

DOI:10.13296/j.1001-1609.hva.2026.09.012

基于调制周期与通道注意力网络的混合气体识别方法研究

刘伟丰¹, 刘玉芳¹, 钱志祥¹, 任天翼¹, 钟理鹏¹, 汪 泓¹, 刘 杰²,
武予然², 赵东辉²

(1. 湖南大学电气与信息工程学院, 长沙 410082; 2. 郑州电力高等专科学校电力工程学院, 郑州 450000)

摘要: 温度调制技术能够显著提升金属氧化物半导体气体传感器的选择性, 增强其识别能力。然而, 现有方法对温度调制过程与气体吸附—反应动力学共同作用下形成的结构化动态响应信息利用不足, 且预测过程可解释性有限。为此, 提出一种基于传感器—周期注意力机制的混合气体体积分数预测方法。通过在调制周期维度建模响应演化规律, 在传感器通道维度刻画多通道交互关系, 并通过可学习重要性加权机制融合关键传感器—周期特征, 实现混合气体体积分数联合预测。以电缆缓冲层烧蚀释放气体为对象的实验结果表明, 所提方法较所选对比模型具有更优预测性能, 体积分数预测决定系数达到0.99。同时, 能够反映不同时序响应对预测结果的贡献, 为混合气体动态响应分析提供可解释依据。

关键词: 气体传感器阵列; 温度调制; 可解释性分析; 气体体积分数识别; 注意力机制; 金属半导体氧化物传感器

Study on Gas Mixture Identification Method Based on Modulation Cycle and Channel Attention Network

LIU Weifeng¹, LIU Yufang¹, QIAN Zhixiang¹, REN Tianyi¹, ZHONG Lipeng¹, WANG Feng¹,
LIU Jie², WU Yuran², ZHAO Donghui²

(1. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China; 2. College of Electric Power Engineering, Zhengzhou Electric Power College, Zhengzhou 450000, China)

Abstract: Temperature modulation technology can significantly improve the selectivity of metal oxide semiconductor gas sensors and enhance their identification capability. However, existing methods inadequately utilize the structured dynamic response information formed by the synergistic interplay between the temperature modulation process and gas adsorption-reaction kinetics. Moreover, the interpretability of their prediction processes remains limited. To address these limitations, in this paper a gas mixture concentration prediction method based on a sensor-period attention mechanism is proposed. By modeling the response evolution patterns along the modulation-period dimension and characterizing multi-channel interaction relationships across the sensor channel dimension, a learnable importance weighting mechanism is employed to fuse critical sensor-period features, thereby enabling joint prediction of gas mixture concentrations. Experimental results targeting the gases released from the ablation of the cable buffer layer demonstrate that the proposed method achieves superior prediction performance compared to the selected benchmark models, with a coefficient of determination of 0.99 for concentration prediction. Furthermore, the method is capable of revealing the contributions of different temporal responses to the prediction results, thereby providing an interpretable basis for dynamic responses analysis of gas mixture.

Key words: gas sensor array; temperature modulation; interpretability analysis; gas concentration identification; attention mechanism; metal oxide semiconductor sensor

收稿日期:2026-03-22; 修回日期:2026-05-21

基金项目:国家自然科学基金项目(52577157);河南省科技攻关项目(262102241067, 262102240131)。

Project Supported by National Natural Science Foundation of China(52577157), Key Scientific and Technological Projects in Henan Province(262102241067, 262102240131).

0 引言

低分子烃类气体如甲烷、乙炔等,是油浸式变压器、电力电缆等设备绝缘劣化和故障发展过程中的重要特征气体,其组分及体积分数变化可反映过热、局部放电和电弧放电等缺陷状态^[1-3]。因此,快速获取典型气体成分与体积分数信息,对电力设备早期缺陷识别、状态评估和风险预警具有重要意义^[4]。目前,气相色谱、拉曼光谱和光声光谱等检测技术已在电力设备故障气体分析中得到广泛研究,具有灵敏度高、定量准确等优点^[5-9];但此类方法通常依赖复杂采样流程,现场部署和在线监测成本较高。

金属氧化物半导体气体传感器具有结构简单、响应快速、灵敏度高和易于阵列化集成等特点,适合面向现场的故障气体检测^[10-13]。然而,金属半导体氧化物(MOS, metal-oxide semiconductor)传感器对相似低分子烃类气体普遍存在交叉敏感和响应重叠问题,限制了其在复杂混合气体环境下的定量识别能力。

为提升MOS气体传感器对交叉敏感气体的区分能力,温度调制通常通过改变微加热器驱动电压,获取不同反应动力学状态下的动态响应信息^[14-16]。与恒温工作方式相比,温度调制能够扩展响应特征维度^[15, 17]。然而,温度调制使传感器输出同时包含周期内波形变化、周期间演化规律以及多通道响应差异,增加了动态响应信号的结构复杂度。因此,如何有效表征温度调制响应中的多维时序信息,成为提升混合气体定量识别性能的关键。

近年来,温度调制响应与深度学习结合已被用于MOS气体传感器的气体识别与体积分数预测。Lee等将温度调制响应与卷积神经网络结合,实现多气体分类和体积分数估计^[18];Hu等利用FFT、DWT、PSO-CNN提取动态调制特征,提高了气体识别能力^[19];Ji等基于动态温度调制实现多组分气体检测^[20];Wang等采用多尺度双向时序卷积网络对工业有机气体进行识别与定量分析^[21]。上述研究表明,温度调制响应中包含丰富的气体判别信息,深度学习模型能够从动态响应信号中提取有效特征,是缓解MOS传感器交叉敏感问题的重要途径^[22]。

然而,现有方法多将温度调制响应作为普通时间序列、频域特征或图像化特征进行处理,对温度调制阵列响应中固有的结构化信息利用仍不充分。具体而言,温度调制响应不仅包含单个调制周期内由加热和冷却过程引起的局部波形变化,还包含同一传感器在不同调制周期之间由气体吸附、反应和扩散过程引起的动态演化规律;同时,不同敏

感材料传感器在同一调制周期内存在交叉敏感与互补响应关系。若忽略调制周期维度和传感器通道维度之间的结构差异,可能限制模型对混合气体动态响应特征的表征能力。此外,现有研究侧重于提升预测精度,对关键传感器通道和关键调制周期响应区域的贡献分析相对不足,模型预测过程的可解释性仍有待提高^[23-26]。

基于上述分析,文中提出一种基于调制周期与通道注意力网络的混合气体体积分数预测方法(MCCAN, modulation - cycle and channel attention network)。研究主要贡献如下:首先,将温度调制传感器阵列响应重构为传感器通道、调制周期和周期内采样点组成的结构化动态响应张量,以显式表征温度调制响应的周期结构和多通道特性;其次,构建调制周期与通道注意力编码器,分别建模同一传感器在不同调制周期之间的动态演化关系,以及同一调制周期内不同传感器通道之间的耦合关系;最后,引入传感器一周重要性加权机制,实现混合气体体积分数联合预测,并为分析不同传感器通道和调制周期对预测结果的贡献提供依据。文中其余部分安排如下:第1节介绍实验平台、传感器阵列和数据获取方法;第2节阐述所提模型;第3节给出性能对比、消融实验和可解释性分析;第4节总结全文。

1 实验平台

1.1 气体检测系统设计

气体敏感检测平台主要由标准气体、质量流量控制器、测试气室、直流电源、数据采集卡和上位机组成,见图1。实验所用标准气体包括甲烷(1 000 ppm)($1 \text{ ppm}=1 \times 10^{-6}$)、乙炔(200 ppm)和空气。




图1 气体敏感分析系统

Fig. 1 Gas sensing and analysis system

测试气室用于固定气体传感器阵列并保证混合气体与敏感元件充分接触,气室体积约为0.6 L,以保证不同体积分数条件下气体流量一致。直流电源(ETM-60 V 5 A)为传感器阵列及温度调制电路提供工作电压。传感器阵列输出的模拟电压信号经数据采集卡(NIUSB-6341)采集并传输至上位机。实验过程中总流量保持为200 sccm。

1.2 基于温度调制的金属板氧化物半导体传感器阵列

温度调制 MOS 气体传感器阵列的结构示意图和实物图见图2。该装置主要由调制信号发生单元、MOS 气体传感器阵列单元、工作模式切换单元和功率/信号接口组成。




图2 气体传感阵列原理图和实物图

Fig. 2 Schematic diagram and physical image of the gas sensor array device

调制信号发生单元由定时器 IC 及其外围阻容元件构成,可产生周期性方波调制信号。通过调节定时电位器和电容参数改变加热回路的导通时间、关断时间和占空比,实现对传感器工作温度的周期性调制。实验中温度调制周期设置为10 s,占空比为10%。MOS 气体传感器阵列由4种商用传感器组成,型号分别为TGS2600、TGS2603、TGS2611、TGS2619,均由 Figaro Engineering Inc.提供。工作模式切换单元由 MOSFET 和滑动开关组成。其中,MOSFET 受调制信号驱动,用于控制传感器加热回路的周期性通断;滑动开关用于实现温度调制模式与恒温工作模式之间的切换。功率/信号接口同时承担装置供电和阵列响应电压输出功能。

温度调制参数依据 MOS 传感器的加热电压—

工作温度特性确定。较高占空比可保证传感器在加热阶段具有充分升温时间,使响应信号保持有效变化;适当的冷却阶段则可增强温度扰动带来的动态响应差异,同时避免传感器温度过低导致输出信号接近无效区间。

如图3所示,温度调制条件下的 MOS 阵列响应信号具有明显的结构化动态特征。从气体敏感过程看,周期性加热与冷却会改变敏感材料表面吸附、脱附及表面反应速率,使传感器输出在单个调制周期内呈现快速起伏,形成周期内局部波形特征;在连续气体暴露过程中,气体扩散、表面覆盖状态变化及反应累积效应会使响应在不同调制周期之间缓慢变化,形成跨调制周期的长期演化趋势。前者反映温度扰动引起的瞬态响应变化,后者反映气体—敏感材料相互作用的累积效应。




图3 500 ppm CH₄条件下温度调制 MOS 气体传感器阵列的响应信号

Fig. 3 Response signals of the temperature-modulated MOS gas sensor array under 500 ppm CH₄

基于上述响应特征,研究将调制周期作为响应重构的基本组织单元,传感器响应划分为由多个温度调制周期构成的时间序列。既保留了单个调制周期内的瞬态波形变化,又显式刻画不同调制周期之间的响应演化,使输入特征组织方式与温度调制

过程的物理结构保持一致。

2 基于调制周期—通道注意力编码器的气体识别模型

如图4所示,左侧为MCCAN的整体算法流程,

包括特征嵌入、位置编码、调制周期—通道注意力建模、重要性加权汇聚和双输出体积分数预测;右侧为周期维度注意力和传感器通道维度注意力的具体结构。




图4 MCCAN模型结构及算法流程示意图

Fig. 4 Schematic diagram of the MCCAN model structure and algorithm workflow

模型以结构化动态响应张量作为输入,其中结构化动态响应信息包括:单个调制周期内由加热和冷却过程形成的周期内波形特征;连续调制周期之间的响应演化特征;不同MOS传感器通道之间由敏感材料和响应特性差异形成的互补响应特征。

在响应嵌入层中,模型对每个传感器通道在每个调制周期内的时间点 T 响应序列进行特征映射,将其由原始时间采样空间转换为 d 维隐空间表示。为区分不同传感器通道和不同调制周期的位置差异,嵌入特征中引入可学习的位置编码。

经响应嵌入层和位置编码后,传感阵列动态响应 X 被转换为传感器—周期特征 $H^0 \in \mathbf{R}^{B \times C \times P \times d}$,其中 B 为批大小; C 为传感器通道数; P 为调制周期数; d 为隐特征维度。

由于温度调制响应同时包含单一传感器的周期演化特性和多传感器之间的互补响应关系,文中采用先周期维度、后传感器维度的逐级注意力建模方式。首先,周期维度注意力用于描述同一传感器通道在不同调制周期之间的动态关联,使每个传感器通道的特征先融合其跨周期响应演化信息。

首先,周期维度注意力用于描述同一传感器通道在不同调制周期之间的动态关联。对于第 b 个样本的第 c 个传感器通道,其周期维度特征表示为

$$H_{b,c,:}^0 \in \mathbf{R}^{P \times d} \quad (1)$$

周期维度多头注意力以上述特征作为查询、键和值,得到

$$H_{b,c,:}^{\text{per}} = \text{MHA}_{\text{per}}(H_{b,c,:}^0) \quad (2)$$

式(2)中: $\text{MHA}_{\text{per}}(\cdot)$ 为周期维度注意力映射; $H_{b,c,:}^{\text{per}}$ 为周期建模后的特征。该阶段使每个周期的响应特征能够融合同一传感器其他周期的信息,用于表征温度调制过程中气体响应状态的周期演化规律。

在获得周期上下文特征后,传感器维度注意力进一步描述同一调制周期内不同传感器通道之间的响应关系。对于第 b 个样本的第 p 个调制周期,其通道维度特征表示为

$$H_{b,:,p}^{\text{per}} \in \mathbf{R}^{C \times d} \quad (3)$$

特征由 C 个传感器通道在当前调制周期下的周期上下文特征构成。为实现跨通道信息的有效聚合,引入与第 p 个调制周期对应的可学习中转向量

$$R_p \in \mathbf{R}^{K \times d} \quad (4)$$

式(4)中, K 为中转向量个数。该向量作为可学习查询表示,用于提取当前调制周期下的跨通道响应信息。

跨通道聚合过程表示为

$$M_{b,p} = \text{MHA}_{\text{agg}}(R_p, H_{b,:,p}^{\text{per}}, H_{b,:,p}^{\text{per}}) \quad (5)$$

式(5)中: $\text{MHA}_{\text{agg}}(\cdot)$ 为信息聚合映射; $M_{b,p}$ 为第 b 个样本在第 p 个周期内的跨通道中间特征,该特征

表示当前周期内多传感器通道的响应特征。

在此基础上,以各传感器通道特征为查询,以跨通道中间特征为键和值,将聚合后的通道信息重新映射至各传感器通道

$$H_{b,:p,:}^{\text{sen}} = MHA_{\text{dist}}(H_{b,:p,:}^{\text{per}}, M_{b,p}, M_{b,p}) \quad (6)$$

式(6)中, $MHA_{\text{dist}}(\cdot)$ 为通道信息分发注意力。每个传感器通道特征均融合了当前周期内其他传感器通道的互补响应信息,得到传感器维度交互后的特征。

随后,通过残差连接、层归一化和前馈网络对周期上下文特征与通道交互特征进行更新,得到注意力编码后的特征表示

$$H = F(H^{\text{per}}, H^{\text{sen}}) \quad (7)$$

式(7)中, $F(\cdot)$ 为特征更新映射。由此得到的 H 同时包含当前传感器当前周期的局部响应信息、同一传感器的跨周期演化信息,以及同一周期内其他传感器通道的互补响应信息。

为在全局特征汇聚过程中保留关键传感器一周期信息,模型引入重要性加权汇聚层。通过可学习评分网络为每个传感器一周期位置生成标量评分

$$S_{b,c,p} = f_{\text{score}}(H_{b,c,p}) \quad (8)$$

式(8)中: f_{score} 为可学习评分网络; $S_{b,c,p}$ 为对应位置的重要性评分。随后,在同一样本内部对所有传感器一周期位置进行归一化,得到重要性权重

$$\alpha_{b,c,p} = \frac{\exp(s_{b,c,p})}{\sum_{c'=1}^C \sum_{p'=1}^P \exp(s_{b,c',p'})} \quad (9)$$

式(9)中, $\alpha_{b,c,p}$ 为第 c 个传感器、第 p 个调制周期对应特征的相对权重。

随后,模型根据重要性权重对全部传感器一周期特征进行加权求和,得到第 b 个样本的全局特征

$$g_b = \sum_{c=1}^C \sum_{p=1}^P \alpha_{b,c,p} H_{b,c,p} \quad (10)$$

式(10)中, g_b 为第 b 个样本的全局特征。

最后,全局特征 g_b 输入回归输出层,得到混合气体的体积分数预测结果

$$\hat{y}_b = f_{\text{reg}}(g_b) = [\hat{y}_{b,1}, \hat{y}_{b,2}] \quad (11)$$

式(11)中, $f_{\text{reg}}(\cdot)$ 为回归输出网络; $\hat{y}_{b,1}$ 和 $\hat{y}_{b,2}$ 分别为第 b 个样本中两个混合气体的预测体积分数。

3 实验结果与分析

3.1 数据集及预处理

实验体积分数组合参考电缆缓冲层烧蚀实验

释放气体的测量结果设置,验证温度调制传感器阵列对典型烧蚀气体响应特征的建模能力。如表1所示的17种体积分数气体的传感阵列响应信号被采集,每种样本在相同实验条件下测量了10次,构建了包含170个标记样本的数据集。每个样本采样时间为400 s,采样频率为10 Hz,其中目标气体响应阶段为100 s,空气冲洗/恢复阶段为300 s,每个样本构成4 000×4维矩阵。此外,环境温度约为25℃,相对湿度为50%~55%,并采用同一传感器阵列完成气体响应数据采集。

表1 实验样本与气体体积分数与组分

Table 1 Gas composition and concentration levels of experimental samples

样本序列	气体类型	CH ₄ 体积分数/ppm	C ₂ H ₂ 体积分数/ppm
1	CH ₄	1 000	0
2	CH ₄	900	0
3	CH ₄	700	0
4	CH ₄	500	0
5	CH ₄	300	0
6	CH ₄	100	0
7	C ₂ H ₂	0	200
8	C ₂ H ₂	0	180
9	C ₂ H ₂	0	140
10	C ₂ H ₂	0	100
11	C ₂ H ₂	0	60
12	C ₂ H ₂	0	20
13	Mixture	900	20
14	Mixture	700	60
15	Mixture	500	100
16	Mixture	300	140
17	Mixture	100	180

上述样本同时包含单一CH₄、单一C₂H₂及CH₄/C₂H₂混合气体响应,用于考察模型在不同组分及体积分数组合条件下对温度调制动态响应的建模能力。

3.2 实验设置和结果

混合气体识别方法在Python 3.12 on Pytorch 2.5.1。模型训练和测试在16 GB内存的NVIDIA GeForce RTX 5080上进行。为了提升样本利用率以及可靠评估模型性能,采用五倍交叉验证,在每个折叠中,60%的数据被用于训练模型,20%的样本作为验证集,20%的数据作为测试集。实验结果以五折交叉验证测试集结果的平均值±标准差表示,用于反映模型在不同数据划分下的平均性能及波动情况。

为降低人工调参引入的主观性并提升搜索效率,采用贝叶斯优化在预设超参数空间内自动寻

优,见表2。

表2 贝叶斯超参数优化

Table 2 Hyperparameter search space for Bayesian optimization

超参数	搜索空间	采样方式
学习率	$[1 \times 10^{-5}, 1 \times 10^{-2}]$	对数均匀采样
Num_filters	[16, 128]	对数均匀整数采样
Kernel_size	[3, 15]	离散均匀整数采样
隐藏层维度	[32, 128]	对数均匀整数采样
编码器层数	[1, 4]	离散均匀整数采样

3.3 基于交叉验证的性能比较

研究将所提模型与 1DCNN、GRU、LSTM、

ResNet、Transformer 进行比较。所有方法均采用五折交叉验证进行评估,并通过贝叶斯优化在各自预设的超参数搜索空间内确定最优配置,各方法的超参数搜索空间范围在附录。

如表3所示,所提模型在CH₄和C₂H₂两个体积分数预测任务中均取得最优平均性能。对于CH₄预测, MCCAN 的 e_{RMSE} 、 e_{MAE} 、 R^2 分别为 30.43 ± 5.34 、 21.12 ± 2.84 、 $0.992 6 \pm 0.002 5$; 对于C₂H₂预测, e_{RMSE} 、 e_{MAE} 、 R^2 分别为 6.79 ± 0.96 、 4.54 ± 0.47 、 $0.990 9 \pm 0.002 7$ 。上述结果表明,所提模型在不同交叉验证划分下均保持了较高的预测精度和较小的性能波动。

表3 性能比较

Table 3 Comparison between the proposed method and existing methods

模型	$e_{RMSE_CH_4}$	$e_{MAE_CH_4}$	$R^2_CH_4$	$e_{RMSE_C_2H_2}$	$e_{MAE_C_2H_2}$	$R^2_C_2H_2$
1DCNN	105.16±32.42	73.80±25.49	0.902 5±0.062 7	14.06±2.79	10.69±3.58	0.959 5±0.018 0
GRU	102.84±21.09	69.15±18.47	0.908 2±0.049 8	12.75±1.56	9.01±1.42	0.967 1±0.010 7
LSTM	118.60±23.91	86.23±22.91	0.884 9±0.043 9	16.38±5.87	11.72±3.13	0.940 6±0.044 5
ResNet	55.57±20.85	41.86±14.99	0.971 1±0.021 2	10.41±2.38	8.16±2.60	0.977 6±0.010 1
Transformer	63.27±33.57	44.01±25.30	0.962 2±0.036 5	8.85±2.77	5.82±1.75	0.982 9±0.010 9
InceptionTime	49.94±10.37	34.74±6.72	0.979 4±0.008 0	8.79±0.94	6.65±0.79	0.984 7±0.002 3
MCCAN	30.43±5.34	21.12±2.84	0.992 6±0.002 5	6.79±0.96	4.54±0.47	0.990 9±0.002 7

与各指标下表现最优的对比模型进行比较。在CH₄预测中, MCCAN 相较于最佳对比模型 InceptionTime, e_{RMSE} 和 e_{MAE} 分别降低 39.06% 和 39.22%; 在C₂H₂预测中, MCCAN 相较于 e_{RMSE} 最优的对比模型 InceptionTime, e_{RMSE} 降低 22.76%, 相较于 e_{MAE} 最优的对比模型 Transformer, e_{MAE} 降低 22.11%。上述结果说明, MCCAN 在不同气体体积分数预测任务中均能有效降低预测误差, 并表现出较好的泛化稳定性。

文中比较了不同模型在各体积分数水平下的预测误差见图5。对于CH₄预测, 1DCNN、GRU、LSTM 在中高体积分数区间误差明显增大, Transformer 在 1 000 ppm 体积分数点误差较高, ResNet 在部分体积分数点表现较好但整体波动仍较明显。InceptionTime 在 500 ppm 体积分数点取得较低误差, 但在高体积分数区间误差仍有增加。相比之下, MCCAN 在 0、100、300、700、900 ppm 等多个体积分数水平下均保持较低误差, 仅在 1 000 ppm 处误差有所上升, 但整体仍优于多数对比模型。

对于C₂H₂预测, 各模型之间的误差差异相对较小, 但在 60、100、180、200 ppm 等体积分数水平下仍能观察到明显差别。其中, InceptionTime 在部分体积分数点表现出较低误差, 而 MCCAN 在 60、180 ppm 体积分数水平下优势较为明显, 并在多数体积分数点上保持较低的误差水平。该结果表明, MCCAN




图5 不同体积分数下模型误差比较

Fig. 5 Comparison of model errors at different concentrations

对不同乙炔体积分数条件下的响应特征具有较稳定的建模能力。

综上, MCCAN 的性能优势并非来自单一体积分数区间, 而是在多个CH₄和C₂H₂体积分数水平上均表现出较好的误差控制能力, 体现了其在双气体体积分数预测任务中的稳定性和泛化能力。

3.4 消融实验

为进一步分析调制周期注意力模块和传感器

注意力模块在所提模型中的作用,分别移除跨传感器注意力模块和去除跨调制周期注意力模块,验证两

个模块在回归性能上的贡献。五折交叉验证下不同消融模型测试结果的平均值±标准差见表4。

表4 消融性能比较

Table 4 Comparison of ablation performance

模型	$e_{\text{RMSE_CH}_4}$	$e_{\text{MAE_CH}_4}$	$R^2_{\text{CH}_4}$	$e_{\text{RMSE_C}_2\text{H}_2}$	$e_{\text{MAE_C}_2\text{H}_2}$	$R^2_{\text{C}_2\text{H}_2}$
完整 MCCAN	30.43±5.34	21.12±2.84	0.992 6±0.002 5	6.79±0.96	4.54±0.47	0.990 9±0.002 7
去除跨传感器注意力模块	36.32±9.86	24.53±5.03	0.989 1±0.005 8	8.27±2.20	5.89±2.07	0.985 9±0.007 9
去除跨调制周期注意力模块	46.40±4.81	31.21±3.86	0.983 1±0.003 5	12.68±4.74	7.79±1.91	0.965 2±0.028 6

消融实验结果见表4。完整 MCCAN 在 CH_4 和 C_2H_2 两个回归任务中均取得最优平均性能。与完整模型相比,去除跨传感器注意力模块和去除跨调制周期注意力模块后, e_{RMSE} 和 e_{MAE} 均增大, R^2 均降低,表明两类注意力模块均对模型性能提升具有有效贡献。从响应机理角度看,去除跨调制周期注意力后性能下降更明显,说明连续调制周期中的响应演化信息对体积分数预测具有重要作用;去除跨传感器注意力后性能同样下降,说明不同传感器通道之间的互补响应信息有助于提升混合气体识别能力。

具体来看,去除跨调制周期注意力模块后性能退化最为明显。 CH_4 的 e_{RMSE} 由 30.43 增大至 46.40, C_2H_2 的 e_{RMSE} 由 6.79 增大至 12.68,说明跨调制周期注意力能够有效建模温度调制响应在不同周期之间的动态演化关系,是提升体积分数回归精度的关键结构。去除跨传感器注意力模块后,模型性能同样下降。 CH_4 的 e_{RMSE} 增大至 36.32, C_2H_2 的 e_{RMSE} 增大至 8.27,说明不同传感器通道之间存在有效互补信息,跨传感器注意力有助于增强多通道响应特征融合能力。

3.5 可解释性分析

为进一步分析模型预测依据,文中对重要性加权汇聚层得到的传感器一周权重进行统计。该权重表示模型在形成全局特征时对不同传感器通道和调制周期位置的相对依赖程度,可用于分析模型更关注哪些响应区域。

由图6(a)可见,不同传感器的归因权重差异明显。传感器3和传感器2的平均权重分别为42.04%和35.88%,高于传感器0的19.33%和传感器1的2.75%。说明模型预测过程中对传感器2和传感器3的响应信息更为敏感。图6(b)为调制周期维度的归因分布。权重在周期维度上呈非均匀分布,其中0-9周期和30-39周期的累计贡献分别为27.55%和31.54%,高于10-19周期的16.90%。表明模型更关注调制初期和后期的响应变化。图6(c)为传感器一周联合归因结果。高权重区域主要分布于传感器2、传感器3的部分前段和后段周期,说明模型并

非均匀利用全部输入,而是倾向于提取特定传感器在特定调制阶段的局部响应特征。




图6 归因权重分布

Fig. 6 Attribution weight distribution

从传感器响应机理角度看,不同MOS传感器敏感材料和表面反应特性不同,对 CH_4 和 C_2H_2 的响应强度及动态变化存在差异,因此不同通道在混合气体识别中的贡献并不相同。温度调制过程中,前段周期通常包含气体进入后响应快速建立的信息,后段周期则反映连续暴露条件下吸附、脱附及表面反应逐步变化后的响应状态。因此,较高权重集中于部分传感器通道及前、后段调制周期,与温度调制响应的通道差异和动态演化特征相一致。

归因分布只能反映模型对输入信息的相对关注程度,尚需进一步验证高、低归因区域对预测性能的实际影响。为此,研究基于联合归因权重设置掩盖实验,分别遮蔽权重最高20%和最低20%的输入区域,并比较模型预测误差变化,以检验归因权重与模型性能退化之间的一致性,见表5。

由表5可知,传感器一周重要性权重与预测性能具有较强关联。未遮挡时,模型在 CH_4 和 C_2H_2

表5 掩盖实验性能比较

Table 5 Performance comparison of masking experiments

条件	e_{RMSE_CH4}	e_{MAE_CH4}	R^2_{CH4}	e_{RMSE_C2H2}	e_{MAE_C2H2}	R^2_{C2H2}
未遮挡	30.80	21.11	0.992 6	6.84	4.53	0.990 9
遮挡20%低重要性序列	71.04	37.05	0.960 7	10.02	6.68	0.980 5
遮挡20%高重要性序列	203.42	156.68	0.677 7	37.85	28.93	0.721 0

预测中的 e_{RMSE} 分别为 30.80 和 6.84, R^2 分别为 0.992 6 和 0.990 9, 模型具有较高预测精度。遮挡 20% 低重要性序列后, CH_4 和 C_2H_2 的 e_{RMSE} 分别增大至 71.04 和 10.02, 模型性能有所下降, 但整体仍保持较高 R^2 。相比之下, 当遮挡 20% 高重要性序列后, CH_4 和 C_2H_2 的 e_{RMSE} 分别显著增大至 203.42 和 37.85, R^2 分别下降至 0.677 7 和 0.721 0, 模型预测性能出现明显退化。综上, 高重要性区域被遮挡后模型性能退化更为明显, 说明该区域包含了与体积分数预测密切相关的关键响应信息。该结果验证了传感器一周期重要性权重与模型预测性能之间的一致性, 也表明所提方法能够从温度调制动态响应中提取具有判别作用的局部特征。

4 结语

文中针对温度调制 MOS 传感器阵列在混合气体定量识别中结构化动态响应利用不足的问题, 提出了一种基于调制周期与通道注意力网络的混合气体体积分数预测方法。该方法将传感器响应重构为周期化多通道张量, 并分别建模调制周期演化关系和传感器通道耦合关系, 实现 CH_4 与 C_2H_2 体积分数的联合预测。

实验结果表明, 所提模型在 CH_4 和 C_2H_2 预测中的 R^2 分别达到 0.992 6 和 0.990 9, 优于 1DCNN、GRU、LSTM、ResNet、Transformer 等对比模型。消融实验表明, 跨调制周期注意力和跨传感器注意力均能有效提升回归性能, 其中跨周期建模贡献更为显著。可解释性分析进一步表明, 模型能够识别对预测结果贡献较大的传感器通道和调制周期区间, 为温度调制响应特征分析提供了依据。

在此基础上, 后续研究将面向更复杂的混合气体工况, 进一步扩展混合气体体积分数组合, 补充不同总体积分数、不同组分比例以及环境中的温湿度波动、传感器个体差异及长期漂移等因素, 以更全面评估所提模型在更广泛体积分数空间下的鲁棒性和泛化能力。

参考文献:

[1] 汪可, 郑东阳, 王健一, 等. 变压器油过热故障产气特性及机理研究综述[J]. 中国电机工程学报, 2025, 45(21): 8605-8621.

Wang Ke, Zheng Dongyang, Wang Jianyi, et al. Overview of gas generation mechanism of transformer oil under local overheating faults[J]. Proceedings of the CSEE, 2025, 45(21): 8605-8621.

[2] 段肖力, 刘雨丰, 刘三伟, 等. 高压 XLPE 电缆缓冲层烧蚀机理及检测方法综述[J]. 电工技术学报, 2025, 40(5): 1540-1558.

Duan Xiaoli, Liu Yufeng, Liu Sanwei, et al. Review on ablative mechanism of the buffer layer in high voltage XLPE cable and associated detection methods[J]. Transactions of China Electrotechnical Society, 2025, 40(5): 1540-1558.

[3] 潘兴亚, 汪超, 邵建伟, 等. 痕量乙炔气体光干涉多谐波信号联合检测技术[J]. 高压电器, 2025, 61(1): 112-120.

Pan Xingya, Wang Chao, Shao Jianwei, et al. Combined detection technology of trace acetylene gas photothermal interference and multi-harmonic signal[J]. High Voltage Apparatus, 2025, 61(1): 112-120.

[4] 李鹏, 毕建刚, 于浩, 等. 变电设备智能传感与状态感知技术及应用[J]. 高电压技术, 2020, 46(9): 3097-3113.

Li Peng, Bi Jiangang, Yu Hao, et al. Technology and application of intelligent sensing and state sensing for transformation equipment[J]. High Voltage Engineering, 2020, 46(9): 3097-3113.

[5] 陈伟根, 赵立志, 彭尚怡, 等. 激光拉曼光谱应用于变压器油中溶解气体分析[J]. 中国电机工程学报, 2014, 34(15): 2485-2492.

Chen Weigen, Zhao Lizhi, Peng Shangyi, et al. Analysis of dissolved gas in transformer oil based on laser raman spectroscopy[J]. Proceedings of the CSEE, 2014, 34(15): 2485-2492.

[6] 陈伟根, 万福, 顾朝亮, 等. 变压器油中溶解气体拉曼剖析及定量检测优化研究[J]. 电工技术学报, 2016, 31(2): 236-243.

Chen Weigen, Wan Fu, Gu Chaoliang, et al. The research for raman analysis of dissolved gases in transformer oil and optimization of quantitative detection[J]. Transactions of China Electrotechnical Society, 2016, 31(2): 236-243.

[7] 张晓星, 胡隽宇, 张引, 等. 基于中红外激光光声光谱的乙炔气体检测研究[J]. 高压电器, 2025, 61(12): 181-187.

Zhang Xiaoxing, Hu Juanyu, Zhang Yin, et al. Study on detection of acetylene based on mid-infrared laser photoacoustic spectroscopy[J]. High Voltage Apparatus, 2025, 61(12): 181-187.

[8] 张寅浩, 张懿议, 李泽瑞, 等. 不同放电类型下电缆附件绝缘界面逸出气体特性[J]. 高电压技术, 2026, 52(1): 481-491.

Zhang Yin hao, Zhang Yiyi, Li Zerui, et al. Characteristics of evolved gas from the insulation interface of cable accessories under different discharge types[J]. High Voltage Engineering, 2026, 52(1): 481-491.

[9] 张潮海, 邹可园, 张晓星. 高压电气设备绝缘气体分解产物光学检测技术研究综述[J]. 高电压技术, 2023, 49(7): 2806-2815.

Zhang Chaohai, Zou Keyuan, Zhang Xiaoxing. Review on optical detection technology of insulating gas decomposition products for high voltage electrical equipment[J]. High Voltage Engineering,

- 2023,49(7):2806-2815.
- [10] 雷芳菲,褚继峰,刘洋,等.基于半导体气体传感阵列的电缆过热故障诊断方法[J].电工技术学报,2023,38(13):3651-3664.
Lei Fangfei, Chu Jifeng, Liu Yang, et al. Fault diagnosis of cable overheating based on semiconductor gas sensing array[J]. Transactions of China Electrotechnical Society, 2023, 38(13):3651-3664.
- [11] 梁坤,刘慧聪,伍洁,等.基于多传感阵列的高压电缆缓冲层烧蚀缺陷检测方法[J].电气工程学报,2025,20(6):125-134.
Liang Kun, Liu Huicong, Wu Jie, et al. Detection method for ablation defects in high-voltage cable buffer layers based on multi-sensor arrays[J]. Journal of Electrical Engineering, 2025, 20(6): 125-134.
- [12] 李浩源,刘洋,朱颖,等.基于超声—气体融合感算的空气开关柜放电故障诊断方法[J].高电压技术,2026,52(4):1969-1982.
Li Haoyuan, Liu Yang, Zhu Ying, et al. Discharge fault diagnosis method for air-insulated switchgear based on integrated ultrasonic-gas sensing and computing[J]. High Voltage Engineering, 2026, 52(4):1969-1982.
- [13] 杨爱军,潘健彬,王琼苑,等.电力嗅觉传感原理与关键技术研究综述[J].高电压技术,2024,50(8):3339-3353.
Yang Aijun, Pan Jianbin, Wang Qiongyuan, et al. Review on sensing principles and key technologies of electric olfaction[J]. High Voltage Engineering, 2024, 50(8):3339-3353.
- [14] Lee A P, Reedy B J. Temperature modulation in semiconductor gas sensing[J]. Sensors and Actuators B-Chemical, 1999, 60(1):35-42.
- [15] Yin Xin, Zhang Lei, Tian Fengchun, et al. Temperature modulated gas sensing e-nose system for low-cost and fast detection[J]. IEEE Sensors Journal, 2016, 16(2):464-474.
- [16] Zhao Wenjie, Ding Kailun, Chen Yinsheng, et al. Optimized low frequency temperature modulation for improving the selectivity and linearity of SnO₂ gas sensor[J]. IEEE Sensors Journal, 2020, 20(18):10433-10443.
- [17] Gosangi R, Gutierrez-Osuna R. Active temperature modulation of metal-oxide sensors for quantitative analysis of gas mixtures[J]. Sensors and Actuators B-Chemical, 2013(185):201-210.
- [18] Lee B, Kang Mingu, Lee K, et al. Multigas identification by temperature - modulated operation of a single anodic aluminum oxide gas sensor platform and deep learning algorithm[J]. ACS Sensors, 2025, 10(2):954-964.
- [19] Hu Z A, Zhao Wenjie, Cheng Haonan, et al. Application of PSO-CNN algorithm in semiconductor gas sensors based on temperature modulation[J]. IEEE Sensors Journal, 2024, 24(20):32717-32728.
- [20] Ji Hanyang, Mi Chunjin, Yuan Zhenyu, et al. Multicomponent gas detection method via dynamic temperature modulation measurements based on semiconductor gas sensor[J]. IEEE Transactions on Industrial Electronics, 2023, 70(6):6395-6404.
- [21] Wang Hao, Zhao Yong, Yuan Zhenyu, et al. Multiscale bidirectional temporal convolutional framework for industrial ketone organic solvent detection based on semiconductor gas sensor[J]. IEEE Transactions on Industrial Electronics, 2024, 71(12):16772-16782.
- [22] Mei Haixia, Peng Jingyi, Wang Tao, et al. Overcoming the limits of cross - sensitivity: pattern recognition methods for chemiresistive gas sensor array[J]. Nano-Micro Letters, 2024, 16(1):269.
- [23] Zhang Y, Yan J. Crossformer: transformer utilizing cross-dimension dependency for multivariate time series forecasting[C]// International Conference on Learning Representations, 2023:9.
- [24] Hsieh T Y, Wang S, Sun Y, et al. Explainable multivariate time series classification: a deep neural network which learns to attend to important variables as well as time intervals[C]//Proceedings of the 14th ACM International Conference on Web Search and Data Mining, 2021:607-615.
- [25] Lim B, Arık S Ö, Loeff N, et al. Temporal fusion transformers for interpretable multi-horizon time series forecasting[J]. International Journal of Forecasting, 2021, 37(4):1748-1764.
- [26] 杜鑫,黄萍,唐崇年,等.基于图时间卷积的变压器油中溶解气体预测方法[J].广东电力,2025,38(4):101-108.
Du Xin, Huang Ping, Tang Chongnian, et al. Prediction of dissolved gases in transformer oil based on graph time convolution [J]. Guangdong Electric Power, 2025, 38(4):101-108.

刘伟丰(1998—),男,博士研究生,主要研究方向为电力设备状态监测(E-mail:liuwf@hnu.edu.cn)。

钟理鹏(1990—),男,博士研究生,副教授,主要研究方向为电力设备状态监测(通信作者)(E-mail:zhonglipeng@hnu.edu.cn)。