火灾预警算法[J]. *计算机工程与设计*, 2020, 41(6): 1639-1644.
- [14] 田东平,赵天绪. 基于 Sigmoid 惯性权值的自适应粒子群优化算法[J]. *计算机应用*, 2008, 28(12): 3058-3061.
- [15] 刘伟,周育人. 一种改进惯性权重的 PSO 算法[J]. *计算机工程与应用*, 2009, 45(7): 46-48.
- [16] 丁承君,张井超,何乃晨. 基于 WPSO-KELM 的火灾预警模型设计[J]. *计算机仿真*, 2018, 35(2): 310-313, 353.
- [17] 刘洋,张鸿,徐娟,等. 改进 PSO 的 SVM 回归模型及在气温预测中的应用[J]. *计算机系统应用*, 2023, 32(9): 203-210.
- [18] HAN Huihui, WANG Jian, CHEN Sen, et al. Product quality prediction based on RBF optimized by firefly algorithm [J]. *Journal of Systems Engineering and Electronics*, 2024, 35(1): 105-117.
- [19] SHI Y, EBERHART R C. A modified particle swarm optimizer [C]//Proceedings of the 1999 Evolutionary Computation. IEEE, 1998: 69-73.