

文章编号: 1006-3080(2025)05-0645-12

DOI: 10.14135/j.cnki.1006-3080.20250215001

多传感器融合与少样本学习的燃烧早期预警及分类方法

詹浪¹, 郭昆仑¹, 顾海昕^{2,3}, 王海伟³, 顾震¹, 王慧锋¹

(1. 华东理工大学信息科学与工程学院, 上海 200237; 2. 应急管理部上海消防研究所, 上海 200032;
3. 上海市应急管理局火灾探测预警技术重点实验室, 上海 200032)

摘要:随着气体传感技术的发展, 集成多种气体传感器的火灾预警仪表在燃烧早期预警中具有广阔的应用前景, 有望成为火灾预防及快速干预的有效手段。然而, 多传感器系统输出具有数据量大、数据异构等特点, 对数据处理和融合处理提出了挑战。本文针对基于多传感器仪表的火灾燃烧场景监测中存在的异常特征捕捉不及时、难以在火灾早期及时分类燃烧场景等问题, 提出了一种融合单类支持向量机(One-Class Support Vector Machine, OCSVM)与少样本学习(Few-shot Learning, FSL)框架的预警分类策略, 用于燃烧早期预警与燃烧场景识别。该策略通过滑动窗口数据处理方法与OCSVM模型的结合, 实现了早期异常监测并进行实时报警; 同时基于元学习框架的Meta-Transformer模型, 针对4种燃烧场景进行精确分类并引入原型网络模块, 提升了模型在少样本条件下对未见场景的识别能力。实验结果表明, 该方法能够在燃烧早期的前5 min内迅速捕捉异常特征, 预警准确率达到97.73%; 在预警后, 对已见和未见的燃烧场景识别平均准确率分别达到97.33%和94.50%。在快速性验证中, 模型对已见和未见的燃烧场景前10 min内识别的平均准确率分别达到94.21%和95.42%。本研究为研制面向燃烧早期判定与识别的多传感器火灾预警仪表提供了新思路, 并有望为智能化的消防应急管理系统发展提供支持。

关键词:火灾预警; 气体传感器; 少样本学习; 原型网络; 人工智能

中图分类号: TP391.4

文献标志码: A

火灾预警与识别系统对于降低火灾风险、减少灾害损失至关重要^[1], 其核心目标在于能在火灾发生的早期阶段及时探知险情并做出有效应对, 尤其针对初期处于阴燃状态的潜在火灾隐患。与明火阶段相比, 早期阴燃具有无焰、缓慢燃烧、热量和可见火焰较少等特征^[2]。传统依赖火焰或温度快速变化来检测火情的系统往往难以捕捉此类隐患, 导致火灾在阴燃阶段容易被忽视。火灾早期通常定义为火情发生后前十几分钟, 这一阶段处于材料热解和烟雾、微小颗粒物的释放期, 还未形成明显明火^[3]。

为了开发用于火灾预警的智能化监测仪表系

统, 基于多传感器系统的智能感知技术^[4]来赋能早期阴燃火灾的识别并实现燃烧场景判断, 国内外学者已展开了众多研究与实践^[5-6]。例如, Kim等^[7]通过极大释然法和非负连续概率分布对电气火灾数据进行拟合, 在电气火灾燃因识别方面取得了较好的效果; Amril等^[8]提出了一种基于传感器的早期火灾检测实验方法, 通过采集室内环境中的阴燃传感器数据, 实时输出当前火灾风险预警等级; Chen等^[9]则提出了一种基于混合贝叶斯网络(BN)的火灾风险分析模型, 结合熵权法评估电缆过载引起的火灾风险水平。尽管这些方法在特定场景下获得了有效成果,

收稿日期: 2025-02-15

基金项目: 应急管理部上海消防研究所基本科研业务费项目(23SX20)

作者简介: 詹浪(2000—), 男, 重庆人, 硕士生, 主要研究方向为多传感预警系统研究。E-mail: zhanlang0815@163.com

通信联系人: 王海伟, E-mail: sitpcreative@126.com; 顾震, E-mail: guzhen@ecust.edu.cn; 王慧锋, E-mail: whuifeng@ecust.edu.cn

引用本文: 詹浪, 郭昆仑, 顾海昕, 等. 多传感器融合与少样本学习的燃烧早期预警及分类方法[J]. 华东理工大学学报(自然科学版), 2025, 51(5): 645-656.

Citation: ZHAN Lang, GUO Kunlun, GU Haixin, et al. Combustion Early Warning and Classification Method Based on Multi-Sensor Fusion and Few-Shot Learning[J]. Journal of East China University of Science and Technology, 2025, 51(5): 645-656.

但大多依赖单一参数(如 PM5、温度或特定气体浓度)进行火灾预警^[9-10],难以全面捕捉材料在热解阶段表现出的复杂、多样特征,且缺乏针对燃烧材料种类及场景差异的识别能力^[11]。若在实际环境中无法辨别当前燃烧材料,就难以及时采取针对性灭火策略^[12],从而限制了模型在多场景应用中的通用性。

此外,在不同火灾场景中,火灾数据难以收集,尤其是早期火情或小范围火焰场景的数据更为稀缺。同时,可燃材料及其分解产物往往具有明显的差异性^[13],传统模型若仅基于固定且有限的数据集进行训练^[14],当输入数据分布与训练样本不一致时,极易出现漏报或误报。为了解决训练数据不足与识别效果需求之间的矛盾,Sun 等^[15]通过少样本度量学习的方式,实现“细粒度”区分不同烟雾类别的识别方法,有效减少了非火灾烟雾的误报并实现火灾预警;Li 等^[16]提出一种融合注意力机制与原型网络的检测方法,有效区分了复杂背景下的小规模森林火灾烟雾;Lee 等^[17]在火灾图像数据不足的情况下,使用生成式对抗网络(GAN)合成火焰图像来弥补数据的不足,并利用少样本学习优化火灾检测模型,结果在仅有少量真实火灾数据的条件下,检测准确率仍能达到与大规模数据训练模型相近的效果。然而,现有研究主要基于图像来进行灾情检测与识别,对其他可同时获取的传感器信息缺乏融合与利用,难以在更复杂多变的环境下保证准确率。此外,大多数方法往往忽视了部署到设备系统的实时性要求,在实

际火情监控场景中难以满足早期快速预警的需求。

针对这些局限性,本文提出了一种基于单类支持向量机与少样本学习框架的火灾预警分类策略:首先,通过多传感器阵列数据融合深入提取火灾早期(包括阴燃阶段)的动态特征,克服单一传感器监测的局限;随后,利用单类支持向量机(One-Class Support Vector Machine, OCSVM)实现火灾风险的实时异常检测,并结合分类结果对当前火灾场景进行实时报警;最后,基于 Meta-Transformer 的少样本学习框架能够在有限样本条件和有限时间内完成对未见材料或新场景的快速适应,实现对火灾早期及阴燃过程的精准且快速识别。

1 基于单类支持向量机与少样本学习框架的预警分类策略

图 1 展示了燃烧早期预警与燃烧场景识别的整体框架,包括数据采集、异常检测和场景分类 3 个核心模块。首先,传感器网络对多种燃烧场景(如木材和蜡烛燃烧)进行实时监测,采集传感器阵列 CO、H₂、挥发性有机物(VOC)等多种特征数据。随后,基于 OCSVM 的异常检测模块对传感器数据进行预处理与分析,实现燃烧早期的异常特征捕捉与实时预警。最后,通过元学习框架的 Meta-Transformer 模型对燃烧场景进行分类识别,针对已见场景与未见场景进行训练与测试,精确区分不同燃烧场景类型。




图 1 基于单类支持向量机与少样本学习框架的燃烧早期预警与燃烧场景识别架构

Fig. 1 Architecture for early fire warning and fire scene recognition based on single-class support vector machine and few-shot learning framework

1.1 基于单类支持向量机的早期预警策略

本文提出的 OCSVM 的早期预警策略如图 2 所示,整体框架由滑动窗口数据处理方法和 OCSVM 模型两部分组成。

由于传感器在监测过程中可能存在滞后性和响应差异^[18],将导致单一传感器数据的偏差,从而影响分析的准确性。为减小不同传感器节点阵列的性能

差异对分析结果的影响,本文对来自 9 个传感器阵列的数据进行整合。具体做法是,在保留各阵列内部特征(如 CO、H₂、VOC、5 μm 颗粒物(PM5)等)的前提下,将传感器阵列在同一时刻的监测数据做算术平均,从而得到一个综合指标用于后续分析。这里主要对不同传感器阵列的数据进行均值处理,而非对单一阵列内部的多维特征进行平均。这种方法




图2 基于单类支持向量机的早期预警架构

Fig. 2 Early warning architecture based on one-class support vector machine

的优势在于,它能够平滑个别传感器阵列由于灵敏度、位置差异或环境干扰所造成的异常波动,从而提升整体数据的可靠性^[19]。通过这种数据融合策略,可以更有效地提取反映系统整体状态的特征信息。在实际操作中,首先对所有传感器阵列的原始数据进行标准化处理,以消除不同数据量纲对平均计算的影响。随后,通过对各传感器阵列的监测数据按时间戳对齐后计算平均值,得到每个时间点的综合数据特征。

在数据处理完成后,本文采用了 OCSVM 方法进行分析。与传统的二分类或多分类方法不同, OCSVM^[20] 专注于从单一类别的数据中学习其分布特征,从而对异常数据进行检测。在异常检测任务中, OCSVM 的关键思路是将输入数据映射到更高维度的特征空间,再通过寻找一个最优的决策边界来划分“正常”与“异常”。原始的综合数据特征向量记为 $\mathbf{x}_i \in R^d$, OCSVM 首先利用核函数 $\varphi(\mathbf{x}_i)$ 将其映射到高维特征空间,该空间可视为 R^m (对于线性核,通常 $m = d$)^[21]。在这个高维特征空间中,算法将大部分正常样本包围在边界内部,并尽可能将异常样本排斥在边界之外^[22]。其目标函数为:

$$\min_{\mathbf{w}, \rho, \xi} \frac{1}{2} \|\mathbf{w}\|^2 + \frac{1}{vn} \sum_{i=1}^n \xi_i - \rho \quad (1)$$

$$\text{s.t. } \varphi(\mathbf{x}_i) \cdot \mathbf{w} \geq \rho - \xi_i, \xi_i \geq 0, i = 1, \dots, n \quad (2)$$

其中, $\mathbf{w}$ 为高维空间中的权重向量, ρ 为超平面的偏置, ξ_i 为松弛变量, v 为异常点比例的超参数, n 为样本总数, $\varphi(\mathbf{x})$ 为样本通过核函数映射到高维空间后的特征表示。

$\mathbf{w}$ 和 ρ 共同决定了超平面在高维特征空间中的位置,该超平面用于划分正常状态数据的决策边界。当传感器采集得到的样本投影到该空间后,其与超平面的相对位置可用于判断其是否属于正常状态。对于火灾传感器其“近似线性”特征的数据分布,

使用高斯核带来的非线性映射优势未必显著,反而可能因为高斯核的过度拟合而出现假阳性或误报。因此在实际训练中,选择线性核函数 (Linear) 进行建模,更适合对传感器数据中常见的噪声与环境扰动保持鲁棒,在多变的火灾现场环境里能减少错误预警, OCSVM 的判别函数可表示为:

$$f(\mathbf{x}) = \varphi(\mathbf{x}) \cdot \mathbf{w} - \rho \quad (3)$$

当 $f(\mathbf{x}) < 0$ 时,判定为“异常”,否则判定为“正常”。

为了进一步提升预警的准确性并减少误报,本文引入了基于时间窗口的分析方法^[23]。具体而言,设定时间窗口大小为 20,即每次分析连续的 20 个时间点的数据,通过 OCSVM 模型判定该时间段内的状态类别。为保证预警的实时性,每次分析后,时间窗口以 1 个时间点为步长进行移动,实时更新数据并重复判定过程。该时间窗口策略的优势在于平衡数据的稳定性和实时性:较小的窗口大小能够快速捕捉短时间内的异常变化,而逐步移动的窗口可持续监测数据变化趋势。

在预警判定过程中,为进一步提升结果的可靠性,系统要求连续 3 次判定同一时间窗口为“异常”或“预警”状态时,才触发报警。这意味着,如果某一时间窗口被连续 3 次判定为预警,则系统记录报警的时间点并输出该时间窗口的序列号作为报警标识。此策略的核心在于,通过增加连续性判断约束,排除因偶然性波动导致的误报,确保触发报警的状态具有较高的置信度。

1.2 基于元学习框架的 Meta-Transformer 架构

在早期火灾风险预测的过程中,需要确定不同场景下可燃材料的热解表现出的各类传感器的监测指标,在火灾场景样本少、预测模型适应性低的情况下,所提出的基于元学习架构主要目标是克服上述有监督深度学习方法的局限性,确保对火灾场景完成可靠识别。

本文提出的 Meta-Transformer 模型架构如图 3 所示, 整体框架设计围绕元学习^[24]思想展开。模型的核心组件包括: 用于高效特征表示的 Transformer

编码器, 用于少样本分类任务的原型网络(ProtoNet)^[25]模块, 以及支持模型在新任务中快速适应的元训练与元测试机制。




图 3 Meta-Transformer 模型架构

Fig. 3 Meta-Transformer model architecture

其中, Meta-Transformer 的编码器采用模块化架构设计, 使得每一层可以独立工作。通过自注意力机制实现层之间的高效通信, 灵活调整模型的规模和复杂性^[26]。在该实现中, 每个模块接收一个一维特征向量输入, 对应传感器数据的特征数。本文通过实验探索了参数的最优配置, 并结合经验测试调整其余超参数, 以确保最佳模型性能。

对于元训练和元测试模块, 本文采用了典型的元学习框架, 以支持集 (Support Set) 和查询集 (Query Set) 构建每个任务 (episode)。元训练阶段的目标是通过多个任务学习任务间通用特征, 使模型能够快速适应新任务; 而元测试阶段的重点是评估模型对未见类别的泛化能力:

(1) 元训练模块: 该模块利用特定场景下的燃烧数据集, 根据少量样本生成原型向量并利用这些原型对数据进行分类的能力, 主要训练相关分类器, 即 Transformer 编码器 f_θ , 其中 θ 表示可训练参数。与传统的监督学习方法不同, 所提出的元学习方法获取元知识, 即使在样本有限的情况下也能更快地适应新任务。

(2) 元测试模块: 训练完成后, 元测试模块使用编码器 f_θ 对收集的少样本的未见场景进行测试。编码器 f_θ 学习一般元知识, 以提取适合当前火灾场景下监测数据的特征向量, 其中元知识代表多个任务

之间的基本共性。

在元训练阶段, 每个 episode 都被标记为 ϵ , 它包含两部分: 用于原型生成^[27]的支持集 (训练集) 和用于场景预测和参数更新的查询集^[28] (验证集)。为了每个任务生成支持集和查询集, 首先从源数据集中随机选择 n 个类别。在每个选定的类别中, 随机选择 k 个实例。其中, n 表示支持集的类别总数, k 表示每个类别的样本数量, 即 N-way, K-shot 设置。总任务数表示为 K_ϵ , 可以使用以下公式确定:

$$K_\epsilon = \frac{p_{\text{train}} \times K}{K_S + K_Q} \times K_{\text{epoch}} \quad (4)$$

其中, K 表示数据总数, p_{train} 是训练数据集的比例, K_S 是支持集的数量, K_Q 是查询集的数量, K_{epoch} 是训练时期的数量。训练中使用的燃烧场景数据被视为可见场景。用作输入的 K 条标注数据, 记为 $S = \{(x_1, y_1), \dots, (x_N, y_N)\}$, 尺寸为 $1 \times 1 \times 10 (C \times H \times W)$, 同时相应的类标签表示为 $y_i = \{1, \dots, K\}$ 。

对于支持集如式 (5), 类别 l 的原型 c_l 是通过属于类别 l 的标签数据集 S_l 中提取的特征向量 (嵌入支持点) 进行平均计算生成的。根据生成的原型对从查询集提取的特征向量进行分类, 该分类方法基于距离函数 d , 其可以是欧几里得距离或余弦相似度等函数。

$$c_l = \frac{1}{|S_l|} \sum_{(x_i, y_i) \in S_l} f_\theta(x_i) \quad (5)$$

本文通过计算查询样本与各类原型向量的欧几里得距离,生成一个概率分布,利用 Softmax 函数^[29]将这些距离转换为属于每个类别的概率分布,最终预测概率最高的类别为输出。欧几里得距离 $p_\theta(y = l|x)$ 表示样本 x 被预测为类别 l 的概率, c_l 表示类别 l 的原型向量, d 表示距离函数,其过程如式(6)所示:

$$p_\theta(y = l|x) = \frac{\exp(-d(f_\theta(x), c_l))}{\sum_l \exp(-d(f_\theta(x), c_l))} \quad (6)$$

模型的参数 θ 在每个训练迭代中通过 Adam 优化器^[30]不断调整,以最小化实际类别 n 的负对数概率,从而提高模型对少样本任务的分类能力,如式(7)所示:

$$L(\theta) = -\lg p_\theta(y = k|x) \quad (7)$$

在元测试阶段,支持集和查询集都由未见过的场景类型组成,主要目的是为了评估模型对新场景的适应能力以及泛化能力。测试模块使用了包括训练阶段使用的可见场景类型和新的未见场景类型的数据集。由于所用实际场景数据集的样本数较少,本文所用到的少样本学习模块(FSL)配置为 4-shot,即支持集中每类有 4 个数据样本。与元训练阶段类似,元测试模块使用训练后的 f_θ 生成 n' 个原型,其中 n' 表示用于元测试的目标类数,用于推理的查询集根据嵌入向量和原型之间的欧几里得距离进行分类。

2 实验结果

2.1 实验细节

2.1.1 数据集 数据集为 Indoor Fire Dataset with Distributed Multi-Sensor Nodes^[31],包括 4 次阴燃火灾实验(重复 3 次)和 3 次干扰实验(乙醇:重复 3 次;除臭剂:重复 2 次;发胶:重复 1 次),在进行实验时穿插了各种背景序列。所有实验均以随机顺序进行,以减少实验顺序的影响。它总共包含 305 304 行和 16 列,结构为连续多元时间序列,采集频率为 10 s 进行一次:每行代表特定时间戳的 EN54 测试室中特定传感器节点位置(CO₂、CO、H₂、湿度、不同大小的颗粒物、空气温度和紫外线)的传感器测量值;列对应于传感器测量值,并包含其他标签,如特定于场景的标签(“scenario_label”),区分“正常”(背景)和“异常”(火灾或干扰场景)的标签(“anomaly_label”)以及将数据分类为“干扰”、“火灾”与“背景”的三元标签(“ternary_label”)。该数据集包含 82.98% 的背景数

据点和 17.02% 的异常数据点,可进一步划分为 12.50% 的火灾异常数据点和 4.52% 的干扰异常数据点。“Sensor_ID”列可用于访问来自不同传感器节点位置的数据。本文只采用 4 类火灾场景数据作为数据集,对无关场景以及干扰场景进行了剔除,并将每种场景下包含的 9 个不同传感器节点阵列作为原始样本。4 类火灾场景数据分别划分为 3 类已见类和 1 类未见类,其中训练集仅包含已见类数据,测试集包含已见类别和未见类别的数据,实验采用 80% 作为训练集,20% 作为测试集的策略,并通过 5 折交叉验证,综合各折实验结果的平均指标以评估模型效果。

2.1.2 评价指标 本文采用预警和分类常用指标,准确率(Accuracy)、召回率(Recall)、精确率(Precision)、特异性(Specificity)、F1 分数、误报率(False Alarm Rate, FAR)、漏报率(Missed Detection Rate, MDR)以及 AUC 值作为模型泛化能力评价指标^[32-33],具体计算公式如下:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (8)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (9)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (10)$$

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (11)$$

$$\text{FAR} = \frac{\text{FP}}{\text{FP} + \text{TN}} \quad (12)$$

$$\text{MDR} = \frac{\text{FN}}{\text{FN} + \text{TP}} \quad (13)$$

$$\text{F1} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}} \quad (14)$$

$$\text{AUC} = \int_0^1 \text{Recall} \, d(\text{Specificity}) \quad (15)$$

其中, TP 表示正例预测为正例的个数, FP 表示负例预测为正例的个数, FN 表示正例预测为负例的个数, TN 表示负例预测为负例的个数。为了更好地描述模型准确率、精确率、召回率、特异性以及 F1 值等评价指标,引入了混淆矩阵和 ROC(Receiver Operating Characteristic)曲线的概念。

2.1.3 元学习模型架构 本文的元学习架构中使用 PyTorch 深度学习框架,实验环境为一块 NVIDIA GeForce RTX 3060 GPU。训练过程采用 Adam 优化器,学习率设置为 0.001,损失函数为 CrossEntropyLoss^[34]。训练的 Epoch 次数设置为 100, Episodic 设置为 10,少样本参数 N, K, Q 分别调整为 3, 4, 2。表 1 列出了

表 1 Meta-Transformer 编码器超参数对比

Table 1 Meta-Transformer encoder hyperparameter comparison

Experiment	Layer	Head	Hidden D	MLP	Accuracy/%	Inference time/s
1	1	2	32	16	85.72	0.015
2	2	4	32	16	94.86	0.021
3	2	4	64	32	95.25	0.023
4	3	4	64	32	94.42	0.028
5	2	8	64	32	95.83	0.035

本文在 Meta-Transformer 编码器中,针对不同层数(Layer)、注意力头数(Head)、隐藏层维度(Hidden D)与前馈网络维度(MLP)等超参数组合所做的 5 次寻优实验。综合准确率与推理效率,本文最终选用两层、8 个注意力头、Hidden $D=64$ 、MLP=32 的方案,兼具较高的准确性与快速性。

2.2 早期预警实验结果分析

2.2.1 OCSVM 模型效果分析 在验证基于 OCSVM 预警模型有效性的实验中,通过对所有燃烧场景实验数据的分析,分别统计了 TP(真阳性)为 696, FP(假阳性)为 10, TN(真阴性)为 166, FN(假阴性)为 10,并计算了多项性能指标,结果如表 2 所示。其中,准确率为 97.73%,精确率为 98.58%,召回率为 98.58%,F1 值为 98.58%,误报率和漏报率分别为 5.68% 与 1.42%。这些指标表明,OCSVM 模型在火灾早期异常监测中的整体性能较高,能够有效平衡精度与召回率,确保火灾预警的可靠性与准确性。

表 2 预警结果指标

Table 2 Early warning result indicators

Accuracy/%	Precision/%	Recall/%	F1-Score/%	FAR/%	MDR/%
97.73	98.58	98.58	98.58	5.68	1.42

2.2.2 不同单类分类器的对比实验 为了更直观地体现 OCSVM 预警模型的性能,并展示其在使用线性核时的优势,本文对多种常见的单类分类器进行了对比实验,结果如表 3 所示,综合准确率、误报率、漏报率 3 项指标,OCSVM(Linear)拥有最高的准确率(97.73%)和最低的误报率(5.68%)、漏报率(1.42%),在整体性能上优于其他单类分类器。

2.2.3 预警结果可视化 此外,实验还输出了 2 类关键的可视化结果(图 4),分别包含了 4 个燃烧场景(电缆、蜡、棉和木材)的特征指标,以进一步验证 OCSVM 模型在燃烧监测中的表现。一方面,OCSVM 识别出的燃烧起始点序列图直观展示了 CO、H₂、VOC、PM5 几个典型传感器特征的变化趋势。实验

表 3 基于不同单类分类器的预警效果

Table 3 Early warning effects based on different single-class classifiers

Model	Accuracy/%	FAR/%	MDR/%
OCSVM(Linear)	97.73	5.68	1.42
OCSVM(RBF)	95.92	12.50	3.12
SVDD(Linear)	97.05	7.39	1.84
Isolation forest	96.37	9.09	2.27
Autoencoder	95.92	10.28	1.42

结果表明,在燃烧过程中,这些传感器特征表现出明显的上升趋势,尤其是在燃烧起始点附近,特征值的上升幅度更加显著。这种趋势与实际燃烧过程中的物理化学反应相符,验证了传感器数据对火灾早期检测的敏感性。

另一方面,OCSVM 内部指标异常分数图提供了模型对异常程度的动态评估。图 4 中显示,随着燃烧过程的加剧,异常分数呈现快速上升的趋势,尤其在燃烧初期特征出现明显波动后,异常分数显著增大。这种变化趋势表明,OCSVM 模型能够对燃烧过程中的异常行为进行及时捕捉,并根据异常分数的增长来识别潜在的火灾风险。

综合实验结果表明,基于 OCSVM 的预警方法能够在燃烧早期通过异常分数变化与特征走势的结合,准确识别燃烧起始点并实现高效的火灾预警。这进一步证明了该方法在实际火灾监测中的实用性与可靠性,为智能火灾预警系统的优化设计提供了理论依据和实践支持。

2.3 场景识别分类结果分析

2.3.1 不同元学习架构的对比实验 本文对比了 Meta-Transformer、ProtoNet、Relation Networks 以及 DAE-LSTM 的元学习模型的平均准确度、模型大小以及推理时间,结果如表 4 所示。对于 DAE-LSTM 模型,本文利用基于编码器的框架将其修改为元学习结构后再进行比较。结果表明,Meta-Transformer 在 4 类元学习架构中的场景分类准确率最高(96.17%),虽然 Meta-Transformer 在推理时间(0.023 s)与模型大小(0.161 MB)上并不具备优势,但是它能够在准确率上取得最优结果,这一微小的成本换来了更高的准确性。

2.3.2 基于 Meta-Transformer 架构的场景识别结果 在场景识别实验中,为了验证本文提出的基于 Meta-Transformer 的少样本学习框架的有效性,对多种燃烧场景进行了分类实验。具体来说,实验将电缆、蜡、棉和木材的其中之一分别作为未见类燃烧场景,




图 4 4 个燃烧场景的可视化以及内部评价指标

Fig. 4 Visualization of four burning scenarios and internal evaluation indicators

其余 3 种场景则作为已见类别。通过这种设置, 评估模型在已见类场景中的分类性能以及对未见类场景的泛化能力。实验结果以混淆矩阵形式呈现, 如图 5 所示。当电缆作为未见类时, 模型对已见类别的分类准确率为 99.67%, 对未见类的分类准确率为 100%; 当蜡作为未见类时, 已见类别的分类准确率为 95%, 未见类的分类准确率为 100%; 当棉作为未见类时, 已见类别的分类准确率为 100%, 未见类的分类准确率为 85%; 当木材作为未见类时, 已见类别的分类准确率为 94.67%, 未见类的分类准确率为 93%。这些结果表明, Meta-Transformer 模型在已见类场景中的

表 4 基于不同元学习模型的效果表现

Table 4 Performance based on different meta-learning models			
Model	Accuracy/%	Memory/MB	Inference time/s
Meta-Transformer	96.17	0.161	0.023
ProtoNet	89.58	0.019	0.013
Relation Networks	85.00	0.021	0.016
DAE-LSTM	93.92	0.013	0.058

分类性能较为稳定, 并且对部分未见类场景(如电缆和蜡)具有较高的泛化能力。然而, 对于某些未见类(如棉和木材), 虽然分类准确率相对略低, 但仍能够




图 5 4 种燃烧场景下的混淆矩阵指标

Fig. 5 Confusion matrix indicators under four burning scenarios

在少样本的条件下实现较为有效的识别。

此外,为进一步验证分类结果的可靠性与模型的辨别能力,实验输出了相应的 ROC 曲线和不同燃烧场景对应的 AUC 值(如图 6 所示)。ROC 曲线清晰地展示了模型在不同分类阈值下的性能,AUC 值则量化地反映了模型的整体分类能力。实验结果显示,无论是已见类还是未见类,Meta-Transformer 框架在各类场景下的 AUC 值均保持在较高水平,表明模型能够有效区分正常燃烧场景与异常燃烧场景。

2.3.3 场景识别快速性验证 在验证分类性能的同时,本文进一步对模型在分类任务中的快速性与实时性进行了详细分析(如图 7 所示)。实验通过调整时间窗口的大小(即用于分类的连续数据片段长度),研究了时间窗口长度对分类准确率的影响,以评估模型在有限数据条件下的响应能力与性能表现。实验采用的传感器数据采集频率为每 10 s 一次,并通过不同长度的时间窗口进行测试。

在时间窗口达到 60 个时间点(10 min)时,无论是已见类还是未见类的分类性能都表现出显著提

升,由此得到了以下分类性能指标:当电缆作为未见类时,已见类的分类准确率为 95.16%,未见类的分类准确率为 100%;当蜡作为未见类时,已见类的分类准确率为 95%,未见类的分类准确率为 100%;当棉作为未见类时,已见类的分类准确率为 95%,未见类的分类准确率为 86.67%;当木材作为未见类时,已见类的分类准确率为 91.67%,未见类的分类准确率为 95%。实验结果表明,随着时间窗口的增加,模型能够逐步捕捉到更充分的时间序列特征,从而提高分类准确率。这些结果进一步验证了时间窗口长度对分类性能的影响。较大的时间窗口使得模型能够提取到更加完整的特征信息,从而在已见类和未见类的分类任务中均取得良好的表现。同时,模型在 10 min 时间窗口内即可实现对已见类和未见类的高效分类,这种快速分类能力对于实时监测系统至关重要。实验结果充分说明,本文提出的框架能够在火灾监测场景中通过少样本数据实现高效场景分类,具有较强的实际应用价值和适应性。

实验结果充分验证了基于 Meta-Transformer 的




图 6 4 种燃烧场景下的 ROC 曲线

Fig. 6 ROC curves under four burning scenarios




图 7 不同时间窗口尺寸的模型准确率

Fig. 7 Model accuracy for different time window sizes

少样本学习框架在火灾场景分类中的准确性和快速性。在不同时间窗口长度下,模型能够平衡分类性能和响应速度,通过提取有限时间序列数据中的特征信息,实现了对已见类和未见类场景的高效分类。

从准确性来看,模型对已见类场景的分类表现稳定,对未见类场景的识别能力突出,展现了少样本学习框架的优势;从实时性和快速性来看,模型能够在短时间窗口内完成高效的分类任务,无需依赖完整数据,显著缩短了预警和响应时间。这一性能对于火灾监测系统具有重要意义:模型能够快速捕捉场景特征变化,为火灾风险的动态监测与分类提供强有力的技术支持,同时为高风险场景的实时智能化监测和应急处理奠定了基础,有效提升系统的整体效率和可靠性。

3 结 论

本文提出了一种融合 OCSVM 与少样本学习框架的预警分类策略,针对传统火灾燃烧场景监测中异常特征捕捉不及时、分类精度不足及样本条件有限的问题,设计了实时预警与分类解决方案,并通过多项实验验证了其有效性与适用性。

在早期预警方面,基于 OCSVM 的异常检测模块通过滑动窗口数据处理方法对多传感器阵列采集的综合特征数据进行分析。实验表明,该模块能够在燃烧初期快速捕捉异常特征,并实现精准的实时报警。在验证实验中,OCSVM 模型的预警准确率达到 97.73%,同时通过时间窗口与连续性约束策略显著降低了误报率,提升了模型的鲁棒性。之后对比了多种常见的单类分类器,展示了 OCSVM 模型的优势。此外,模型输出的燃烧起始点序列与异常分数图清晰展示了燃烧特征的演化过程,进一步验证了其在火灾监测中的实际应用潜力。

在场景分类方面,基于 Meta-Transformer 的少样本学习框架在少量训练数据下表现出优异的分类性能。通过引入元学习机制,模型能够快速提取任务间的通用特征,实现对已见类场景的高效分类及未见类场景的良好泛化。实验结果表明,在时间窗口长度为 10 min 时,已见类和未见类的分类准确率均达到较高水平(最高分别达 99.67% 和 100%),并且通过调整时间窗口大小进一步验证了模型在分类准确性、实时性和快速性上的平衡能力。这种特性使得模型在有限数据条件下即可快速完成分类任务,为火灾监测与预警系统的动态适应性提供了技术保障。

本文提出的预警分类策略不仅有效解决了火灾

监测中的实时性与准确性问题,还通过少样本学习框架提升了模型在复杂燃烧场景下的泛化能力。该方法能够在火灾燃烧早期实现准确异常检测与快速场景分类,为火灾监测系统的智能化发展提供了理论支持与实践依据,具有较高的应用潜力与推广价值。未来工作考虑引入自适应窗口机制增强模型的鲁棒性与泛化能力,以便模型能够更灵活地应对多阶段燃烧过程。同时,进一步优化多传感器的融合方法,探索该策略在其他动态监测任务中的应用与拓展。

参考文献:

- [1] TORERO J L, GERHARD J I, MARTINS M F, *et al.* Processes defining smouldering combustion: Integrated review and synthesis[J]. *Progress in Energy and Combustion Science*, 2020, 81: 100869.
- [2] MITCHELL H, AMIN R, HEIDARI M, *et al.* Structural hazards of smouldering fires in timber buildings[J]. *Fire Safety Journal*, 2023, 140: 103861.
- [3] 秦蕴竹, 张轶超, 陈玉莹, 等. 阴燃林火的消防技术与策略[J]. *消防科学与技术*, 2025, 44(1): 112-118.
- [4] 张金宝, 万永菁, 林家骏. 一种多传感器信息融合系统效能的评估方法[J]. *华东理工大学学报(自然科学版)*, 2005, 31(2): 263-267.
- [5] 张超. 电气柜火灾预警系统设计[D]. 四川绵阳: 西南科技大学, 2022.
- [6] 夏小兰, 刘旭东, 王新江. 基于图像识别的火灾、烟雾报警系统在光伏区的应用及展望[J]. *水电站机电技术*, 2024, 47(6): 77-80.
- [7] KIM S, LEE S. Maximum likelihood estimation of probabilistic non-suppression model for OECD NPP electrical fire applying non-negative continuous distribution[J]. *Fire Safety Journal*, 2021, 122: 103323.
- [8] NAZIR A, MOSLEH H, TAKRURI M, *et al.* Early fire detection: A new indoor laboratory dataset and data distribution analysis[J]. *Fire*, 2022, 5(1): 11.
- [9] CHEN X, HUANG G, GAO X, *et al.* BN-RA: A hybrid model for risk analysis of overload-induced early cable fires[J]. *Applied Sciences*, 2021, 11(19): 8922.
- [10] ZHANG J, ZHANG B, WANG L, *et al.* The state of the art of combustion behavior of live wires and cables[J]. *Materials Reports*, 2017, 31(15): 1-9.
- [11] YANG M, BIAN Y, YANG J, *et al.* Combustion state recognition of flame images using radial Chebyshev moment invariants coupled with an IFA-WSVM model[J]. *Applied Sciences*, 2018, 8(11): 2331.
- [12] FONOLLOSA J, SOLÓRZANO A, MARCO S. Chemical sensor systems and associated algorithms for fire detection:

- A review[J]. *Sensors*, 2018, 18(2): 553.
- [13] KHAN M M, TEWARSON A, CHAOS M. Combustion Characteristics of Materials and Generation of Fire Products[M]//SFPE Handbook of Fire Protection Engineering. USA: Springer, 2015: 1143-1232.
- [14] JHA S, PATTNAIK F, NANDA S, *et al.* Investigations of thermal effects during pyrolysis of agro-forestry biomass and physicochemical characterizations of biofuel products[J]. *Biocatalysis and Agricultural Biotechnology*, 2024, 61: 103379.
- [15] SUN B, CHENG P, HUANG Y. Few-shot fine-grained forest fire smoke recognition based on metric learning[J]. *Sensors*, 2022, 22(21): 8383.
- [16] LI T, ZHU H, HU C, *et al.* An attention-based prototypical network for forest fire smoke few-shot detection[J]. *Journal of Forestry Research*, 2022, 33(5): 1493-1504.
- [17] LEE J M, DAE-SEONG K. Generating fire objects and few-shot learning optimization method for fire situation detection model[C]//2019 International Conference on Information and Communication Technology Convergence (ICTC). Korea: IEEE, 2019: 1166-1171.
- [18] VERGARA A, VEMBU S, AYHAN T, *et al.* Chemical gas sensor drift compensation using classifier ensembles[J]. *Sensors and Actuators B: Chemical*, 2012, 166: 320-329.
- [19] HESTERBERG T. Weighted average importance sampling and defensive mixture distributions[J]. *Technometrics*, 1995, 37(2): 185-194.
- [20] BOUNSIAR A, MADDEN M G. One-class support vector machines revisited[C]//2014 International Conference on Information Science & Applications (ICISA). Korea: IEEE, 2014: 1-4.
- [21] MIAO X, LIU Y, ZHAO H, *et al.* Distributed online one-class support vector machine for anomaly detection over networks[J]. *IEEE Transactions on Cybernetics*, 2018, 49(4): 1475-1488.
- [22] SHANG W, ZENG P, WAN M, *et al.* Intrusion detection algorithm based on OCSVM in industrial control system[J]. *Security and Communication Networks*, 2016, 9(10): 1040-1049.
- [23] SOLOMON M M, DESROSIER J. Survey paper: Time window constrained routing and scheduling problems[J]. *Transportation Science*, 1988, 22(1): 1-13.
- [24] HOSPEDALES T, ANTONIOU A, MICAELLI P, *et al.* Meta-learning in neural networks: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 44(9): 5149-5169.
- [25] WANG J, ZHAI Y. Prototypical Siamese networks for few-shot learning[C]//2020 IEEE 10th International Conference on Electronics Information and Emergency Communication (ICEIEC). [s.l.]: IEEE, 2020: 178-181.
- [26] SHAW P, USZKOREIT J, VASWANI A. Self-attention with relative position representations[C]//The 16th Annual Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. USA: [s.n.], 2018.
- [27] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C]//Conference on Neural Information Processing System. [s.l.]: [s.n.], 2017.
- [28] CHI Z, WANG Z, YANG M, *et al.* Learning to capture the query distribution for few-shot learning[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021, 32(7): 4163-4173.
- [29] WANG F, CHENG J, LIU W, *et al.* Additive margin softmax for face verification[J]. *IEEE Signal Processing Letters*, 2018, 25(7): 926-930.
- [30] DIEDERIK P K. Adam: A method for stochastic optimization[C]// International Conference on Learning Representations. (No Title), San Diego, CA, USA : Proceedings of Machine Learning Research, 2014.
- [31] VORWERK P, KELLETER J, MÜLLER S, *et al.* Distance-based analysis of early fire indicators on a new indoor laboratory dataset with distributed multi-sensor nodes[J]. *Fire*, 2023, 6(8): 323.
- [32] CHEN T H, WU P H, CHIOU Y C. An early fire-detection method based on image processing[C]//2004 International Conference on Image Processing. Singapore: IEEE, 2004, 3: 1707-1710.
- [33] 许奕杰, 王嵘, 万永菁, 等. 基于 AE-LSTM 网络模型的机场周界入侵报警及分类算法 [J]. 华东理工大学学报 (自然科学版), 2021, 47(3): 323-330.
- [34] MAO A, MOHRI M, ZHONG Y. Cross-entropy loss functions: Theoretical analysis and applications[C]//International Conference on Machine Learning. [s.l.]: PMLR, 2023: 23803-23828.

Combustion Early Warning and Classification Method Based on Multi-Sensor Fusion and Few-Shot Learning

ZHAN Lang¹, GUO Kunlun¹, GU Haixin^{2,3}, WANG Haiwei³, GU Zhen¹, WANG Huifeng¹

(1. School of Information Science and Engineering, East China University of Science and Technology, Shanghai 200237, China; 2. Shanghai Fire Research Institute, Ministry of Emergency Management, Shanghai 200032, China; 3. Key Laboratory of Fire Detection and Early Warning Technology, Shanghai Emergency Management Bureau, Shanghai 200032, China)

Abstract: With the advancement of gas sensing technology, fire early-warning instruments integrating multiple gas sensors exhibit significant application potential in the early detection of combustion, offering a promising approach for fire prevention and rapid intervention. However, multi-sensor systems generate large volumes of heterogeneous data, posing challenges for data processing and fusion. To address the issues of delayed abnormal feature capture and the difficulty of timely classification of combustion scenarios in the early stages of fire incidents, this study proposes an early-warning and classification strategy that integrates the One-Class Support Vector Machine (OCSVM) with a Few-Shot Learning (FSL) framework. This strategy is designed for early combustion warning and scenario recognition. By incorporating a sliding-window data processing method with the OCSVM model, the proposed approach enables early anomaly detection and real-time alarm triggering. Furthermore, leveraging the Meta-Transformer model within a meta-learning framework, the method achieves precise classification of four combustion scenarios. A prototype network module is introduced to enhance the model's ability to recognize unseen scenarios under few-shot learning conditions. Experimental results demonstrate that the proposed method effectively captures abnormal features within the first five minutes of combustion, achieving an early-warning accuracy of 97.73%. Following the warning phase, the recognition accuracy for seen and unseen combustion scenarios reaches 97.33% and 94.50%, respectively. Additionally, in a rapid-response validation, the average recognition accuracy for seen and unseen combustion scenarios within the first ten minutes reaches 94.21% and 95.42%, respectively. This study provides a novel approach for the development of multi-sensor fire early-warning instruments tailored for early combustion detection and recognition. Furthermore, it holds potential for supporting the advancement of intelligent fire emergency management systems.

Key words: burning scene; OCSVM; few-shot learning; prototype network; artificial intelligence

(责任编辑: 王晓丽)