数据-物理融合驱动煤自燃智能预警:从实验室标定到现场跨域自适应模型

罗振敏[1,2],张利冬[1],张　蕙[1],苏　彬[1],王　涛[1],王亚超[1]
(1. 西安科技大学 安全科学与工程学院,陕西 西安　710054;
2. 陕西省工业过程安全与应急救援工程技术研究中心,陕西 西安　710054)

摘要:煤自燃的精准预警是煤矿火灾防治的重点与难点. 然而,传统基于固定阈值的经验模型由于难以适应不同矿区煤质与环境的差异,泛化能力不足. 针对这一挑战,本研究提出了一种数据与物理驱动相融合的跨矿区煤自燃智能预警模型. 首先,基于102组煤自燃程序升温试验,明确了CO,C_2H_4,C_2H_2作为标志性气体的阶段特征,并引入了煤质和环境权重因子,构建了动态调整预警阈值的跨矿区煤自燃四级预警体系. 在此基础上,通过将煤氧化过程的物理规律转化为学习特征,建立了数据-物理融合的预警模型. 结果表明:在多种算法的对比中,随机森林模型在试验数据上表现出最优的预测性能(训练:R^2=0.99;测试:R^2=0.93)和计算效率(预测时间<0.4 s). 同时,将该模型直接应用于大佛寺煤矿(发火场景)时,能准确输出以橙色和黄色为主的高温预警信号;而在惠宝煤矿(安全场景)则能持续保持绿色安全预警,无误报情况发生,该结果验证了本文所构建的预警体系与模型具备卓越的跨矿区适应性和泛化能力. 研究成果可为解决煤自燃预警模型的普适性难题提供有效方法.

关键词:煤自燃预警;跨域自适应;数据-物理融合驱动;随机森林;煤矿安全
中图分类号:X 936;TD76　　**文献标志码**:A　　**文章编号**:1000-1964(2026)02-0288-21

Data-physics fusion-driven intelligent early warning of spontaneous coal combustion: From laboratory calibration to domain adaptive field model

LUO Zhenmin[1,2], ZHANG Lidong[1], ZHANG Hui[1], SU Bing[1], WANG Tao[1], WANG Yachao[1]
(1. School of Safety Science and Engineering, Xi'an University of Science and Technology, Xi'an, Shaanxi 710054, China;
2. Shaanxi Engineering Research Center for Industrial Process Safety and Emergency Rescue, Xi'an, Shaanxi 710054, China)

Abstract: Accurate early warning of spontaneous coal combustion is the priority and difficulty of coal mine fire prevention and control. However, the traditional empirical model based on fixed thresholds has insufficient generalization capability due to the difficulty of adapting to the differences in coal quality and environment in different mining areas. To address this challenge, an intelligent early warning model for spontaneous coal combustion across mining areas that integrates data and physical drivers was proposed in this work. At first, the stage characteristics of CO, C_2H_4, and

收稿日期:2025-11-04　　**修回日期**:2025-12-26　　**DOI**:10.13247/j.cnki.jcumt.20250499
基金项目:国家自然科学基金项目(51674193)
通信作者:罗振敏(1976—),女,山东省济宁市人,教授,博士生导师. E-mail: zmluo@xust.edu.cn
引用格式:罗振敏,张利冬,张　蕙,等. 数据-物理融合驱动煤自燃智能预警:从实验室标定到现场跨域自适应模型[J]. 中国矿业大学学报,2026,55(2):288-308.
LUO Zhenmin, ZHANG Lidong, ZHANG Hui, et al. Data-physics fusion-driven intelligent early warning of spontaneous coal combustion: From laboratory calibration to domain adaptive field model[J]. Journal of China University of Mining & Technology, 2026, 55(2): 288-308.

C_2H_2 as marker gases were clarified based on 102 sets of coal spontaneous combustion temperature programming experiments. And coal quality and environmental weighting factors were introduced to construct a four-level warning system for spontaneous coal combustion across mining areas with dynamically adjusted warning thresholds. On this basis, a data-physics fusion-driven early warning model was established by transforming the physical laws of coal oxidation process into learning features. The results show that among various algorithms, the random forest model exhibited optimal prediction performance (training: $R^2 = 0.99$; testing: $R^2 = 0.93$) and computational efficiency (prediction time <0.4 s) on experimental data. When directly applied to the Dafosi coal mine (fire scenario), the model accurately output high-temperature warning signals predominantly in orange and yellow. In contrast, at the Huibao coal mine (a safe scenario), it consistently maintained green safety warnings without any false alarms. These results validate that the early warning system and model developed in this study possess excellent cross-mining area adaptability and generalization capability, providing an effective solution to the challenge of developing universally applicable prediction models for coal spontaneous combustion.

Key words: coal spontaneous combustion early warning; domain adaptive; data-physics fusion-driven; random forest; coal mine safety

我国“贫油少气、相对富煤”的能源禀赋特征决定了煤炭在未来很长一段时期内仍然是我国的主体能源[1]. 据统计，我国超90%的煤层为自燃或易自燃状态，每年引发矿井火灾超4 000起，其中因煤自燃导致的矿井火灾数量占比高达85%～90%[2-3]. 此外，煤自燃还造成巨大资源损失和环境负担，每年损失煤炭约4 146万t，伴生CO_2排放约8 728万t，直接经济损失超200亿元[4]. 灾后治理费用更是早期预警成本的10倍以上[5]. 因此，发展精准、实时的煤自燃早期预警技术，对保障煤矿安全高效开采及生态环境保护具有重大意义[6].

煤自燃预警研究的发展，经历了从指标气体探索到过程建模深化，再向智能方法拓展的演进路径. 早期研究侧重于通过试验方法确定关键气体指标及其临界阈值. 例如，文献[7]通过气体浓度及其比值分析将煤自燃细分为7个阶段；文献[8]进一步结合多参数特征阐明了各阶段的物理化学机制；文献[9]通过建立六级预警系统，改善了传统方法对中温氧化阶段识别不足的问题；文献[10]则分别研究了二次氧化气体干扰和非自燃源CO的影响，推动了预警指标的精准化；文献[11]通过热重试验确定了煤样的临界温度与干裂温度，构建了分级预警阶段体系；文献[12]则采用Logistic回归对气体体积分数进行拟合，建立了基于统计学特征的煤自燃危险等级划分方法. 这些研究逐步完善了预警指标与分级标准，为煤自燃的阶段性判断提供了方法.

随着人工智能与数据挖掘技术的兴起，煤自燃预警研究逐步进入数据驱动阶段. 文献[13]融合多源数据构建了基于人工神经网络(ANN)的预警指标体系. 文献[14]利用长短期记忆网络(LSTM)等时序模型实现了CO浓度的动态预测. 文献[15]结合t-分布随机邻域嵌入(t-SNE)与K-均值聚类算法(K-means)实现了多气体特征的无监督预警分级. 文献[16]将声发射与次声波信号与支持向量机(SVM)相结合，为煤自燃监测预警提供了新的感知方法. 这些方法推动了预警模型从静态判断向动态预测的转变，表明了数据智能在复杂建模方面的潜力.

然而，煤自燃是一个涉及物理化学性质、环境条件和反应动力学等多维耦合的复杂动态过程[17-18]，其内在机理的强非线性与条件依赖性，对预警模型的泛化能力提出了更高要求. 尽管已有研究在预警标准与模型构建方面取得了显著进展，但在应对不同矿区煤质特性与环境条件的差异性时，仍面临适应性不足的挑战. 具体而言，在融合煤的静态属性与氧化动态特征方面尚不充分，对煤自燃核心物理机制的嵌入性表达也可进一步加强. 这可能导致模型在跨场景应用时出现泛化能力下降，且其决策逻辑的黑箱特性也一定程度制约了结果的可解释性与工程可信度. 因此，探索数据驱动方法与煤自燃物理特性之间的深度融合路径，是进一步提升预警模型跨矿区适应能力与实用价值的关键方向.

故本研究提出了一种数据与煤自燃物理特性融合驱动的煤自燃智能预警方法，来强化模型从实验室到现场应用的迁移能力．通过开展102组程序升温试验，构建融合煤质与环境权重因子的动态加权四级预警体系，为模型建立物理基础．又通过对比多种机器学习算法的性能，筛选出效果最优的建模路径．最终，将优选模型应用于不同类型矿区的实际场景，验证其在跨域条件下的泛化性能与可靠性．

1 跨矿区煤自燃四级预警体系与数据集构建

1.1 基于程序升温试验的特征分析与预警体系建立

1.1.1 程序升温试验测试系统

为了构建不同矿区煤自燃预警指标体系，本研究以大佛寺、魏家地、磁窑堡等17座典型矿井煤样为研究对象，煤样的工业分析结果如表1所示．将采集的原煤样在氮气氛围中破碎，利用筛子将煤样筛分成粒度区间为0～＜0.9，0.9～＜3.0，3.0～＜5.0，5.0～＜7.0和7.0～10.0 mm的5个粒级，其平均粒径分别为0.45，1.95，4.00，6.00和8.50 mm．在此基础上，将上述5种单一粒级煤样按一定比例混合，配制得到平均粒径为4.18 mm的混合煤样．最终，共获得6种不同粒径的试验煤样，各取1 kg备用．分别装入煤样罐，进行煤氧复合反应试验，共计开展102组程序升温试验．随后利用煤自燃程序升温试验，测试102组煤炭样本在煤自燃氧化过程中CO，CO_2，CH_4，C_2H_6，C_2H_4，C_2H_2气体的产生规律及不同温度下气体的产生量，为煤自燃预警指标的实验室标定提供依据．程序升温试验装置如图1所示．试验采用直径为9.5 cm、长度为25 cm的钢管作为反应器，装入煤样1 kg．为保障气流分布均匀，煤样上下两端各预留约2 cm自由空间．反应器置于可控硅控温的程序升温箱中，通入经预热的空气，测定不同煤温下的气体组分．待温度达到设定值后停止加热，开启炉门使系统自然对流冷却．整个试验系统由气路单元、控温单元与气样采集分析单元3部分组成．本研究中，程序升温试验速率设定为0.3 ℃/min，空气流量设定为120 mL/min．

图2统计了102组程序升温箱中煤样加热升温试验的条件，包括平均粒径、试管煤高、煤体积、容重、孔隙率．从图中可知，孔隙率分布在0.2%～0.9%区间，平均值约为0.5%，通过均质化处理来消除孔隙效应对氧化反应的干扰．其次，煤体积呈现显著右偏分布（数值为981～5259 cm^3），平均值远高于中位数，主要是由于试验采用了恒定体积装样来维持一致的气流路径．平均粒径分布（数值为0.45～8.50 mm）则显示出以4 mm为主峰、同时包含长尾大颗粒的双峰特征．容重数据（数值为0.19～1.12 g/cm^3）表现出极大离散性，低容重样本对应高活性煤．最后，试管煤高（数值为12.50～22.80 cm）的右偏分布反映了床层高度对氧气停留时间和转化率的显著影响．

表1 煤样工业分析

Table 1 Industrial analysis of coal samples %

序号	样本名称	M_{ad}	A_{ad}	V_{ad}	FC_{ad}
1	大佛寺煤样	3.76	11.87	29.56	54.81
2	魏家地煤样	1.85	10.75	34.83	52.57
3	磁窑堡煤样	11.73	8.11	43.98	36.18
4	芙蓉煤样	4.17	17.13	17.05	61.65
5	东山煤样	1.33	6.26	41.91	50.50
6	枣泉2号煤样	3.63	10.91	33.88	51.58
7	枣泉矿12105煤样	12.16	3.94	26.97	56.93
8	赵石畔煤样	3.57	14.60	40.43	41.40
9	塘口煤样	1.55	11.44	38.88	48.13
10	白皎煤样	19.59	20.96	8.31	51.14
11	灵新煤样	4.71	5.19	42.75	47.35
12	下沟煤样	4.86	13.89	41.22	40.03
13	鲁班山煤样	1.89	18.80	8.68	70.63
14	硫磺沟煤样	1.07	13.44	10.51	74.98
15	星村煤样	6.43	11.62	30.62	51.33
16	双鸭山煤样	4.02	7.13	27.62	61.23
17	潘一煤样	1.52	11.29	33.60	53.59

注：M_{ad}为空气干燥基水分；A_{ad}为空气干燥基灰分；V_{ad}为空气干燥基挥发分；FC_{ad}为空气干燥基固定碳．

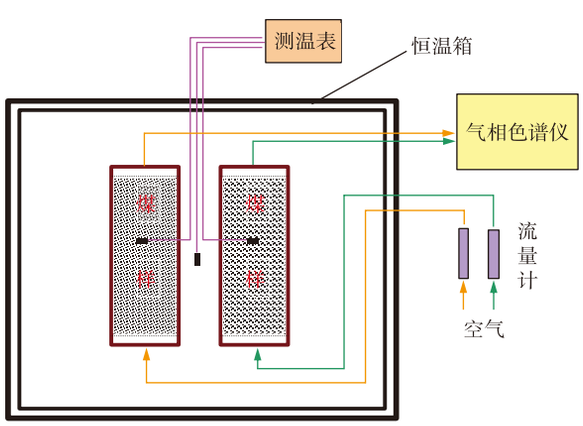

图1 煤自燃程序升温试验装置

Fig. 1 Equipment of coal spontaneous combustion temperature programming experiment

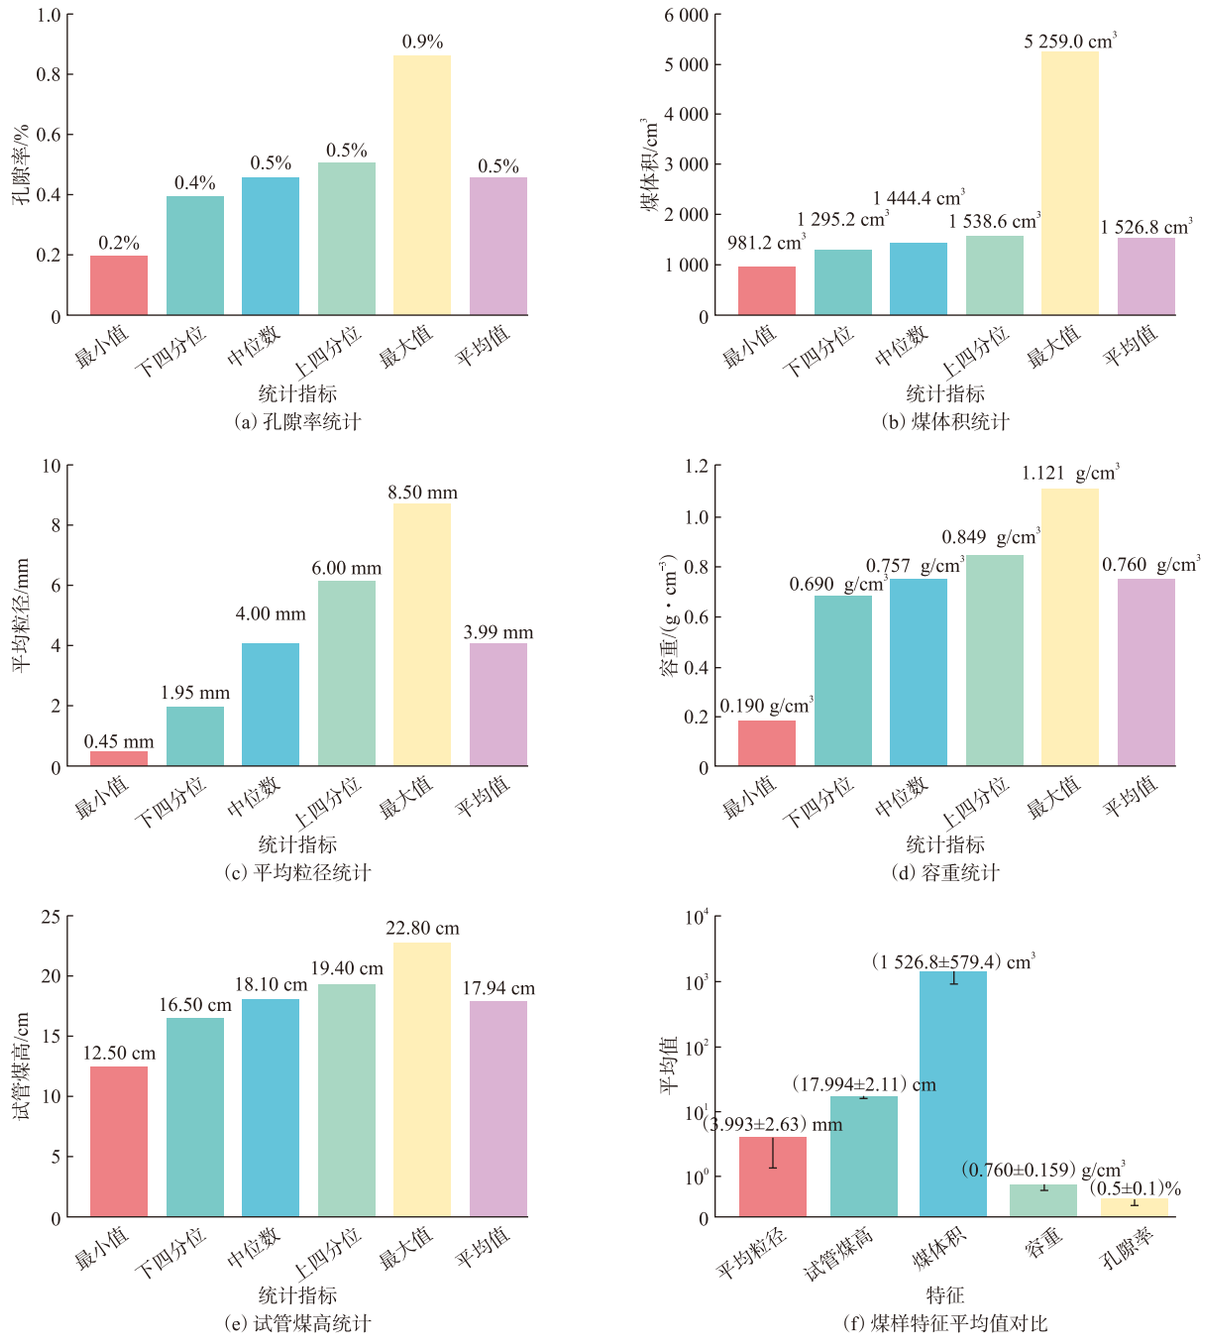

图 2　102 组程序升温煤样加热试验条件统计

Fig. 2　Statistical of heating experimental conditions for 102 groups of programmed warming coal sample

基于上述分析,在构建煤自燃预警模型时,本研究将孔隙率与煤体积设定为控制气流条件的变量来建立标准化的氧化环境基准,从而消除因气流路径差异对煤氧复合反应过程带来的一定干扰. 与此同时,模型通过容纳容重、平均粒径及煤高的自然波动来提升其对工程实际中煤体物理属性不确定性的表征能力与泛化性能. 因此,选择孔隙率、煤体积、容重、平均粒径及煤高等特征变量有助于识别不同煤质在等效氧化环境下的反应特性,也能够更准确地反映现场条件下由于煤体堆积状态、破碎程度及装填高度等因素所引起的自燃倾向性变化.

1.1.2　煤自燃气体演化规律与特征温度分析

煤自燃是一个涉及复杂物理化学反应的动态过程,伴随该过程持续释放出以 CO,CO_2,CH_4等为代表的特征气体产物. 这些气体的生成速率及其组分比例直接反映了煤体氧化程度与热动力状态的演变规律. 在众多气体中,部分规律显著、特

征明确的气体被选作煤自燃的标志性气体，用于现场监测与预警，从而实现对煤自然发火状态的判断与预测．本研究基于102组程序升温试验数据，采用中位数统计方法分析了气体浓度（本文中气体浓度均指气体的体积分数）随温度的变化趋势，如图3所示．需注意，高温区间的氧气浓度升高实为样本分布不均导致的统计假象，并非真实物理规律．各独立试验中氧气浓度均随煤温升高单调下降，符合煤氧化反应原理．尽管均值统计在高温段受样本分布干扰，中位数分析仍能准确表征气体浓度整体演化规律，为跨矿区煤自燃预警指标优选提供了可靠依据．

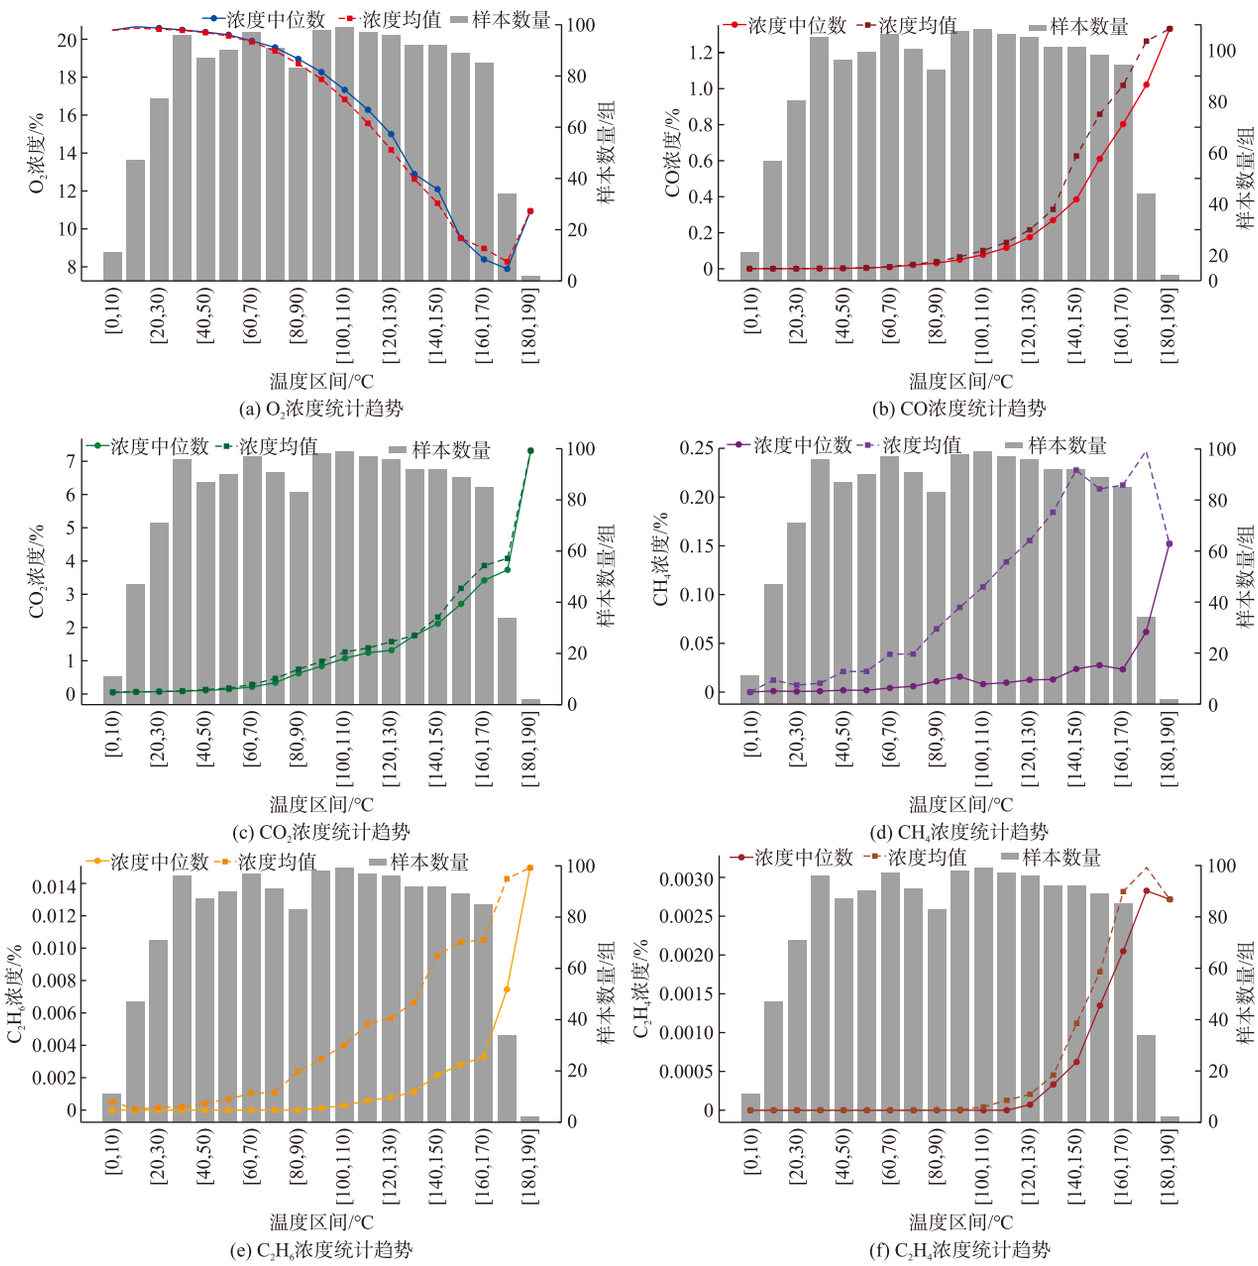

图3 102组程序升温试验中各气体浓度变化统计趋势

Fig. 3 Statistical trend diagram of gas concentration changes in 102 sets of program temperature experiments

从图3中各气体浓度随温度变化的整体趋势来看，中位数曲线较均值曲线更能稳定地反映气体生成的本质规律，特别是在样本分布不均的高温区段表现尤为明显．如图3a所示，O_2浓度自30 ℃起随煤温升高呈单调下降趋势，尤其在60～70 ℃后降速显著加快，表明煤氧复合反应的持续增强．值得注意的是，在150 ℃以上高温区段，虽然样本数量减少可能导致均值统计出现波动，但

中位数曲线仍保持稳定的下降趋势，表明氧化反应持续进行．CO作为煤自燃早期预警的关键指标气体，其浓度变化具有明确的临界特征．由图3b可知，CO在75 ℃前其浓度均值接近零且标准差极小，在突破75 ℃后其浓度显著上升，且在60～70 ℃区间出现均值跃升，标准差同步扩大，表明该温度区间内CO浓度发生第1次突变．煤自燃临界温度是常温下煤温由低至高上升过程中，引起煤氧复合自动加速的第1个温度点[19]；从微观上看，是煤中桥键与氧复合的三步反应总速度加快，煤的化学吸附达到最大平衡点后，解析速度加快的起点温度[20]．宏观上表现为煤对氧的消耗速率增大，反应产物CO的产生量开始增多，放热强度增强，煤体升温速度加快[21-23]．结合图3b来看，CO浓度发生突变的温度即为煤自燃临界温度．CO_2浓度（图3c）虽然随温度升高而持续增长，但是受煤体赋存及环境背景干扰大，标准差范围宽广，规律性相对较弱，故不宜作为独立预警指标．烃类气体中，C_2H_6（图3e）与CH_4（图3d）浓度变化在中低温段较为平缓，且CH_4受煤体吸附气影响显著，数据离散度较大，指示特性不及烯烃明确．而由图3f可知，在100 ℃以下C_2H_4浓度均值为零，其标准差近乎于零；在110 ℃左右开始检出C_2H_4，其浓度随温度升高而显著增长，该特征温度点清晰，突变明显，标志着煤分子侧链断裂的热解反应开始，因此C_2H_4是标志煤自燃进入加速氧化阶段的特征指标．此外，尽管本次试验的温度范围未覆盖C_2H_2的生成区间（通常为260～310 ℃），本研究仍将其纳入预警体系，主要基于煤自燃预警对指标气体完整性及灵敏性的综合考量．一方面，C_2H_2作为煤分子在高温环境下发生热解与氧化反应的确定性产物，其生成行为具备良好的规律性与可识别性，是我国煤自燃预警体系中公认的激烈氧化阶段关键气体[24-25]．另一方面，一个具备工程实用价值的预警体系应完整涵盖从初始氧化至明火临界状态的全过程．因此，将C_2H_2设为一级预警判据，是基于煤自燃反应物理特性与工程先验的必要设计，以实现对明火临界状态的理论预警，保障体系在应用中的完整性．

因此，基于煤自燃过程中的气体生成趋势与标志性气体优选原则，结合102组程序升温试验结果及矿井现场预警需求，本研究构建了以CO，C_2H_4和C_2H_2为核心指标的跨矿区煤自燃四级预警体系．该体系依据煤自燃发展的阶段性特征，建立了从临界氧化至激烈燃烧的全过程预警体系．其中，CO作为煤氧化初期的特征产物，被确立为临界阶段（快速氧化阶段）的预警指标，其在四级与三级预警中的浓度拐点与增长趋势，可用来有效识别煤自燃的早期征兆．C_2H_4作为煤体进入热解阶段（高速氧化阶段）的标志性气体，用于二级预警．C_2H_2则作为预警煤自燃进入裂变阶段（激烈氧化阶段）的标志性气体．

图4展示了102组程序升温试验数据的Z-score（标准分数）标准化热图，各气体的Z-score标准化热图明确了不同样本在温度序列上的浓度分布一致性及异常点，进一步验证了标志性气体的可靠性．由图4a可知，O_2浓度随着温度升高绝大多数样本的Z-score值呈由正（蓝色，高于平均）向负（红色，低于平均）的变化，且颜色过渡集中出现在60～80 ℃与120～140 ℃区间，这与O_2消耗速率在临界温度和加速氧化温度点的阶跃式增加现象吻合．从CO的Z-score热图可知（图4b），在低于75 ℃的低温区，几乎所有样本的Z-score值均接近零或为负值，呈现出均匀的蓝色，而当温度升高到75 ℃后，大量样本转变为高Z-score的红色区域，该结果验证了CO作为临界温度预警指标的灵敏性和可靠性．对于烃类气体，从C_2H_4的Z-score热图（图4f）可知，在温度低于110 ℃时基本为蓝色，而在高于110 ℃后出现连续、集中的红色高值区，且异常样本数量少，表明C_2H_4在110 ℃左右的初始产生温度点较为稳定，极少受样本个体差异影响，符合作为中期预警标志的灵敏性和可靠性要求．相比之下，CH_4（图4d）和C_2H_6（图4e）的Z-score热图则显示，其高值区虽也随温度升高而出现，但分布相对分散，且在较低温度下即存在部分样本的异常高值，表明其浓度受煤体本身吸附气体含量等固有因素影响较大，数据离散度高于C_2H_4，因此未被选为煤自燃预警标志性气体．同样的，从CO_2的Z-score热图（图4c）可知，其高值区在整个温度范围内分布广泛且无明显突变边界，不同样本间的响应差异显著，规律性不及CO和C_2H_4．

因此基于上述分析，CO作为预警煤自燃进入临界阶段的标志性气体，C_2H_4气体作为预警煤自燃进入热解阶段的标志性气体，并结合理论将C_2H_2作为高温裂解阶段的煤自燃预警标志性气体．

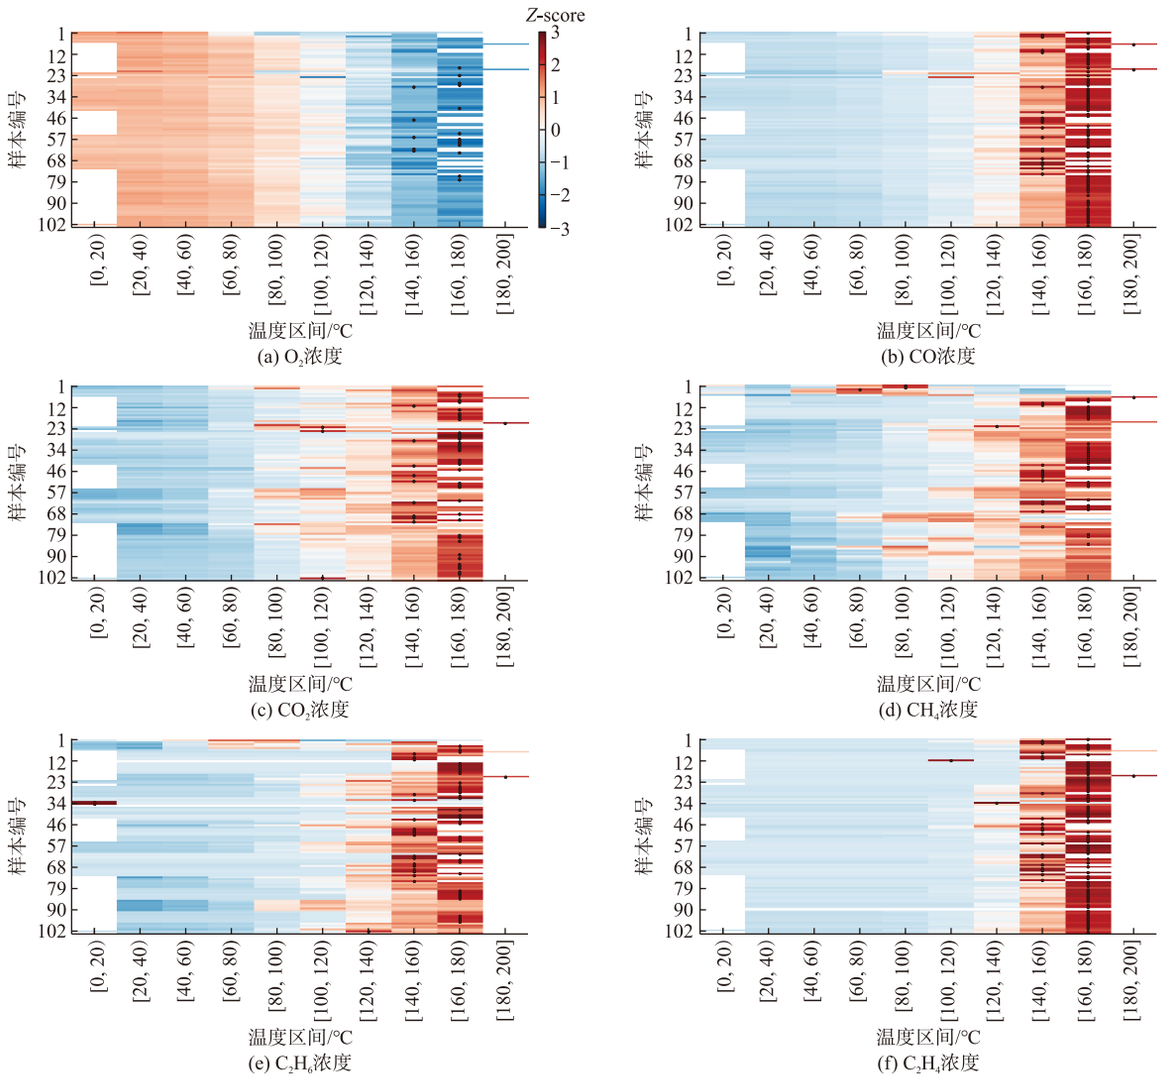

图 4 102组程序升温试验数据的 Z-score标准化热图

Fig. 4 Z-score normalized thermograms for 102 sets of programmed warming experimental data

1.1.3 跨矿区煤自燃加权四级预警体系构建

煤自燃是一个以煤氧复合反应为主导的复杂非线性发展过程,具有明显的阶段性特征,通常可划分为潜伏、自热与燃烧3个阶段. 在矿井开采过程中,煤自燃预警的核心在于对氧化早期低温阶段的有效识别与监测. 为此,本研究基于前述选定的煤自燃标志性气体,结合Arrhenius反应动力学理论、煤氧化机理与热传导理论,并综合考虑煤质特性及环境条件对煤自燃行为的影响,建立了跨矿区煤自燃加权相对四级预警体系,从而实现对不同矿区的自适应预警.

1)为构建定量化的煤自燃四级预警体系并确保理论分析的严谨性,本节对后续分析中将涉及的核心数学符号与关键函数进行统一定义,令 T 为煤体温度,℃;t 为时间,min;$C_{CO}(T)$ 为CO浓度随温度变化的函数,%;$C_{C_2H_4}(T)$ 为 C_2H_4 浓度随温度变化的函数,%;$C_{C_2H_2}(T)$ 为 C_2H_2 浓度随温度变化的函数,%;$C_{O_2}(T)$ 为氧气浓度随温度变化的函数,%. 其次根据Arrhenius定律,煤氧化反应速率 $r(T)$ 可表示为:

$$r(T)=A\cdot e^{-\frac{Ea}{RT}}\cdot\left[C_{O_2}(T)\right]^n\cdot f, \tag{1}$$

式中:A 为指前因子;E_a 为活化能,kJ/mol;R 为理想气体常数;n 为反应级数;f 为煤质特性修正函数.

2)在本研究中,为实现对煤自燃初期过程的精准判别,四级预警体系将无预警阶段(绿色安全)的温度结束点定义为CO生成速率开始显著升高的对应温度,记为 ΔT_{CO}. 该温度点本质上是CO生成速率函数的第1个拐点,标志着煤氧相互作用从物理吸附主导转变为化学氧化主导,反应进入可自维持加速状态. 由于不同煤样的氧化特性与产气规律存

在差异，ΔT_{CO}的具体数值会因煤样而异．因此，为实现跨矿区的普适性预警，本研究通过分析CO浓度曲线的高阶导数来辨识该特征点．

首先，将CO生成速率$v_{CO}(T)$定义为浓度对温度的一阶导数以量化反应的瞬时强度，如式(2)所示；其次，将CO生成加速度$a_{CO}(T)$定义为速率对温度的一阶导数以描述速率的变化趋势，如式(3)所示；根据拐点的数学本质，ΔT_{CO}被定义为满足$v_{CO}(T)$函数二阶导数为0且三阶导数非0的温度点，如式(4)所示．拐点的出现表明函数曲率发生变化，对应煤氧化反应从物理吸附主导转为化学氧化主导的临界点．

$$v_{CO}(T)=\frac{\mathrm{d}C_{CO}(T)}{\mathrm{d}T}, \tag{2}$$

$$a_{CO}(T)=\frac{\mathrm{d}v_{CO}(T)}{\mathrm{d}T}=\frac{\mathrm{d}^2C_{CO}(T)}{\mathrm{d}T^2}, \tag{3}$$

$$\frac{\mathrm{d}^2v_{CO}(T)}{\mathrm{d}T^2}\Big|_{T=\Delta T_{CO}}=0\text{且}\frac{\mathrm{d}^3v_{CO}(T)}{\mathrm{d}T^3}\Big|_{T=\Delta T_{CO}}\neq 0, \tag{4}$$

3)同理，四级预警体系中的四级预警阶段(黄色预警)是在无预警结束点(ΔT_{CO})的基础上，捕捉CO生成的首次显著突变，标志着煤氧化进程从缓慢氧化进入快速氧化阶段．因此，CO突变点被确定为三级预警阶段的结束临界判据．为了精确识别此突变点温度T_{mut}，首先定义CO突变检测函数$D_{mut}(T)$，如式(5)所示；并基于$D_{mut}(T)$，CO突变点T_{mut}被定义为满足式(6)的最小温度：

$$D_{mut}(T)=\begin{cases}1, & \left|\dfrac{\mathrm{d}v_{CO}(T)}{\mathrm{d}T}\right|>\kappa\cdot\sigma_{v_{CO}}\\ 0, & \text{其他},\end{cases} \tag{5}$$

$$T_{mut}=\min\{T>\Delta T_{CO}\,|\,D_{mut}(T)=1\}, \tag{6}$$

式中：κ为灵敏度系数；$\sigma_{v_{CO}}$为ΔT_{CO}前$v_{CO}(T)$的标准差．

4)四级预警体系中的三级预警阶段(橙色预警)则标志着煤自燃进程进入了分子结构热解的关键时期．该阶段的结束临界点以C_2H_4的首次持续检出为判据，其物理本质是芳香环之间的亚甲基桥键、醚键等开始发生断裂，从而生成并释放出C_2H_4等烯烃气体．宏观上，标志着煤体已从快速氧化(四级预警)进入了热解阶段(三级预警)，自燃危险性显著升高．因此，C_2H_4的首次持续检出温度($T_{C_2H_4}$)被确定为三级预警阶段的结束临界判据．同时为排除检测波动与偶然脱气的干扰，定义C_2H_4的持续检出函数$D_{C_2H_4}(T)$，如式(7)所示；并基于$D_{C_2H_4}(T)$，$T_{C_2H_4}$被定义为满足式(8)的最小温度：

$$D_{C_2H_4}(T)=\begin{cases}1, & \text{若 } C_{C_2H_4}(T')>\delta \text{ 对所有}\\ & T'\in[T,T+\Delta T]\text{成立}\\ 0, & \text{其他},\end{cases} \tag{7}$$

$$T_{C_2H_4}=\min\{T>T_{mut}\,|\,D_{C_2H_4}(T)=1\}, \tag{8}$$

式中：δ为C_2H_4检测灵敏度阈值；ΔT为持续温度区间；T'为积分变量，表示在温度区间$[T,T+\Delta T]$内的任意一点温度．

5)四级预警体系中的二级预警阶段(红色预警)与一级预警阶段(深红色预警)代表煤自燃进程已进入极端裂解状态与临近明火燃烧的临界危险状态．二级预警阶段结束临界点以C_2H_2气体的首次检出为启动信号，深红色预警开始临界点则以C_2H_2在连续温度区间内的稳定出现作为升级判据，如式(9)所示．

$$T_{C_2H_2}=\min\{T>T_{C_2H_4}\,|\,C_{C_2H_2}(T)>\delta_{C_2H_2}\}, \tag{9}$$

式中：$\delta_{C_2H_2}$为C_2H_2的检测阈值．

基于上述对各阶段特征气体临界点的数学界定，本研究构建的跨矿区煤自燃四级预警体系如表2所示．该体系明确了从绿色安全到红色预警的4个等级、各等级对应的特征气体判据及其临界温度点的物理意义．

表2　基于试验分析后的跨矿区煤自燃四级预警体系

Table 2　Four-level early warning system for spontaneous coal combustion across mining areas based on experimental analysis

预警阶段	预警颜色	温度区间	阶段起始与结束的标志性气体浓度临界判据	物理意义
无预警	绿色	$T<\Delta T_{CO}$	起始：常温对应下的CO浓度；结束：CO生成速率曲线出现数学拐点，且CO浓度首次超越修正后的安全阈值$C_{CO}(T)$	煤氧复合以物理吸附为主，反应缓慢，处于安全状态
四级预警	黄色	$\Delta T_{CO}\sim T_{mut}$	起始：CO浓度达到修正阈值C_{CO}；结束：CO生成速率发生首次突变，$D_{mut}(T)$	煤自燃进入自动加速阶段，CO生成速率显著增加
三级预警	橙色	$T_{mut}\sim T_{C_2H_4}$	起始：CO生成速率进入突变增长阶段，$D_{mut}(T)$；结束：C_2H_4气体首次被持续检出，$D_{C_2H_4}(T)$	氧化反应加速，温度上升加快，C_2H_4开始稳定生成
二级预警	红色	$T_{C_2H_4}\sim T_{C_2H_2}$	起始：C_2H_4浓度稳定超过持续检出阈值$D_{C_2H_4}(T)$；结束：C_2H_2气体首次被检出，$C_{C_2H_2}(T)$	煤体进入裂解阶段，生成C_2H_2气体
一级预警	深红色	$T\geqslant T_{C_2H_2}$	起始：C_2H_2浓度首次超过检测阈值$C_{C_2H_2}(T)$	C_2H_2持续生成，可能发生明火燃烧

上述研究基于标志性气体确立了跨矿区煤自燃的各级预警临界点ΔT_{CO}, T_{mut}, $T_{C_2H_4}$, $T_{C_2H_2}$. 然而,由于不同矿区煤质的显著差异,固定的临界点温度值在实际预警中适用性有限. 为实现预警体系的跨矿区自适应能力,本研究基于工业分析结果量化煤质特性对氧化进程的影响,构建煤质权重因子α_m,以修正煤样的实际预警阈值.

1)定义煤质参数向量$\boldsymbol{P}_{m,i}=(V_{ad}, FC_{ad}, M_{ad}, A_{ad}, d_p)$,其中,$d_p$为煤体平均粒径,mm. 因此,煤质权重因子$\alpha_m$可表示为各煤质参数影响函数的加权和,如式(10)~(11)所示.

$$\alpha_m=\sum_{i=1}^{5} w_i \cdot f_i(\boldsymbol{P}_{m,i}), \tag{10}$$

$$\sum_{i=1}^{5} w_i=1, \tag{11}$$

式中:w_i为各参数的权重系数;f_i为将各参数归一化并表征其与自燃倾向性关系的分量函数.

2)基于102组程序升温试验数据,利用多元回归分析确定权重系数w_i. 通过对试验数据进行拟合,得到各煤质参数对临界点温度(ΔT_{CO}, T_{mut}, $T_{C_2H_4}$, $T_{C_2H_2}$)的回归系数,权重系数可按下式计算:

$$T_{c,1}=\beta_0+\beta_1 V_{ad}+\beta_2 FC_{ad}+\beta_3 M_{ad}+\beta_4 A_{ad}+\beta_5 d_p+\varepsilon, \tag{12}$$

$$w_i=\frac{|\beta_j|}{\sum_{j=1}^{5}|\beta_j|}, \tag{13}$$

式中:$T_{c,1}$为煤质参数对应下煤自燃的各级预警临界点温度,包括ΔT_{CO}, T_{mut}, $T_{C_2H_4}$, $T_{C_2H_2}$;β_0为常数项;β_1,β_2,β_3,β_4,β_5分别为各煤质参数对临界点温度的回归系数;ε为残差.

前述构建的煤质权重因子修正了煤体自身的化学属性对氧化进程的影响. 然而,煤自燃同样受到环境条件的影响. 孔隙结构、堆积状态和通风条件等物理环境因素通过控制氧气扩散与热量积聚,同样会对预警临界点温度造成影响. 因此,本节理论构建环境权重因子α_e,以此量化环境参数对煤自燃进程的调控作用.

1)环境权重因子α_e是环境参数的无量纲指标,其值大于1表示当前环境条件会加速煤体氧化,使预警提前;小于1则表示环境条件抑制氧化,预警延迟. α_e可表示为各环境参数影响函数的加权和:

$$\alpha_e=\sum_{j=1}^{3} v_j \cdot g_j(\boldsymbol{P}_{e,j}), \tag{14}$$

$$\sum_{j=1}^{3} v_j=1, \tag{15}$$

式中:$\boldsymbol{P}_{e,j}$为环境参数向量,$\boldsymbol{P}_{e,j}=(p, \rho_b, Q)$;其中,$p$为煤体孔隙率,%;$\rho_b$为煤体容重,g/cm^3;$Q$为环境空气流量,mL/min;$v_j$为各环境参数的权重系数;$g_j$为将各参数归一化并表征其与自燃倾向性关系的分量函数.

2)环境权重系数v_j可通过与煤质权重系数相同的多元回归方法确定. 其对应的环境权重多元线性回归模型如下:

$$T_{c,2}=\gamma_0+\gamma_1 p+\gamma_2 \rho_b+\gamma_3 Q+\varepsilon, \tag{16}$$

$$v_j=\frac{|\gamma_k|}{\sum_{k=1}^{3}\gamma_k}, \tag{17}$$

式中:$T_{c,2}$为环境参数对应下煤自燃的各级预警临界点温度;γ_0为常数项;γ_1,γ_2,γ_3分别为各环境参数对临界点温度的回归系数.

将环境参数与煤质参数一同纳入对临界点温度T_c的回归模型中,通过分析标准化回归系数的绝对值大小来分配权重. 其对应煤质权重和环境权重多元线性回归模型如下:

$$T_c=\kappa_0+T_{c,1}+T_{c,2}+\epsilon, \tag{18}$$

式中:κ_0为综合回归模型的截距项;ϵ为模型的随机误差项.

在上述研究中建立了煤质权重因子与环境权重因子,然后利用权重因子对理论临界阈值进行修正,使其能够反映特定煤质与环境条件下的煤自燃预警风险状态. 修正后的标志性气体的有效预警浓度阈值与修正后的临界点温度如下所示:

$$C^{eff}(T)=C^{theory}(T)\cdot\alpha_m\cdot\alpha_e, \tag{19}$$

$$T_c^{eff}=T_c^{theory}\cdot\exp\left[-k_m(\alpha_m-1)-k_e(\alpha_e-1)\right], \tag{20}$$

式中:$C^{eff}(T)$为各标志性气体有效浓度阈值,%,是用于判断气体是否超标的动态标准;$C^{theory}(T)$为各标志性气体理论浓度阈值,%,是由程序升温试验确定的参考浓度;T_c^{eff}为有效临界点温度,℃,表示当前煤质与环境下的实际临界点温度;T_c^{theory}为理论临界点温度,℃,表示在标准煤样和理想环境下的参考临界点温度;k_m和k_e分别为煤质温度偏移系数和环境温度偏移系数,通过试验数据的非线性回归分析拟合得到.

基于修正后的有效阈值,本研究构建的跨矿区自适应动态煤自燃四级预警体系如表3所示. 该体系明确了从绿色安全到红色预警的4个等级、各等级对应的特征气体判据及临界温度点的物理意义.

表 3　基于煤质权重因子与环境权重因子修正后的跨矿区煤自燃四级预警体系

Table 3　Four-level early warning system for spontaneous coal combustion across mining areas based on the correction of coal quality weighting factors and environmental weighting factors

预警阶段	预警颜色	温度区间	阶段起始与结束的标志性气体浓度临界判据	物理意义
无预警	绿色	$T<\Delta T_{CO}^{eff}$	起始：常温，背景 CO 浓度；结束：CO 生成速率曲线出现数学拐点，且 CO 浓度首次超越修正后的安全阈值 $C_{CO}^{eff}(T)$	煤氧复合以物理吸附为主，反应缓慢，处于安全状态
四级预警	黄色	$\Delta T_{CO}^{eff}\sim T_{mut}^{eff}$	起始：CO 浓度达到修正阈值 C_{CO}^{eff}； 结束：CO 生成速率发生首次突变 $D_{mut}^{eff}(T)$	煤自燃进入自动加速阶段，CO 生成速率显著增加
三级预警	橙色	$T_{mut}^{eff}\cap T<T_{C_2H_4}^{eff}$	起始：CO 生成速率进入突变增长阶段 $D_{mut}^{eff}(T)$； 结束：C_2H_4 气体首次被持续检出，$D_{C_2H_4}^{eff}(T)$	氧化反应加速，温度上升加快，C_2H_4 开始稳定生成
二级预警	红色	$T_{C_2H_4}^{eff}\sim T_{C_2H_2}^{eff}$	起始：C_2H_4 浓度稳定超过持续检出阈值 $D_{C_2H_4}^{eff}(T)$； 结束：C_2H_2 气体首次被检出，$C_{C_2H_2}^{eff}(T)$	煤体进入裂解阶段，生成 C_2H_2 气体
一级预警	深红色	$T\geqslant T_{C_2H_2}^{eff}$	起始：C_2H_2 浓度首次超过检测阈值 $C_{C_2H_2}^{eff}(T)$	C_2H_2 持续生成，可能发生明火燃烧

1.2　面向跨域任务的多源异构数据集构建与预处理

1.2.1　试验数据与现场监测数据的来源与特征

为了验证基于煤质权重因子与环境权重因子修正后的跨矿区煤自燃四级预警体系（表 3）的有效性，本文选取大佛寺、魏家地、磁窑堡等 17 座典型矿井煤样，通过程序升温试验系统获取煤自燃氧化过程中多种气体的浓度随温度变化的规律，共完成 102 组试验，并分析了 O_2，CO，CO_2，CH_4，C_2H_6，C_2H_4 等气体与温度的表征关系．研究表明，不同环境条件下不同煤种的煤炭性质不同，对煤炭自燃有影响[18]．因此，为全面表征煤样特性，试验同步测定了 17 组煤样的工业分析（M_{ad}，A_{ad}，V_{ad}，FC_{ad}）及物理参数（孔隙率、煤体积、容重、平均粒径与煤高）．综上，本研究构建的煤自燃试验数据集共包含 102 组样本，包括 9 项静态特征（工业分析与物理参数）与 7 项时序特征（O_2，CO，CO_2，CH_4，C_2H_6，C_2H_4 的浓度及煤温），关于数据集的详细特征描述见本文 1.1 节．同时，为了验证跨矿区煤自燃加权四级预警体系在现场应用过程中的准确性，分别选择大佛寺煤矿 40105 工作面和惠宝煤矿 3^{-1} 煤层 3104 工作面作为试验基地采集现场数据．

为构建大佛寺现场煤自燃监测数据集，本研究采用束管监测系统对 40105 工作面进行连续气体浓度监测．在 285 d 的监测周期内，共获取了 285 组连续气体浓度数据，现场实际监测气体为 CO，O_2，CO_2，CH_4 和 C_2H_6．监测过程中，受工作面推进及顶板坍塌影响，部分测点出现数据中断或失效．为保障数据的连续性与有效性，本研究选取其中一致性较好的 105 号支架监测数据作为代表，构建大佛寺现场煤自燃监测数据集．图 5 所示为 40105 工作面架后 O_2，CO，CO_2，CH_4，C_2H_6 和 C_2H_4 的浓度．由该图可知，在一个循环中，CO，CO_2，CH_4 的浓度呈相同变化趋势，气体浓度逐渐升高达到峰值；而 O_2 浓度呈相反趋势，其浓度逐渐下降至本循环最小值．该结果主要是由于随着采空区工作面的开采，煤体氧化程度增大，O_2 逐渐消耗产生大量的 CO，CO_2 和 CH_4．

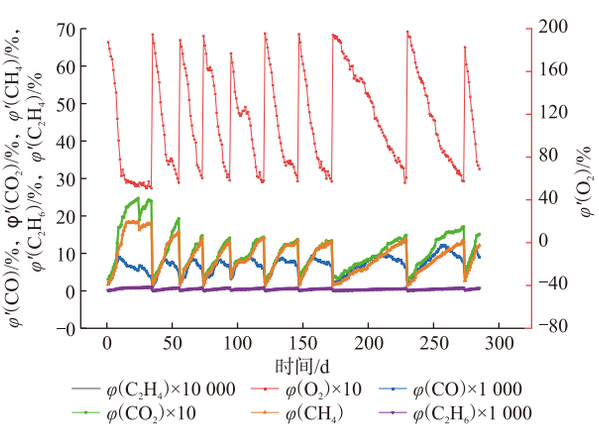

注：$\varphi'(C_2H_4)$，$\varphi'(O_2)$，$\varphi'(CO)$，$\varphi'(CO_2)$，$\varphi'(CH_4)$，$\varphi'(C_2H_6)$ 均为按照图例将数值放大后的各气体浓度．

图 5　大佛寺煤矿 40105 工作面各气体浓度随时间的变化

Fig. 5　Variation of each gas concentration with time in the working face of 40105 in Dafosi coal mine

同样的，采用束管监测系统在惠宝煤矿 3^{-1} 煤层 3104 工作面进行连续气体浓度监测来构建惠宝煤矿现场煤自燃监测数据集．其工作面采样器按照束管保护在回风隅角埋设采样点，获取 2024 年 5 月 12 日至 2024 年 11 月 10 日采样数据共计 183

组，现场实际监测气体为CO，O_2. 图6所示为3104工作的O_2和CO的浓度变化情况. 从图6中可以看出，CO浓度在1.8×10^{-5}～3.0×10^{-5}之间波动，整体呈先上升后下降趋势，在8月至9月达到最高值（2.8×10^{-5}～2.9×10^{-5}），在10月降至1.4×10^{-5}～1.6×10^{-5}，这可能是由于夏季高温可能加速煤氧化反应，导致CO浓度升高. O_2浓度在18.5%～20.1%之间波动，略低于实验室条件（20.95%），每15～20 d出现一次小幅下降，可能与工作面通风周期性调整有关，在约9月底，O_2浓度骤降至18.5%，对应CO浓度同步升高至2.4×10^{-5}，局部氧化反应可能加剧.

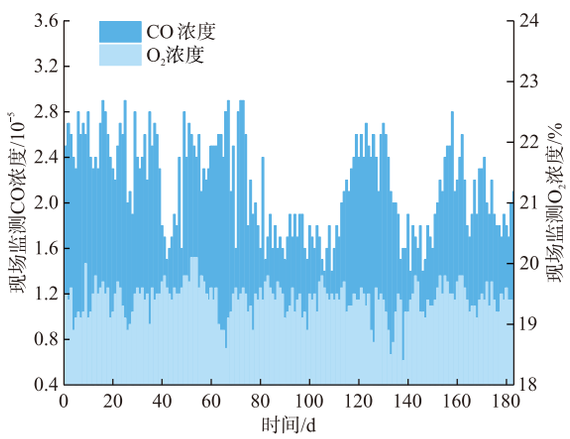

图6 惠宝煤矿3104工作面各气体浓度随时间的变化情况

Fig. 6 Variation of the concentration of each gas in the working face of 3104 in Huibao Coal Mine with time

1.2.2 煤自燃试验数据集特征变量的相关性分析

为分析特征变量相关性对模型预测结果的潜在影响，本研究对煤自燃试验数据集进行了处理. 针对时序特征，通过提取均值将其转换为静态表示，以与静态特征保持一致性. 最终得到热力矩阵图如图7所示，该图直观展示了变量间的相关程度. 分析图7可知，各变量间的相关性揭示了煤自燃过程中复杂的物理化学作用. 水分（M_{ad}）与挥发分（V_{ad}）呈现显著负相关，表明煤样中水分的存在会抑制挥发分的析出，这可能是由于水分蒸发消耗热量并占据孔隙空间，阻碍了挥发分析出. 而煤温与O_2浓度呈明显负相关，体现了煤氧复合反应对氧气的消耗过程. 同时，煤温与CO和CO_2浓度呈正相关，说明温度升高促进了煤的氧化反应. 气体产物之间的相关性进一步揭示了反应路径的关联性，CO与CO_2浓度的正相关性表明它们作为氧化反应主要产物的同步生成特性. 而CH_4浓度与C_2H_6和C_2H_4浓度的正相关性则体现了煤大分子结构热解过程中烷烃类气体的协同释放规律. 在物理特性方面，平均粒径、试管煤高、煤体积、容重和孔隙率等变量之间也存在密切的相互关联关系. 煤颗粒的平均粒径影响煤的堆积状态，进而影响孔隙率和容重. 而较小的粒径会增加容重而降低孔隙率，这种物理结构的协同变化在热力图上表现为较为显著的相关性强度.

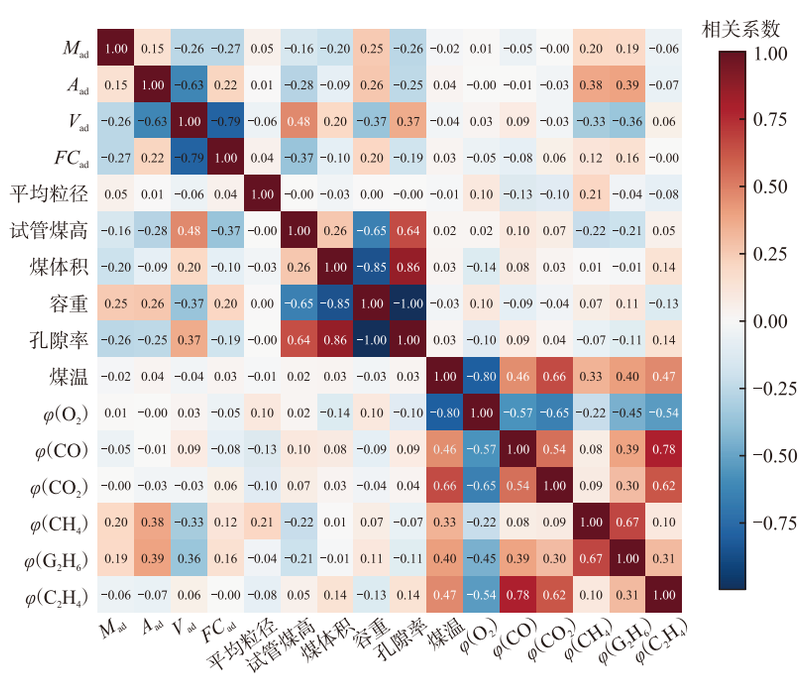

图7 煤自燃试验数据集特征变量热力矩阵

Fig. 7 Thermal matrix of feature variables of the coal spontaneous combustion experimental dataset

1.2.3　试验与现场数据集划分与归一化处理

为构建和验证跨矿区煤自燃四级预警体系与模型，本研究分析了3种不同来源的数据集，并对其进行了明确的划分．首先，煤自燃试验数据集基于17种典型煤样的102组程序升温试验构建，包含了完整的静态特征（工业分析、物理参数）和动态气体浓度序列，用于煤自燃跨域自适应预警模型核心判别规则的建立与参数训练．现场数据集一来自大佛寺煤矿40105工作面的285 d连续监测数据，现场数据集二来自惠宝煤矿3104工作面的183 d监测数据，两者共同用于测试模型在真实矿井环境中的适应性与泛化能力．在数据划分上，煤自燃试验数据集被随机划分为训练集（占总数据比例为80%，共82组）和验证集（占比为20%，共20组），用于模型的初步训练与参数优化．2个现场数据集则作为独立的测试集，以此来避免与训练集在样本来源和时间序列上的重叠，以评估模型在未知场景下的预警准确性和跨矿区应用潜力．

考虑各特征变量量纲与数值范围的差异性，本研究对所有输入特征进行了归一化预处理．对于煤样的工业分析、物理参数及气体浓度等特征，采用最小-最大归一化方法，将其线性变换至[0，1]区间，其计算公式为

$$X_{\mathrm{norm}}=\frac{X-X_{\min}}{X_{\max}-X_{\min}},\tag{21}$$

式中：X_{norm}为经过最小-最大归一化处理后的特征值；X为原始数据；$X_{\min}$和$X_{\max}$分别为对应特征在训练集中的最小值和最大值．

2　物理引导的煤自燃预警跨域自适应模型

2.1　数据-物理融合预警模型框架：特征工程、算法体系与预警自适应

本研究基于102组煤自燃程序升温试验构建煤自燃试验数据集，并通过束管系统分别采集大佛寺煤矿40105工作面和惠宝煤矿3104工作面气体浓度，并建立了相应的现场数据集．在此基础上，通过深度融合煤自燃的物理特性与数据特征，构建了一种数据-物理融合驱动的煤自燃预警跨域自适应模型，实现了从传统经验模型向物理引导的数据驱动模型的跨越．其模型框架包括特征工程、模型结构与预警自适应机制3个部分，模型框架如图8所示．

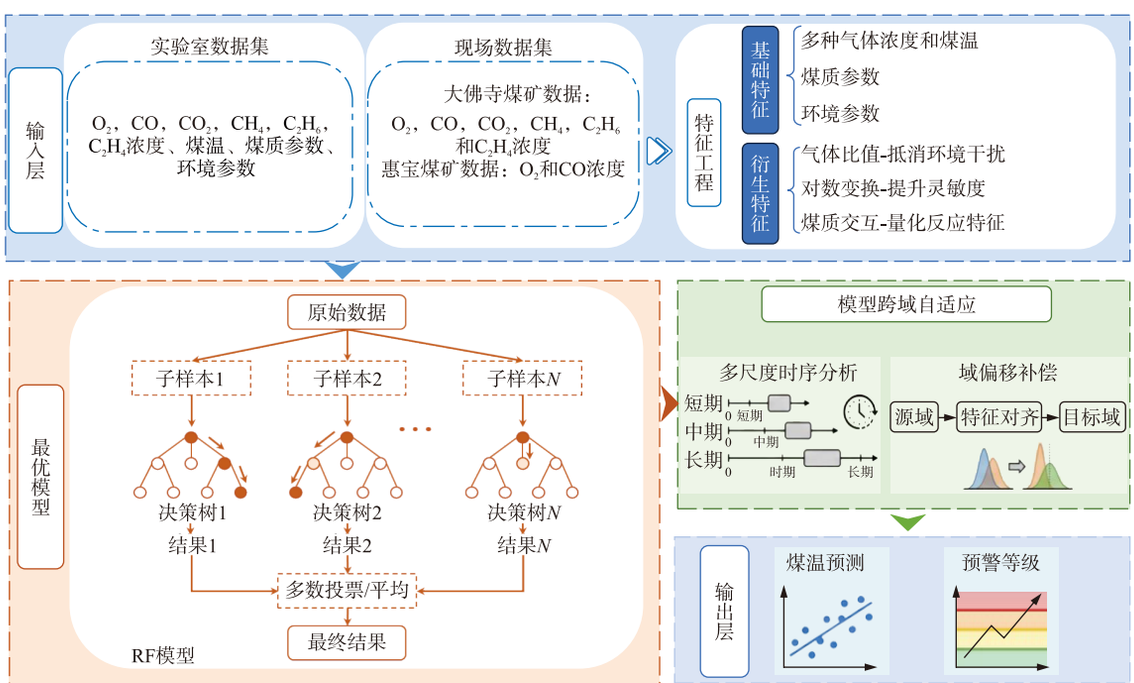

图8　数据-物理融合驱动煤自燃智能预警模型框架

Fig. 8　Data-physical fusion-driven intelligent early warning model framework for coal spontaneous combustion

在特征工程层面，模型重点在于将煤自燃物理特性转化为可量化的机器学习特征．尽管表3所构建的跨矿区煤自燃四级预警体系中以CO，O_2，C_2H_4，C_2H_2等气体浓度作为煤自燃预警标志，但是模型在复杂环境下识别气体易产生偏差．因此，本研究在基础气体浓度指标上，基于煤氧化反应动力学理论，设计了多层次的物理特征．首先，依据反应路径理论构建了$\varphi(\mathrm{CO})/\varphi(\mathrm{CO_2})$，

$\varphi(C_2H_4)/\varphi(C_2H_6)$等气体浓度比值特征，这些特征能够有效表征不同温度区间主导反应路径的转变规律．其次，基于阿伦尼乌斯定律对气体浓度进行对数变换，将指数增长关系线性化，来提升模型在低温阶段的预警灵敏度．此外，通过融合煤质特性参数与气体浓度数据，构建了能够量化煤质对氧化反应活性影响的交互特征．例如，挥发分交互特征捕捉低温氧化活性，水分灰分交互项表明传质传热限制，固定碳交互特征针对高温非线性反应行为．这些特征的设计充分考虑了煤自燃的物理化学本质，为模型提供了坚实的物理基础．

在模型结构方面，由于本研究煤自燃预警数据具有显著的多尺度、非线性与高维特性．特别是试验数据来自程序升温试验过程，呈现出阶段性演化规律，包括低温阶段的缓慢氧化、中温阶段的加速氧化及高温阶段的热解反应．而现场数据则受限于监测点稀疏、噪声干扰强、煤温数据缺失等实际问题，进一步增加了模型的复杂度．且样本分布存在显著不平衡，安全阶段样本数量远多于预警阶段．此外，数据中气体浓度与温度之间呈典型的非线性关系，符合阿伦尼乌斯方程所描述的指数增长规律．不同温度区间对应不同的氧化反应机制，体现出明显的多阶段性．特征维度包括气体浓度、衍生气体浓度比值指标与煤质参数等多源信息，构成高维输入空间．针对上述数据特点，本研究采用了基于物理约束的机器学习方法．具体而言，在模型训练过程中引入了物理一致性约束，如在损失函数中加入单调性约束，确保预测温度随氧化进程单调递增．同时利用迁移学习技术，将实验室标定数据作为源域，现场数据作为目标域，通过域自适应算法有效缓解了分布差异问题．通过对比随机森林、梯度提升、支持向量回归、岭回归以及时空自适应Transformer等多种算法，构建了能够适应数据特性的多算法对比模型．

在预警自适应机制方面，建立了物理规则与数据驱动相融合的决策结构．该结构包含预警等级量化、跨域自适应、多尺度时间适应、不确定性管理等模块．通过动态阈值修正策略，实现基于煤质特性的预警阈值自适应调整．采用域偏移补偿技术，有效解决实验室与现场数据分布差异问题．结合多尺度时序分析方法，提升模型对煤自燃过程的动态捕捉能力．以共同确保模型能够从实验室环境平稳过渡到现场应用．

本研究通过上述3个层面的结合，实现数据驱动方法与煤自燃物理特性的耦合，能够有效克服传统预警模型在跨矿区应用中存在的适应性不足问题，为煤自燃预警提供了新的技术途径．

2.2 基于物理特征加权的多目标模型

本研究的数据-物理融合驱动煤自燃预警模型，在融合煤自燃物理特性的基础上，从4个维度构建输入特征．气体浓度特征作为基础输入，直接表征煤氧复合反应强度(式(22))．气体浓度比值特征基于反应路径理论构建，具有抑制通风干扰、识别反应路径转换的作用(式(23))．对数变换特征依据阿伦尼乌斯定律将指数增长规律线性化，增强对早期微弱氧化信号的识别能力(式(24))．煤质交互特征通过融合煤岩组分参数与气体动态，量化煤质特性对氧化反应活性的影响(式(25))．模型输出定义为双任务结构，主要输出为煤温预测值，实现对煤体热状态的连续回归预测．辅助输出为预警等级，对应表3四级预警体系，实现从安全到紧急状态的离散分类．输入与输出之间的映射关系可表述为式(26)．

$$\boldsymbol{X}_{\text{gas}}=\left[\varphi(\text{CO}),\varphi(\text{O}_2),\varphi(\text{CO}_2),\varphi(\text{CH}_4),\varphi(\text{C}_2\text{H}_4),\varphi(\text{C}_2\text{H}_2)\right] \tag{22}$$

$$\boldsymbol{X}_{\text{ratio}}=\left[\varphi(\text{CO})/\varphi(\text{CO}_2),\varphi(\text{CO})/\varphi(\text{O}_2),\varphi(\text{C}_2\text{H}_4)/\varphi(\text{CH}_4)\right] \tag{23}$$

$$\boldsymbol{X}_{\text{lg}}=\left[\lg\left(1+\varphi(\text{CO})\right),\lg\left(1+\varphi(\text{C}_2\text{H}_4)\right)\right], \tag{24}$$

$$\boldsymbol{X}_{\text{interaction}}=\begin{bmatrix} V_{\text{ad}}\times\varphi(\text{CO}) & V_{\text{ad}}\times\varphi(\text{C}_2\text{H}_4) & V_{\text{ad}}\times\dfrac{\varphi(\text{CO})}{\varphi(\text{CO}_2)} & V_{\text{ad}}\times\lg(1+\varphi(\text{CO})) \\ M_{\text{ad}}\times\varphi(\text{O}_2) & M_{\text{ad}}\times\varphi(\text{CO}_2) & M_{\text{ad}}\times\dfrac{\varphi(\text{O}_2)}{\varphi(\text{CO}_2)} & M_{\text{ad}}\times T_{\text{pred}} \\ A_{\text{ad}}\times\varphi(\text{O}_2) & A_{\text{ad}}\times\dfrac{1}{\varphi(\text{CO})} & A_{\text{ad}}\times p & A_{\text{ad}}\times\rho_{\text{b}} \\ FC_{\text{ad}}\times\varphi(\text{CO}_2) & FC_{\text{ad}}\times\dfrac{\varphi(\text{CO}_2)}{\varphi(\text{CO})} & FC_{\text{ad}}\times T_{\text{pred}}^2 & \end{bmatrix}, \tag{25}$$

$$\left[T_{\text{pred}}, L\right]=f'(\boldsymbol{X}_{\text{gas}}, \boldsymbol{X}_{\text{ratio}}, \boldsymbol{X}_{\text{lg}}, \boldsymbol{X}_{\text{interaction}}; \Theta) \quad ,(26)$$

式中：$\boldsymbol{X}_{\text{gas}}$为气体浓度特征向量；$\boldsymbol{X}_{\text{ratio}}$为气体浓度比值特征向量；$\boldsymbol{X}_{\text{lg}}$为对数变换特征向量；$T_{\text{pred}}$为模型的温度预测值，℃；$L$为预警等级；$\boldsymbol{X}_{\text{interaction}}$为煤质交互特征向量；$p$为煤体孔隙率，%；$\rho_{\text{b}}$为煤体容重，g/cm^3；$\Theta$为模型参数集合；$f'$为非线性预测函数.

针对煤自燃预警数据所呈现的多尺度、非线性及高维特性，本研究构建了包含5类机器学习算法的对比模型体系. 在此基础上，引入多目标优化框架，将预测精度、物理合理性与模型泛化能力统一纳入优化目标，从而保障最终所建模型在遵循煤自燃物理规律的前提下达到最优的综合性能.

1）随机森林（Random Forest Regressor，RFR）模型构建

随机森林算法的Bagging集成框架通过特征随机性和样本重采样的双重随机机制，有效抑制过拟合，适合处理高维小样本数据[26]. 决策树的层级结构契合煤温变化的阶段性特征，能够自动捕捉临界温度附近的非线性跃变行为. 该模型的表达式为

$$\hat{y}_{\text{RF}}=\frac{1}{B}\sum_{b=1}^{B}T_b(\boldsymbol{x};\Theta_b), \qquad (27)$$

式中：$\hat{y}_{\text{RF}}$为随机森林预测的温度值；B为决策树的数量，控制模型复杂度与稳定性；T_b为第b棵决策树的预测函数；$\boldsymbol{x}$为输入特征向量；Θ_b为第b棵决策树的参数集合.

2）梯度提升（Gradient Boosting Regressor，GBR）模型构建

梯度提升算法通过序列优化策略，以前向分步加法模型的方式修正基学习器的预测误差[27]，实现对温度演变趋势的拟合，其表达式如式（28）所示. 该方法能够有效捕捉程序升温试验中温度变化的时序依赖性与非线性累积效应，因为每一棵新树的构建都专注于学习前一序列残差的分布规律. 这种递进式学习机制使其能够自适应地识别从缓慢氧化到加速氧化的关键转变点，从而在时间序列预测任务中表现出更强的鲁棒性.

$$F_m(\boldsymbol{x})=F_{m-1}(\boldsymbol{x})+\nu\cdot h_m(\boldsymbol{x}), \qquad (28)$$

式中：F_m，F_{m-1}分别为第m，$m-1$轮迭代后的强学习器；ν为学习率控制每轮迭代的步长；h_m为第m轮训练的弱学习器（通常为决策树）.

3）支持向量回归（Support Vector Regression，SVR）模型构建

支持向量回归通过核函数方法将原始特征空间中的非线性关系映射到高维特征空间，从而将复杂的非线性拟合问题转化为高维空间中的线性回归问题[28]. 本研究选用径向基（RBF）核函数，因其具有局部响应特性和平滑的函数过渡特性，能够有效拟合煤自燃过程中气体浓度与温度之间存在的复杂非线性映射关系. 该核函数通过调整其带宽参数，可以捕捉从缓慢氧化到加速氧化的不同阶段中，特征气体浓度随温度变化的动态规律. 该模型的表达式为

$$\hat{y}_{\text{SVR}}=\sum_{i=1}^{N}(\alpha_i-\alpha_i^*)K(x_i,x)+b_0, \qquad (29)$$

式中：$\hat{y}_{\text{SVR}}$为支持向量回归预测的温度值；α_i和α_i^*为拉格朗日乘子，对应支持向量的权重；$K(x_i, x)$为核函数，实现非线性映射，在本研究中采用RBF核函数；b_0为偏置项；N为支持向量的数量.

4）岭回归（Ridge Regression，RR）基准模型

在构建数据-物理融合驱动煤自燃智能预警模时，本研究采用岭回归法建立基准模型. 通过最小化残差平方和与系数平方和的加权总和来实现参数估计，其中正则化参数用于平衡模型拟合程度与结构复杂度，而L2范数则作为衡量模型复杂度的约束条件. 作为线性基准参照模型，为评估后续复杂非线性模型的性能提升提供了明确对比依据. 该模型的表达式为

$$\hat{y}_{\text{RR}}=\arg\min_{\beta}+\left(\left\|\boldsymbol{y}-\boldsymbol{X}\boldsymbol{\beta}\right\|^2+\lambda\left\|\boldsymbol{\beta}\right\|^2\right), \qquad (30)$$

式中：$\hat{y}_{\text{RR}}$为岭回归系数估计值；arg min为使后续函数取得最小值的自变量取值；$\boldsymbol{\beta}$为模型的系数向量；$\boldsymbol{y}$为观测温度向量；$\boldsymbol{X}$为特征矩阵；λ为正则化参数，控制模型复杂度.

5）时空自适应Transformer（STAEformer）模型构建

针对煤自燃过程所具有的气体浓度随时间演变的时间依赖性，以及现场不同监测点之间相互关联的空间依赖性，本研究建立时空自适应Transformer模型. 在模型构建过程中，基于Transformer融合自适应位置编码，使模型能够感知监测点的布局关系. 其次，构建了多尺度时间注意力机制，通过并联不同宽度的时序卷积核，分别提取气体浓度的瞬时波动、阶段性转变和长期趋势特征. 最后，引入图结构空间编码，将巷道网络建模为图结构，建立监测点之间的空间关联与气体扩散路径. 该模型的表达式为

$$AT(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=\mathrm{softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{d_{\mathrm{k}}}\right)\boldsymbol{V}, \quad (31)$$

$$PE(t,j)=\sin\left(\frac{t}{10\,000^{j/d}}\right), \quad (32)$$

$$\boldsymbol{h}_i^{(l+1)}=\sigma\left[\sum_{j\in N(i)}\frac{1}{\sqrt{\hat{o}_i^{(l)}\hat{o}_j^{(l)}}}\boldsymbol{W}^{(l)}\boldsymbol{h}_j^{(l)}\right], \quad (33)$$

$$MH(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=\mathrm{Con}(h_1,\cdots,h_h)\boldsymbol{W}^{\mathrm{O}}, \quad (34)$$

$$h_i=AT(\boldsymbol{Q}\boldsymbol{W}_i^{Q},\boldsymbol{K}\boldsymbol{W}_i^{K},\boldsymbol{V}\boldsymbol{W}_i^{V}), \quad (35)$$

式中：$AT(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})$为注意力函数的输出；softmax为归一化指数函数；$\boldsymbol{Q}$为查询矩阵；$\boldsymbol{K}$为键矩阵；$\boldsymbol{V}$为值矩阵；d_{k}为键向量维度；$PE(t,j)$为在位置t上，位置编码向量第j维的值，t为序列中的绝对位置索引；i为维度索引；d为模型隐藏层维；$\boldsymbol{h}_i^{(l+1)}$为节点i在第$l+1$层的输出特征向量；σ为非线性激活函数；$N(i)$为节点i的邻居节点集合；$\hat{o}_i^{(l)}$和$\hat{o}_j^{(l)}$分别为节点i，j在第l层变换后的度；$\boldsymbol{W}^{(l)}$为第l层可学习的权重矩阵；$\boldsymbol{h}_j^{(l)}$为邻居节点j在第l层的输入特征向量；$MH(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})$为多头注意力模块的最终输出；Con为沿特征维度的拼接操作；$\boldsymbol{h}_i$为第i个注意力头的输出矩阵；h为注意力头数，本研究中设置为8；$\boldsymbol{W}_i^{Q}$，$\boldsymbol{W}_i^{K}$，$\boldsymbol{W}_i^{V}$为第i个注意力头的投影矩阵；$\boldsymbol{W}^{\mathrm{O}}$为输出投影矩阵.

6)多目标优化与超参数调优

为构建一个兼具高预测精度、物理合理性与良好泛化能力的煤自燃预警模型，本研究设计了一个多目标优化框架. 该框架通过一个复合损失函数来联合优化上述3个目标，其定义为精度损失(L_{acc})、物理约束损失(L_{phy})和泛化损失(L_{gen})的加权和，如式(36)所示. 首先，L_{acc}用于最小化预测值与真实温度之间的偏差，同时考虑了均方误差与平均绝对误差2种度量. 其次，为增强模型的物理可信度，L_{phy}将煤自燃过程中的温度演化引入优化过程，通过设计物理一致性评估函数，确保预测结果符合煤自燃特征温度的关键出现节点，从而在数据拟合中嵌入物理规律. 最后，L_{gen}通过比较模型在训练集与测试集上预测表现的稳定性，对模型在未知数据上的表现进行优化来提升模型的迁移适用性. 上述3项损失的权重分配通过网格搜索方法确定，以确保模型达到最优平衡. 基于此优化目标，本研究采用网格搜索与交叉验证方法得到对各模型最优超参数组合，如表4所示.

$$\min(L_{\mathrm{total}})=\alpha\cdot L_{\mathrm{acc}}+\beta\cdot L_{\mathrm{phy}}+\gamma\cdot L_{\mathrm{gen}}, \quad (36)$$

$$L_{\mathrm{acc}}=\frac{1}{N}\sum_{i=1}^{N}(y_i-\hat{y}_i)^2+\lambda_1\cdot\frac{1}{N}\sum_{i=1}^{N}\left|y_i-\hat{y}_i\right|, \quad (37)$$

$$L_{\mathrm{phy}}=\lambda_2\sum_{j=1}^{M}\left[\hat{y}_j\notin\Phi(T_{\mathrm{critical}})\right]+\lambda_3\sum_{k=1}^{P}\left|f_{\mathrm{phy}}(\hat{y}_k)\right|, \quad (38)$$

$$L_{\mathrm{gen}}=\frac{1}{K}\sum_{k=1}^{K}\left(\frac{\sigma^2_{\mathrm{train},k}}{\sigma^2_{\mathrm{test},k}}-1\right)^2, \quad (39)$$

式中：L_{total}为总损失函数；α，β，γ为权重系数，其最优值通过网格搜索确定；y_i为第i个样本的真实温度值；$\hat{y}_i$，$\hat{y}_j$，$\hat{y}_k$分别为第i，j，k个样本的预测温度值；N为样本总数；λ_1为均方误差与平均绝对误差的权重平衡参数；$\Phi(T_{\mathrm{critical}})$为基于煤自燃临界点温度的物理约束集合；$f_{\mathrm{phy}}$为物理一致性评估函数；$\lambda_2$，$\lambda_3$为物理约束违规的惩罚系数；$M$，$P$为不同类型的物理约束数量；$\sigma^2_{\mathrm{train},k}$为第$k$折训练集的预测方差；$\sigma^2_{\mathrm{test},k}$为第$k$折测试集的预测方差；$K$为交叉验证折数，本研究取5.

表4 数据-物理融合驱动煤自燃智能预警模型最佳超参数组合

Table 4 Optimal hyperparameter combinations for data-physics fusion-driven coal spontaneous combustion intelligent warning models

模型名称	超参数名称与范围	最优参数组合
RF模型	n_estimators: [50, 100, 200]; max_depth: [5, 10, 15, None]; min_samples_split: [2, 5, 10]; min_samples_leaf: [1, 2, 4]; max_features: ['auto', 'sqrt', 0.5, 0.8]	100; 10; 5; 2; sqrt
GBR模型	n_estimators: [50, 100, 200]; learning_rate: [0.01, 0.05, 0.1, 0.2]; max_depth: [3, 4, 5, 6]; min_samples_split: [2, 5, 10]; min_samples_leaf: [1, 2, 4]	100; 0.1; 6; 5; 2
SVR模型	kernel: ['linear', 'rbf', 'poly']; C: [0.1, 1.0, 10.0, 100.0]; epsilon: [0.01, 0.1, 0.5, 1.0]; gamma: ['scale', 'auto', 0.1, 1.0]	rbf; 1.0; 0.1; scale
RR模型	alpha: [0.001, 0.01, 0.1, 1.0, 10.0, 100.0] solver: ['auto', 'svd', 'cholesky', 'lsqr', 'sparse_cg', 'sag', 'saga']	1.0; auto
STAEformer模型	d_model: [64, 128, 256]; nhead: [4, 8, 16]; num_layers: [2, 3, 4]; dim_feedforward: [128, 256, 512]; dropout: [0.1, 0.2, 0.3] learning_rate: [0.0001, 0.0005, 0.001]	128; 8; 3; 256; 0.1; 0.001

2.3　基于物理规则的跨域自适应方法

本研究基于物理规则建立了煤自燃预警跨域自适应方法包括预警等级量化、跨域自适应、多尺度时间适应、不确定性自适应管理以及自适应性能评估指标[29]. 该方法克服了传统预警模型在跨矿区应用时存在的适应能力不足、迁移效果不佳等难题. 通过采用动态阈值修正、域偏移补偿、多尺度时序分析等方法，使预警模型能够从实验室环境过渡到工业现场.

1)预警等级量化则是基于表3构建的跨矿区四级预警体系，通过煤质与环境权重因子实现阈值的动态修正来提升模型的跨矿区适应性，具体计算过程见式(1)～(20).

2)跨域自适应模型通过引入域偏移补偿函数[30]，解决实验室条件与工业现场环境之间的数据分布差异问题. 该补偿函数基于现场数据分布与实验室数据分布的差异进行动态调整，实现模型从受控实验环境到复杂工业场景的平滑迁移. 自适应权重更新机制则采用递减学习率策略，并引入阿伦尼乌斯方程的温度依赖特性. 确保模型在保持稳定性的同时能够快速适应现场数据特征. 计算过程如下：

$$f_{\text{adapt}}(\boldsymbol{x})=f_{\text{lab}}(\boldsymbol{x})+\Delta(\boldsymbol{x},D_{\text{lab}},D_{\text{field}}),\quad(40)$$

$$\Theta_{t+1}=\Theta_t+\eta_t\cdot\nabla L(\boldsymbol{x}_t,\hat{y}_t),\quad(41)$$

式中：$f_{\text{lab}}(x)$为基于实验室数据训练的基准模型；$\Delta(x,D_{\text{lab}},D_{\text{field}})$为域偏移补偿函数；$D_{\text{lab}}$为实验室数据分布；$D_{\text{field}}$为现场数据分布；$\Theta_{t+1},\Theta_t$分别为$t+1$和$t$时刻的模型参数；$\eta_t$为自适应学习率；$\nabla L$为损失函数梯度；$\boldsymbol{x}_t$为在时间步$t$的输入特征向量；$\hat{y}_t$为基于气体浓度的温度估计值.

3)基于煤自燃过程的多阶段特性，建立了物理引导的时间自适应机制，通过建立不同时间尺度上的自适应机制，有效捕捉煤自燃过程的时序特性. 短期自适应采用滑动窗口加权策略，其滑动窗口大小依据煤氧复合反应的特征时间确定. 中期自适应引入周期性正弦函数[31]. 计算过程如下：

$$y_t^{\text{pred}}=\sum_{i=1}^{w}w_i\cdot f(x_{t-i},\Theta_{t-i}),\quad(42)$$

$$\Theta_{\text{season}}=\Theta_{\text{base}}+\gamma\cdot\sin\left(\frac{2\pi t}{T_{\text{year}}}\right),\quad(43)$$

式中：y_t^{pred}为在时间点t的预测值；Θ_{t-i}为$t-i$时刻的模型参数；w为滑动窗口大小；w_i为时间衰减权重；Θ_{season}为季节性调整后的模型参数向量；Θ_{base}为基准模型参数向量；γ为节调幅度；T_{year}为年周期.

4)不确定性自适应则通过贝叶斯方法[32]量化预测的不确定性，通过引入煤自燃过程的物理约束作为先验分布，为风险预警提供概率依据. 预测不确定性的估计基于参数后验分布的计算，能够反映模型在不同输入条件下的置信水平. 在方差项中，进一步区分了2种误差来源，测量误差项依据传感器精度确定，模型误差项则基于煤氧化反应速率的不确定性进行估计，从而确保不确定度评估具有明确的物理意义. 表达式如下：

$$p(y\mid x,D)=\int p(y\mid x,\Theta)\cdot p(\Theta\mid D)\,\mathrm{d}\Theta,\quad(44)$$

$$\sigma^2(x)=E_\Theta[f^2(x,\Theta)]-E_\Theta[f(x,\Theta)]^2,\quad(45)$$

式中：D为训练数据；p为概率密度函数；$\sigma^2(x)$为预测方差(不确定性度量)；E_Θ为参数后验分布的期望.

5)自适应性能评估指标采用多目标加权函数衡量预警模型的综合性能[33]. 引入物理合理性评分，该指标通过比较模型预测与煤自燃经典理论的符合程度，确保自适应方法在提高精度的同时不牺牲模型的可靠性和可解释性. 其表达式如下：

$$J_a=\frac{1}{N}\sum_{i=1}^{N}(\alpha\cdot A_i+\beta\cdot S_i+\gamma\cdot P_i),\quad(46)$$

式中：J_a为目标函数的最优值；A_i为第i个时间段的预测精度；S_i为模型稳定性指标；P_i为物理合理性评分.

3　基于煤自燃试验数据的模型对比与性能评估

为了评估RF模型、GBR模型、SVR模型、RR模型和STAEformer模型对煤自燃试验数据的预警温度和阶段的预测性能，考虑使用以下指标来定量判断模型的预测性能.

1)平均绝对误差(E_{MAE})：取值范围为[0，+∞)，预测值与试验值的误差越小，数值越小，说

明预测模型的精度越高.

2)均方根误差(E_{RMSE}):样本标准偏差,表示样本的分散程度,数值越小,非线性拟合效果越好.

3)确定系数(R^2):取值范围为[0, 1],越接近1,表明模型的拟合和泛化能力越好.

3个度量公式定义如下:

$$E_{MAE}=\frac{1}{n}\sum_{i=1}^{n}\left|\hat{y}_i-y_i\right|, \tag{47}$$

$$E_{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i-y_i)^2}, \tag{48}$$

$$R^2=1-\frac{\sum_{i=1}^{n}(y_i-\hat{y}_i)^2}{\sum_{i=1}^{n}(y_i-\dot{y})^2}, \tag{49}$$

式中:n为样本数据的总和;y_i为第i个样本的真实温度值;$\hat{y}_i$为第i个样本的预测温度值;$\dot{y}$为试验值的平均值.

表5为RF模型、GBR模型、SVR模型、RR模型和STAEformer模型对煤自燃试验数据的预警温度和阶段的预测性能.从表中可知,不同的机器学习模型在煤自燃试验数据上表现出不同的性能特征.总体而言,集成树模型(RF和GBR模型)在预测精度与泛化能力上均表现出绝对优势,其测试集上的E_{MAE}均低于9.5 ℃,R^2高于0.92.该结果可能是由于煤自燃过程是一个典型的多阶段、非线性化学反应过程,气体浓度与温度之间的关系呈现复杂的指数特征.RF和GBR模型通过集成大量决策树,能够有效捕捉高维特征空间中复杂的非线性映射,从而实现对预警温度和阶段的较好预测.值得注意的是,RF模型通过Bagging集成策略引入了更高的随机性,在煤自燃试验数据集上表现出更优的鲁棒性和泛化性能.与集成树模型相比,SVR与RR模型表现欠佳.RR模型(R^2=0.89)尚可作为基线参考,而SVR模型可能因数据非线性显著且超参数敏感,导致拟合效果较差.STAEformer模型虽更加适合处理时空依赖,但在样本有限的试验数据上表现最差(R^2=0.60),训练耗时也最长.该结果表明复杂模型在小数据集上出现欠拟合状态.综上分析,RF模型在精度、泛化性与效率上综合最优,适合作为数据-物理融合驱动煤自燃智能预警模型的基础模型.

表5 RF,GBD,SVR,RR和STAEformer模型对煤自燃试验数据的预警温度和阶段预测性能

Table 5 Performance of RF, GBD, SVR, RR and STAEformer models for predicting warning temperatures and stages for experimental data on spontaneous coal combustion

模型名称	训练阶段			测试阶段			训练时间/s
	E_{MAE}/℃	E_{RMSE}/℃	R^2	E_{MAE}/℃	E_{RMSE}/℃	R^2	
RF模型	4.24	5.46	0.99	9.18	11.81	0.93	0.30
GBR模型	2.79	3.60	0.99	9.34	12.21	0.92	0.31
SVR模型	19.13	24.70	0.69	19.33	24.21	0.69	0.30
RR模型	10.50	13.83	0.90	11.69	14.51	0.89	0.40
STAEformer模型	20.50	26.30	0.65	21.80	26.30	0.60	7.40

如图9所示,RF模型在煤自燃试验数据集上表现出较好的综合性能,进一步证明了表5的性能指标结果.从图9a来看,模型预测结果与实际煤温高度吻合,模型整体R^2高达0.973 5,E_{RMSE}与E_{MAE}分别为7.20与5.23 ℃.由从图9b可知,模型能够划分从低温安全状态到高温危险状态的完整演变过程,各阶段边界明确且与实际温度演化规律一致.误差分析(图9c)则表明预测偏差集中在零值附近窄幅区间,呈正态分布,证明了模型的稳定性和可靠性.从图9d可知模型预警逻辑与表3逻辑一致,随着CO标志性气体浓度升高,预警等级相应提升,体现了数据与物理特性的契合.这些结果证明了RF模型在煤自燃预警中兼具预测精度、稳定性和物理解释性,为其在跨域自适应预警中进一步应用奠定了基础.

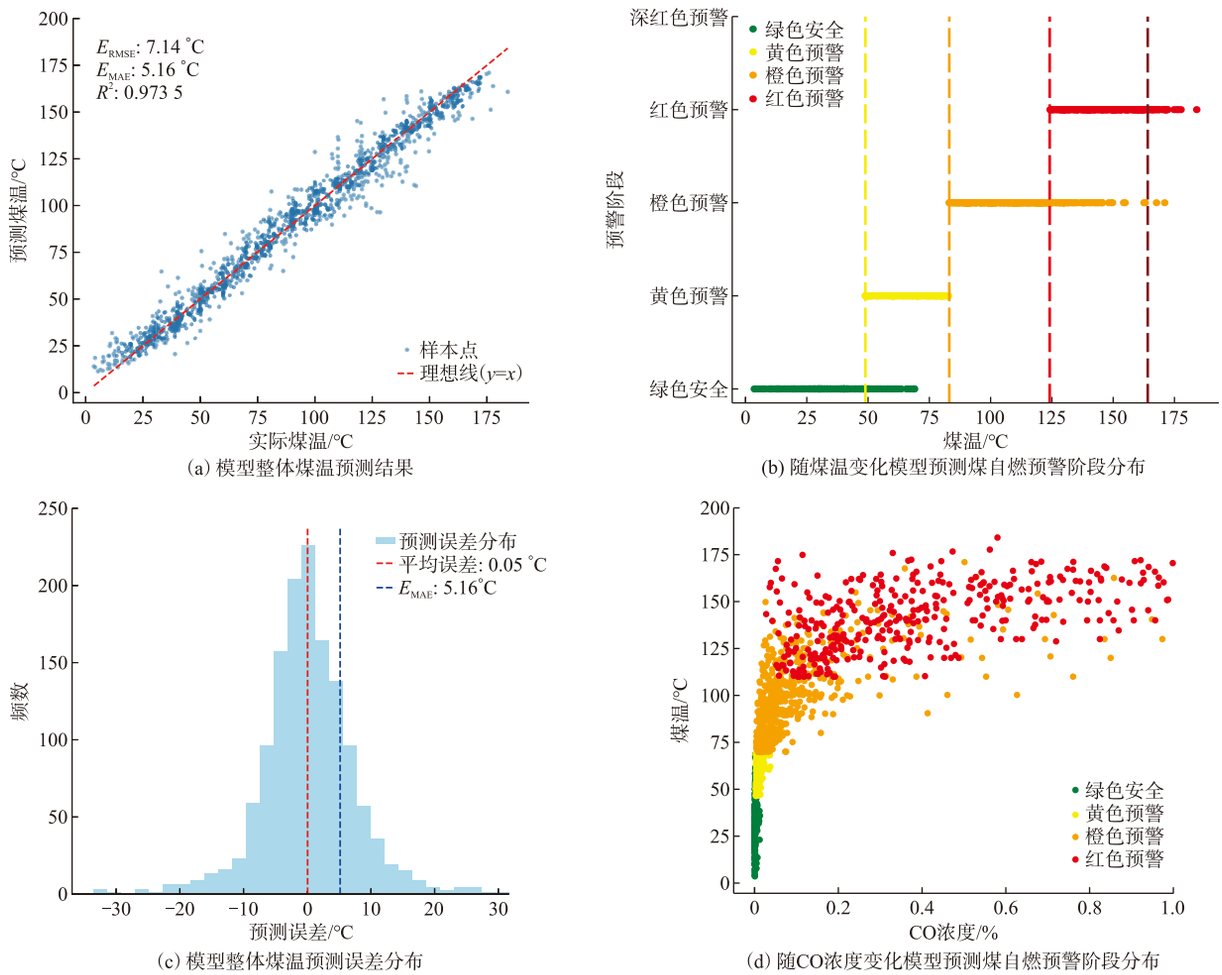

(a) 模型整体煤温预测结果　(b) 随煤温变化模型预测煤自燃预警阶段分布

(c) 模型整体煤温预测误差分布　(d) 随CO浓度变化模型预测煤自燃预警阶段分布

图 9　基于煤自燃实验数据集 RF 模型对煤温与预警阶段预测情况

Fig. 9　Prediction of coal temperature and warning stage based on RF model of coal spontaneous combustion experimental dataset

4　工业现场验证与模型迁移

本研究基于随机森林(RF)算法构建了数据—物理融合驱动的煤自燃智能预警模型．通过煤自燃程序升温试验数据的优化与验证后，进一步将 RF 模型应用到矿井现场，评估其在实际矿井环境中的跨域迁移性能．如图 10 所示，在存在真实发火历史的大佛寺煤矿，模型面对与实验室受控条件显著不同的数据分布，基于气体浓度数据并结合预警等级量化、跨域自适应、多尺度时间适应、不确定性自适应管理机制以及自适应性能评估指标，成功识别出煤温峰值近 110 ℃的危险状态，准确触发橙色预警，其决策逻辑与真实火情演化吻合．为量化验证模型输出的合理性，将预测温度序列与现场独立监测的 CO 浓度进行相关性分析，结果显示二者的皮尔逊相关系数为 0.87，表明该相关性具有高度的统计学显著性($p<0.000\ 1$)．该结果表明模型有效捕捉了煤氧化过程中温度与 CO 生成之间的内在物理关联．与此同时，在惠宝煤矿的安全场景中，模型始终保持绿色安全预警，预测温度稳定在 20～45 ℃区间，体现了较好的阴性判断能力．现场监测数据显示，CO 浓度在 1.8×10^{-5}～3.0×10^{-5}范围内波动，未出现持续上升趋势．O_2浓度维持在 18.5%～20.1% 之间，未见异常耗氧现象．该结果定量验证了模型在真实复杂环境下具备良好的阴性识别能力与误报控制水平．

从工程应用情况来看，RF 模型展现出显著的部署优势．其单次预测时间低于 0.4 s 的实时性表现，满足井下监测系统对响应速度的严格要求．相较于计算复杂度高的深度学习模型，该模型在保证预警精度的同时，兼具优异的计算效率和经济性，为不同信息化基础的煤矿提供了切实可行的解决方案．该结果表明，本研究构建的物理引导数据驱动煤自燃预警模型成功突破了传统经验模型的适应性局限，实现了从实验室到多样化矿井工业场景的平滑迁移，为煤矿煤自燃防控提供了兼具准确性、鲁棒性和实用性的预警模型．

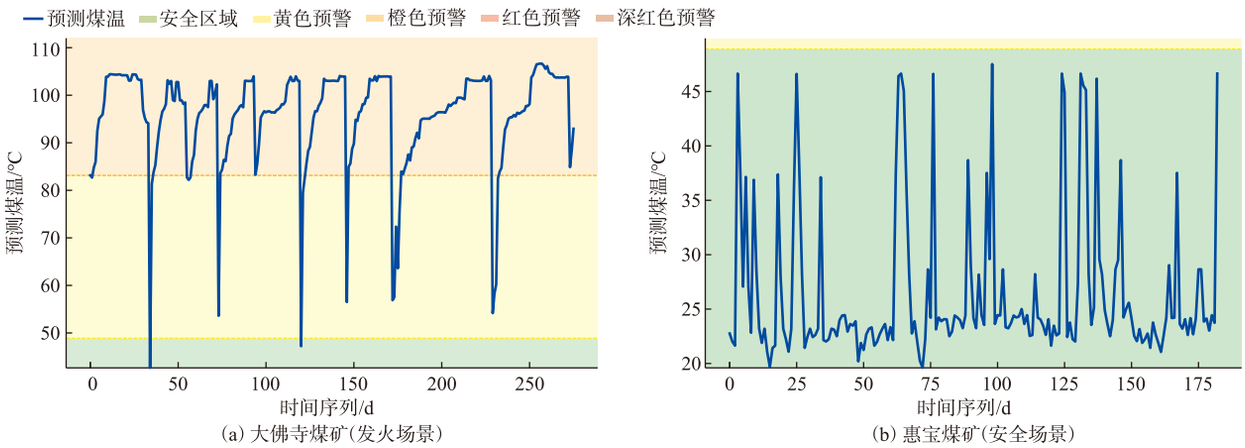

图 10 煤自燃智能预警模型跨矿区验证结果

Fig. 10 Cross-mining validation results of the coal spontaneous combustion intelligent early warning model

5 结 论

1)基于 17 座煤矿 102 组程序升温试验数据，构建了基于动态阈值修正的跨矿区煤自燃加权四级预警理论体系. 该体系通过引入煤质权重因子和环境权重因子，实现了煤自燃各级预警临界判据点对不同矿区的动态自适应，为模型跨域迁移奠定了物理规则内核和可解释性依据，克服了传统固定阈值法的固有局限.

2)基于煤自燃试验数据融合理论体系的核心规则，构建了物理与数据驱动相融合的预警模型，通过模型对比，明确了随机森林算法在精度(训练：R^2=0.99；测试：R^2=0.93)与效率(预测时间<0.4 s)上的综合优势，将其确定为跨域模型的最佳承载算法，实现了对煤自燃复杂非线性过程的较好拟合.

3)通过跨域矿井现场验证，证明了本文所提预警体系与跨域自适应模型具有优良的跨矿区适应性和工程实用价值. 在同一模型参数下，大佛寺煤矿(发火场景)能准确识别危险状态，惠宝煤矿(安全场景)则实现零误报. 该结果强有力地证明了本预警体系与模型解决了不同矿区的泛化难题，实现了从实验室到矿井现场的可靠迁移. 针对高温预警判据在实验验证方面的局限，未来拟升级试验系统，以分析 C_2H_2 在 200 ℃以上的生成规律，从而完善预警体系验证.

参考文献：

[1] 康红普，谢和平，任世华，等. 全球产业链与能源供应链重构背景下我国煤炭行业发展策略研究[J]. 中国工程科学，2022，24(6)：26-37.
KANG Hongpu, XIE Heping, REN Shihua, et al. Development strategy of China's coal industry under the reconstruction of global industrial chain and energy supply chain [J]. Strategic Study of Chinese Academy of Engineering, 2023, 24(6): 26-37.

[2] 孙继平，钱晓红. 2004—2015 年全国煤矿事故分析[J]. 工矿自动化，2016，42(11)：1-5.
SUN Jiping, QIAN Xiaohong. Analysis of coal mine accidents in China during 2004—2015 [J]. Journal of Mine Automation, 2016, 42(11): 1-5.

[3] 邓 军，屈高阳，任帅京，等. 地下煤火火源探测研究[J]. 工矿自动化，2023，49(6)：68-77.
DENG Jun, QU Gaoyang, REN Shuaijing, et al. Research on underground coal fire source detection [J]. Journal of Mine Automation, 2023, 49(6): 68-77.

[4] 邓 军，王津睿，任帅京，等. 采空区煤自燃高温点识别与探测技术研究与展望[J]. 煤炭学报，2024，49(2)：885-901.
DENG Jun, WANG Jinrui, REN Shuaijing, et al. Identification and detection technology for high-temperature spontaneous combustion points in goaf areas [J]. Journal of China Coal Society, 2024, 49(2): 885-901.

[5] FENG Q H, ZHANG J Y, ZHANG X M, et al. Proximate analysis based prediction of gross calorific value of coals: A comparison of support vector machine, alternating conditional expectation and artificial neural network [J]. Fuel Processing Technology, 2015, 129(1): 120-129.

[6] 张鹏宇，马 砺，石新慧，等. 基于时序优化长短期记忆网络的采空区环境多参数预测[J]. 中国矿业大学学报，2025，54(3)：653-666.
ZHANG Pengyu, MA Li, SHI Xinhui, et al. Multi-parameter prediction of goaf environment based on

time-series optimizedlong short-term memory network [J]. Journal of China University of Mining & Technology,2025,54(3):653-666.

[7] ZHOU Q, MAO X S, JIA B J. Development of a graded early warning index system and identification of critical temperatures for coal spontaneous combustion using composite gas characteristics [J]. ACS Omega, 2024, 9(33): 35515-35525.

[8] ZHU H Q, SHENG K, ZHANG Y L, et al. The stage analysis and countermeasures of coal spontaneous combustion based on "five stages" division [J]. Plos One, 2018(13): e0202724.

[9] GUO J, QUAN Y P, CAI G B, et al. Meticulous graded and early warning system of coal spontaneous combustion based on index gases and characteristic temperature[J]. ACS Omega, 2023(8): 6801-6812.

[10] GUO C W, JIANG S G, SHAO H, et al. Effect of secondary oxidation of pre-oxidized coal on early warning value for spontaneous combustion of coal [J]. Applied Sciences, 2023(13): 3154.

[11] WANG C X, HU P, SUN Y F, et al. Study on CO source identification and spontaneous combustion warning concentration in the return corner of working face in shallow buried coal seam [J]. Environmental Science and Pollution Research, 2024(31): 15050-15064.

[12] 贾澎涛,张　杰,郭风景.基于GAT-Informer的采空区煤自燃温度预测模型[J].工矿自动化, 2024, 50(11):92-98.
JIA Pengtao, ZHANG Jie, GUO Fengjing. Coal spontaneous combustion temperature prediction model for goaf area based on GAT Informer [J]. Journal of Mine Automation,2024,50(11):92-98.

[13] 任万兴,郭　庆,石晶泰,等.基于标志气体统计学特征的煤自燃预警指标构建[J].煤炭学报,2021,46(6):1747-1758.
REN Wanxing, GUO Qing, SHI Jingtai, et al. Construction of early warning indicators for coal spontaneous combustion based on statistical characteristics of index gases [J]. Journal of China Coal Society, 2021, 46(6): 1747-1758.

[14] 邓　军,肖　旸,陈晓坤,等.矿井火灾多源信息融合预警方法的研究[J].采矿与安全工程学报,2011,28(4):638-643.
DENG Jun, XIAO Yang, CHEN Xiaokun, et al. Study on early warning method of multi-source information fusion for coal mine fire [J]. Journal of Mining & Safety Engineering, 2011, 28(4): 638-643.

[15] 罗振敏,张利冬,宋泽阳.基于全连接的长短期记忆网络实现采空区CO多步预测[J].清华大学学报(自然科学版),2024,64(6):940-952.
LUO Zhenmin, ZHANG Lidong, SONG Zeyang. Multistep prediction of CO in the extraction zone based on a fully connected long short-term memory network [J]. Journal of Tsinghua University (Science and Technology), 2024, 64(6): 940-952.

[16] ZHANG P Y, CHEN X K. An unsupervised learning approach for coal spontaneous combustion warning level classification using *t*-sen and *k*-means clustering [J]. Applied Sciences-Basel, 2025, 15(7): 3756.

[17] 孔　彪,郑永超,冯　新,等.基于支持向量机的煤自燃声学预警方法研究[J].清华大学学报(自然科学版),2025,65(4):769-776.
KONG Biao, ZHENG Yongchao, FENG Xin, et al. Research on acoustic early warning method for coal spontaneous combustion based on optimization support vector machine [J]. Journal of Tsinghua University (Science and Technology), 2025, 65(4): 769-776.

[18] OREM W H, FINKELMAN R B. Coal formation and geochemistry[M]. Oxford: Elsevier-Pergamon, 2003: 191-222.

[19] GBADAMOSI A R, ONIFADE M, GENC B, et al. Analysis of spontaneous combustion liability indices and coal recording standards/basis [J]. International Journal of Mining Science and Technology, 2020, 30(5):723-736.

[20] LIU Y, SHI Z Z, JIA Y X, et al. Distinguishing the self-ignition and ignition temperatures of coal based on Semenov's thermal explosion theory [J]. Flue, 2025, 384: 33982.

[21] 王德明.矿井火灾学[M].徐州:中国矿业大学出版社,2008:219-240.
WANG Deming. Mine fire science [M]. Xuzhou: China University of Mining and Technology Press, 2008: 219-240.

[22] KAM A Y, HIXSON A N, PERLMUTTER D D. The oxidation of bituminous coal: II experimental kinetics and interpretation [J]. Chemical Engineering Science, 1976, 31(9): 821-834.

[23] NALBANDIAN H. Propensity of coal to self-heat [M]. London: IEA Clean Coal Centre, 2010.

[24] WANG Y J, ZHANG X M, ZHANG H M, et al. Effects of temperature gradient and particle size on self-ignition temperature of low-rank coal excavated from inner Mongolia, China [J]. Royal Society Open Science, 2019, 6(9): 190374.

[25] LIANG Y T, ZHANG J, WANG L C, et al. Forecasting spontaneous combustion of coal in underground coal mines by index gases: A review [J]. Journal of Loss Prevention in the Process Industries, 2019, 57: 208-222.

[26] 苗国栋.用于煤自燃预报的大分子量气态产物生成机理及运移特征研究[D].徐州:中国矿业大学,2024.
MIAO Guodong. Formation mechanism and transportation characteristics of higher-molecular-weight gaseous products for forecasting coal spontaneous combustion [D]. Xuzhou: China University of Mining and Technology, 2024.

[27] 张利冬,宋泽阳,罗振敏,等.基于机器学习的煤自然发火期预测[J].中国安全科学学报,2022,32(12):118-124.
ZHANG Lidong, SONG Zeyang, LUO Zhenmin, et al. Prediction of coal spontaneous combustion period based on machine learning [J]. China Safety Science Journal, 2022, 32(12): 118-124.

[28] 王 宸,宋言明,肖 双,等.基于极限梯度提升的表面气动热预测代理模型[J/OL].北京航空航天大学学报,2025,1-16 [2025-11-10]. https://doi.org/10.13700/j.bh.1001-5965.2025.0515.
WANG Chen, SONG Yanming, XIAO Shuang, et al. Surrogate model for surface aerodynamic heating prediction based on extreme gradient boosting [J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 1-16 [2025-11-10]. https://doi.org/10.13700/j.bh.1001-5965.2025.0515.

[29] 杨 暾,叶树刚,马 明,等.基于KPCA-PSO-SVR模型的煤层厚度动态预测方法[J/OL].煤田地质与勘探,2025,1-12 [2025-11-15]. https://link.cnki.net/urlid/61.1155.P.20250822.1203.004.
YANG Tun, YE Shugang, MA Ming, et al. Dynamic prediction method of coal seam thickness based on KPCA-PSO-SVR model [J/OL]. Coal Geology & Exploration, 2025, 1-12 [2025-11-15]. https://link.cnki.net/urlid/61.1155.P.20250822.1203.004.

[30] 王 岩,寇浩楠,张旭辉,等.数字李生驱动的智能掘进设备虚实交互控制方法[J].中国矿业大学学报,2025,54(2):330-342
WANG Yan, KOU Haonan, ZHANG Xuhui, et al, Virtual physical interaction control method for intelligent cantileverroadheader driven by digital twin [J]. Journal of China University of Mining &. Technology, 2025,54(2):330-342.

[31] 吴 娟.基于衰减补偿的高斯束偏移方法研究[D].北京:中国石油大学(北京),2016.
WU Juan. Research on Gaussian beam migration method based on attenuation compensation [D]. Beijing: China University of Petroleum (Beijing), 2016.

[32] 覃海波,雒江涛,许国良.联合滑动窗口和加权评分的多人比赛球员重识别算法[J].计算机辅助设计与图形学学报,2024,36(11):1781-1790.
QIN Haibo, LUO Jiangtao, XU Guoliang. Algorithm for players re-identification in multiplayer sports game joint sliding window and weighted scoring [J]. Journal of Computer-Aided Design & Computer Graphics, 2024, 36(11): 1781-1790.

[33] 蒋丹萍,戴紫彬,刘燕江,等.贝叶斯优化驱动的粗粒度可重构密码逻辑阵列设计空间探索方法[J].电子与信息学报,2025,47(11):4482-4492.
JIANG Danping, DAI Zibin, LIU Yanjiang, et al. Bayesian optimization-driven design space exploration method for coarse-grained reconfigurable cipher logic array [J]. Journal of Electronics & Information Technology, 2025, 47(11): 4482-4492.

[34] 王 乐,李 冬,余慕春,等.基于动态加权系数和多目标进化的模型修正方法[J].振动与冲击,2020,39(4):284-290.
WANG Le, LI Dong, YU Muchun, et al. A method of model updating based on dynamic weighting coefficients and multi-objective evolution [J]. Journal of Vibration and Shock, 2020, 39(4): 284-290.

(责任编辑 沈春妮 仝 腾)