

基于 STM32F 和极限学习机在火灾检测中的应用

刘 恺, 赵先锋, 包月青

(浙江工业大学 信息工程学院, 杭州 310014)

摘要: 针对传统单一信号的火灾检测方式存在误判问题, 以及布线复杂并且性价比低的弱点, 提出了基于 STM32F 和极限学习机火灾检测方法; 该方法首先通过 STM32F 模块采集多个传感器的值 (烟雾传感器, 甲烷传感器, 可燃气体传感器, 一氧化碳传感器), WLAN 为载体进行数据发送, 然后采用加权滤波对数据进行去噪处理, 获得极限学习机的训练和测试样本库, 模型训练结束后, 以测试数据进行方法验证, 并对验证结果进行评估; 结果表明, 该方法能够准确判断火灾类型, 准确度达到 90% 以上; 在火灾处理算法方面, 极限学习机相对于 BP 神经网络、支持向量机和贝叶斯网络训练时间短, 准确率高, 具有较高的应用于推广价值。

关键词: 多传感器; 火灾检测; 加权滤波; 极限学习机; 数据融合

Application of STM32F and ELM in Fire Detection

Liu Kai, Zhao Xianfeng, Bao Yueqing

(College of Information Engineering, Zhejiang University of Technology, Hangzhou 310032, China)

Abstract: Traditional fire detection mechanisms which aims at using a single signal method results in misjudgements, complex wiring and low performance-to-price ratio. Aiming at solving these problems, a method of fire detection based on STM32F and extreme machine learning algorithms is proposed. For our model, the value of multiple sensors by STM32F module is collected, a WLAN is used as the carrier to transmit data and then denoised by weighted filter to obtain the training data for the ELM. After the model training, a simulation experiment on fire detection is finally carried out on a test data to evaluate and verify the resulting performance. The result shows that, our method can accurately identify fire types with 90% accuracy. In fire signal processing algorithms, the proposed model is faster and achieves higher accuracy when compared with several state-of-the-art methods such as BP neural network, Naive Bayesian and SVM, and it is practical and worthy of using abroad.

Keywords: multisensor; fire detection; weighted filter; extreme learning machine; data fusion

0 引言

火灾一直威胁着人类生命财产安全。目前几种主要的火灾探测技术包括吸气式^[1], 红外光束^[2], 图像视频技术^[3], 布线复杂且性价比低、结构不灵活等缺点。随着无线局域网 (wireless local area network, WLAN)^[4] 的发展, 无线网络已经广泛部署于各种室内场合, 如学校、医院、餐厅、小区等。如果能充分利用这些网络资源来实现火灾检测, 将大大降低系统成本。

在火灾信号处理算法方面, 英国的 Thomas H. Mcavoy 把统计概率学应用到火灾检测中, 很好地解决了传统的感烟探测器的精确度低的问题, 对阴燃火有迅响应时间快^[4], 但该方法利用单一传感器, 很容易受到干扰源的影响。对单一的传感器火灾探测系统来说, 经常会出现误报的问题。因此许多研究者使用两种或两种以上的不同类型探测器同步进行检测, 同时和智能算法相结合。我国的杨宗凯以半导体感温, 离子感烟和湿

度模拟传感量为基本特征, 并附加其相应的趋势特征对神经网络进行训练, 较好地克服干扰信号影响^[5]。周晓琳采用了多传感器数据融合技术实现对火灾特征信息的采集与处理; 然后提出了一种新的神经网络算法, 建立 BP 网络火灾预警模型^[6]。然而 BP 神经网络训练速度慢, 易出现过拟合情况。另外, 赵鹏利用数字图像处理技术, 通过对像素特征空间进行弹性约束, 模糊匹配识别区域, 有效的提高火焰小的情况下系统的识别率^[7]。然而火灾发生过程中会产生大量烟雾, 造成图像质量低, 该技术对火焰的特征提取存在较大偏差, 致使探测的精度下降。Andrew 利用 PEN3 电子鼻工具和协方差 k-最近邻概率神经网络算法, 根据火灾的燃烧的气味进行早期火灾检测^[8], 响应速度快。Chen Jing 阐述了火灾报警和火灾燃烧过程中的理化特性之间的关系, 并提出了基于贝叶斯网络的火灾预警模型^[9]。但贝叶斯网络训练过程复杂, 需要的数据多。Wang Hairong 提出基于 RBF 的分布式神经网络火灾预警模型, 同时利用遗传算法来优化 RBF 网络模型, 提高预警模型的适应性和可行性^[10], 实现在较少的数据集下也能达到很好的精度。Qian Ding 采集多个传感器数据, 然后利用改进的 D-S 证据理论对火灾发生的概率进行判断, 很好的解决了证据冲突的问题^[11]。刘云翔将模糊推理技术和神经网络相结合, 应用在火灾

收稿日期: 2017-11-23; 修回日期: 2017-12-20。

基金项目: 浙江省自然科学基金资助项目 (LY14F050004)。

作者简介: 刘 恺 (1961-), 男, 浙江杭州人, 教授, 硕士研究生导师, 主要从事通信及信号处理, 火灾检测等方面的研究。

检测中,实现较高的可靠性和准确性,但需要在建立精确的火灾样本和收集分析其他火灾传感信号等方面进一步完善^[12]。

基于以上研究,本文引入具有良好的非线性映射能力和建模速度快的极限学习机来检测火灾,利用 STM32F 采集火灾发生过程中各传感器的值,通过 WLAN 将火灾数据传到终端进行分析处理,建立 STM32F 极限学习机火灾检测模型。该方法较单一传感器和 BP 神经网络、支持向量机、朴素贝叶斯方法相比能更为全面判断火灾状态,准确地检测是否出现火情,减少误报率,提高系统的准确度。

1 火灾采集系统的设计

火灾采集系统主要采用 MQ2 烟雾传感器, MQ4 甲烷传感器, MQ5 可燃气体传感器, MQ7 一氧化碳传感器,实时检测环境中的烟雾信号,克服单一传感器造成的误报问题。多传感器模拟数据传输至 STM32F 微处理器进行 A/D 转换,转换成数字电压信号。采用 32 位处理器,可有效提高系统数据分析和处理能力。在通过 ESP8266 无线模块将多传感器数据传输到终端主机,集中显示和管理所有传感器。终端上采用 C# 编写的客户端用于接收和显示各传感器数据。该无线模块解决了传统报警器无法接入 WIFI 网络,采用物联网方案中的 WIFI 联网,具有成本低,兼容性好,能直接适配现有无线网络,更方便的对系统进行远程控制。无线采集模块实物如图 1 所示。

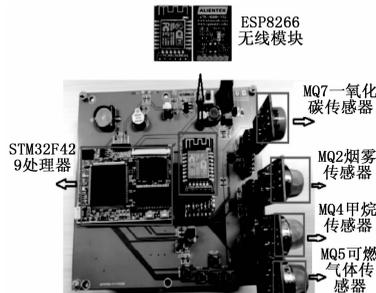


图 1 STM32F 无线采集模块

1.1 传感器的选择

不同燃烧物在燃烧过程中会伴随不同的产物,但一些信息只有火灾发生很长一段时间后才会检测出来,像火焰,燃烧音,固态高温产物等。经过实验发现温度在火灾初始阶段变化不明显,早期火灾以产生释放出烟雾和一些气体为主,基于此我们将火灾发生初期的气体作为火灾判断依据,气体检测装置选择 MQ 系列传感器,包括 MQ2 烟雾传感器, MQ4 甲烷传感器, MQ5 可燃气体传感器, MQ7 一氧化碳传感器。

1) MQ 系列传感器是一系列的模拟气敏传感器,主要由不同杂质含量、不同构造的二氧化锡构成。不同型号的传感器对于不同的气体有不一样的敏感度。

2) MQ 系列传感器采用 5 V 供电,模拟电压输出范围为 0~5 V,为 MCU 内部 ADC 最大支持 3.3 V 输入,所以通过电阻分压的方式等比降低输入电压,并且采用 LM358 设计电压跟随器电路,提高外部电路的输入阻抗,从而提

高 MCU 内部 ADC 检测的精度。

1.2 采集控制器的选择

系统采用 STM32F429 处理器完成传感器数据采集,传统的基于 8 位,16 位的单片机,完成火情分析时间一般为 15~18 s,对多数据处理能力较差,且存在模块功能弱的缺点,故不适合本系统多传感器的多数据处理的实现;基于 DSP 单片机虽具有较强的数据处理能力,但是成本较高,不易推广^[13],STM32F429 提供了 1 MB 闪存、256 KBS RAM,芯片内资源能够满足大多数应用要求。另外提供了 84 MHz 的 32 位宽的数据总线,能够使用低成本的外部 SRAM。此芯片拥有 3 个 12 位 ADC,其中 ADC1 拥有 16 复用通道,对于模拟信号的传感器拥有很好的兼容性,便于对于 MQ 系列传感器的数据采集。同时该处理器拥有 8 个串口资源,能够同时满足数据采集和通信。

1.3 无线传输模块选择

无线模块采用 ESP8266 模块,该模块采用 WIFI 芯片作为无线通信的载体,能够充分兼容现有的无线网络,能够使系统具有更加强大的兼容性能,能够在任何一个拥有 WIFI 的地方接入互联网,也可以使用任何具有无线功能的终端接入该系统。这样就可以利用现存的 WIFI 网络进行火灾检测。天线方面使用简单的 PCB 天线即可达到空旷环境下 400 m 的传输距离。该模块采用 TTL 电平与 MCU 通信,内置 TCP/IP 协议栈,通过 AT 指令控制芯片完成各种配置,兼容 3.3 V 和 5 V 单片机系统,拥有 WIFI STA、AP 和 WIFI STA+WIFI AP 三种模式,能够使用各种场合。使用编写好的 PC 客户端程序,可以通过 TCP/IP 协议对已经接入网的控制平台进行访问,读取控制台数据。

2 火灾数据采集及极限学习机分类方法

传统火灾检测系统基于单一传感器,但单一传感器检测存在可靠性差,容易受到环境干扰等缺点。不同燃烧物特性不同,单一传感器无法准确判断火灾种类。多传感器信息融合能有效克服单一传感器带来的不足,综合各类传感器信息,对燃烧物进行更细粒度分析,实现火灾燃烧物识别。在实际测量中,监控点 (monitor point, MP) 接收从接入点 (access point, AP) 发来的数据包分组,同时将各个传感器状态信息数据记录到一个 txt 文件中。txt 文件中的数据由多个数据包构成,而每个数据包代表燃烧物在某时刻各个传感器值。

2.1 传感器数据预处理

在对各燃烧物数据进行极限学习机分类前,需要进行数据的预处理,实验环境中,燃烧物和传感器有一定距离,传感器的输出值很容易受到周围环境影响,包含各种噪。图 2 (a) 为纸张燃烧过程中甲烷天然气传感器信号输出,从图中可以看出输出信号中含有许多噪声分量。噪声可能来源环境和元器件电磁干扰。

本文采用加权移动平均滤波从测量信号中滤除噪声,保留反映真实情况的样本数据。

在某个时段传感器接收的数据可以表示为 $\{X_1, X_2,$

..., X_t }, 滤波后 t 时刻值为:

$$X_t = \frac{1}{m + (m-1) + \dots + 1} \times (m \times X_t + (m-1) \times X_{t-1} + \dots + 1 \times X_{t-m+1}) \quad (1)$$

m 表示移动窗的大小, X_t 表示 t 时刻滤波后的值。由公式 (1) 可以看出, 加权移动平均滤波器不同地对待移动期内的各个数据。对近期数据给予较大的权数, 对较远的数据给予较小的权数。图 (b) 为滤波后的波形图, 加权平均滤波有效滤除信号中噪声部分。

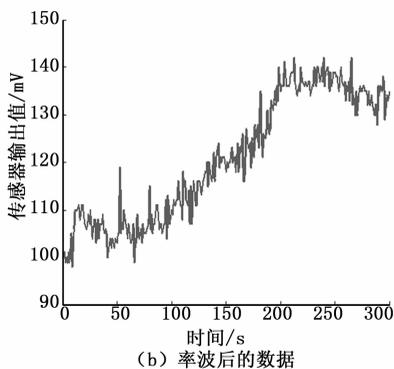
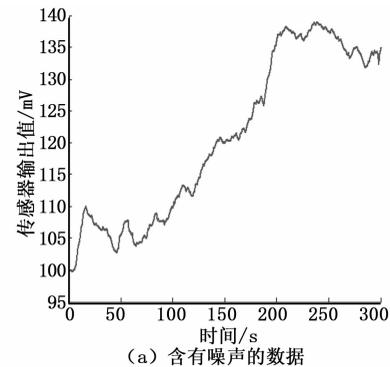


图 2 噪声数据和滤波后的数据

数据预处理第二步就是归一化, 归一化是指将每一维度的数据转换 (0, 1) 的范围内, 这就防止样本中某些取值过大的特征对其他特征产生影响, 归一化方法为:

$$X_{new} = \frac{(X_{old} - X_{min})}{(X_{max} - X_{min})} \quad (2)$$

式中, X_{new} , X_{old} 为归一化之前和处理后的样本数据, X_{min} , X_{max} 分别为训练数据中的最小值和最大值。从公式中可以看出若采集数据中存在噪声, 就会对归一化产生干扰, 因为噪声可能为训练数据中的最大值或者最小值, 导致归一化失败, 这也是在归一化之前先进行滤波的原因。

2.2 极限学习机分类原理

极限学习机^[14-15]是一种单隐层前馈神经网络。网络的输入层权重和隐藏层偏置是随机产生的, 输出层权重利用 Moore-Penrose 广义逆计算得到, 因此网络的学习速率有很大的提高。

给定一个样本集 (X_i, t_i) , $i=1, 2, \dots, N$, 其中 $t_i = (t_{i1}, t_{i2}, \dots, t_{im}) \in \mathbf{R}^m$, 网络隐含层具有 L 个单隐层节点, 激励函数为 $g(x)$, 则 ELM 网络实际输出为:

$$\sum_{i=1}^L \beta_j g(W_i \cdot Z_i + b_i) = y_j, \quad j = 1, 2, \dots, N \quad (3)$$

其中: $W_i = (w_{i1}, w_{i2}, \dots, w_{im})$, 表示输入节点与第 i 个隐含层节点连接权重, $\beta_i = (\beta_{i1}, \beta_{i2}, \dots, \beta_{im})$ 表示第 i 个隐含层节点与输出节点之间的连接权重, b_i 表示第 i 个隐含层节点的偏移值。文献 [15] 以证明极限学习机能够以零误差逼近训练样本, 即 $\sum_j^m \|y_j - t_i\| = 0$ 。因此网络输出可以表示为:

$$\sum_{i=1}^L \beta_j g(W_i \cdot X_j + b_i) = t_j, \quad j = 1, 2, \dots, N \quad (4)$$

由矩阵表示为:

$$H\beta = T \quad (5)$$

其中:

$$H(W_1, W_2, \dots, W_L, b_1, b_2, \dots, b_L, X_1, X_2, \dots, X_N) =$$

$$\begin{bmatrix} g(W_1 \cdot X_1 + b_1) & \dots & g(W_L \cdot X_1 + b_L) \\ g(W_1 \cdot X_2 + b_1) & \dots & g(W_L \cdot X_2 + b_L) \\ \dots & & \dots \\ g(W_1 \cdot X_N + b_1) & \dots & g(W_L \cdot X_N + b_L) \end{bmatrix}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, \quad T = \begin{bmatrix} t_1^T \\ t_2^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$$

则式 (5) 中 β 由最小二乘法解得:

$$\beta = H^+ T \quad (6)$$

其中: H^+ 为隐含层输出矩阵的广义逆。

从 ELM 算法过程可知, 在设定合适的隐藏层神经元后, 随机为输入权重和偏差赋值, 在计算隐藏层矩阵后, 通过最小二乘法得到输出权重, 这样就一次完成该问题的求解过程, 不需迭代。

3 火灾检测实验及分析

3.1 实验平台

实验平台主要分为接入点 (AP) 和监控点 (MP), 其中 AP 是由 STM32F429 处理器、传感器、无线模块采用 ESP8266 模块构成的采集系统, MP 为安装了自己用 C# 编写桌面端软件笔记本电脑, 操作系统为 Windows7。在采集数据时, 燃烧点放置在房间内某个位置, MP 接收来自 AP 的数据包, 并从中提取出燃烧物数据。数据中包含了燃烧物各个传感器信息。

3.2 实验环境及参数设置

为采集火灾环境数据, 我们选取一间长宽高为: 2.4 m \times 1.8 m \times 2.9 m 房间。实验图如 3 所示, 选取 4 个数据集点, 燃烧点之间距离为 1.2 m, 燃烧点距 AP 距离为 1 m, AP 高度为 30 cm。我们选取纸张, 布料, 塑料, 木材作为火灾信号, 蜡烛, 香烟和正常状态为非火灾信号。经实验研究蜡烛, 香烟作为干扰源也会释放出烟雾, 但在早期相对于火灾源, 产生烟雾较少。我们可以根据这一特性进行判别火灾信号和干扰信号。采集系统每隔 2 秒收发一次传

传感器数据, 初始阶段火灾环境特征变化较小, 发展阶段随着气体释放, 燃烧物各种气体体积分数增高, 烟气量开始增加。利用发展阶段早期气体变化进行判断, 缩短预警时间, 降低火灾损失。

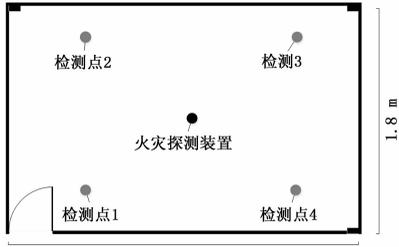


图 3 火灾检测实验图

3.3 实验结果分析

对于每种燃烧物, 我们选取前 250 个样本值, 构成样本集。训练样本和测试样本个数如表 1 所示。

表 1 训练样本和测试样本

| | 火灾数据 | 非火灾数据 |
|------|------|-------|
| 训练样本 | 800 | 600 |
| 测试样本 | 200 | 150 |

为了研究起火点对算法影响, 我们将 4 个起火点的传感器数据按照表 1 构成 4 个样本集, 对每个样本集先利用移动加权滤波处理, 然后采用极限学习机方法对其预测, 测试样本预测结果如图 4 所示。

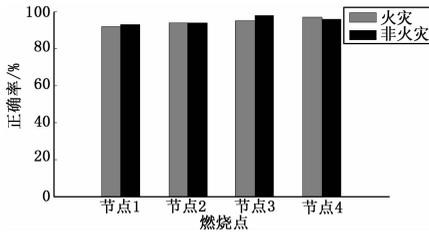


图 4 不同节点正确率

从图中可以看出, 在 4 个样本集中无论对于火灾信号还是非火灾信号, 极限学习机网络都能达到高于 90% 的正确率。位置对分类准确性影响较小。

为了检测算法的有效性, 我们在每个火灾试验点随机选取 250 个样本, 作为训练样本。50 个样本作为测试样本。统计火灾状态下单一传感器和多传感器分别作为极限学习机网络的输入, 比较结果见表 2。

表 2 单一传感器和融合后结果对比

| 传感器 | 非火灾概率/% | 火灾概率/% | 判决结果 |
|--------|---------|--------|------|
| MQ2 | 48.07 | 51.93 | 火灾 |
| MQ4 | 64.58 | 35.42 | 无火灾 |
| MQ5 | 77.79 | 22.21 | 无火灾 |
| MQ7 | 35.87 | 64.13 | 火灾 |
| ELM 融合 | 3.93 | 96.07 | 火灾 |

如表 2 所示, 用单一种类传感器进行火灾类型判别时, 极限学习网络输出火灾和非火灾概率相差较小, 这样就容易造成误判; 而使用极限学习机理论融合多种传感器信息后, 两者概率之差增大, 在一定程度上提高了火灾检测系统的准确率。

同时本研究将极限学习机和传统的分类算法 BP 神经网络、支持向量机、朴素贝叶斯做比较, BP 神经网络和朴素贝叶斯采用 MATLAB 自带工具箱, 其中 BP 神经网络利用 Levenberg-Marquandt 规则训练前向网络。支持向量机使用 libsvm-2.89 工具箱, 测试集比较结果如图 5 所示。

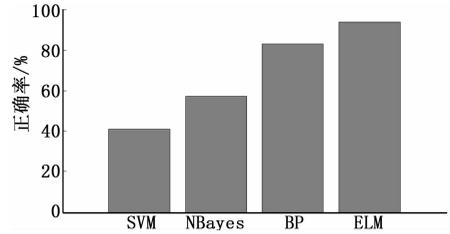


图 5 不同算法结果对比图

从图 5 中可以看出, 支持向量机和朴素贝叶斯正确率只有 40.8% 和 57.6%。而 ELM 达到 94.3% 的正确率。同时也高于 BP 神经网络。支持向量机虽然通过核函数将非线性数据映射到高维空间进行分类, 但对非线性问题没有通用解决方案, 必须谨慎选择 Kernel function 来处理。朴素贝叶斯模型假设属性之间相互独立, 而火灾环境中的特征量是很难保证是完全独立的, 这给朴素贝叶斯模型的正确分类带来了一定影响。用神经网络算法虽然能够识别一些干扰信号, 并且能够较为准确地判断火情但是火灾的数据与收集需要神经网络有足够多的训练样本。同时学习的样本过多使整个网络变得很大, 影响收敛的速度。因此 ELM 网络在火灾检测中具有较大的优势。

表 3 为 4 种方法的性能分析, BP 神经网络和 ELM 都能达到较高的正确率, 但 ELM 网络结构简单, 无需迭代进行学习, 所以在训练和测试所需时间远少于 BP 神经网络, BP 神经网络由于需要进行反馈学习, 训练时间较长。朴素贝叶斯方法、SVM 方法和极限学习机训练时间短, 但训练集和测试集正确率都低于 ELM 方法。极限学习机在达到较高的正确率, 同时能够大大降低训练时间。

表 3 3 种算法性能比较

| 类别 | SVM | Nbyes | BP | ELM |
|----------|-------|-------|-------|-------|
| 训练集正确率/% | 54.35 | 57.65 | 95.79 | 99.2 |
| 测试集正确率/% | 40.05 | 40.82 | 82.57 | 96.5 |
| 训练时间/s | 0.248 | 0.147 | 27.91 | 0.149 |
| 测试时间/s | 0.059 | 0.071 | 0.048 | 0.036 |

4 结论

利用搭建的 STM32 无线数据采集平台, 进行燃烧物数据采集, 实验平台灵活, 不受环境限制。针对单一传感器检测时出现的不足, 研究了将极限学习机网络应用于火灾检测的方法。使用多种传感器对火灾早期烟雾特征进行测量, 降低单个传感器带来的不确定性误差。实验结果表明, 该方法和单一传感器、SVM、Nbyes、BP 神经网络相比, 可以更快速准确的反应出发生火灾的可能性, 降低训练时间, 实现了火灾的早期发现, 为及时灭火奠定了基础。本方法在某些方面还存在改进地方, 如讨论燃烧物量对各个观察特征的影响, 针对有风环境等更复杂的情况则需要进一步的深入研究, 我们的研究工作可为以后深入研究提供技术基础。

参考文献:

[1] 张 旭. 吸气式极早期火灾探测技术及方法研究 [D]. 成都: 电子科技大学, 2016.

[2] 邱培芳. 适用于不同光源条件下的红外光束感烟探测器 [J]. 消防科学与技术, 2015, 34 (12): 1570.

[3] 罗 胜, Jiang Y Z. 视频检测烟雾的研究现 [J]. 中国图象图形学报, 2013, 18 (10): 1225 - 1236.

[4] Richard W, Reneke P. A New Approaches to the Interpretation of Signals from Fire Sensors [J]. Journal of Japan Society for Fuzzy Theory and Systems, 2007, 6 (2): 29 - 35.

[5] 何建华, 杨宗凯. 基于神经网络和模糊逻辑的智能火灾探测 [J]. 华中理工大学学报, 1997, 25 (2): 9 - 12.

[6] 周晓琳. 基于神经网络的多传感器数据融合火灾预警系统研究 [D]. 长春: 长春理工大学, 2012.

[7] Zhao P. Intelligent fire warning system based on fuzzy extension constraint algorithm [A]. 2014 Fifth International Conference on Intelligent Systems Design and Engineering Applications [C]. 2014: 578 - 581.

[8] Anderw A M, Kamarudin K, Mamduh S M, et al. Classification of domestic burning smell using covariance k - nearest neighbor algorithm for early fire detection application [J]. Chemical Engineering Transactions, 2014, 40: 271 - 276.

[9] Chen J, Fu J Q. Fire alarm system based on multi - sensor Bayes network [J]. Procedia Engineering, 2012, 29: 2551 - 2555.

[10] Wang H R, Yang W G, et al. Application of distributed GA - Based RBF neural network in fire detection [A]. International Conference on Computing [C]. 2008, 3: 398 - 402.

[11] Ding Q, Peng Z H, Liu T Z, et al. Building fire alarm system with multi - sensor and information fusion technology based on D - S evidence theory [J]. Algorithms, 2014, 7 (4): 906 - 909.

[12] 刘云翔, 原鑫鑫, 袁晨超, 等. 模糊推理技术和神经网络在火灾检测系统中的应用 [J]. 计算机测量与控制, 2013, 21 (12): 3219 - 3221.

[13] 刘燕燕, 杨帮华, 丁丽娜, 等. 基于 STM32 的红外火灾探测系统设计 [J]. 计算机测量与控制, 2013, 21 (1): 65 - 67.

[14] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: a new learning scheme of feedforward neural networks [A]. Proceedings of IEEE International Joint Conference on Neural Networks [C]. 2004 2: 985 - 990.

[15] Huang G B, Wang D H, Lan Y. Extreme learning machine: survey [J]. International Journal of Machine Learning and Cybernetics, 2011, 2 (1): 107 - 122.

(上接第 30 页)

[7] 甄红涛, 齐晓慧, 李 杰, 等. 四旋翼无人机 L1 自适应块控反步姿态控制器设计 [J]. 控制与决策, 2014, 20 (6): 1076 - 1082.

[8] 张海博, 胡庆雷, 马广富, 等. 多航天器系统分布式有限时间姿态协同跟踪控制 [J]. 控制与决策, 2014 (9): 1593 - 1598.

[9] 黄婷婷, 王大明. 基于 C8051F040 船载动中通天线姿态控制系统的研究 [J]. 计算机与数字工程, 2013, 41 (11): 1751 - 1752.

[10] 高桂杰, 张艳霞, 夏 刚, 等. 四轴平台随动系统的模型分析与设计 [J]. 导航与控制, 2014, 13 (4).

[11] 李 钊, 孙 健. 随动式车载光电搜跟系统研究 [J]. 电子产品世界, 2017, 24 (4): 43 - 46.

[12] 杨 震, 王 帆, 张金云, 等. 一种惯性平台随动轴控制方法设计与实现 [J]. 导航与控制, 2015, 14 (4).

[13] 卢 军, 刘 杰, 胡 凡. 基于 Android 和物联网的四轴运动

平台控制系统设计与实现 [J]. 制造技术与机床, 2016 (2): 64 - 68.

[14] 张彦斐, 宫金良, 林于一. 一种并联操作机器人的驱动力矩特性分析 [J]. 机械设计与研究, 2013, 29 (4): 19 - 21.

[15] 刘 洋, 姜 辉, 林诚才. 基于自抗扰控制器的力矩电机伺服系统控制 [J]. 计算机测量与控制, 2015, 23 (6): 2018 - 2021.

[16] 余书豪, 湛永祥. 电动机正反转控制程序的优化设计与研究 [J]. 组合机床与自动化加工技术, 2016 (2): 95 - 97.

[17] 李巧莲, 韩宝江. 高效电机检测技术 [J]. 电机与控制应用, 2013, 40 (7): 1 - 5.

[18] 金华松, 孙永江, 刘 军, 等. 航天测量船伺服直流电机测试系统设计与实现 [J]. 电机与控制应用, 2013, 40 (3): 53 - 56.

[19] 陈海涛, 宋申民, 李学辉. 航天器有限时间饱和姿态跟踪控制 [J]. 中国惯性技术学报, 2017, 25 (4): 536 - 543.