研究论文

DOI：10.11949/0438-1157.20260055

基于BO-CNN与Grad-CAM的天然气管道可解释性多工况识别方法

孔德志[1]，贾文龙[1]，向敏[2]，李长俊[1]，刘珈铨[1]

（[1]西南石油大学石油与天然气工程学院，四川 成都 610500；[2]国家管网集团生产部，北京 100013）

摘要： 准确识别天然气管道调压、调流、堵塞、泄漏及阀门关断等多类工况，是管道故障诊断和在线仿真数字滤波的基础。本研究提出一种融合贝叶斯优化与梯度加权类激活映射（gradient-weighted class activation mapping，Grad-CAM）可解释性分析的多工况智能识别框架。基于某输气管道的动态仿真数据，建立卷积神经网络模型（convolutional neural network，CNN）；采用Grad-CAM方法对CNN模型进行改进；利用贝叶斯优化算法（Bayesian optimization，BO）对L2正则化系数、学习率以及丢弃率进行优化，形成了CNN-Grad-CAM模型；利用覆盖压力（7.5~9.5 MPa）、流量（1250×10^4~1550×10^4 $m^3\cdot d^{-1}$）等多种运行条件的时序数据集，对模型进行检验。结果表明：分类识别率达到了98.75%；与其他模型相比，CNN-Grad-CAM模型能够更好地提取到局部特征，面对易混淆的工况也能够准确识别。在数据缺失和噪声干扰等复杂场景下模型依旧能够保持稳定性能。对某输气管道的泄漏信号识别准确率为100%。

关键词： 天然气；管道工况识别；神经网络；算法；贝叶斯优化；Grad-CAM；可解释性分析

中图分类号： TE 88　　**文献标志码：** A

文章编号： 0438-1157（2026）10-6189-11

Interpretable multi-condition identification method for natural gas pipelines based on BO-CNN and Grad-CAM

KONG Dezhi[1], JIA Wenlong[1], XIANG Min[2], LI Changjun[1], LIU Jiaquan[1]

([1]*School of Petroleum and Natural Gas Engineering, Southwest Petroleum University, Chengdu* 610500, *Sichuan, China*; [2]*PipeChina Production Department, Beijing* 100013, *China*)

Abstract: Accurate identification of multiple operating conditions in natural gas pipelines, such as pressure and flow regulation, blockage, leakage, and valve shut-off, serves as the foundation for pipeline fault diagnosis and digital filtering in online simulations. This paper proposes an intelligent identification framework for multiple operating conditions that integrates Bayesian optimization (BO) with the interpretability analysis of gradient-weighted class activation mapping (Grad-CAM). First, a convolutional neural network (CNN) model is established based on dynamic simulation data from a gas pipeline. The model is then improved using the Grad-CAM method. Subsequently, Bayesian optimization is employed to optimize the L2 regularization coefficient, learning rate, and dropout rate, resulting in the developed CNN-Grad-CAM model. The model is validated using a time-series dataset covering various operating conditions, including pressures ranging from 7.5 MPa to 9.5 MPa and flow rates from 1250×10^4 $m^3\cdot d^{-1}$ to 1550×10^4 $m^3\cdot d^{-1}$. The results indicate that the classification recognition rate reaches 98.75%.

收稿日期： 2026-01-13　　**修回日期：** 2026-04-01

通信作者： 贾文龙（1986—），男，博士，教授，jiawenlong08@126.com

第一作者： 孔德志（2002—），男，硕士研究生，2421830512@qq.com

基金项目： 国家重点研发计划项目（2025YFF1505700）

引用本文： 孔德志, 贾文龙, 向敏, 李长俊, 刘珈铨. 基于BO-CNN与Grad-CAM的天然气管道可解释性多工况识别方法[J]. 化工学报, 2026, 77(10): 6189-6199

Citation: KONG Dezhi, JIA Wenlong, XIANG Min, LI Changjun, LIU Jiaquan. Interpretable multi-condition identification method for natural gas pipelines based on BO-CNN and Grad-CAM[J]. CIESC Journal, 2026, 77(10): 6189-6199

Compared with other models, the CNN-Grad-CAM model demonstrates superior capability in extracting local features and accurately identifying easily confused operating conditions. Furthermore, the model maintains stable performance even in complex scenarios involving data loss and noise interference. The identification accuracy for actual leakage signals from a specific gas pipeline achieves 100%.

Keywords: natural gas; pipeline operating condition identification; neural network; algorithm; Bayesian optimization; Grad-CAM; interpretability analysis

引 言

天然气作为一种优质高效的低碳能源，是中国经济高质量发展新时期具消费潜力的化石能源[1-3]，同时也是我国实现“双碳”目标的重要能源支撑[4]。管道作为输送天然气的核心基础设施，具有安全、高效、便捷等特点。截至2024年底，我国天然气管道总里程已超过12.8万千米，覆盖全国。然而管道在运行过程中会因各种因素而出现调压调流、堵塞、泄漏以及阀门关断等工况。其中，异常工况（如堵塞、泄漏等）若不能及时识别与处置，易引发安全事故、输送中断、设备损伤以及运行效率下降等问题[5-6]，严重影响管道的安全平稳运行。因此，准确、及时地识别各类工况，尤其是异常工况，对于实现早期预警、支持运行决策、提升管道智能化管理水平具有重要的工程意义。传统的工况诊断方法主要依赖于基于机理模型的瞬变流分析[7]、基于统计理论的信号处理[8]以及专家系统规则[9]等。尽管这些方法在一定程度上奠定了理论基础，但在实际应用中往往面临严峻挑战：机理模型严重依赖管道的精确物理参数，在复杂工况下适应性不足[10]；基于阈值规则的专家系统误报率高，且难以区分症状相似的工况[11]；传统机器学习方法则高度依赖专家的特征工程，其性能瓶颈明显[12]。

为了突破上述局限，研究者们逐渐将目光转向数据驱动技术。如有学者采用时间序列森林[13]、支持向量机[14-17]、XGBoost[18]等浅层模型，在特定场景下取得了良好效果。郑坚钦等[19-20]尝试结合卷积自编码器、变分模态分解等信号处理技术与神经网络，提升了特征质量。近年来，长短期记忆网络（LSTM）、卷积神经网络等深度学习模型已广泛应用于端到端的学习任务中，展现了强大的时序数据处理能力[21-25]。

尽管相关研究已取得显著进展，但当前领域仍存在不足：第一，研究对象多集中于输油管道，由于天然气与石油在物理特性上存在本质区别，天然气的可压缩性导致水力瞬变过程更复杂、非线性更强。因此，适用于输油管道的模型可能无法捕捉到天然气管道在复杂工况下的精细特征。针对天然气管道，尤其是其多种典型工况的综合识别研究尚显不足。第二，现有研究，包括先进的深度学习模型，大多停留在追求高精度分类的“黑箱”阶段，模型决策的内部逻辑缺乏合理解释，这阻碍了其在安全苛求的工业场景中获得工程师的信任与采纳。

针对以上不足，本文提出一种融合可解释性分析的天然气管道多工况智能识别框：构建卷积神经网络模型，直接从多通道SCADA时序数据中实现调压调流、堵塞、泄漏及阀门关断4类工况的端到端识别；引入梯度加权类激活映射技术对模型决策进行可视化与量化分析，揭示关键传感器与时间点，并结合管道流动与热力学机理验证决策依据；通过消融实验与多模型对比，评估模型在不同时间长度、采样间隔、数据缺失以及噪声场景下的性能，为工业应用提供依据。

1 数据集构建

1.1 数据获取

由于输气管道异常工况的实测数据较少，难以满足模型的训练需求，因此本文以某输气管道为例，采用动态仿真模拟的方式生成各类异常工况的数据，用于模型的训练与验证。该输气管道沿线通过阀室和站场将管道划分为30余个管段，每段长度介于8~32 km。管道管径为1016 mm，运行流量范围为1250×10^4~1550×10^4 $m^3\cdot d^{-1}$，设计压力为10 MPa。

为构建数据集，本文设置了不同的压力和流量工况（首站压力范围为7.5~9.5 MPa，流量范围为1250×10^4~1550×10^4 $m^3\cdot d^{-1}$），并在不同管段处分别模拟了堵塞（堵塞面积30%~70%）、阀门关断、泄漏（泄漏孔径25~600 mm）以及调压、调流共5类工况。利

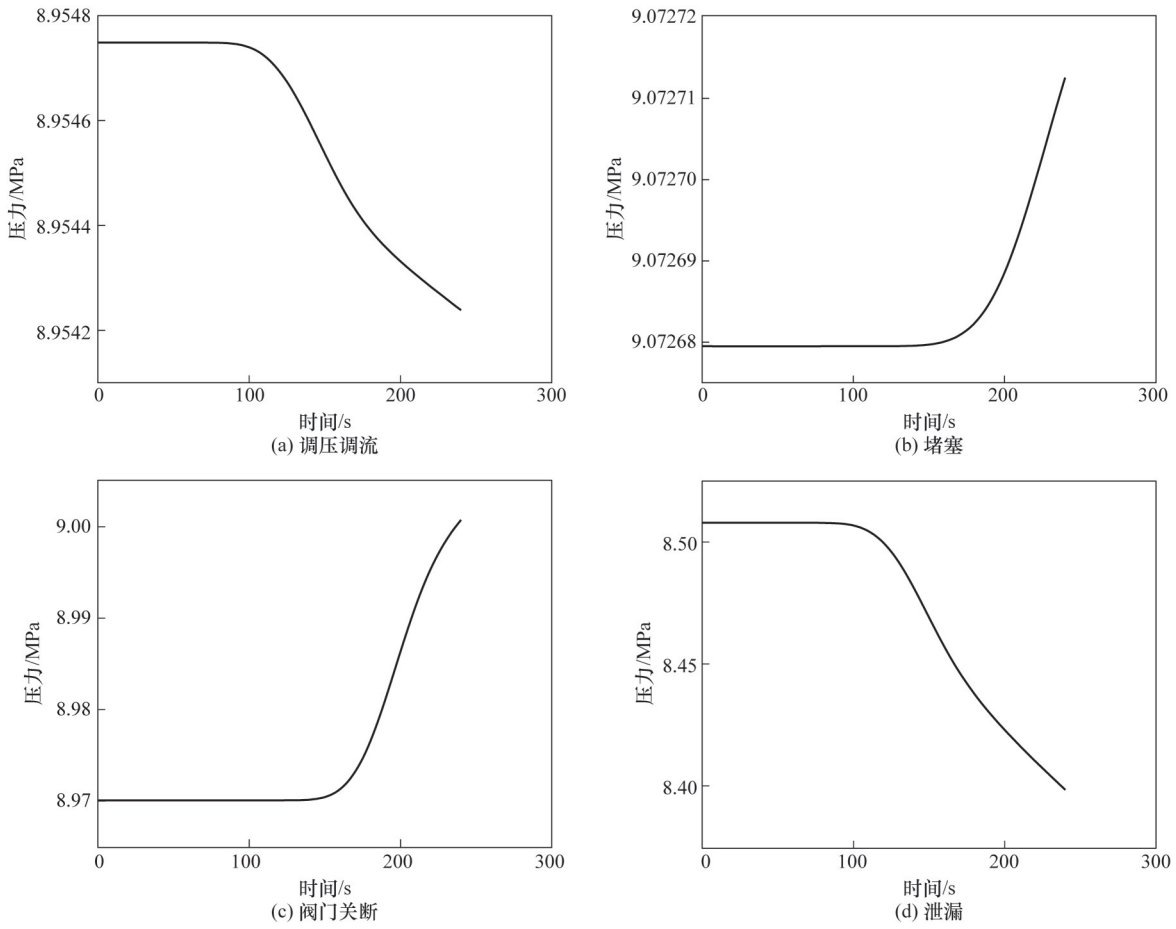


图1 不同工况下压力随时间的变化曲线

Fig.1 Curves of pressure variation with time under different operating conditions

用Pipeline Studio软件进行仿真模拟，考虑到工况扰动在管道中具有沿程传播特性，为同时表征其在上下游的响应差异并提供更充分的空间对比信息，本文选取上下游相邻的4个阀室作为观测点，以5 s为间隔采集压力数据，最终获得共约800条时长为240 s的时间序列数据。图1为模拟得到的上述4种典型工况下阀室压力随时间变化过程。

1.2 数据预处理

数据预处理主要包括数据打标签和归一化处理。

(1)数据打标签：为了使模型能够更好地完成分类任务，对各类工况的数据分别打上标签。

(2)归一化处理：为了消除数据特征之间的量纲影响，需要对数据进行归一化处理。本文选择的归一化方法是分组基准归一化，该方法以每组特征的初始值作为基准，通过相对变化量和组内最大波动进行归一化处理，保留了组内特征的相对变化趋势。其计算公式如下：

$$x_i^* = \frac{x_i - x_0}{x_{\max} - x_{\min}} \tag{1}$$

式中，x_i为每组数据的原始数据点；x_0为每组的第一个数据；$x_{\max}$为每组最大的数据；$x_{\min}$为每组最小的数据；x_i^*为归一化值。

将处理后的数据按照8∶1∶1的比例分为训练集、验证集和测试集。训练集用于模型的训练，验证集用于模型的参数调整，测试集用于模型准确率的测试。

2 CNN-Grad-CAM模型

2.1 模型构建

传统CNN模型虽然在活动识别、文本分类、定位等[26-28]领域应用广泛，但其决策过程缺乏可解释性，限制了其在安全敏感场景下的可信度与应用。为解决CNN模型决策“黑箱”问题，Selvaraju等[29]提出梯度加权类激活映射(gradient-weighted class activation mapping，Grad-CAM)方法，通过可视化模型关注的关键区域，为增强CNN的可解释性提供了

重要依据。

本文将卷积神经网络模型与Grad-CAM方法相结合，构建了CNN-Grad-CAM模型，如图2所示，其核心架构包括3层卷积层、1个自适应池化层和2个全连接层。模型通过卷积层自动从原始时间序列数据中提取局部特征，并逐步学习数据中的高级特征。在每个卷积层后面都跟随ReLU激活函数以引入非线性，并使用最大池化层减少数据维度，以此降低计算复杂度。经过卷积层提取的特征会通过自适应池化层进行汇聚，生成固定长度的特征向量，最后通过两个全连接层将提取的特征映射到4个类别进行分类。为进一步增强模型的可解释性，本文在训练后引入Grad-CAM方法，通过对卷积层特征梯度进行加权可视化，揭示模型决策所依赖的关键时间点与传感器通道，从而将模型输出与管道物理机制相关联，提升了其在工业场景中的可信度。此外，为了提高模型的性能与鲁棒性，本文采用AdamW优化器进行训练，AdamW优化器通过自适应调整学习率并引入权重衰减，有效防止过拟合[30]。

2.2 模型评价指标

为了分析模型对输气管道异常工况的分类情况，采用准确率、精确率、召回率以及F1分数4项指标，对模型在验证集和测试集的表现进行评估，其计算公式如下：

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \tag{2}$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \tag{3}$$

$$\text{F1} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \tag{4}$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{5}$$

其中，TP为真实标签为正，模型预测也为正；TN为真实标签为负，模型预测也为负；FP为真实标签为负，模型预测为正；FN为真实标签为正，模型预测为负。

2.3 超参数优化

在CNN-Grad-CAM模型中，超参数会直接影响模型对输气管道多工况的分类精度。为了使模型达到最优效果，本文选择贝叶斯优化算法[31]对模型进行超参数优化。相较于经验调参或穷举式搜索等传统方法，该方法采用高效的超参数搜索策略，显著降低整体调参开销、提高模型开发与训练迭代效率[32]。BO算法通过构建一个代理模型（高斯过程）来近似目标函数，并使用采集函数来选择下一步的评估点[33]。本文选择的采集函数为期望改进，其公式如下：

$$\text{EI}(x) = \left(\mu(x) - f(x^+) - \xi\right)\phi\left(\frac{\mu(x) - f(x^+) - \xi}{\sigma(x)}\right) + \sigma(x)\phi\left(\frac{\mu(x) - f(x^+) - \xi}{\sigma(x)}\right) \tag{6}$$

式中，EI(x)表示在输入点x的期望改进值；$\mu(x)$表示预测均值，反映了模型对该点目标函数值的估计；$f(x^+)$表示最优目标函数值；ξ表示探索参数，ξ大于0时，公式中的改进量会纳入一个“松弛”项，鼓励模型探索那些预测均值略高于当前最优但不确定性较高的区域，ξ等于0时即为标准EI；$\sigma(x)$表示预测标准差，用于衡量模型对该点预测的不确定性；ϕ

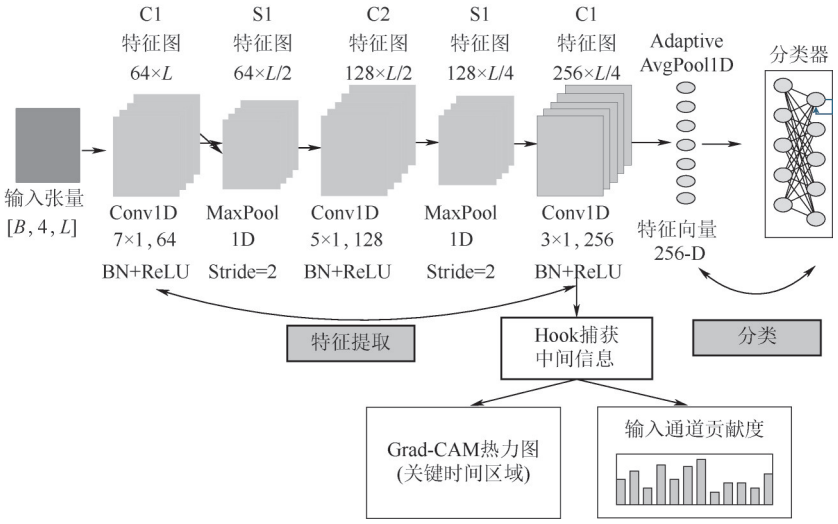


图2 CNN-Grad-CAM模型结构

Fig.2 CNN-Grad-CAM model structure

表示标准正态分布的累积分布函数。

为对比分析BO算法对天然气管道工况分类模型的提升幅度，本文选择了网格搜索（grid search，GS）、粒子群优化（particle swarm optimization，PSO）以及随机搜索（random search，RS）优化算法进行对比。CNN-Grad-CAM模型的待优化参数及范围如表1所示。

表1 CNN-Grad-CAM模型超参数及优化范围

Table 1 Hyperparameters and optimization ranges of the CNN-Grad-CAM model

超参数	参数含义	优化范围
l2_reg	L2正则化系数	0.0001~0.01
learning_rate	学习率，控制每次梯度下降时参数调整的幅度	0.0001~0.01
dropout_rate	丢弃率，训练时随机“暂时丢弃”的神经元比例	0.1~0.5

将模型分别用这几类优化算法优化，利用测试集数据对其进行验证，得到结果如表2所示。

表2 不同优化算法下的CNN-Grad-CAM模型的最优超参数与模型精度

Table 2 Optimal hyperparameters and model accuracy of the CNN-Grad-CAM model under different optimization algorithms

优化算法	超参数	Accuracy	Precision	Recall	F1
未优化	[0.001,0.01,0.3]	0.9494	0.9583	0.9500	0.9495
GS	[0.00133, 0.00520, 0.276]	0.9730	0.9742	0.9734	0.9729
BO	[0.00021, 0.00021, 0.173]	0.9873	0.9881	0.9875	0.9875
PSO	[0.00780, 0.00100, 0.325]	0.9698	0.9705	0.9701	0.9698
RS	[0.00174, 0.00307, 0.323]	0.9620	0.9674	0.9625	0.9623

从表中结果可以看出，模型在不同的超参数优化算法的优化下，其性能均得到了不同程度的提升，验证了模型超参数优化的必要性。其中，BO算法的优化表现最为优异，其优化后的模型在测试集上的各项指标均达到了98%以上，领先于其他优化算法；GS优化算法同样展现出强大的寻优能力，取得了97.30%的准确率，其性能仅次于BO。

3 实验结果分析

3.1 模型重要性分析

3.1.1 时间点重要性分析 基于Grad-CAM生成的时序特征重要度，揭示了CNN-Grad-CAM模型在识别4类工况时，所依赖的关键时间序列特征及其对应的物理过程。如图3所示，不同工况的特征重要度随时间演化呈现出截然不同的模式，这与各类工况独特的物理本质和动态演化过程高度吻合。

调压调流工况的重要度在第12~20个时间节点（对应工况发生后60~100 s）形成明显峰值区域，表明模型重点关注压力调节过程中从扰动开始到新稳态建立的关键过渡阶段。堵塞工况的重要度在第13~28个时间节点持续维持高位，这反映模型主要依赖堵塞发生后上游压力持续积聚的完整过程进行识别，而非只关注初始冲击。阀门关断工况的重要度在第0~4个时间节点的初始阶段较高，随后平缓下降，这说明模型重点捕捉阀门动作引发的初始压力突变，同时兼顾后续的压力波传播与反射特征。泄漏工况的重要度在第12~36个时间节点形成宽阔的峰值平台，体现了模型兼顾泄漏初期的压力突降信号与后续低压稳态的持续特征。结果表明，CNN-Grad-CAM能够依据各类工况的物理本质自动学习关键时序特征，其决策过程具有明确的物理可解释性。

3.1.2 通道重要性分析 根据SCADA系统数据采集规则，通道1~4分别对应沿线4个阀室的压力。基于此物理背景，Grad-CAM分析结果揭示了CNN模型决策与管道水力物理场之间较强的相关性。通道重要性结果如图4所示。

CNN-Grad-CAM模型对不同工况的注意力分布与天然气可压缩、压力传播快的流体特性密切相关。调压调流工况下各通道的重要性分布相对均匀，体现了天然气系统调压时上下游协同响应的整体性；堵塞工况则显著集中于通道2和通道3，对应天然气在堵塞点上游迅速积聚、压力骤升的典型特征；阀门关断时各通道的重要性普遍较低，反映了天然气管道中阀门快速关断引起的压力突变主要集中于阀门相邻管段，传播过程中的信号衰减较快；泄漏工况下中上游通道的重要性较高，这符合天然气泄漏引发的负压波向上游快速传播且影响范围较广的物理特性。该结果表明模型能依据天然气管道特有的瞬态响应机理，自适应聚焦于关键传感器信号，增强了决策的物理可解释性与工况辨识的可信度。

3.2 数据时间步长的影响分析

为探究数据采样时间间隔对分类模型性能的影响，本文依照SCADA系统采集数据的规则，测试了5种不同间隔长度（5、10、20、30、60 s）的数据集。

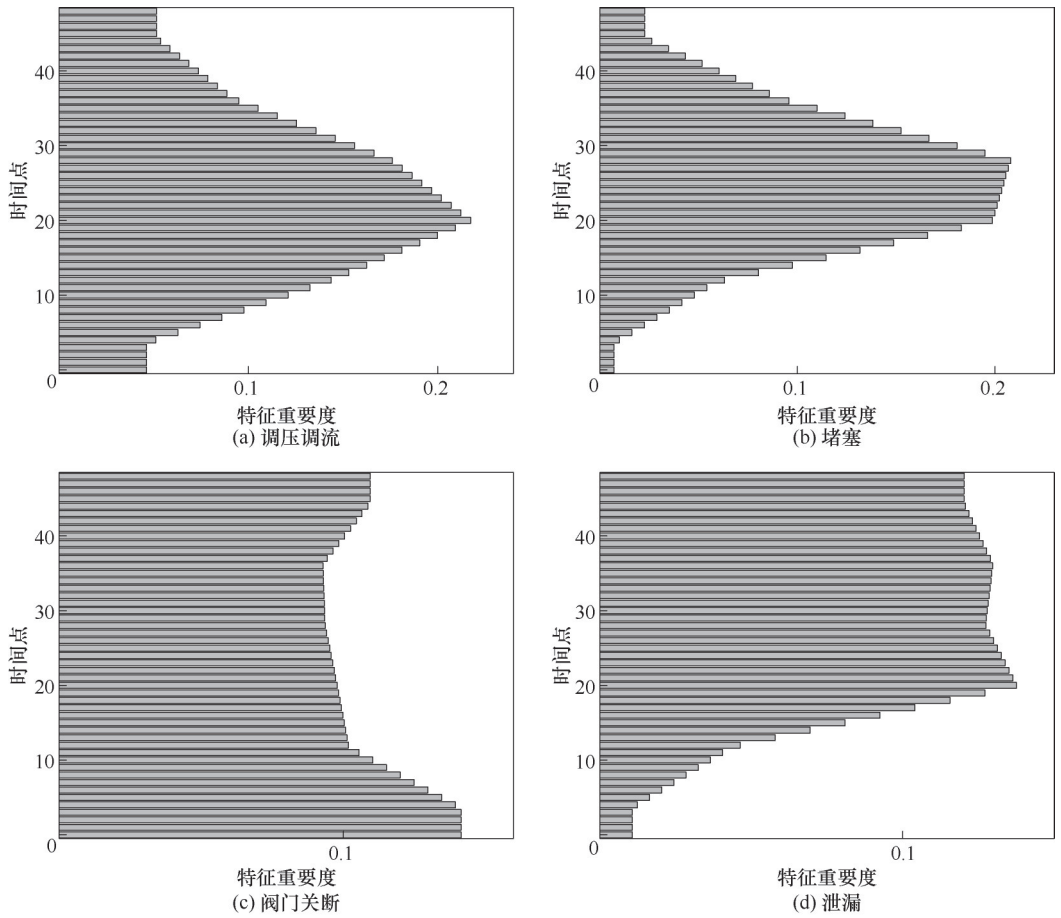


图3 时间点特征重要度

Fig.3 Feature importance of time points

将不同时间步长的数据集分别放入CNN-Grad-CAM模型进行训练，同时利用BO算法进行超参数优化得到各自的最优超参数，利用测试集数据对训练后的模型进行测试，得到的结果如表3所示。

实验结果表明，CNN-Grad-CAM模型在所有测试的时间间隔下均表现出优秀的分类性能，准确率等核心指标均高于96%。其中，时间间隔长度为5 s时各项指标表现最优，表明5 s的采样间隔最有利于模型同时捕捉到瞬态过程的突变信号与稳态过程的稳定特征。时间间隔长度的敏感性分析表明，CNN-Grad-CAM分类模型在保持超高精度的同时，对数据采集频率的变化不敏感。这从另一个维度验证了模型并非简单的记忆特定模式，而是真正学习到了4类工况背后普适的、与时间尺度无关的深层物理特征。

3.3 不同时长的数据分析

为确定模型性能与输入数据历史时长的关系，本研究在固定5 s时间间隔的基础上，进一步测试了60、90、120、180、240 s共5种不同总时长的数据序列。将不同时长的数据集放入模型中进行训练，同时利用BO算法优化超参数，得到测试结果如表4所示。

表4结果显示，在所测试的5种不同时长的实验中，准确率均在95%以上，表明不同时长对模型的影响较小，模型的适应能力较强；随着时长的逐步增长，模型的各项指标结果大致呈现上升的趋势，这是由于更长的序列数据所包含的信息更加完整，更有利于模型学习到不同工况各自具备的特征。

3.4 数据缺失情况下的识别准确率分析

本实验模拟了数据缺失场景——缺失整个阀室数据，以评估模型的空间依赖性与鲁棒性。

如表5所示，当缺失第一站或第二站数据时，模型准确率急剧下降至65%以下，性能衰减超过30%，这揭示了上游传感数据是模型识别工况初始瞬态特征的核心与决策锚点。相比之下，第三、四站数据缺失对性能影响有限，各项指标均维持在94%以上，说明上游信息已能提供足够的核心判别

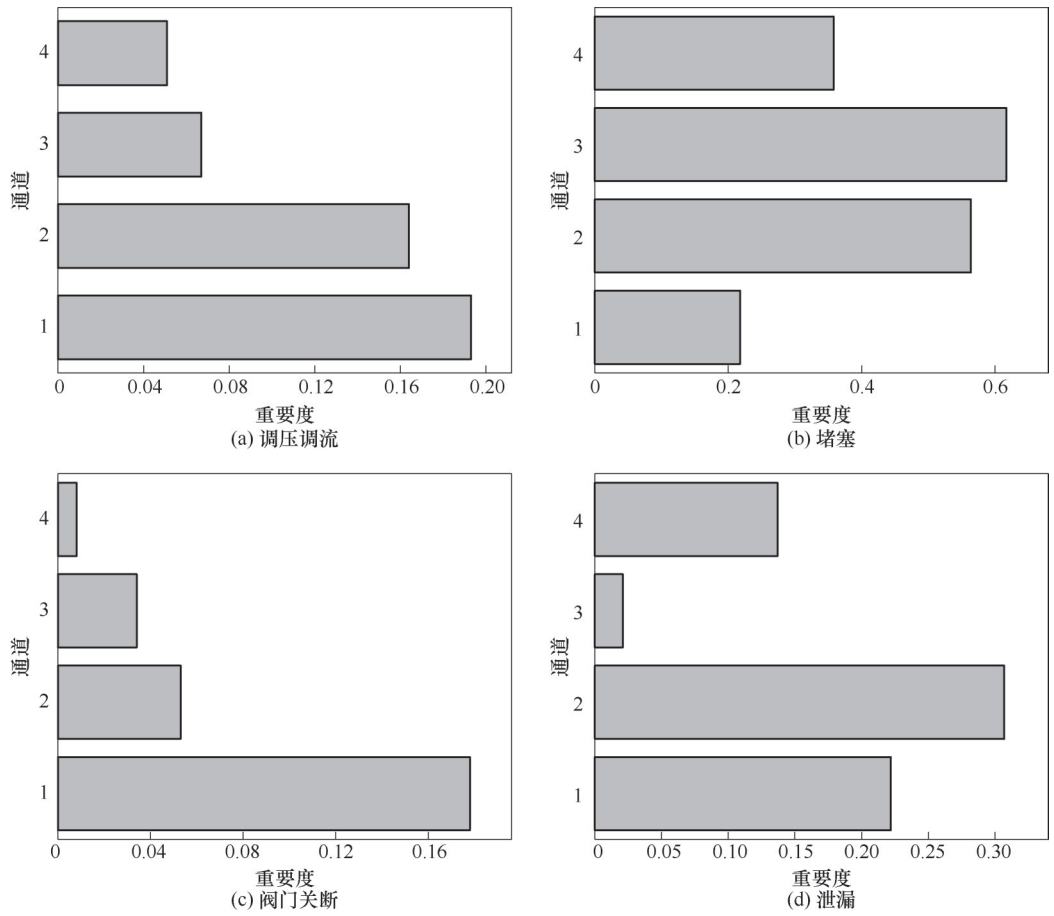


图4 通道特征重要度

Fig.4 Feature importance of channels

表3 各时间窗长度的运行指标结果

Table 3 Results of operational indicators at each time step

步长/s	最优超参数	Accuracy	Precision	Recall	F1
5	[0.00230,0.00049, 0.424]	0.9873	0.9881	0.9875	0.9875
10	[0.00428,0.00028, 0.196]	0.9750	0.9773	0.9747	0.9751
20	[0.00407,0.00038, 0.393]	0.9750	0.9799	0.9699	0.9744
30	[0.00352,0.00013, 0.301]	0.9625	0.9637	0.9631	0.9624
60	[0.00230,0.00049, 0.424]	0.9750	0.9708	0.9737	0.9710

表4 不同时长运行结果

Table 4 Results under different time durations

时长/s	超参数	Accuracy	Precision	Recall	F1
60	[0.00054,0.00817,0.122]	0.9625	0.9598	0.9700	0.9630
90	[0.00084,0.00019,0.46]	0.9500	0.9498	0.9533	0.9490
120	[0.00194,0.00282,0.476]	0.9750	0.9772	0.9772	0.9772
180	[0.00003,0.00511,0.201]	0.9750	0.9714	0.9772	0.9739
240	[0.00002,0.00021,0.173]	0.9873	0.9881	0.9875	0.9875

特征，而第三站和第四站数据在模型识别工况中只起到一定的辅助作用。

当缺失两站阀室的数据时，如表6所示，缺失前两站或首尾两站数据时，模型性能严重失效，准确率仅有38.63%，进一步证明上游信息是不可或缺的决策核心，其蕴含的工况初始瞬态特征具有不可替

表5 缺失一个阀室数据运行结果

Table 5 Results with missing data from one valve chamber

缺失数据阀室	Accuracy	Precision	Recall	F1
第一站	0.6455	0.8211	0.6489	0.6163
第二站	0.6404	0.8252	0.6371	0.5866
第三站	0.9403	0.9479	0.9409	0.9404
第四站	0.9606	0.9625	0.9612	0.9603

表6 缺失两个阀室数据运行结果

Table 6 Results with missing data from two valve chambers

缺失数据阀室	Accuracy	Precision	Recall	F1
第一、二站	0.3863	0.5500	0.3862	0.2849
第三、四站	0.9158	0.9314	0.9158	0.9160
第一、四站	0.6366	0.7747	0.6382	0.6073
第二、三站	0.6010	0.6813	0.5983	0.5492

代性。与之形成鲜明对比的是，缺失后两站数据时模型仍保持较高的性能，说明下游数据主要起辅助验证作用。该分析不仅验证了模型决策的物理一致性，也为工程实践中传感器部署的优先级与系统鲁棒性设计提供了关键依据：确保上游站点数据的可靠性对维持系统高性能至关重要。

3.5 模型性能对比

为了验证CNN-Grad-CAM模型在管道异常工况分类的可行性与准确性，本文将CNN-Grad-CAM模型与CNN模型、LSTM模型、多层感知机（multilayer perceptron，MLP）以及Transformer模型进行对比，此外，对这几个模型均使用BO优化算法进行了超参数优化。随后使用相同的数据对这几个模型进行训练，并利用测试数据对模型进行测试，得到的结果如表7所示。

表7 不同模型的训练指标

Table 7 Results of training indicators for different models

模型	评价指标			
	Accuracy	Precision	Recall	F1
CNN-Grad-CAM	0.9875	0.9808	0.9886	0.9842
CNN	0.9873	0.9881	0.9868	0.9871
LSTM	0.9114	0.9191	0.9232	0.9097
MLP	0.9494	0.9535	0.9493	0.9499
Transformer	0.9114	0.9352	0.9125	0.9097

表7和图5中的结果显示，CNN-Grad-CAM模型的各项指标均优于其他模型。去除Grad-CAM模块后的CNN模型，各项性能指标相较于CNN-Grad-CAM模型无明显变化，表明Grad-CAM方法并不会对模型的性能产生影响。LSTM模型、MLP模型以及Transformer模型均出现了将大量调压调流工况识别成泄漏工况，这是因为调压调流工况与泄漏工况特征十分相似，表明这3类模型并未能够捕捉到这两种工况在动态过程上的本质区别，容易被宏观上的相似性所迷惑；而CNN-Grad-CAM模型并未出现将调压调流工况和泄漏工况混淆的情况，仅出现将少量调压调流和泄漏工况错误地识别成了堵塞和阀门关断。此外，LSTM模型和MLP模型还出现将少量阀门关断样本识别成了堵塞，这是由于阀门关断与堵塞工况在发生时均出现了压力上升的相似特征，表明这两个模型也未完全学会区分这两类工况的本质特征。

3.6 噪声干扰下的识别结果分析

为进一步评估模型在实际工业环境中对数据噪声的鲁棒性，模拟了不同强度的高斯白噪声干扰场景，同时对比了LSTM、MLP以及Transformer模型在同样噪声下的鲁棒性，得到的结果如图6所示。

实验结果显示，随着噪声强度的增加，各模型准确率均出现下降的趋势，其中MLP模型的准确率从94.94%下降至72%左右，表明MLP模型的抗噪声能力相对较差，Transformer模型也出现了相似的情况；相比之下，CNN-Grad-CAM模型的抗噪声能力比较优秀，在低噪声情况下，模型的整体准确率依旧能够维持在94%以上；此外，LSTM模型也表现出比较优秀的抗噪声能力，其准确率随着噪声的增强下降得相对比较平缓，表明LSTM模型也具备较强的鲁棒性。

3.7 基于CNN-Grad-CAM模型的泄漏信号识别

我国南部某干线输气管道全长205.15 km，管径406.4 mm，壁厚8 mm，输气能力72×10^4 $m^3\cdot d^{-1}$。在2022年12月15日由于第三方破坏，1号阀门和输气站阀门之间的管道发生了泄漏，1号阀门在泄漏后经29 min压力从3.77 MPa下降到了3.67 MPa；输气站阀门在泄漏后21 min，压力从3.724 MPa下降至3.240 MPa。利用CNN-Grad-CAM模型对采集到的两组时序数据进行识别，得到的结果如图7所示。

如图7所示，利用CNN-Grad-CAM模型对前两个阀室实测数据进行识别，识别结果为泄漏，识别准确率达到100%。这表明CNN-Grad-CAM模型在实际应用中适用性较好。

4 结 论

本文提出了一种基于卷积神经网络（CNN）与Grad-CAM方法相结合的天然气管道多工况智能识别框架，并通过实验验证了该方法在天然气管道工况识别中的有效性。主要结论如下。

（1）本文通过贝叶斯优化（BO）自动寻优CNN超参数，模型在测试集上的准确率、精确率、召回率与F1分数均优于网格搜索、粒子群优化等传统方法。同时，引入梯度加权类激活映射（Grad-CAM）对模型决策过程进行可视化与量化分析，有效揭示了不同工况下关键传感器通道与时间点的贡献度，从而在物理机理层面验证了模型分类的合理性与可信性，为实际工程部署提供了可靠依据。

（2）与LSTM、MLP及Transformer等模型相比，

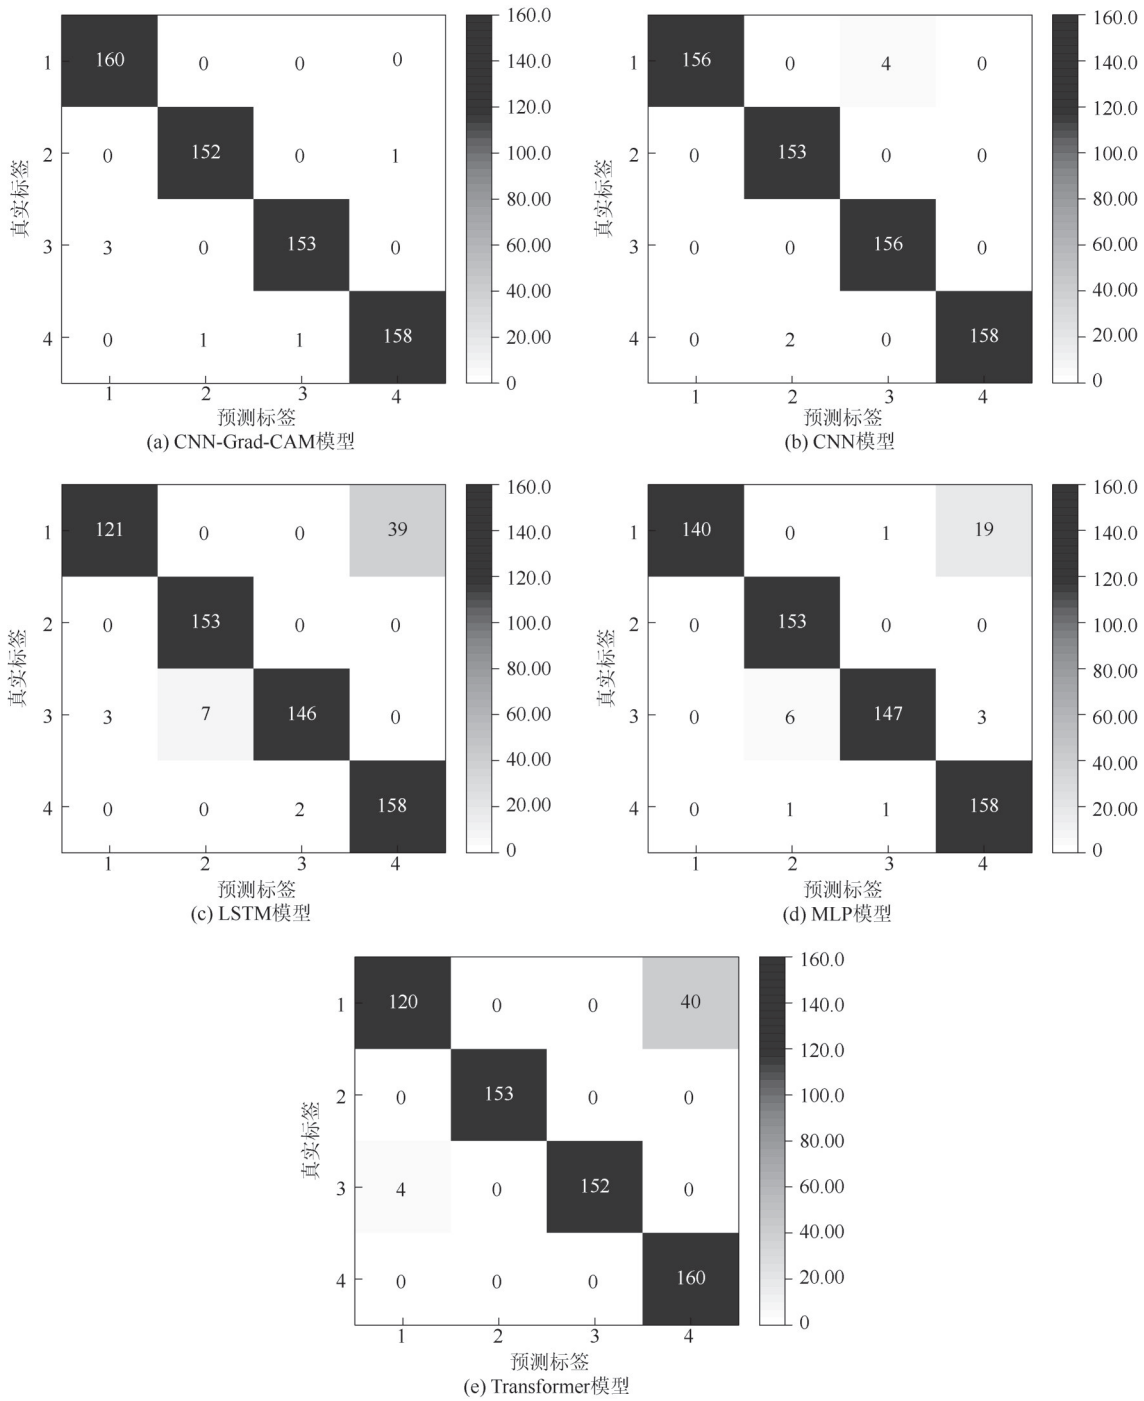


图5 不同模型的训练集混淆矩阵图

Fig.5 Confusion matrix plots of training sets for different models

CNN-Grad-CAM在多项评价指标上均表现最优,其局部特征提取能力与管道水力瞬变信号的局部形态特性高度契合,尤其在对易混淆工况的区分上表现出更强的判别能力。

(3)实验表明,模型在5 s采样间隔、240 s总时长下性能最优,在数据缺失场景下,模型表现出对关键信息的依赖性与对辅助信息缺失的容忍性,验证了其决策的物理一致性,同时也为现场传感器布设与系统冗余设计提供了依据。

(4)在添加高斯白噪声的测试中,CNN-Grad-CAM模型展现出较强的抗噪能力。这证明了模型并非过拟合于仿真"干净"数据,其学习到的是各类工况的本质特征。此外,在对某输气管道实际泄漏信号的识别中准确率达到了100%。

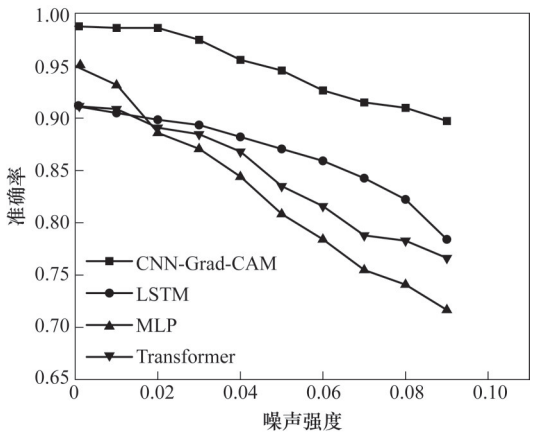


图6 不同强度噪声干扰下各模型的准确率

Fig.6 Accuracy of each model under different noise interference intensities

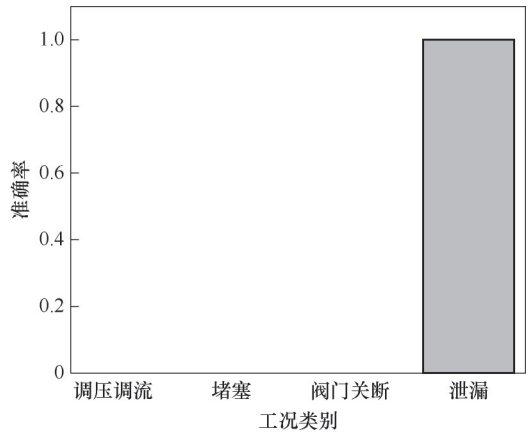


图7 基于CNN-Grad-CAM的泄漏信号识别结果

Fig.7 Leakage signal identification results based on CNN-Grad-CAM

参考文献

[1] 李洪兵, 韩咪, 刘可, 等. 中国城市天然气需求趋势预测[J]. 油气与新能源, 2024, **36**(3): 6-13.
Li H B, Han M, Liu K, et al. Forecast of urban natural gas demand trend in China[J]. Petroleum and New Energy, 2024, **36**(3): 6-13.

[2] 冯卓, 姜美君, 潘凯. 新型天然气市场竞争博弈研究[J]. 油气与新能源, 2024, **36**(3): 14-20.
Feng Z, Jiang M J, Pan K. Research on competition game in the new natural gas market[J]. Petroleum and New Energy, 2024, **36**(3): 14-20.

[3] 刘玥奇, 侯磊, 唐帅帅, 等. 基于费用函数的天然气管道系统供气可靠性优化分配[J]. 油气与新能源, 2024, **36**(6): 63-74.
Liu Y Q, Hou L, Tang S S, et al. Optimal allocation of gas supply reliability in natural gas pipeline system based on cost function[J]. Petroleum and New Energy, 2024, **36**(6): 63-74.

[4] 刘帅. "双碳"目标下天然气发电与新能源融合产业碳减排技术路径[J]. 油气与新能源, 2025, **37**(4): 83-88.
Liu S. Carbon reduction technology pathways for natural gas power generation and new energy integration under the "dual carbon" goals[J]. Petroleum and New Energy, 2025, **37**(4): 83-88.

[5] Korlapati N V S, Khan F, Noor Q, et al. Review and analysis of pipeline leak detection methods[J]. Journal of Pipeline Science and Engineering, 2022, **2**(4): 100074.

[6] Adegboye M A, Fung W K, Karnik A. Recent advances in pipeline monitoring and oil leakage detection technologies: principles and approaches[J]. Sensors, 2019, **19**(11): 2548.

[7] 郭洪猛. 基于瞬变流法管道泄漏检测若干技术研究[D]. 天津: 天津大学, 2007.
Guo H M. Study on leak detection technology of pipeline based on transient fluid methods[D]. Tianjin: Tianjin University, 2007.

[8] 郑杰, 吴荔清, 刘润华, 等. 输油管道泄漏检测信号的统计处理方法[J]. 石油大学学报(自然科学版), 2001, **25**(3): 84-85.
Zheng J, Wu L Q, Liu R H, et al. A statistic processing method for automatic detection of signal of pipe laying leakage[J]. Journal of the University of Petroleum China, 2001, **25**(3): 84-85.

[9] Xu D L, Liu J, Yang J B, et al. Inference and learning methodology of belief-rule-based expert system for pipeline leak detection[J]. Expert Systems with Applications, 2007, **32**(1): 103-113.

[10] Wu Y D, Sicard B, Gadsden S A. Physics-informed machine learning: a comprehensive review on applications in anomaly detection and condition monitoring[J]. Expert Systems with Applications, 2024, **255**: 124678.

[11] 朱群雄, 高慧慧, 徐圆. 工业过程报警管理研究进展[J]. 自动化学报, 2017, **43**(6): 955-968.
Zhu Q X, Gao H H, Xu Y. A survey on alarm management for industrial processes[J]. Acta Automatica Sinica, 2017, **43**(6): 955-968.

[12] Wang Q K, Lu H F. Machine learning methods for predicting residual strength in corroded oil and gas steel pipes[J]. npj Materials Degradation, 2025, **9**: 30.

[13] 张丽, 苏怀, 范霖, 等. 基于时序片段的油气管道运行工况识别方法[J]. 中国安全生产科学技术, 2022, **18**(11): 99-104.
Zhang L, Su H, Fan L, et al. Recognition method on operating conditions of oil and gas pipelines based on sequential segment[J]. Journal of Safety Science and Technology, 2022, **18**(11): 99-104.

[14] 李苗, 李凌波, 左志恒, 等. 基于机器学习的成品油管道运行工况识别[J]. 中国安全科学学报, 2024, **34**(6): 127-135.
Li M, Li L B, Zuo Z H, et al. Machine learning-based recognition for recognizing operating conditions of multi-product pipelines[J]. China Safety Science Journal, 2024, **34**(6): 127-135.

[15] 毛兴翔, 吴世德, 王文明, 等. 基于支持向量机的燃气管道泄漏识别方法研究[J]. 石油机械, 2021, **49**(7): 147-154.
Mao X X, Wu S D, Wang W M, et al. Research on gas pipeline leakage identification method based on support vector machine[J]. China Petroleum Machinery, 2021, **49**(7): 147-154.

[16] 吴瑕, 陈红环, 贾文龙, 等. 基于SVM的干线输气管道泄漏压降速率信号识别[J]. 中国安全科学学报, 2024, **34**(6): 119-126.
Wu X, Chen H H, Jia W L, et al. Dentification of leakage pressure drop rate signal of trunk gas pipeline based on SVM[J]. China Safety Science Journal, 2024, **34**(6): 119-126.

[17] 贾文龙, 孙溢彬, 汤丁, 等. 基于支持向量机的输气管道泄漏压降信号智能识别方法[J]. 化工进展, 2022, **41**(9): 4713-4722.
Jia W L, Sun Y B, Tang D, et al. Intelligent recognition method for pressure drop signals of gas pipeline leakage based on support vector machine[J]. Chemical Industry and Engineering Progress,

2022, **41**(9): 4713-4722.

[18] 贾文龙, 陈浚哲, 李长俊, 等. 基于TPE-XGBoost模型的输气管道泄漏定位方法[J]. 化工学报, 2025, **76**(10): 5510-5521.
Jia W L, Chen J Z, Li C J, et al. Leak localization method for gas pipeline based on TPE-XGBoost modeling[J]. CIESC Journal, 2025, **76**(10): 5510-5521.

[19] 郑坚钦, 杜渐, 梁永图, 等. 基于CAE-TSNE的成品油管道运行工况识别[J]. 石油科学通报, 2024, **9**(1): 148-157.
Zheng J Q, Du J, Liang Y T, et al. Research on pipeline operating condition recognition based on CAE-TSNE[J]. Petroleum Science Bulletin, 2024, **9**(1): 148-157.

[20] 郑颢. 基于IHBA-VMD和多特征提取的不同管道工况识别技术[J]. 油气田地面工程, 2025, **44**(3): 44-50.
Zheng H. Recognition technology for different pipeline working conditions based on IHBA-VMD and multi-feature extraction[J]. Oil-Gas Field Surface Engineering, 2025, **44**(3): 44-50.

[21] Ma Y B, Shang Z Y, Zheng J, et al. Research on leak detection and localization algorithm for oil and gas pipelines using wavelet denoising integrated with long short-term memory (LSTM) - transformer models[J]. Sensors, 2025, **25**(8): 2411.

[22] An Y, Wang X C, Chu R H, et al. Event classification for natural gas pipeline safety monitoring based on long short-term memory network and Adam algorithm[J]. Structural Health Monitoring, 2020, **19**(4): 1151-1159.

[23] 李琅, 蒋忠胜, 胡洲畅, 等. 基于CNN-Transformer的DAS管道泄漏信号识别方法[J]. 光学学报, 2025, **45**(10): 114-123.
Li L, Jiang Z S, Hu Z C, et al. Pipeline leak signal recognition method based on CNN-transformer for DAS[J]. Acta Optica Sinica, 2025, **45**(10): 114-123.

[24] Wang C, Zheng J Q, Liang Y T, et al. Deeppipe: operating condition recognition of multiproduct pipeline based on KPCA-CNN[J]. Journal of Pipeline Systems Engineering and Practice, 2022, **13**(2): 04022006.

[25] 李传宪, 刘定宏, 李剑, 等. 基于优化BP网络的液体管道工况识别方法研究[J]. 石油化工高等学校学报, 2018, **31**(6): 73-81.
Li C X, Liu D H, Li J, et al. Condition recognition of liquid pipeline based on optimized BP artificial neural network[J]. Journal of Petrochemical Universities, 2018, **31**(6): 73-81.

[26] Minaee S, Kalchbrenner N, Cambria E, et al. Deep learning: based text classification: a comprehensive review[J]. ACM Computing Surveys, 2022, **54**(3): 1-40.

[27] Shi B G, Bai X, Yao C. An end-to-end trainable neural network for image-based sequence recognition and its application to scene text recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, **39**(11): 2298-2304.

[28] Deng J K, Guo J, Xue N N, et al. ArcFace: additive angular margin loss for deep face recognition[C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 4685-4694.

[29] Selvaraju R R, Cogswell M, Das A, et al. Grad-CAM: visual explanations from deep networks *via* gradient-based localization [J]. International Journal of Computer Vision, 2020, **128**(2): 336-359.

[30] Sun S L, Cao Z H, Zhu H, et al. A survey of optimization methods from a machine learning perspective[J]. IEEE Transactions on Cybernetics, 2020, **50**(8): 3668-3681.

[31] Zhou B L, Khosla A, Lapedriza A, et al. Learning deep features for discriminative localization[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 2921-2929.

[32] Bergstra J, Bengio Y. Random search for hyper-parameter optimization[J]. The Journal of Machine Learning Research, 2012, **13**: 281-305.

[33] Jones D R, Schonlau M, Welch W J. Efficient global optimization of expensive black-box functions[J]. Journal of Global Optimization, 1998, **13**(4): 455-492.