

基于多模态信息融合的抽油机故障诊断技术研究

赵祥东¹ 蒋薇¹ 高国海¹ 王杨² 张嫩婧¹ 王欣¹

(1. 西南石油大学 计算机与软件学院, 成都 610500)

(2. 绵阳师范学院, 绵阳 621000)

摘要:【目的】针对抽油机故障诊断中样本不均衡和诊断信息单一的问题,提出一种基于多模态信息融合的故障诊断方法,以提升故障诊断的准确性和可靠性。【方法】首先,采用数据增广技术解决故障样本不均衡问题,增强少数类样本的诊断精度;其次,分别对示功图和油井动态生产数据进行特征提取,并融合这两类特征;最后,基于Transformer模型构建故障诊断框架,实现对抽油机故障的精确诊断。【结果】试验结果表明,提出的方法在准确率和 F_1 值上均表现优异,为抽油机故障诊断提供了更加可靠且有效的解决方案。

关键词: 示功图; 多模态融合; 故障诊断; 深度学习; 数据增广

中图分类号: TE933 **DOI:** 10.16579/j.issn.1001.9669.2026.06.007

0 引言

在我国,超过90%的油井采用有杆泵采油技术^[1]。然而,井下开采环境极其复杂,常常导致抽油机故障,从而影响石油开采效率^[2]。因此,对抽油机运行状态进行实时、有效的监控,及时、准确地诊断和处理故障,对于提高石油生产效率至关重要。

传统的抽油机故障诊断方法包括经验诊断、振动分析、温度监测、声发射法和电流分析等。这些方法通过观察抽油机的运行状态、分析不同的信号特征来识别故障,但这些方法通常依赖专家经验和专业设备^[3],在实际的诊断过程中存在成本高、效率低、准确性差等问题。示功图是抽油机系统生产过程中,由测力计测得的一条反映系统反复行程中的位移和负载关系的封闭曲线图像^[4]。分析示功图的几何形态可以清晰地观察出抽油机系统的运行状态,进而诊断其故障。传统的示功图分析主要依赖人工识别,DEREK等^[5]开发了一个基于规则的专家系统,该系统通过访谈业内权威专家,提炼并编码制成一系列诊断规则,不但工作量大,而且识别准确率容易受到人为因素的影响,效率低下,难以满足油田现场实时监测和故障诊断的需求。

随着机器学习相关技术的不断发展,研究人员提出一系列面向示功图的智能诊断技术。这类技术通

常先获取示功图的特征,再将其特征向量输入神经网络、分类模型等进行有监督学习,最终实现输入特征的分类,并据此实现抽油机故障类型的诊断。FENG等^[6]提出一种基于支持向量机(Support Vector Machine, SVM)模型的抽油机故障诊断方法。该方法采用二维曲线变换,提取示功图的特征,使用非线性主成分分析进行多类识别降维,然后将降维后的特征输入到SVM模型中进行故障诊断,试验表明,所提出的方法优于基于传统小波的方法。WANG等^[7]构建了一种基于K-means聚类算法的抽油机故障诊断方法。该方法分别使用了3种特征提取方法,将示功图转化为相应的特征向量,然后使用K-means聚类算法对示功图进行聚类(基于特征向量),从而将示功图划分为不同类别,试验结果表明,使用基于原始向量的特征提取方法在准确率方面最优,其效率可提高数十倍。侯延彬等^[8]建立了一种基于极限学习机(Extreme Learning Machine, ELM)模型的抽油机故障诊断方法。该方法使用灰度矩阵方法对示功图进行特征提取,然后将提取到的特征向量输入到ELM中,建立了一种诊断识别模型。试验结果表明,该方法在识别准确率上优于广义回归神经网络(Generalized Regression Neural Network, GRNN)、最小二乘支持向量机(Least Squares Support Vector Machine, LS-SVM)及反向传播神经网络(Back Propagation Neural Network, BPNN)方法。

收稿日期: 2024-10-17 修回日期: 2024-11-18

基金项目: 国家自然科学基金优秀青年科学基金项目(52222402); 油气藏地质及开发工程国家重点实验室开放性研究课题(PLN 2022-33); 南充市科技计划项目(23XNSYSX0111)

作者简介: 赵祥东,男,2000年生,四川成都人,硕士; 主要研究方向为智慧新能源; E-mail: z18582485121@outlook.com。

王欣(通信作者),男,1981年生,江苏扬州人,博士,教授,博士研究生导师; 主要研究方向为人工智能、机器学习及智慧油气田; E-mail: xinwang@swpu.edu.cn。

引用格式: 赵祥东,蒋薇,高国海,等. 基于多模态信息融合的抽油机故障诊断技术研究[J]. 机械强度,2026,48(6):62-69.

ZHAO Xiangdong, JIANG Wei, GAO Guohai, et al. Research on fault diagnosis technology of pumping units based on multi-modal information fusion[J]. Journal of Mechanical Strength, 2026, 48(6): 62-69.



免费获取

上述技术虽基本实现了基于示功图的抽油机故障诊断,但仍存在着一定的局限性。第一,仅依赖示功图作为诊断依据,存在特征不充分的问题。如图1、图2所示,存在“气影响”故障的示功图与正常工况的示功图的载荷曲线相似度很高,仅依靠示功图难以进行准确诊断。抽油机井在生产过程中采集到的生产数据,以及抽油机和管柱的相关工作数据等同样能反映出抽油机的工作状态^[9],但这些数据在诊断工作中往往被忽略。第二,由井下环境复杂而带来的样本不均衡问题通常很少被关注,以本研究采集到的油田现场实际生产数据为例,“连抽带喷”、“供液不足”、“气影响”故障类型的数据量分别仅占总体数据量的2.7%、26.9%和12.1%。样本不均衡会严重影响分类模型的准确性。为了克服上述局限,本文提出一种基于多模态信息融合的抽油机故障诊断方法,通过多模态信息融合技术,弥补单一模态数据的不足,提升模型故障判别的能力^[10]。首先,通过数据增广技术来解决样本不均衡问题^[11];其次,对示功图和油井数据分别进行特征提取,并将两个模态的特征进行融合;最后,采用基于Transformer的模型实现故障分类。试验结果表明,相比单一模态,多模态融合预测模型可以利用更加丰富的特征信息来捕捉复杂的故障模式,模型的鲁棒性和准确率均得到了有效提升。




图1 存在气影响故障的示功图

Fig. 1 Indicator diagram with the gas-affected fault




图2 正常工况下的示功图

Fig. 2 Indicator diagram of the normal working condition

1 模型原理

1.1 多层感知机

多层感知机(Multilayer Perceptron, MLP)是人工神经网络(Artificial Neural Network, ANN)的一种,由多个

层组成,每层包含若干个神经元,该模型能够有效捕捉数据中的多维特征。MLP通常包含3个主要部分:

1)输入层。接收输入数据,并将其传递给下一层。

2)隐藏层。作为MLP的核心部分,隐藏层由多个层叠加而成。每个隐藏层中的神经元接收前一层的输出,通过激活函数进行非线性变换,然后将结果传递给下一层。每个神经元的执行如式(1)所示。

$$z_j^{(l)} = \sum_s w_{sj}^{(l)} a_s^{(l-1)} + b_j^{(l)} \quad (1)$$

式中, $z_j^{(l)}$ 为第 l 层第 j 个神经元的线性变换结果; $w_{sj}^{(l)}$ 为第 l 层第 j 个神经元和第 $l-1$ 层第 s 个神经元之间的权重; $a_s^{(l-1)}$ 为第 $l-1$ 层第 s 个神经元的激活值; $b_j^{(l)}$ 为第 l 层第 j 个神经元的偏置。

线性组合的结果 $z_j^{(l)}$ 会通过一个激活函数,以引入非线性因素,从而使模型能够处理复杂的非线性问题。本文使用的是ReLU激活函数,其表达式为

$$f(x) = \max(0, x) \quad (2)$$

3)输出层。将最后一个隐藏层的输出变换为最终的输出结果。

1.2 卷积神经网络

卷积神经网络(Convolutional Neural Network, CNN)是一种深度学习模型^[12],它独特的网络结构和局部连接特性使其能够有效地提取图像中的空间和局部特征^[13-14]。该方法能够很好地对示功图中的空间特征进行提取。CNN由多层组成,每层都执行特定的操作。

卷积层是CNN的核心层,负责提取输入数据中的特征,通过在输入图像上应用卷积核(或滤波器),产生特征图。卷积层运算式为

$$(f * g)(u, v) = \sum_m \sum_n f(m, n) g(u - m, v - n) \quad (3)$$

式中, f 为输入图像; g 为卷积核; (u, v) 为输出特征图的坐标; m 为卷积核在高度方向上的索引; n 为卷积核在宽度方向上的索引。

池化层用于下采样、减小特征图的尺寸、降低计算量并引入不变性。本文使用的是平均池化,其计算式为

$$y = \frac{1}{|P|} \sum_{i \in P} x_i \quad (4)$$

式中, y 为池化窗口内所有值的平均值; P 为池化窗口内所有位置的集合; $|P|$ 为池化窗口内元素的数量,即池化窗口的大小; x_i 为池化窗口第 t 个位置上的值。

1.3 Transformer模型

Transformer模型具有优异的并行处理能力、长程依赖捕捉能力、自注意力机制和灵活的架构设计^[15],较传统的循环神经网络、长短期记忆网络等具有显著

优势。

Transformer由编码器和解码器两部分组成,每个部分又由多个相同的层堆叠而成。每个编码器层包含两个子层:多头自注意力机制和前馈神经网络。

多头自注意力机制对输入进行自注意力计算^[16]。

1)输入向量 X 分别乘第 h 个头的 W_h^Q 、 W_h^K 、 W_h^V 权重矩阵,得到相应的 Q_h 、 K_h 、 V_h ,即

$$\begin{cases} Q_h = XW_h^Q \\ K_h = XW_h^K \\ V_h = XW_h^V \end{cases} \quad (5)$$

式中, W_h^Q 、 W_h^K 、 W_h^V 分别为第 h 个注意力头对应的线性矩阵, W_h^Q 、 W_h^K 、 $W_h^V \in \mathbb{R}^{d_{\text{model}}}$,其中, $\mathbb{R}^{d_{\text{model}}}$ 为 d_{model} 维实数向量空间, d_{model} 为Transformer中输入/隐藏表示的特征维度(模型维度); Q_h 为由输入向量 X 乘权重矩阵 W_h^Q 线性变换得到的Query矩阵; K_h 为由输入向量 X 通过权重矩阵 W_h^K 线性变换得到的Key矩阵; V_h 为由输入向量 X 通过权重矩阵 W_h^V 线性变换得到的Value矩阵。

2)注意力权重通过缩放点积注意力(Scaled Dot-Product Attention, SDPA)计算,为

$$V_{\text{Attention}}(Q_h, K_h, V_h) = \text{Softmax} \frac{Q_h K_h^T}{\sqrt{d_k}} V_h \quad (6)$$

式中, $V_{\text{Attention}}(Q_h, K_h, V_h)$ 为注意力机制的输出矩阵; $Q_h K_h^T$ 为注意力得分矩阵; d_k 为Key(同时也是Query)

向量的特征维度(即每个注意力头中Key/Query的维度),通常情况下, $d_k = d_{\text{model}}/H$,其中, H 为注意力头数。

每个编码器中的前馈神经网络包含2个线性变换,之间有1个ReLU激活函数,前馈神经网络计算式为

$$f_{\text{FFN}}(x) = \max(0, xW_1 + b_1)W_2 + b_2 \quad (7)$$

式中, x 为输入前馈神经网络的向量; W_1 、 W_2 均为前馈神经网络的权重矩阵; b_1 、 b_2 均为前馈神经网络的偏置项。

最终模型的输出结果需先经过线性变换处理,再通过Softmax函数运算,最终生成预测结果。

2 基于多模态信息融合的抽油机故障诊断模型

为了克服现有示功图故障诊断技术的局限,本文提出一种抽油机故障诊断新方法,即增广-示功图-油井数据-特征串接(Augmentation-Indicator diagram-Oil well-Concatenate, AIOC)方法。该方法通过对多模态数据的融合,弥补了单一模态下特征表示的不足,能够得到更加准确的预测结果。AIOC的工作流程如图3所示。它主要由3个模块构成:样本增广、数据融合、故障诊断。简单而言,AIOC首先对示功图和油井数据展开数据增广,扩充训练样本;随后进行特征提取并融合;最后基于Transformer的预测模型,实现故障诊断。




图3 AIOC方法的工作流程图

Fig. 3 Flow chart of the AIOC method

2.1 样本增广

2.1.1 油井数据主成分分析

抽油机采收过程中影响抽油机工作状态的因素众多,不加区分地考虑所有参数不仅会降低模型计算效率,还可能影响模型预测精度。因此,有必要对抽油机工况主控因素进行筛选。本文利用斯皮尔曼

相关系数法对47个生产参数、管柱参数及工作参数进行了主成分分析。去除相关性小于0.3的参数后,共选取17个特征作为抽油机故障诊断参数,其中生产参数6个、管柱相关参数4个、抽油机工作参数7个。详细参数如表1所示,其中“相关参数”列中,粗体标注参数为选取参数。

表 1 模型输入参数

Tab. 1 Input parameters of the model

参数类别	相关参数
生产参数	日产液量、日产水量、日产油量、含水率、油压、套压、月产液量、月产油量、年累产液量、年累产油量、年累产水量、含沙量、油气、采出液浓度、采出液黏度、捞油量、捞液量
管柱参数	动液面、沉没度、流压、静压、静液面、泵径、泵深、冲程、冲次、最大冲程、最大冲次、冲程利用率、冲次利用率
抽油机工作参数	上行电流、下行电流、电压、平衡比、时率、最大载荷、最小载荷、电流、悬点额定载荷、载荷、交变载荷、消耗、百米吨液耗电、转排量、排量、转速、提捞次数

2.1.2 示功图预处理

示功图中也包含了冗余信息(图4),有必要进行预处理。首先,对示功图进行二值化处理^[17],方便后续图像处理模型更准确地提取关键特征。

本文采用固定阈值法进行二值化处理,即

$$g(x, y) = \begin{cases} 1, I(x, y) > T \\ 0, I(x, y) \leq T \end{cases} \quad (8)$$

式中, $g(x, y)$ 为二值化后图像在像素点 (x, y) 的像素值; x 与 y 为图像中的像素坐标; $I(x, y)$ 为二值化前的原始灰度图像在像素点 (x, y) 的像素值; T 为预设阈值,取1,即所有灰度值大于1的像素点被设为255(白色),灰度值小于或等于1的像素点被设为0(黑色)。其次,对示功图进行了尺寸统一处理,通过双三次插值方法^[18],利用目标像素周围的16个像素来计算新像素的颜色值,最终将图像缩放到(256,256)的标准尺寸。




图4 原始示功图

Fig. 4 Original indicator diagram

该步骤的目的是消除示功图之间的尺寸差异,使得后续的特征提取更加准确可靠。处理后的示功图如图5所示。




图5 二值化后的示功图

Fig. 5 Indicator diagram after binarization

2.1.3 数据增广

由于数据存在明显的类别不平衡现象,严重影响了故障诊断的准确性。本文针对油井数据和示功图数据分别采用了不同的数据增广技术。

1)针对油井数据,采用合成少数类过采样技术(Synthetic Minority Over-sampling TEchnique, SMOTE)。该算法中每个少数类样本进行数据增广的基本流程^[19]如下:

a. 选择少数类样本。从少数类样本集中随机选择1个样本 $X_i=(X_i^1, X_i^2, \dots, X_i^D)$ 。其中, D 表示样本维度,每个维度代表不同的参数,如日产液量、日产水量、油压、套压等。

b. 确定 K 个近邻。找到该样本 X_i 在少数类样本中的 K 个最近邻样本。

c. 生成新样本。从上述 K 个最近邻中随机选择一个邻居 X_n ,然后按照式(9)生成一个新的样本 X_{new} ,即

$$X_{new} = X_i + \lambda(X_n - X_i) \quad (9)$$

式中, λ 为一个介于0~1的随机数。

该算法中设置了两个核心参数,即过采样倍率(N_f)和最近邻的样本数(K_n)。表2所示为利用SMOTE算法进行增广时所采用的关键参数设置。

表2 SMOTE算法参数设置表

Tab. 2 Parameter setting table of the SMOTE algorithm

参数	故障类别	
	气影响	连抽带喷
N_f	45	72
K_n	5	5

同时,对油井数据进行了标准化处理,将其缩放到相同的尺度范围内。通过标准化,消除了不同油井数据之间的尺度差异,确保了后续特征提取过程中的数据一致性和可比性。标准化计算式为

$$X' = \frac{X - \mu}{\sigma} \quad (10)$$

式中, X' 为标准化后的数据; X 为原始数据; μ 为数据的均值; σ 为数据的标准差。

2)针对示功图数据,采用融合随机噪声的方式进行数据增广,即从每一类别下的图像中随机选择图像后,与随机噪声进行融合,生成新的图像。

在两类数据增广完成后,对增广形成的油井数据与示功图数据进行匹配,即对增广形成的两类数据在相同类别下进行随机匹配,形成新的训练数据,为后续的特征融合和模型训练提供高质量的数据。

2.2 数据融合

AIOC利用CNN和MLP处理不同类型的数据,并实现特征融合。具体而言,模型首先将经过二值化处理的示功图输入CNN进行特征提取,得到特征向量 V_{Ep} ;同时,油井数据通过MLP层进行特征提取,得到特

征向量 V_{EL} ; 提取出来的 2 个特征向量通过串接的方式融合为新的特征向量 V_{EL} , 实现 2 个模态数据的融合。

针对示功图编码, 本文使用的 CNN 主要包括 3 组卷积层。其中, 每组卷积层均采用 ReLU 激活函数。每组卷积层的输出都经过标准化处理, 以加速训练过程。前 2 组卷积层使用最大池化操作来减小特征图的尺寸, 第 3 组卷积层则采用全局平均池化, 降低数据维度, 保留关键特征。第 1 层、第 2 层以及第 3 层的卷积核数量分别设置为 32、64 及 128。

针对油井数据编码, 本文使用的 MLP 由 4 层全链接层构成, 激活函数为 ReLU。这 4 层全连接层的神经元数量分别设置为 1 024、512、256、128。

2.3 故障诊断

将融合后得到的特征向量 V_{EL} 输入到基于 Transformer 的预测模型, 对故障类型进行预测, 该模型通过自注意力机制来自适应地为每个特征分配不同的权重, 进而捕捉特征之间的依赖关系。图 6 所示为 Transformer 层的工作原理。




图 6 Transformer 层的工作原理

Fig. 6 Working principle of the Transformer layer

首先, 模型接收融合向量 V_{EL} , 并通过重塑层将融合向量 V_{EL} 进行重塑, 以扩充序列维度, 使其符合

Transformer 层的输入要求; 接着, 利用式 (5) 对输入的融合向量 V_{EL} 进行自注意力计算, 随后利用式 (6) 计算每个头的注意力权重; 然后对每个注意力头进行组合, 并采用线性映射, 得到多头注意力值 V_{MH} , 如式 (11)、式 (12)^[20] 所示。

$$H_h = \text{Attention}(Q_h W_h^Q, K_h W_h^K, V_h W_h^V) \quad (11)$$

$$V_{MH}(Q, K, V) = \text{Concat}(\{H_h\}_{h=1}^q) W^O \quad (12)$$

式中, H_h 为第 h 个注意力头的注意力; q 为多头注意力头数, 本文取 $q = 8$; W^O 为多头注意力拼接后输出的映射矩阵。

多头注意力机制从不同角度更加精细地融合数据间的影响关系, 使得 Transformer 模型能够更好地融合 2 种模态的数据; 层归一化用于提高训练稳定性和模型性能, 增强模型的泛化能力。Transformer 网络参数设置时, 多头注意力头数设为 8, 前馈网络维度设为 128。

随后, 通过展平层展平 Transformer 编码层的输出, 再通过全连接层将其降维至与故障类型数量相同的维度。最后, 经过 Softmax 函数将模型的输出转化为概率分布, 提供各故障类型的预测概率, 从而实现故障诊断。

3 试验结果及对比分析

3.1 数据集与试验环境

本文采用的数据为国内某油田某采油厂采收过程工况分析数据。表 3 所示为油井生产数据及施工数据的样例, 数据集中还包括 519 份示功图样本, 其工况类型有正常、供液不足、气影响、连抽带喷 4 种。通过观察发现, 这些数据表现出明显的类别不均衡现象, 如图 7 所示, 其中, 连抽带喷仅出现过 14 次。

表 3 油井生产数据及施工数据

Tab. 3 Production and construction data of the oil well

沉浸度/m	日产液量/t	日产油量/t	含水率/%	日产水量/t	油压/MPa
19.74~828.29	30.96~133.11	0.36~10.06	88.51~99.60	29.77~130.74	0.24~0.84
8.70~180.70	33.02~124.94	0.95~9.27	84.55~98.06	29.85~117.14	0.26~0.75
98.04~422.28	35.81~139.92	0.73~10.58	90.98~98.24	34.93~129.34	0.25~0.61
643.37~932.22	43.76~107.66	0.50~5.24	93.12~99.01	42.66~102.92	0.24~0.60
上行电流/A	下行电流/A	电压/V	平衡比/%	时率/%	动液面/m
19.52~117.03	19.93~102.47	0.00~400.86	56.47~165.18	19.35~100.00	105.43~865.69
27.48~114.57	25.10~103.82	0.00~392.8	79.10~165.32	48.39~100.00	629.76~950.85
22.04~123.70	20.83~104.53	135.13~400.86	75.36~117.38	76.20~100.00	473.33~860.91
25.60~72.73	24.07~67.80	208.30~378.33	87.13~106.10	47.45~100.00	0.00~247.96
流压/MPa	静压/MPa	最大载荷/kN	最小载荷/kN	套压/MPa	
4.86~8.08	9.10~13.21	19.56~88.37	10.24~39.15	0.31~0.88	
0.55~2.76	9.29~11.21	45.45~91.25	8.98~31.17	0.37~0.97	
1.08~3.50	9.29~13.21	47.54~90.51	14.08~32.71	0.37~0.84	
5.19~8.02	9.40~11.35	18.05~35.99	8.77~24.77	0.41~0.62	




图 7 故障类型分布

Fig. 7 Distribution of the fault types

3.2 评价指标

为了评估每个故障类型的诊断效果,本文选用的评价指标为准确率(Accuracy) $A_{\text{准}}$ 和 F_1 值。 $A_{\text{准}}$ 衡量了模型在总体样本上的预测准确率,即

$$A_{\text{准}} = \frac{P_{\text{T, total}}}{P_{\text{N, total}}} \quad (13)$$

式中, $P_{\text{T, total}}$ 为所有类型中被正确分类的样本总数; $P_{\text{N, total}}$ 为数据集中的样本总数。

F_1 值综合了精确率和召回率,能够更全面地反映模型在识别某一类型时的准确性和完整性。 F_1 值的范围为0~1,数值越高,表示分类器对该类型的识别效果越好。对于每个类型 c , F_1 值的计算式为

$$F_{1c} = \frac{2P_c P_{R,c}}{P_c + P_{R,c}} \quad (14)$$

式中, P_c 为分类器预测为类型 c 的样本中真正属于类型 c 的样本比例, $P_c = \frac{P_{\text{T},c}}{P_{\text{T},c} + P_{\text{F},c}}$,其中, $P_{\text{T},c}$ 为属于类型 c 并被正确分类的样本数, $P_{\text{F},c}$ 为被错误分类为类型 c 的样本数; $P_{R,c}$ 为分类器在所有属于类型 c 的样本中被成功识别出的比例。

3.3 试验结果

3.3.1 数据增广处理

在处理519份整体数据集时,按照6:4的比例划分训练集和测试集。在数据集中,正常类别与供液不足类别的样本数量已相对均衡,因此,本试验的样本增广仅针对少数类样本,即“气影响”故障和“连抽带喷”故障类样本。表4所示为训练集中示功图和油井数据增广前、后的类别分布。

表4 示功图和油井数据增广前、后类别分布

Tab. 4 Indicator diagram and category distribution of the well data before and after augmentation

故障类型	原始数量	示功图增广后数量	油井数据增广后数量
正常	185	185	185
供液不足	81	81	81
气影响	36	81	81
连抽带喷	9	81	81

3.3.2 模型试验结果

在增广后的训练集上进行模型训练,模型超参数设置如下:训练轮数 S_{epoch} 设为120,批大小 b_{size} 设为64,即每次参数更新使用64条样本构成一个小批量进行前向传播与反向传播。具体的试验结果如表5所示。由表5可知,AIOC具有优异的性能,模型的整体诊断准确率为94.79%。对于“正常”“供液不足”“气影响”和“连抽带喷”故障类别,模型的 F_1 值分别为92%、94%、82%、98%。

表5 试验结果

Tab. 5 Test results

故障类型	F_1 值/%	准确率/%
正常	92	94.79
供液不足	94	
气影响	82	
连抽带喷	98	

3.3.3 对比试验

为了验证提出的基于多模态信息融合的抽油机故障诊断方法的性能优势,开展了对比试验。值得一提的是,为了凸显多模态数据融合的效果,在对比试验中,针对对比模型,均没有为其融合油井数据,仅利用示功图数据对抽油机进行故障诊断。涉及的对比模型如下:

1)GM-ELM模型。根据文献[8]¹⁶⁷³⁻¹⁶⁷⁸中的方法,利用灰度矩阵-极限学习机(Gray Matrix-Extreme Learning Machine,GM-ELM)进行示功图特征提取,并将提取的特征输入到基于Transformer的模型中进行故障分类。

2)C-NLPCA模型。利用文献[6]¹²⁷²¹⁻¹²⁷²⁹中的方法,通过二维曲线(Curvelet)变换提取示功图特征,并借助非线性主成分分析(Nonlinear Principal Component Analysis, NLPCA)进行多类识别降维,再将降维后的特征输入到基于Transformer的模型中。

试验结果如表6所示,GM-ELM的准确率为89.06%,C-NLPCA的准确率为90.62%,这2组对比模型的故障诊断准确率都明显低于AIOC。进一步的,可以明显看出,前两者的正常、气影响和连抽带喷的 F_1 值均低于AIOC模型,供液不足与AIOC模型的 F_1 值持平。试验结果表明,仅利用示功图信息对抽油机进行故障诊断具有一定的局限性,AIOC通过融合示功图和油井数据的特征信息,能够提升模型对故障类型的识别能力,有效弥补了单一模态数据带来的信息不足,对于提升故障诊断精度具有显著效果。

表 6 对比试验结果
Tab. 6 Results of the comparative test

模型	F_1 值/%				准确率/%
	正常	供液不足	气影响	连抽带喷	
GM-ELM	88	94	73	95	89.06
C-NLPCA	91	94	73	97	90.62
AIOC	92	94	82	98	94.79

3.3.4 消融试验

通过消融试验验证多模态信息融合在提升诊断精度方面的关键作用。其中,消融模型 1 从 AIOC 中去除油井数据及其特征提取模块(AIOC-Oil well, AIOC-O),消融模型 2 从 AIOC 中去除示功图及其特征提取模块(AIOC-Indicator diagram, AIOC-I);消融模型 3 则从 AIOC 中去除数据增广模块(AIOC-Augmentation, AIOC-A)。试验结果如表 7 所示。

表 7 消融试验结果
Tab. 7 Results of the ablation test

模型	F_1 值/%				准确率/%
	正常	供液不足	气影响	连抽带喷	
AIOC-O	46	76	59	79	72.54
AIOC-I	87	90	42	92	80.61
AIOC-A	81	86	60	78	82.69
AIOC	92	94	82	98	94.79

由表 7 可知,AIOC-O 的准确率为 72.54%,表明仅依赖示功图信息进行故障诊断具有一定的局限性;AIOC-I 的准确率为 80.61%,表明油井数据虽关键,但单一模态的信息量仍显不足;AIOC-A 的准确率为 82.69%,表明虽然基于多模态信息融合的方法能够提升诊断精度,但故障样本不均衡问题仍显著影响最终的诊断结果。

进一步分析 4 种故障类型的 F_1 值,3 组消融试验的表现结果均不及 AIOC,这证明了多模态信息融合的引入能够丰富诊断视角,提供更为全面的故障信息,进而提升故障识别的效率和准确性;同时,数据增广技术的有效应用,不仅解决了故障样本不均衡问题,还进一步强化了模型的鲁棒性和准确性。

综上所述,构建的模型利用数据增广技术,融合示功图数据与油井数据,在抽油机故障诊断领域展现出了显著的优势,具有重要的理论价值和实践意义。

4 结论

针对抽油机故障诊断中样本不均衡和诊断信息单一的问题,通过分析研究和试验对比,得出以下主要结论:

1)提出一种基于多模态信息融合的抽油机故障诊断方法。与示功图作为唯一诊断依据的方法相比,多模态信息融合的方法可以有效弥补单一模态下信息不足的问题,更好地提高故障识别能力;与已有基

于 Transformer 的方法相比,该方法增强了对少数类故障的识别能力,更具通用性和实用价值。

2)提出的基于多模态信息融合的抽油机故障诊断方法在故障诊断的准确率和 F_1 得分上均展现出显著优势。该方法的总体准确率达到 94.79%,各故障类型的 F_1 得分也均处于较高水平。这进一步证明,融合示功图和油井数据信息的方法能有效提升抽油机故障诊断的准确度。

参考文献(References)

- [1] 吕孝孝,王早祥,刘延鑫,等. 故障工况下有杆泵采油系统运行特性及示功图研究[J]. 中国石油大学学报(自然科学版),2020,44(2):117-126.
LÜ Xiaoxiao, WANG Hanxiang, LIU Yanxin, et al. Study on operating performance and indicator diagram of rod pump production system under fault conditions [J]. Journal of China University of Petroleum (Edition of Natural Science), 2020, 44(2):117-126. (In Chinese)
- [2] WU W, XING X, WEI H X, et al. Fault diagnosis of pumping system based on multimodal attention learning (CBMA Learning) [J]. Journal of Process Control, 2023, 128: 103006.
- [3] 赵新语,樊军,何方,等. 基于全局与局部特征结合的抽油机故障诊断[J]. 机械强度,2023,45(6):1286-1292.
ZHAO Xinyu, FAN Jun, HE Fang, et al. Fault diagnosis of pumping unit based on global and local features [J]. Journal of Mechanical Strength, 2023, 45(6):1286-1292. (In Chinese)
- [4] GIBBS S G. Predicting the behavior of sucker-rod pumping systems [J]. Journal of Petroleum Technology, 1963, 15(7): 769-778.
- [5] DEREK H J, JENNINGS J W, MORGAN S M. Sucker rod pumping unit diagnostics using an expert system [C]//Proceedings of the Permian Basin Oil and Gas Recovery Conference. Richardson: Society of Petroleum Engineers, 1988: SPE-17318-MS.
- [6] FENG K, JIANG Z N, HE W, et al. A recognition and novelty detection approach based on Curvelet transform, nonlinear PCA and SVM with application to indicator diagram diagnosis [J]. Expert Systems with Applications, 2011, 38(10): 12721-12729.
- [7] WANG X, SHAO Z W, SHEN Y C, et al. Research on fast marking method for indicator diagram of pumping well based on K-means clustering [J]. Heliyon, 2023, 9(10): e20468.
- [8] 侯延彬,陈炳均,高宪文. 基于 GM-ELM 的有杆泵抽油井故障诊断[J]. 东北大学学报(自然科学版),2019,40(12):1673-1678.
HOU Yanbin, CHEN Bingjun, GAO Xianwen. Fault diagnosis of sucker rod pumping wells based on GM-ELM [J]. Journal of Northeastern University (Natural Science), 2019, 40(12): 1673-1678. (In Chinese)
- [9] 唐丽雯,樊军,赵新语,等. 基于功图故障特征分析的液量计量方法研究[J]. 机械设计与制造,2024(9):164-168.
TANG Liwen, FAN Jun, ZHAO Xinyu, et al. Research on measurement method based on fault types and strength characteristics of power diagram [J]. Machinery Design & Manufacture, 2024(9): 164-168. (In Chinese)

- [10] LI J N, SHAO J, WANG W, et al. An evolutionary deep learning method based on multi-feature fusion for fault diagnosis in sucker rod pumping system [J]. Alexandria Engineering Journal, 2023, 66:343-355.
- [11] 周萱,吴伟丽. 基于改进SMOTE不均样本处理和IHPO-DBN的变压器故障诊断方法研究[J]. 电力系统保护与控制, 2024, 52(11):21-30.
ZHOU Xuan, WU Weili. Transformer fault diagnosis method based on improved SMOTE unbalanced sample processing and IHPO-DBN [J]. Power System Protection and Control, 2024, 52(11):21-30. (In Chinese)
- [12] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6):84-90.
- [13] 张朝林,范玉刚. CEEMD与卷积神经网络特征提取的故障诊断方法研究[J]. 机械科学与技术, 2019, 38(2):178-183.
ZHANG Zhaolin, FAN Yugang. Fault diagnosis of a bearing using feature extraction method based on CEEMD algorithm and CNN [J]. Mechanical Science and Technology for Aerospace Engineering, 2019, 38(2):178-183. (In Chinese)
- [14] 孙歧峰,李克昊,段友祥,等. 基于卷积神经网络与特征聚类的荧光薄片分析方法[J]. 石油学报, 2024, 45(3):548-558.
SUN Qifeng, LI Kehao, DUAN Youxiang, et al. Fluorescent thin section analysis method based on convolutional neural network and feature clustering [J]. Acta Petrolei Sinica, 2024, 45(3):548-558. (In Chinese)
- [15] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//Proceedings of the 31st International Conference on Neural Information. New York: Curran Associates Inc., 2017: 6000-6010.
- [16] 陈俊英,席月芸,李朝阳. 多尺度局部特征和Transformer全局学习融合的发动机剩余寿命预测[J]. 自动化学报, 2024, 50(9):1818-1830.
CHEN Junying, XI Yueyun, LI Zhaoyang. Prediction of aeroengine remaining life by combining multi-scale local features and transformer global learning [J]. Acta Automatica Sinica, 2024, 50(9):1818-1830. (In Chinese)
- [17] FARRAHI M R, CHERIET M. AdOtsu: an adaptive and parameterless generalization of Otsu's method for document image binarization [J]. Pattern Recognition, 2012, 45(6):2419-2431.
- [18] 庞志勇,谭洪舟,陈弟虎. 一种改进的低成本自适应双三次插值算法及VLSI实现[J]. 自动化学报, 2013, 39(4):407-417.
PANG Zhiyong, TAN Hongzhou, CHEN Dihui. An improved low-cost adaptive bicubic interpolation arithmetic and VLSI implementation [J]. Acta Automatica Sinica, 2013, 39(4):407-417. (In Chinese)
- [19] 石洪波,陈雨文,陈鑫. SMOTE过采样及其改进算法研究综述[J]. 智能系统学报, 2019, 14(6):1073-1083.
SHI Hongbo, CHEN Yuwen, CHEN Xin. Summary of research on SMOTE oversampling and its improved algorithms [J]. CAAI Transactions on Intelligent Systems, 2019, 14(6):1073-1083. (In Chinese)
- [20] 李康,李爽,高小永,等. 多变量时序标记Transformer及其在电潜泵故障诊断中的应用[J]. 控制与决策, 2025, 40(4):1145-1153.
LI Kang, LI Shuang, GAO Xiaoyong, et al. Multivariate time series tokenized Transformer and its application in fault diagnosis of electric submersible pump [J]. Control and Decision, 2025, 40(4):1145-1153. (In Chinese)

Research on fault diagnosis technology of pumping units based on multi-modal information fusion

ZHAO Xiangdong¹ JIANG Wei¹ GAO Guohai¹ WANG Yang² ZHANG Weijing¹ WANG Xin¹

(1. School of Computer Science and Software Engineering, Southwest Petroleum University, Chengdu 610500, China)

(2. Mianyang Teachers' College, Mianyang 621000, China)

Abstract: [Objective] A fault diagnosis method based on multimodal information fusion was proposed. It addressed the issues of sample imbalance and limited diagnostic information in rod pump fault diagnosis. The goal was to improve the accuracy and reliability of fault diagnosis. [Methods] Firstly, data augmentation techniques were applied to address sample imbalance. This enhanced the diagnostic accuracy of minority class samples. Secondly, features were extracted from dynamometer cards and dynamic production data. These features were then fused. Finally, a transformer-based fault diagnosis framework was constructed. This framework achieved precise diagnosis of rod pump faults. [Results] The test results show that the proposed method performs well in accuracy and F_1 -score. It offers a more reliable and effective solution for rod pump fault diagnosis.

Key words: Indicator diagram; Multimodal fusion; Fault diagnosis; Deep learning; Data augmentation

Corresponding author: WANG Xin, E-mail: xinwang@swpu.edu.cn

Fund: Excellent Young Scientists Fund of National Natural Science Foundation of China (52222402); Open Research Project of State Key Laboratory of Oil and Gas Reservoir Geology and Exploitation Engineering (PLN 2022-33); Nanchong Science and Technology Plan Project (23XNSYSX0111)

Received: 2024-10-17 Revised: 2024-11-18

(编辑:刘欢欢)