文章编号:1674-2869(2024)01-0079-06

基于多传感器数据融合的机房火灾检测算法

张 冉[1,2],吴云韬*[1,2],于宝成[1,2],徐文霞[1,2]
1. 智能机器人湖北省重点实验室(武汉工程大学),湖北 武汉 430205;
2. 武汉工程大学计算机科学与工程学院,湖北 武汉 430205

摘 要:针对机房传统单传感器报警系统存在漏报率高、准确率低等问题,提出了一种基于多传感器数据融合的机房火灾检测算法。该算法首先采用寻优能力强的麻雀搜索算法(SSA)优化极限学习机(ELM)的预测精度和准确度。其次通过SSA-ELM算法模型对机房内多传感器采集的温度、烟雾浓度、CO浓度进行特征层数据融合,输出各火情概率。最后利用模糊推理将输出的各火情概率和火灾持续时间在决策层中进行特征融合,决策出火情警报等级。仿真实验表明:本文算法能根据多传感器数据融合的结果并结合不同危险等级区域给出合理的警报决策,极大提高了机房火灾检测的灵活性和准确性。

关键词:火灾检测;SSA-ELM;多传感器;模糊推理
中图分类号:TN911 **文献标识码**:A **DOI**:10.19843/j.cnki.CN42-1779/TQ.202303028

Fire detection algorithm in computer rooms based on multi-sensor data fusion

ZHANG Ran[1,2], *WU Yuntao*[*1,2], *YU Baocheng*[1,2], *XU Wenxia*[1,2]
1. Hubei Key Laboratory of Intelligent Robot (Wuhan Institute of Technology), Wuhan 430205, China;
2. School of Computer Science & Engineering, Wuhan Institute of Technology, Wuhan 430205, China

Abstract: Aiming at the problems of high leakage rate and low accuracy of traditional single-sensor alarm system in computer rooms, we proposed a fire detection algorithm for computer room based on multi-sensor data fusion. Firstly, the algorithm optimizes the prediction accuracy and precision of the extreme learning machine (ELM) using the sparrow search algorithm (SSA) with high optimization seeking ability. Secondly, the feature layer data fusion of temperature, smoke concentration, and CO concentration collected by multiple sensors in an engine room was performed through the SSA-ELM algorithm model to output the probability of each fire condition. Finally, the features of output probability and duration of each fire were fused in the decision layer using fuzzy reasoning to decide the fire alarm level. Simulation experiments show that the algorithm can give a reasonable alarm decision based on the results of multi-sensor data fusion and combined with different hazardous areas, which greatly improves the flexibility and accuracy of fire detection in computer rooms.

Keywords: fire detection; SSA-ELM; multi-sensor; fuzzy reasoning

机房作为数据中心,各领域对其环境稳定性的要求日益提高,若不及时处理由设备故障引起的火灾,将会导致火势变大,给机房带来巨大损失,为此,在火灾发生初期进行准确识别并给出相应警报预警,对无人值守机房的安全维护尤为重要。在火灾发生初期,周围环境中的气体、温度都

收稿日期:2023-03-20
基金项目:湖北省重点研发计划项目(NO.2022BAA052);湖北三峡实验室开放基金(SC215001)
作者简介:张 冉,硕士研究生。Email:1451649887@qq.com
***通信作者**:吴云韬,博士,教授。Email:ytwu@wit.edu.cn
引文格式: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.

会发生相应变化，并且参数相互关联，机房传统的检测通过单一参量变化无法确定火灾是否发生，情况复杂时，易发生误报、漏报情况。因此，学者们的研究热点逐渐集中于基于多传感器的火灾检测。郑皓天等[1]通过遗传算法对误差逆传播(back propagation，BP)神经网络进行优化，提出了基于3种不同特征参量的火灾识别算法。苏醒等[2]利用复合数字滤波法以及模糊推理技术，并结合多传感器数据融合技术，实现了对火灾的预测。Zervas等[3]通过多传感器数据融合技术研究火灾早期情况，并通过参考温度、湿度和视觉传感器覆盖的区域等特征，结合Dempster/Shafer(D-S)证据理论推断火灾发生可能性。Liang等[4]通过BP神经网络对温度、CO浓度、烟雾浓度进行融合，实现了火灾的早期预警。

上述火灾探测方法不同，因此适应的对象和范围也有差异，人工神经网络(如BP神经网络)具有自适应性等优点，但需要较大的训练样本，训练时间比较长[5]。支持向量机(support vector machine，SVM)对解决小样本有着特殊优势，算法较简单，但需要设置大量参数，不合理的参数设置会使算法性能变得很糟糕[6]，且参数的设置对算法的精确度有较大影响[7]。由于极限学习机(extreme learning machine，ELM)泛化能力强，且学习速率快[8]，为此针对机房火灾检测，本文采用麻雀搜索算法(sparrow search algorithm，SSA)优化ELM并结合模糊推理的数据融合算法，将环境特征(如温度、烟雾浓度、CO浓度)与火灾持续时间、设备保护等级等信息进行数据融合，最终决策出火灾警报等级，实现对机房火灾探测与维护。

1 多传感器数据融合原理及设计

为实现对火灾更准确、快速地探测，本文采用多传感器数据融合技术，结合环境特征及其他特征参数进行综合决策，火灾探测融合算法结构主要流程为：通过对火灾现场中传感器采集到的信息数据进行特征融合，并结合火灾现场的其他参数信息进行决策层综合分析，最终得到可以判断火灾是否发生的预警信息。

信息层选用3种传感器(CO传感器、温度传感器、烟雾传感器)完成对火灾的探测，并对信息进行预处理，特征层对特征参量进行特征数据提取，并对提取的数据进行特征融合，分析出火灾发生概率，决策层将火灾发生概率与火灾现场的其他多特征参数信息进行融合判断分析，其中多特征参数信息包括火灾延续时间、不同气候(温度和湿度等环境影响)影响下的各类不同设备保护等级，最终决策出火灾是否发生。

2 多传感器数据融合火灾检测算法

2.1 信息层实现

本文采用多种传感器对环境信息进行收集，用来判断火灾的发生，由于不同类型的传感器收集信息的特征参量范围、大小都不相同，需进行归一化处理，归一化公式见式(1)。

$$A_c = \frac{X_c - X_{\min}}{X_{\max} - X_{\min}} \tag{1}$$

对于式(1)，c表示传感器采集CO浓度、烟雾浓度、温度等数据的参量个数，A_c表示输入c个参量后归一化后的值，X_c表示由实验数据确定的c个参量的输入值，$X_{\min}$和$X_{\max}$分别为选取参量的最小输入值和最大输入值。

2.2 特征层数据融合处理

2.2.1 极限学习机 ELM是由高滢等[9]提出的一种新型神经网络算法，ELM与传统神经网络相比，具有参数设置更少、学习效率更高、泛化能力更强等优点。ELM的网络结构由输入层、隐含层、输出层3部分组成，是一种新式的前馈神经网络，通过对隐含层神经元数目进行设定，利用解方程的方法得到输出权值。ELM网络结构如图1所示。图1中X_1~X_3为输入神经元节点；W_{ij}为第i个神经元与隐含层神经元j之间的连接权值；b_{jk}为隐含层神经元j与输出层第k个神经元之间的连接权值；Y_1~Y_3为模型输出。

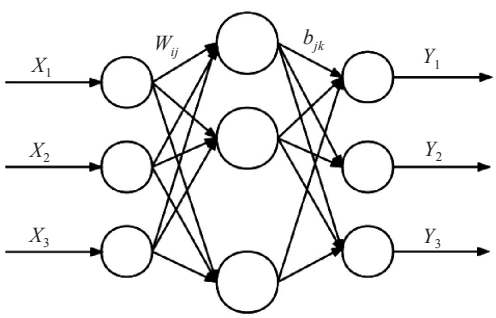

图1 ELM网络结构

Fig. 1 ELM network structure

本次ELM网络结构模型中，X、Y分别为输入值和输出值，其数学模型如式(1-3)所示。

$$\boldsymbol{w} = \begin{bmatrix} w_{11} & \cdots & w_{1n} \\ \vdots & & \vdots \\ w_{l1} & \cdots & w_{ln} \end{bmatrix} \tag{1}$$

式中：$\boldsymbol{w}$为输入层和隐含层之间的连接权值矩阵，l为隐含层中的神经元数目，n为输入层神经元数，w_{ln}为输入层和隐含层之间的l层n列的连接权值。

$$\boldsymbol{b}=\begin{bmatrix} b_{11} & \cdots & b_{1m} \\ \vdots & & \vdots \\ b_{l1} & \cdots & b_{lm} \end{bmatrix} \tag{2}$$

式中：$\boldsymbol{b}$为隐含层和输出层之间的连接权值矩阵，m为输出层神经元数，b_{lm}为隐含层和输出层之间的l层m列的连接权值。

$$\boldsymbol{a}=\begin{bmatrix} a_1 & a_2 & \cdots & a_l \end{bmatrix}^{\mathrm{T}} \tag{3}$$

式中：$\boldsymbol{a}$为隐含层神经元阈值矩阵，其中a_l表示隐含层中第l个神经元的阈值。

ELM网络输出模型为：

$$\boldsymbol{T}=\begin{bmatrix} t_1 & t_2 & \cdots & t_m \end{bmatrix}$$

$$\boldsymbol{t}_j=\begin{bmatrix} t_{1j} \\ t_{2j} \\ \vdots \\ t_{mj} \end{bmatrix}=\begin{bmatrix} \sum_{i=1}^{l} b_{i1}g\left(w_i x_j+a_i\right) \\ \sum_{i=1}^{l} b_{i2}g\left(w_i x_j+a_i\right) \\ \vdots \\ \sum_{i=1}^{l} b_{im}g\left(w_i x_j+a_i\right) \end{bmatrix} \tag{4}$$

式中：$\boldsymbol{T}$为输出数据集，t_m表示第m个训练样本的网络输出值，$\boldsymbol{t}_j$为矩阵$\boldsymbol{T}$的列向量集合，t_{mj}表示第m个输出神经元对应于隐含层神经元j的输出值，b_{im}表示隐含层神经元j对输出神经元m的连接权值，$g(\cdot)$为隐含层神经元激励函数，x_j为隐含层神经元j的输入样本，w_i为隐含层神经元j对应输入样本x_j的权值，a_i为隐含层神经元j的阈值。

可将式(4)简写为$\boldsymbol{T}'=\boldsymbol{H}\boldsymbol{b}$，其中$\boldsymbol{T}'$为$\boldsymbol{T}$的转置矩阵，$\boldsymbol{H}$为隐含层输出矩阵，$\boldsymbol{H}$的表达式为：

$$\boldsymbol{H}=\begin{bmatrix} g\left(w_1 x_1+a_1\right) & \cdots & g\left(w_l x_1+a_l\right) \\ \vdots & & \vdots \\ g\left(w_1 x_Q+a_1\right) & \cdots & g\left(w_l x_Q+a_l\right) \end{bmatrix} \tag{5}$$

式中：w_l表示隐含层第l个神经元的权值，x_Q表示输入的第Q个数据样本。

2.2.2　*麻雀搜索算法*　麻雀搜索算法[10]是一种新型的群智能优化算法，主要受麻雀的觅食和反哺食等行为的启发，具有寻优性强、收敛速度快等特点，SSA算法中，麻雀种群被分为发现者和加入者，麻雀搜索算法首先需对麻雀种群与适应度进行初始化，种群采用随机生成位置的方法初始化麻雀种群的个体位置，数学表达式如式(6)所示。

$$\boldsymbol{X}=\begin{bmatrix} x_{11} & \cdots & x_{1d} \\ \vdots & & \vdots \\ x_{s1} & \cdots & x_{sd} \end{bmatrix} \tag{6}$$

式中：s为麻雀数量，d为要优化的变量维度，x_{sd}表示第s个麻雀对于第d个参数的取值，具有较好适应度值的麻雀在觅食过程中，需对食物进行迭代搜索，其位置变化采用式(7)更新：

$$X_{(t+1),qr}=\begin{cases} X_{t,qr}\cdot\exp\left(-\dfrac{q}{a\cdot t_{\max}}\right), & R_2<F \\ X_{t,qr}+Q\cdot\boldsymbol{L}, & R_2\geqslant F \end{cases} \tag{7}$$

式中：t为当前迭代的次数；$X_{t,qr}$和$X_{(t+1),qr}$分别表示第t次和第t+1次迭代中，具有较好适应度值的第q只麻雀在维度r上的位置；$t_{\max}$为本次计算中最大的迭代次数；R_2为预警值，$R_2\in[0,1]$；F为安全值，$F\in[0.5,1]$；Q为随机数，服从正态分布；a表示随机数，$a\in(0,1)$；$\boldsymbol{L}$为一个1×d的矩阵，其中所有元素值都为1；q=1，2，3，…，s；r=1，2，3，…，d。

当$R_2<F$，表明此时并没有捕食者，发现者进一步扩大搜索；当$R_2\geqslant F$，表明发现捕食者，所有麻雀需要飞到其他安全区域，加入者位置更新公式如式(8)所示：

$$X_{(t+1),qr}=\begin{cases} Q\cdot\exp\left(\dfrac{X_{t,\mathrm{w}}-X_{t,qr}}{q^2}\right), & q>\dfrac{s}{2} \\ X_{(t+1),\mathrm{p}}+\left|X_{t,qr}-X_{(t+1),\mathrm{p}}\right|\cdot\boldsymbol{A}^{+}\cdot\boldsymbol{L}, & q\leqslant\dfrac{s}{2} \end{cases} \tag{8}$$

式中：$X_{(t+1),\mathrm{p}}$为第t+1次迭代后发现者的最优位置，$X_{t,\mathrm{w}}$为第t次迭代全局最差位置，$\boldsymbol{A}$为1×d矩阵，每个元素随机选取1或-1，$\boldsymbol{A}^{+}=\boldsymbol{A}^{\mathrm{T}}\left(\boldsymbol{A}\boldsymbol{A}^{\mathrm{T}}\right)^{-1}$，当$q>s/2$，说明适应度较低的第$q$个加入者未得到食物，需飞往其他地方觅食。

一般情况，假设这些意识到危险的麻雀占总数量的10%到20%，它们的初始位置在种群中随机产生，其数学模型如式(9)所示：

$$X_{(t+1),qr}=\begin{cases} X_{t,\mathrm{b}}+B\cdot\left|X_{t,qr}-X_{t,\mathrm{b}}\right|, & f_q>f_{\mathrm{g}} \\ X_{t,qr}+K\cdot\left(\dfrac{X_{t,qr}-X_{t,\mathrm{w}}}{f_q-f_{\mathrm{w}}+\varepsilon}\right), & f_q=f_{\mathrm{g}} \end{cases} \tag{9}$$

式中：$X_{t,\mathrm{b}}$为第t次迭代后全局最优位置；B为步长控制参数，是一个服从均值0，方差1的正态分布的随机数；K为随机数，$K\in[-1,1]$；ε为常数；f_q为麻雀个体的适应度值；f_{g}和f_{w}分别为全局最好和最差适应度值。

当$f_q>f_{\mathrm{g}}$，表明该麻雀处于全局危险位置，大

概率受到攻击；当$f_q = f_g$，表明该麻雀意识到自身大概率被捕食的危险，需尽快移动并与种群汇合。

2.2.3 基于SSA-ELM特征层数据融合模型 算法模型步骤如下：

(1)数据进行归一化，并分配训练集和数据集。

(2)对麻雀优化算法的迭代次数、种群、发现者以及加入者比例进行初始化。

(3)构建极限学习机网络结构，设置网络参数。

(4)计算麻雀群体的适应度值，并找到最佳适应度值f_g和最差适应度值f_w。

(5)根据式(7-9)更新发现者、加入者及意识到危险麻雀的位置，若更新后的位置优于先前的，则替换它。

(6)进行迭代，不断更新麻雀位置，达到t_{max}时停止，迭代过程中适应度最低的麻雀为最优解。

(7)迭代完成，将得到的最优权值和阈值赋予极限学习机，构建SSA-ELM模型。

2.3 决策层数据融合模型

2.3.1 决策层模型构建 决策层主要对各决策因子之间的关系进行分析，并输出分析结果。为更好判断火灾发生概率对火灾是否发生的影响，在决策层采用模糊推理技术[11]进行融合，本文引入4种决策因子(明火概率、阴燃火概率、火灾延续时间、设备危险等级)。

火灾延续时间T由式(10)判定。

$$T(h) = \left[T(h+1)+1\right] \times V\left[Y_i(x) - T_d\right] \quad (10)$$

式中，h表示当前时间段，h+1表示下一个时间段，$Y_i(x)$表示从特征层输出的明火、阴燃火概率，$V(\cdot)$为阶跃函数，T_d为将要报警的阈值。

本文对机房火灾进行预测，由不同设备所处的周围环境决定其危险等级，比如在机房门廊、过道等边缘位置，设备危险等级可表示为低；在不间断电源(uninterruptible power supply，UPS)、电闸等设备所处的机房核心位置，其危险等级应表示为高，面对不同位置的设备根据实际情况确定其危险等级。

决策层模型如图2所示，该模型通过结合各决策因子，结合模糊化处理，决策出最终结果。

2.3.2 决策层信息融合 输入/输出量的模糊化：在决策层信息模糊化处理中，将输入量(明火概率、阴燃火概率、火灾延续时间、设备危险等级)进行模糊化处理，模糊集划分为正小(PS)、正中(PM)、正大(PH)，隶属函数采用三角函数。输出量模糊集划分为无(PN)、小(PS)、中(PM)、大(PB)，隶属函数采用三角函数。

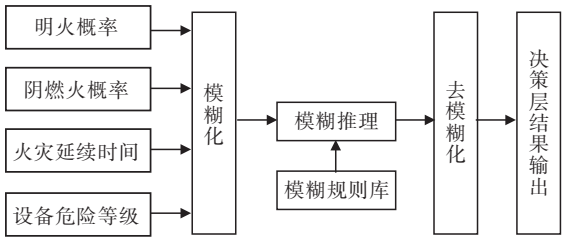

图2 决策层融合模型流程

Fig. 2 Decision level fusion model process

模糊逻辑推理：本文通过实际情况对火灾进行辨识，从而建立模糊规则。根据马达尼法推理规则推断，模糊规则库的数量可根据输入量之间的关系来确定，本文在系统中有4个输入量，每个输入量的模糊等级设定为3，即在模糊规则库中建立了3×3×3×3=81条模糊规则，其模糊规则形式为“IF(火灾概率 is 正小)and(火灾延续时间 is 正小)and(设备危险等级 is 正小)then(决策结果输出 is 正小)”。

去模糊化：根据模糊规则输出的结果也是模糊的，需进行去模糊化操作。本文采用面积重心法去模糊化[12]，公式如式(11)所示。

$$U = \frac{\int_z u(z)\, z\mathrm{d}z}{\int_z u(z)\,\mathrm{d}z} \quad (11)$$

式中，U表示去模糊化后得到的输出值，用来进一步分析，$u(z)$为输出的隶属函数，z为模糊规则的输出变量。

对去模糊化后得到的U进行多级别判断，当U<0.25时，判定为无火情；当0.25≤U<0.5时，判定为警戒；当0.5≤U<0.75时，判定为报警；当U≥0.75时，判定为严重报警。

3 火灾检测算法仿真分析

若机房发生火灾，其周围主要参数温度、CO浓度、烟雾浓度会发生明显变化，因此，采用标准试验火数据进行仿真，分别对特征层、决策层进行算法仿真分析。麻雀搜索算法参数如下：麻雀规模为30，最大迭代次数为50，发现者比例占种群总数70%，意识到危险的麻雀占种群总数20%，安全阈值F为0.6。ELM算法设置如下：隐含层个数为10，训练次数为1 000，学习速率为0.01，激活函数为Sigmod。BP算法参数如下：训练次数为1 000，学习速率为0.01，最大迭代次数为50。

3.1 特征层SSA-ELM模型仿真分析

本文从中国标准明火SH4、标准阴燃火SH1、

厨房环境下标准干扰信号选取实验数据 40 组[13]，选取 30 组作为训练样本，10 组作为测试样本，进行仿真实验分析。

图 3 为本算法 SSA-ELM 模型的收敛过程，经过第 6 次迭代后模型达到最优，可知本模型具有较高的收敛速度和精度。图 4(a)给出了各算法模型的预测结果，可知，经过 SSA 算法优化的 ELM 模型预测精度明显高于 ELM 模型，有着较强的泛化能力，通过 SSA 算法对 ELM 模型的权值和阈值进行优化，性能有较大提升，即 SSA 算法有较强寻优能力。

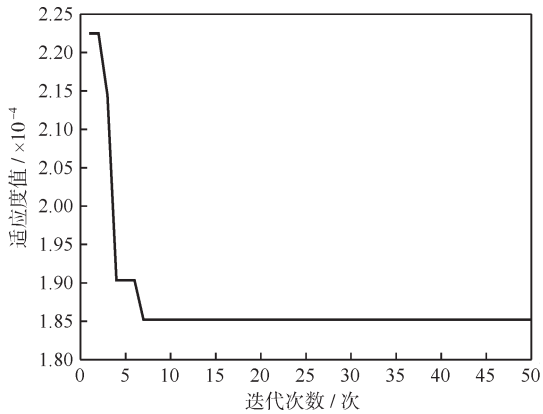

图 3　SSA-ELM 适应度曲线

Fig. 3　SSA-ELM fitness curve

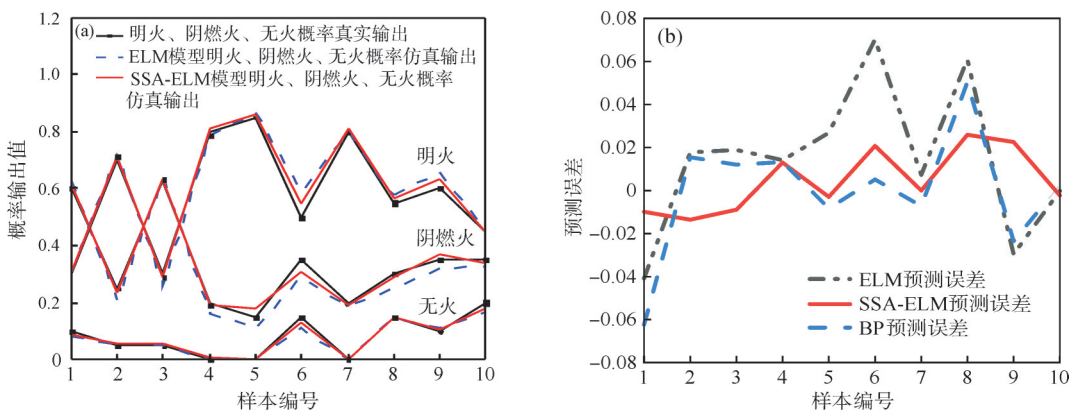

图 4　仿真预测结果：(a) 火灾概率仿真，(b) 测试集预测误差

Fig. 4　Simulation prediction results: (a) fire probability simulation , (b) test set prediction error

模型经过训练，各模型误差曲线如图 4(b)所示，可以明显看出 SSA-ELM 模型的误差曲线较为平稳，其他模型误差起伏较大。可见，SSA-ELM 模型检测精度较高，可以有效降低火灾探测的误差率，提高火灾预测的准确率。

为进一步评价算法检测结果的优劣性，选取平均绝对误差(mean absolute error，MAE)、均方误差(mean-square error，MSE)和均方根误差(root mean square error，RMSE)作为预测评价指标，将优化后的算法重复执行 30 次后，记录相关指标如表 1 所示。

表 1　性能对比

Tab. 1　Performance comparison

算法模型	MAE	MSE	RMSE
BP	0.029 341	0.038 261	0.042 351
ELM	0.024 416	0.032 153	0.029 843
SSA-ELM	0.013 423	0.011 235	0.018 732

经对比发现，在本文采用的 MAE、MSE、RMSE 3 个指标上，SSA-ELM 算法的预测精度最高。可知，通过 SSA 优化 ELM 权值和阈值的火灾检测算法的预测精度更高，大大提高了火灾检测的准确率。

3.2　决策层模糊推理仿真分析

由特征层仿真分析可知，SSA-ELM 模型可准确识别火灾发生的概率，决策层将多特征参数信息进行融合，更直接地给出警报决策。并且将特征层明火、阴燃火概率仿真结果与火灾延续时间、设备危险等级等信息输入决策层，通过仿真输出报警决策结果。

决策层仿真采用 30 组经特征层输出的明火、阴燃火概率，通过决策层融合输出，验证决策层有效性。仿真结果如图 5 所示。

由图 5 可以看出，通过对明火、阴燃火概率的输出，结合附加信息的决策层可以做出准确的决策输出，对机房内不同危险等级的设备，可以做到明显的识别，满足对机房火灾的准确预警。

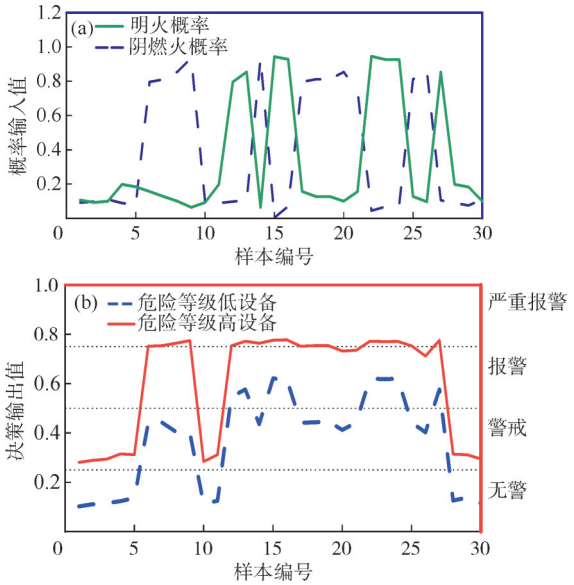

图5 决策层仿真结果：(a) 概率输入，(b) 决策输出

Fig. 5 Decision layer simulation result: (a) probability input, (b) decision output

4 结 论

针对传统机房火灾检测的不足，本文采用了基于多传感器数据融合的火灾检测算法，在特征层中提出了一种基于SSA算法优化ELM权值和阈值的火灾探测模型，经研究发现，模型的泛化能力和检测精度提升明显，可有效提高火灾检测的准确率；在决策层中采用模糊推理技术，结合机房环境多特征信息，根据设备的危险程度灵活给出警报信息，分析不同的警报等级给出准确的火灾识别结果，极大提高了火灾检测系统的准确性和灵活性。

参考文献

[1] 郑皓天，朱俊奇，贾荣田. GA优化BP神经网络在多参量火灾探测中的应用[J]. 消防科学与技术，2021，40(5)：725-729.

[2] 苏醒，李鸿，姜俊彤. 基于CAN和模糊推理的一款地铁列车火灾报警系统的设计与仿真研究[J]. 计算机应用与软件，2021，38(6)：94-97.

[3] ZERVAS E, MPIMPOUDIS A, ANAGNOSTOPOULOS C, et al. Multisensor data fusion for fire detection [J]. Information Fusion, 2011, 12(3): 150-159.

[4] LIANG Y H, TIAN W M. Multi-sensor fusion approach for fire alarm using BP neural network [C]//2016 International Conference on Intelligent Networking and Collaborative Systems (INCOS). Piscataway: IEEE, 2016: 99-102.

[5] 严巡，王长权，袁肖肖，等. 利用BP人工神经网络预测盐水中CO_2的溶解度[J]. 中国科技论文，2017，12(24)：2831-2834.

[6] 何经纬，刘黎志，彭贝，等. 基于Spark并行SVM参数寻优算法的研究[J]. 武汉工程大学学报，2019，41(3)：283-289.

[7] 赵云涛，王佳，周小平. 基于支持向量机的公共建筑火灾风险评估[J]. 建筑科学，2015，31(3)：98-101，109.

[8] 杨锡运，关文渊，刘玉奇，等. 基于粒子群优化的核极限学习机模型的风电功率区间预测方法[J]. 中国电机工程学报，2015，35(增刊)：146-153.

[9] 高滢，王芃，薛友，等. 计及需求侧管理的电-气集成能源系统协同规划[J]. 电力系统自动化，2018，42(13)：3-11.

[10] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems science & Control engineering, 2020, 8(1): 22-34.

[11] 冯俊宗，何光层，代航，等. 基于数据融合技术的无人值守变电站火灾探测算法研究[J]. 消防科学与技术，2022，41(9)：1281-1286.

[12] 钱伟，何志祥，张德银. 基于模糊神经网络的火灾传感器特征参数融合算法[J]. 传感技术学报，2017，30(12)：1906-1911.

[13] 张晶. 多传感器信息融合在火灾探测中的应用研究[D]. 广州：广东工业大学，2003.

本文编辑：霍淑利