

基于改进型 T-S 模糊 RBF 神经网络的红外火焰探测器识别算法

冯宏伟¹, 刘媛媛^{2,3}, 温子腾³, 谭勇³

(1. 无锡职业技术学院, 江苏 无锡 214121; 2. 无锡科技职业学院, 江苏 无锡 214028;

3. 江南大学 物联网工程学院, 江苏 无锡 214122)

摘要: 针对三波段红外火焰探测器中可能出现的单一非火焰波段通道的数据丢失、失真、饱和 3 种对火焰特征数据的强干扰情况, 本文提出了一种改进型 T-S(Takagi-Sugeno, 高木-关野)模型 RBF(Radial Basis Function, 径向基函数)神经网络的火焰识别的鲁棒性融合算法。该算法通过聚类算法确定模型需要的模糊规则数, 在模糊后件多项式中加入特征分量隶属度生成节点输出, 同时定义了加权模糊节点激活度和特征表征系数代替了原先模型的马氏距离(模糊规则适用度)。通过设计三波段火焰探测器并进行了常规及鲁棒性实验, 实验数据证实, 改进型模型在隐含层所需节点数、收敛速度、精度、泛化能力、鲁棒性上较传统 T-S 模型的 RBF 神经网络模型、GA(Genetic Algorithm, 遗传算法)-BP(Back Propagation, 反向传播)模型都有明显的提升。

关键词: 红外火焰探测器; 改进型 T-S; RBF 神经网络; 识别算法

中图分类号: TN215 文献标识码: A 文章编号: 1001-8891(2021)01-0037-07

Recognition Algorithm for an Infrared Flame Detector Based on an Improved Takagi-Sugeno Fuzzy Radial Basis Function Neural Network

FENG Hongwei¹, LIU Yuanyuan^{2,3}, WEN Ziteng³, TAN Yong³

(1. Wuxi Institute of Technology, Wuxi 214122, China; 2. Wuxi Professional College of Science and Technology, Wuxi 214028, China;

3. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China)

Abstract: To address the data loss, distortion, and saturation of a single non-flame channel that may occur in a three-band infrared flame detector, a robust fusion algorithm for flame recognition based on a radial basis function (RBF) neural network entailing an improved Takagi-Sugeno (T-S) model is proposed in this paper. In this algorithm, the number of fuzzy rules required by the model is determined by a clustering algorithm. The membership degree of the feature component is added to the subsequent fuzzy polynomial to generate node output, and the weighted fuzzy node activation degree and feature characterization coefficient are defined to replace the Markov distance (fuzzy rule applicability) of the original model. Through the design of a three-band flame detector and routine and robustness experiments, it is shown that the proposed model significantly improves the number of nodes, convergence speed, accuracy, generalization ability, and robustness as compared with those of the traditional T-S model RBF neural network and genetic algorithm-back propagation models.

Key words: infrared flame detector, improved T-S, RBF neural network, recognition algorithm

0 引言

火灾发生初期的阴燃阶段, 人们虽无法用肉眼观察识别, 但在火焰中却存在着多种波长的红外线紫外线^[1]。三波段红外火焰探测器就是利用了 3 个对红外线敏感的红外传感器, 对特定范围内的火灾红外辐射

波长进行探测。为确保探测器能够在高低温、高湿、震动等最苛刻的环境下, 具备对误报警极高的免疫力, 必需借助有效的检测算法将采集到的 3 个传感器数据进行优化处理^[2]。

虽然 T-S 型模糊推理具备运用少量的模糊规则可生成复杂的非线性函数的特点, 能够相对有效地解决

收稿日期: 2020-04-19; 修订日期: 2020-12-18.

作者简介: 冯宏伟(1982-), 男, 山东郓城, 硕士, 副教授/高工, 研究方向为智能仪器仪表的研发与设计。E-mail: fenghw@wxit.edu.cn.

基金项目: 国家自然科学基金项目(61374047)。

高维系统中的规则难题^[3]。可是，由于 T-S 型模糊模型推理出的结论参数是线性函数并非模糊数，这将无法从实际应用中的经验值和数据来直接利用，只能通过对其特定的算法训练来获取。然而，神经网络的出现解决了 T-S 模型参数难辨识的问题^[4]。RBF 神经网络拥有的局部响应特性，使其拥有网络训练速度快，不存在局部最优问题等优点^[5]。由于融合 T-S 模型的标准 RBF 神经网络隐含层接受区域的局部性，导致网络在测试中表现往往较差，即泛化能力不理想^[6]。

本文借助文献[7]中提及的一种 RBF 网络结构归一化的加强模型，和其提出的一种先对训练数据聚类产生模糊规则数及节点中心的方法，同时结合三波段红外火焰探测中可能出现的单一非火焰通道发生数据丢失、失真、饱和 3 种强干扰的情况，对融合 T-S 模型的 RBF 神经网络模型进行了以下改进：

1) 为了使模型具有较强的鲁棒性抵抗数据干扰，对模糊后件中模糊规则的输出的计算中加入了特征分量的隶属度，使得模型能够有效抑制特征分量的波动对于模型的影响。

2) 为了进一步提升模型的鲁棒性，对模型中所需的隐含层节点数目进行减少，将模糊前件中模糊规则适用度 (RBF 中马氏距离) 的生成公式修改为加权平均的形式生成加权模糊节点激活度，从而充分考虑到不同特征对于不同种类样本的表征程度不同。

3) 为了提升模型规则的解释性、模型泛化能力，根据不同种类样本中不同特征的离散程度不同确定加权模糊节点激活度中的特征表征系数 θ_j^i 的初值。

1 红外火焰探测器整体结构

本文选用三波段红外火焰探测器作为测试平台，其硬件结构主要由红外传感器检测模块、前置放大及信号采集模块、模数转换模块、微处理器模块和信号输出模块等构成。系统硬件结构如图 1 所示。




图 1 三波段火焰探测器结构框图

Fig.1 Structure diagram of three-band flame detector

传感器检测模块选用 3 个中心波长分别为 3.8 μm 、4.3 μm 和 5.0 μm 窄带带宽均为 150 nm 的红外热释电传感器。前置放大及信号采集模块主要由微信号预处理电路、运算放大电路和滤波电路组成。模数转换模块选用内置可编程增益调节 (Programmable Gain

Amplifier, PGA) 的 18 位模数转换芯片 ADS8694，可根据信号的强弱自适应调节增益以确保采集信号的完整。微处理器模块是以 STM32F429 为核心构建的电路，为火焰识别算法得以实现搭建了测试平台，其信号输出模块可与远控端的上位机连接，收发与上位机的监控、配置等相关参数，可组建一套完整的火灾报警集总控制系统。

2 改进型 T-S 模糊 RBF 神经网络

本文拟采用的改进型融合 T-S 模型的 RBF 模糊神经网络结构由前件网络和后件网络两部分组成，其结构图如图 2 所示。




图 2 改进型融合 T-S 模型的 RBF 模糊神经网络结构图

Fig.2 Structural diagram of RBF fuzzy neural network based on improved T-S model

2.1 前件网络

模型的前件网络包含 3 个部分，分别是输入层、隐含层、归一化层。

1) 输入层

输入样本 $X = [x_1, \dots, x_i, \dots, x_n]$ 其中 n 是输入特征的维数，本系统中 $n=12$ 。

2) 隐含层

首先对参与训练的样本数据采用 k-means 聚类算法将数据聚为 h 类，即隐含层也称为模糊规则层含有 h 个节点，每个节点均具有 n 个高斯隶属度函数。之后将这 h 类样本的样本聚类中心 c_j^i 作为隐含层各高斯隶属度函数的初始中心参数。

$$\mu_j^i = \exp\left(-\frac{(x_i - c_j^i)^2}{2b_j^i}\right) \quad (1)$$

公式(1)的形式为高斯隶属度函数, 其中, b_j^i 代表第 i 个特征分量中第 j 个模糊子集的隶属度函数宽度。在 k -means 产生的 h 类样本集中, 不同特征对于不同种类的样本的表征程度是有较大差异的^[7]。

基于上述思想将马氏距离产生激活强度的做法改为一种加权平均算子:

$$w_j = (\theta_j^1 \mu_j^1 + \theta_j^2 \mu_j^2 + \dots + \theta_j^n \mu_j^n) / n \quad (2)$$

将 w_j 定义为加权模糊节点激活度, 式(2)中的 θ_j^i 定义为特征表征系数。 θ_j^i 初始值的设定, 是由该聚类结果中第 j 类第 i 维特征数据相对于其它特征数据的相对离散程度而确定的。具体操作如下:

①将所有样本数据中的特征归一化处理;

②将属于聚类结果中第 j 类的所有 k 个样本取出计算数据中不同特征的标准差, 如下:

$$\text{ave}_j^i = \sum_{t=1}^k X_j^i(t) / k \quad (3)$$

$$\text{std}_j^i = \sqrt{\sum_{t=1}^k (X_j^i(t) - \text{ave}_j^i)^2} \quad (4)$$

式中: ave_j^i 表示该聚类结果中第 j 类数据第 i 维特征的均值; $X_j^i(t)$ 表示该聚类结果中第 j 类数据中的第 t 个样本的第 i 维特征。式(4)中, std_j^i 表示该聚类结果中第 j 类数据第 i 维特征的标准差。

③通过计算得到的聚类结果中第 j 类数据不同特征分量的标准差来确定 θ_j^i 的初值:

$$\theta_j^i = \frac{n}{\text{std}_j^i} / \sum_{i=1}^n \frac{1}{\text{std}_j^i} \quad (5)$$

3) 归一化层

$$w_0 = W_0 / n \quad (W_0 \text{ 为任何预定的正值}) \quad (6)$$

$$\bar{w}_j = \frac{w_j}{\sum_{j=0}^h w_j} = \frac{\sum_{i=1}^n \frac{\theta_j^i}{n} \exp\left(-\frac{(x_i - c_j^i)^2}{2(b_j^i)^2}\right)}{W_0 + \sum_{j=1}^h \left(\sum_{i=1}^n \frac{\theta_j^i}{n} \exp\left(-\frac{(x_i - c_j^i)^2}{2(b_j^i)^2}\right)\right)} \quad (7)$$

$$\bar{w}_0 = \frac{w_0}{\sum_{j=0}^h w_j} = \frac{W_0}{W_0 + \sum_{j=1}^h \left(\sum_{i=1}^n \frac{\theta_j^i}{n} \exp\left(-\frac{(x_i - c_j^i)^2}{2(b_j^i)^2}\right)\right)} \quad (8)$$

归一化后的 \bar{w}_j , 被应用于生成输出层输入与后件网络隐含层的连接权值。同样, \bar{w}_0 被应用于后件网络隐含层偏置与输出层输入的连接权值。

2.2 后件网络

在后件网络中, 包含了与前件网络中的 h 个隐含层节点一一对应的 h 条模糊规则, 每条产生的输出记

为 y_j 。传统 RBF 神经网络中的输出仅由输入值和后件网络中输入层与隐含层的连接权值决定, 若输入数据中发生若干特征分量数据丢失、失真、饱和的情况时, 传统的后件网络隐含层节点的输出值就有可能发生较大波动, 导致网络失去判别的能力。

本系统在输出 y_j 的生成规则中加入各特征分量模糊隶属度的影响, 如下式(9)所示, 就可在干扰发生时降低甚至是忽略干扰特征对于输出的影响, 在聚类结果各类样本集所对应的模糊规则中, 使输出值不至于有较大的变化。

$$y_j = p_j^0 + p_j^1 x_1 \mu_j^1 + p_j^2 x_2 \mu_j^2 + \dots + p_j^n x_n \mu_j^n \quad (9)$$

$(x_i \in A_j^1, x_i \in A_j^2, \dots, x_n \in A_j^n)$

式(9)可以看到, 该类模糊规则能起到对非属于该类样本中的特征分量进行抑制和剔除, 可大大加强模型的鲁棒性。同时若在错误样本训练网络时, 传统的融合 T-S 模型的 RBF 模糊神经网络, 归一化后仅选择一条或几条数值非常小且为最大的规则 w_j 来激活节点产生输出。将导致传统网络并不能很好地保留 RBF 网络的局部响应特性, 存在文献[8-9]提出的网络收敛慢、有可能存在局部最优情况。改进后的融合 T-S 模型的 RBF 模糊神经网络, 尽管也采取了归一化提升模型泛化能力的做法, 但在模糊规则对应的模糊节点输出 y_j 的产生过程中通过式(9)能够有效抑制错误样本的输出, 很大程度上增加了模型的局部响应能力。

输出层的输入 y_{n1} 为 y_j 与前件网络中归一化适用度 \bar{w}_j 的线性组合, 如式(10)所示:

$$y_{n1} = \bar{w}_0 + \sum_{j=1}^h \bar{w}_j y_j \quad (10)$$

因本文将探讨的是二分类问题, 所以输出层的激活函数选用双曲正切函数, 如式(11)所示:

$$y_n = \tanh(y_{n1}) \quad (11)$$

2.3 模型参数学习

在改进的模型中, 因 p_j^0 、 w_0 的调整不受隶属度函数的制约, 所以在代价函数中引入正则项的惩罚因子 λ/n 。定义的代价函数为:

$$E = \frac{1}{2} e^2 = \frac{1}{2} (y_d - y_n)^2 + \lambda/n (|p^0| + |w_0|) \quad (12)$$

式中: E 为代价函数; e 为样本误差; y_d 为网络的期望输出; y_n 是网络的实际输出。

3 数据采集及实验验证

本文依据不同波段波形时域信号之间的关系、频域信号中火焰闪动频率集中在 3~25 Hz 的理论条件^[10],


来提取特征训练网络并进行判别测试。

3.1 数据采集及处理


本实验的时域信号的实时采集频率为 5 kHz，经过滤波去噪处理后，可直接用于分析的数据频率为 144 Hz。同时将采集数据进行如下处理：

- 1) 将时域信号减去基准电压幅值 2 V，之后 200 点截断信号加入汉宁窗处理。
- 2) 将汉宁窗处理后的信号补 0 后，进行快速傅里叶变换 (Fast Fourier Transform, FFT)，以获取信号频谱。

图 3~图 5 分别给出了正庚烷、太阳光和电烙铁 3 种物体的采集波形和处理波形。



(a) Time domain diagram of N-heptane combustion sampling




(b) 4.3 μm channel windowed spectrum


图 3 正庚烷燃烧数据图

Fig.3 Data chart of n-heptane combustion

图 3(a)为正庚烷在 1 平方英尺容器中燃烧时，离火源 35 m 正对方向采集的时域图，图 3(b)为 4.3 μm 火焰通道经加窗 FFT 变换后的频谱。



(a) Time domain diagram of electric iron acquisition




(b) 4.3 μm channel windowed spectrum

图 4 电烙铁采集数据图


Fig.4 Data chart of electric iron collection

图 4(a)为 220VAC100 W 交流电烙铁工作时，正对方向 3.0m 处采集的时域图，图 4(b)为 4.3 μm 火焰

通道经加窗 FFT 变换后的频谱。



(a) Time domain sunlight acquisition



(b) 4.3 μm channel windowed spectrum

图 5 太阳光采集数据图

Fig.5 Data chart of natural light collection


图 5(a)为探测器水平方向采集太阳光的时域图，图 5(b)为 4.3 μm 火焰通道经加窗 FFT 变换后的频谱。

3.2 火焰探测器的鲁棒性实验


本实验主要是针对火焰探测中可能出现的 3 种强干扰问题展开讨论。

1) 数据丢失

若单一非火焰传感器故障、通道数据传输问题、硬件老化引起的单一非火焰探测通道数据丢失，则表现为单一通道信号在电压 0 V 附近，其它通道和火焰通道频谱基本不受影响。图 6 和图 7 分别为在 3.8 μm 通道、5.0 μm 通道中存在数据丢失时的正庚烷火焰采集图。




(a) Time domain diagram of N-heptane combustion sampling




(b) 4.3 μm channel windowed spectrum

图 6 正庚烷火焰下 3.8 μm 通道数据丢失图

Fig.6 Data loss of 3.8 μm channel in N-heptane flame



(a) Time domain diagram of N-heptane combustion sampling




(b) 4.3 μm channel windowed spectrum

图7 正庚烷火焰下 5.0 μm 通道数据丢失图


Fig.7 Data loss of 5.0 μm channel in N-heptane flame

2) 数据失真

若单一非火焰探测通道多级放大器故障、单一非火焰探测传感器失灵引起的数据失真表现为单一通道信号在基准电压 2V 附近, 其它通道和火焰通道频谱不受影响。图 8 和图 9 分别为在 3.8 μm 通道、5.0 μm 通道中存在数据失真时的正庚烷火焰采集图。




(a) Time domain diagram of N-heptane combustion sampling




(b) 4.3 μm channel windowed spectrum

图8 正庚烷火焰下 3.8 μm 通道数据失真图

Fig.8 Data distortion of 3.8 μm channel in N-heptane flame



(a) Time domain diagram of N-heptane combustion sampling




(b) 4.3 μm channel windowed spectrum

图9 正庚烷火焰下 5.0 μm 通道数据丢失图


Fig.9 Data distortion of 5.0 μm channel in N-heptane flame

3) 数据饱和

在单一强干扰源如: 强背景光照射、高温物体距离过近将会引起对应的背景光源干扰通道、人工热源干扰通道数据饱和, 其它通道数据、频谱变化不大。图 10 和图 11 分别为在 3.8 μm 通道、5.0 μm 通道中存在数据饱和时的正庚烷火焰采集图。




(a) Time domain diagram of N-heptane combustion sampling




(b) 4.3 μm channel windowed spectrum

图10 正庚烷火焰下 3.8 μm 通道数据饱和图

Fig.10 Data saturation of 3.8 μm in N-heptane flame



(a) Time domain diagram of N-heptane combustion sampling



(b) 4.3 μm channel windowed spectrum

图11 正庚烷火焰下 5.0 μm 通道数据饱和图

Fig.11 Data saturation of 5.0 μm in N-heptane flame

表 1 部分样本示意表

Table 1 Schematic table of some samples

Sample No.	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	x_{11}	x_{12}
1	2.58	2.51	2.46	1.02	0.97	16	0.840	0.032	0.023	0.027	1.6875	0.207
2	2.39	2.71	2.43	0.88	0.89	12	0.408	0.032	0.020	0.023	2.25	0.284
3	2.07	2.32	2.10	0.89	0.90	40	0.237	0.017	0.020	0.012	1.6875	0.061
4	2.15	2.24	2.29	0.95	1.02	4	0.306	0.0261	0.023	0.019	0.5625	0.062

3.3 特征提取

从上述实验中采集的数据中每 200 点提取一个样本，每个样本由下述 12 个特征组成：

$$X = [x_1, x_2, \dots, x_{12}] \quad (13)$$

式中： $x_1 \sim x_3$ 分别代表 $3.8 \mu\text{m}$ 、 $4.3 \mu\text{m}$ 和 $5.0 \mu\text{m}$ 通道的电压峰值； x_4 代表 x_1 与 x_2 的比值； x_5 代表 x_3 与 x_2 的比值； x_6 代表波形中存在的极值点个数，一定程度上可以表征火焰的闪动现象； x_7 代表频谱中 $1 \sim 10 \text{ Hz}$ 信号幅值之和； x_8 代表频谱中 $11 \sim 25 \text{ Hz}$ 幅值之和； x_9 代表频谱中 $26 \sim 45 \text{ Hz}$ 幅值之和； x_{10} 代表频谱中 $46 \sim 72 \text{ Hz}$ 幅值之和； x_{11} 代表频谱组成中幅值最高的频率值； x_{12} 代表频谱中频率最高的幅值。表 1 为部分样本示意表。

4 算法验证

4.1 模型训练及测试

本文取实验样本共 606 组，对改进 T-S-RBF 模型、传统 T-S-RBF 模型、GA-BP 模型进行训练，其中正样本 300 组和负样本 306 组，样本输出标签 1 代表“有火”，标签 -1 代表“无火”。随后用实验采集的另外 176 组测试样本对上述得到的 3 种模型进行测试。在火焰的判断中模型输出值大于 0 认为存在火焰，模型输出值小于 0 认为不存在火焰。

改进 T-S-RBF 模型的 c_j^i, θ_j^i 以及传统 T-S-RBF 模型的 c_j^i 都按第 3 部分的方法确定，改进 T-S-RBF 模型、传统 T-S-RBF 模型的 p_j^i, p^0 为 $[-1, 1]$ 的随机数， w^0 取 0， b_j^i 均为 0.2 以保证局部响应的能力。BP 模型的参数初值选定按遗传算法进行优化选定参数。

定义归一化误差为：

$$\text{RSME} = \sqrt{\frac{1}{N} \sum_{k=1}^N (e_k)^2} \quad (14)$$

式(14)中训练时 $N=606$ ，测试时 $N=176$ ， e_k 代表第 k 个样本的误差。从图 12 中可看到，改进后的模型因在模糊后件中模糊规则中加入了各特征分量的隶属度关系，使得模型的局部响应能力有较大的提

升。表 2 中可以看到，改进后 TS-RBF 模型不管是训练时的拟合程度，还是模型的泛化能力相较传统的 TS-RBF 模型、GA-BP 模型都有较大的提升，并且在对于火焰的判断中的正确率也是达到了 100%。

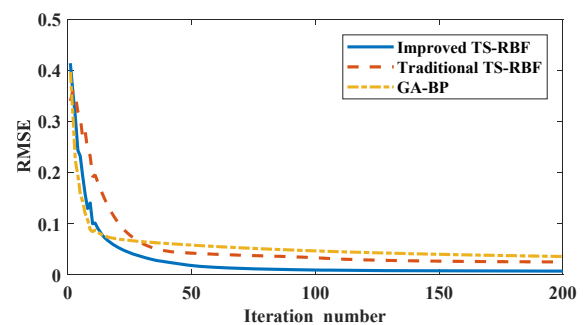


图 12 模型归一化训练误差比较图

Fig.12 Comparison of normalized training errors of models

表 2 网络效果比较

Table 2 Comparison of network effects

Network type	RSME training	Training accuracy	RSME Test	Test accuracy	Node
Improved T-S-RBF	0.007	100%	0.006	100%	15
Traditional T-S-RBF	0.025	100%	0.071	97.5%	50
GA-BP	0.035	100%	0.074	98.7%	17

4.2 模型鲁棒性测试

上述 3 种模型在常态工作情况下均能满足应用需求，但在数据发生一定程度损失，模型在可靠性方面存在较大差异。

本文针对 $3.8 \mu\text{m}$ 通道和 $5.0 \mu\text{m}$ 通道中分别出现的数据丢失、数据失真、数据饱和共 6 种情况进行鲁棒性实验。各情况分别提取了 100 组测试样本，其中正、负样本各 50 组对上述 3 种正常数据训练完成的模型进行测试。

1) 数据丢失

从表 3 可知，在单一非火焰通道发生数据丢失的情况下，改进 T-S-RBF 模型可较好地判断火焰具有极高的鲁棒性，传统 T-S-RBF 模型和 GA-BP 模型都不能够达到需求的判断正确率，且分别在 $5.0 \mu\text{m}$ 和 $3.8 \mu\text{m}$ 通道发生数据丢失的情况下模型基本失效。

表3 数据丢失模型效果比价

Table 3 Comparison of data loss models

Network type	RSME of 3.8 μm	Test accuracy	RSME of 5.0 μm	Test accuracy
Improved T-S-RBF	0.0226	100%	0.0051	100%
Traditional T-S-RBF	0.6185	90%	0.9356	77%
GA-BP	1.3362	53%	0.2379	99%

2) 数据失真

从表4可知,在单一非火焰通道发生数据失真的情况下,改进 T-S-RBF 模型可较好地判断火焰具有极高的鲁棒性。GA-BP 模型也在 5.0 μm 通道发生数据失真时,表现出较好的预测能力,而传统 T-S-RBF 模型在 5.0 μm 通道发生数据失真的情况下模型的预测能力极低无法达到要求。

表4 数据失真模型效果比价

Table 4 Comparison of data distortion models

Network type	RSME of 3.8 μm	Test accuracy	RSME of 5.0 μm	Test accuracy
Improved T-S-RBF	0.0093	100%	0.0109	100%
Traditional T-S-RBF	0.386	96%	0.6542	86%
GA-BP	0.3769	94%	0.0605	100%

3) 数据饱和

从表5可以知道,在单一非火焰通道发生数据饱和的情况下,改进 T-S-RBF 模型表现出较强的火焰识别能力,具有极高的鲁棒性。GA-BP 模型虽然也具有一定的预测能力,但远远达不到预测要求且输出波动严重。传统 T-S-RBF 模型在单一非火焰通道发生数据饱和的情况下,模型完全失效失去判断火焰的能力。

表5 数据饱和和模型效果比价

Table 5 Comparison of data saturation models

Network type	RSME of 3.8 μm	Test accuracy	RSME of 5.0 μm	Test accuracy
Improved T-S-RBF	0.0227	100%	0.0475	100%
Traditional T-S-RBF	1.4715	45%	1.2798	51%
GA-BP	0.6012	89%	0.6364	86%

5 结论

本文提出的改进 T-S-RBF 算法,通过在模糊后件模糊规则输出的计算中加入了特征分量的隶属度,使得模型能够有效抑制特征分量的波动所带来的影响,同时在模糊规则适用度的生成规则中,充分考虑到不同特征对于不同种类样本的表征程度。

结合三波段火焰探测器的设计和相关采集实验数据的处理,实现了对模型的收敛速度、收敛精度、泛化能力、鲁棒性等均进行了验证,并与传统 TS-RBF 模型和 GA-BP 模型进行了同向比较,各项性能指标上均有明显的提升。同时,在模型训练复杂度、时间上较传统的模型稍有增加,并且在如何快速确定最优模糊规则数目上还有进一步优化空间。

参考文献:

- [1] 魏崇毓,王馨民. 基于红外、紫外双波段探测的智能水炮系统设计[J]. 红外技术, 2016, 38(10): 877-883.
WEI Chongyu, WANG Xinmin. Design of Intelligent Water Cannon System Based on PIRS and UV Detection[J]. *Infrared Technology*, 2016, 38(10): 877-883.
- [2] 邓理文,刘晓军. 基于模糊神经网络的智能火灾探测方法研究[J]. 消防科学与技术, 2019, 38(4): 522-525.
DENG Liwen, LIU Xiaojun. Intelligent fire detection method based on fuzzy neural network[J]. *Fire Science and Technology*, 2019, 38(4): 522-525.
- [3] YAO Lina, ZHANG Yanna. Fault diagnosis and model predictive tolerant control for non-Gaussian stochastic distribution control systems based on T-S fuzzy model[J]. *International Journal of Control Automation & Systems*, 2017, 15(1): 2921-2929.
- [4] 程玉虎,王雪松,孙伟. 自适应 T-S 型模糊径向基函数网络[J]. 系统仿真学报, 2007(19): 4440-4444.
CHENG Yuhu, WANG Xuesong, SUN Wei. Proposal of Adaptive T-S Fuzzy Radial Basis Function Network[J]. *Journal of System Simulation*, 2007(19): 4440-4444.
- [5] WU Qinghui, WANG Xinjun, SHEN Qinghuan. Research on dynamic modeling and simulation of axial-flow pumping system based on RBF neural network[J]. *Neurocomputing*, 2016, 186: 200-206.
- [6] 张谦,王双红,陈海峰. 基于 RBF 模糊神经网络的垂直轴风力机设计[J]. 计算机测量与控制, 2014, 22(7): 2237-2239, 2243.
ZHANG Qian, WANG Shuanghong, CHEN Haifeng. Research on vertical axis wind turbine control algorithm based on RBF fuzzy neural network[J]. *Computer Measurement and Control*, 2014, 22(7): 2237-2239, 2243.
- [7] JUANG Chiafeng, CHIU Shihhsuan, CHANG Shuwew. A Self-Organizing TS-Type Fuzzy Network With Support Vector Learning and its Application to Classification Problems[J]. *IEEE Transactions on Fuzzy Systems*, 2007, 15(5): 998-1008.
- [8] 张颖. 改进的 T-S 模糊神经网络在化工软测量中的应用[J]. 电子测量与仪器学报, 2010, 24(6): 585-589.
ZHANG Ying. Improved T-S fuzzy neural network applied in soft sensing of chemical industry[J]. *Journal of Electronic Measurement and Instrument*, 2010, 24(6): 585-589.
- [9] 阮慧,党德鹏. 基于 RBF 模糊神经网络的信息安全风险评估[J]. 计算机工程与设计, 2011, 32(6): 2113-2115, 2128.
RUAN Hui, DANG Depeng. Risk assessment of information security based on RBF fuzzy neural network[J]. *Computer Engineering and Design*, 2011, 32(6): 2113-2115, 2128.
- [10] 袁积德. 三波段红外火焰探测器的研究与开发[D]. 杭州: 浙江大学, 2012.
YUAN Jide. Research and Development of Triple Channels Infrared Flame Detector[D]. Hangzhou: Zhejiang University, 2012.