文章编号:1673-0291(2026)02-0143-10 **DOI**:10.11860/j.issn.1673-0291.20250087

基于特征级多源数据融合的ZYJ7转辙机故障诊断

李建国,王鹏泽
(兰州交通大学 自动化与电气工程学院,兰州 730070)

摘 要:针对传统单一数据源转辙机故障诊断方法受限于单一形态数据故障特征表征不充分的问题,在应对复杂的故障类型时,存在诊断精度不高,无法精准、细致地定位故障等局限性,难以满足实际应用需求.为提升ZYJ7电液转辙机诊断性能,首先,本文基于现场实测的油压、电流、功率数据,提出了一种基于特征级多源数据融合的深度学习故障诊断方法,对转辙机油压、电流、功率多模态数据进行归一化、降噪和时空特征提取.然后,利用双线性插值统一各模态特征矩阵尺寸,引入注意力机制实现特征矩阵的动态加权融合.最后,将融合特征输入卷积神经网络(Convolutional Neural Networks,CNN)和长短期记忆网络(Long Short-Term Memory,LSTM)构成的神经网络中进行分类,并与单一数据源、简单表决、简单拼接和固定权重故障诊断模型对比验证.实验结果表明:本文提出的特征级多源数据融合模型相较于单一数据源、简单表决、简单拼接和固定权重模型准确率分别提升7.19%、4.38%、3.13%、1.88%,验证了本文提出的故障诊断方法的有效性,为转辙机故障诊断提供借鉴.

关键词:故障诊断;转辙机;多源数据融合;深度学习;神经网络
中图分类号:U284.92 **文献标志码**:A

Feature-level multi-source data fusion for fault diagnosis of ZYJ7 switch machine

LI Jianguo, *WANG Pengze*
(School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: Traditional single-source data-based fault diagnosis methods for railway switch machines are limited by insufficient fault feature representation from a single data modality. When dealing with complex fault types, these methods often suffer from low diagnostic accuracy and an inability to precisely and finely locate faults, making them inadequate for practical applications. To improve the diagnostic performance of the ZYJ7 electro-hydraulic switch machine, this paper proposes a deep learning-based fault diagnosis method based on feature-level multi-source data fusion using real-world oil pressure, current,

收稿日期:2025-06-27;**修回日期**:2025-11-24
基金项目:甘肃省自然科学基金(26JRRA565);教育部高校产学研创新基金(2023IT185);甘肃省教育厅2025年高等教育教学改革研究项目(GJJGB150);教育部供需对接就业育人项目(20230106827);甘肃省教育厅2023年高等学校创新创业教育示范课程(202306);兰州交通大学2024年实验教改重点项目(2024004)
Foundation items: Gansu Provincial Natural Science Foundation (26JRRA565); Ministry of Education's University Industry-University-Research Innovation Fund (2023IT185); Gansu Provincial Education Department's 2025 Higher Education Teaching Reform Research Project (GJJGB150); Ministry of Education's Supply and Demand Matchmaking Employment Education Project (20230106827); Gansu Provincial Education Department's 2023 Higher Education Innovation and Entrepreneurship Education Demonstration Course (202306); Lanzhou Jiaotong University's 2024 Experimental Teaching Reform Key Project (2024004)
第一作者:李建国(1974—),男,甘肃平凉人,副教授,博士.研究方向为交通信息工程及控制.**email**:lijianguo@mail.lzjtu.cn.

引用格式:李建国,王鹏泽.基于特征级多源数据融合的ZYJ7转辙机故障诊断[J].北京交通大学学报,2026,50(2):143-152.
LI Jianguo, WANG Pengze. Feature-level multi-source data fusion for fault diagnosis of ZYJ7 switch machine[J]. Journal of Beijing Jiaotong University, 2026, 50(2): 143-152.(in Chinese)

and power data. First, multi-modal data from oil pressure, current, and power signals are normalized, denoised, and subjected to spatiotemporal feature extraction. Then, bilinear interpolation is employed to unify the dimensions of feature matrices across different modalities, and an attention mechanism is introduced to achieve dynamic weighted fusion of these feature matrices. Finally, the fused features are fed into a hybrid neural network composed of Convolutional Neural Networks (CNN) and Long Short-Term Memory (LSTM) networks for classification. The proposed method is compared with single-source data models, simple voting methods, simple concatenation methods, and fixed-weight fusion models. Experimental results show that the proposed feature-level multi-source data fusion model improves diagnostic accuracy by 7.19%, 4.38%, 3.13%, and 1.88%, respectively, demonstrating its effectiveness and providing a valuable reference for fault diagnosis of railway switch machines.

Keywords: fault diagnosis; switch machine; multi-source data fusion; deep learning; neural network

转辙机是铁路信号系统的核心设备,其运行状态直接关系到铁路运输系统的效率和安全性.能够及时准确地发现故障是保障铁路运营安全的重要措施.然而,转辙机受室外条件影响大,故障原因复杂多样,导致微机监测系统虚警率、误报率高,仍需要对故障类型进行人工分析判断,该方式效率低下,难以满足现代铁路系统的实时性要求.研究高效、自动化的转辙机故障诊断方法具有重要实际意义[1-3].

深度学习在处理复杂的非线性问题、自动提取特征及提高诊断精度方面具有显著优势,能够有效应对传统方法难以解决的复杂工况和数据噪声问题.诸多学者提出了不同的深度学习模型来优化故障诊断过程.文献[4]提出了一种基于改进对抗网络和自适应数据对齐的转辙机故障诊断方法,将一维时域功率数据转换为二维空间图像作为类聚输入数据,从而增强模型对不同故障类型的区分能力;文献[5]采用主成分分析方法进行电流特征简约,将简约特征嵌入功率曲线深度森林模型增强模型内在特征代表性,该方法有效降低了数据维度,提高了模型计算效率;文献[6]介绍了一种半监督自适应矩阵机方法,利用少量标记样本和大量未标记样本进行学习,从而在标记数据有限的情况下提升转辙机电流数据集的状态诊断能力;文献[7]使用半监督元学习网络收集A相电流特征,增强了ZYJ7转辙机故障诊断模型的稳定性和泛化性.以上文献说明基于电气特性的故障诊断模型虽在电路状态表征上具有优势,但仅依靠电气特性无法充分反映机械部分的健康状态,尤其是对于机械结构和电液转辙机ZYJ7转辙机油路的复杂故障难以有效识别与定位.文献[8]对单侧油缸油压数据进行时空特征组合实现对油路故障的识别;文献[9]通过左右液压缸油压监测数据的对比学习正则化特征空间,以提升液压系统故障的检测能力,该方法在提高模型对油压特征的敏感性方面表现良好;文献[10]采用可视图算法将时域油压信号转换为复杂网络图提取多种统计特征实现故障诊断.以上文献说明油压特性可以有效识别与液压系统相关的故障,尤其是油泵、管路和执行器等的故障问题,但是液压系统故障在故障发生的后期才能通过油压波动表现出来,存在早期预警滞后性与电路状态表征盲区.为解决以上研究中存在的问题,本文提出一种基于特征级多源数据融合的故障诊断方法,选择油压、电流与功率作为主要特征来源,油压信号能够直接反映液压系统在道岔转换过程中的工作状态,当存在卡阻、漏油或压力不足等机械类故障时,其曲线会出现显著异常,是表征机械执行单元健康状况的关键指标.电流作为电机驱动的直接反映量,可以体现负载和能耗的变化,在电机过载、绕组故障或传动阻力异常时伴随电流突变或波动,对电气类故障尤为敏感.功率特征则在电压与电流的基础上进一步从能量消耗的角度刻画转辙机的运行效率,当机械阻力增加或电机性能下降时,功率曲线能够提供额外的诊断信息.油压、电流与功率3类信号分别从机械执行、驱动电机和能量消耗3个角度反映转辙机运行状态,具有较强的互补性,通过信息融合技术捕捉多模态数据间的复杂关系,不仅能够全面刻画转辙机在复杂工况下的动态行为,还能有效提升故障诊断的准确性和鲁棒性.

在具体的故障诊断算法层面,卷积神经网络(Convolutional Neural Networks,CNN)与长短期记忆网络(Long Short-Term Memory,LSTM)组合模型表现出相对更强的抗噪性.文献[11]使用三相交流道岔转辙机动作功率信号结合多通道输入方法提高模型泛化能力;文献[12]基于1DCNN与BiLSTM的组合模型,进一步利用双向LSTM捕捉时间序列数据中更丰富的前后依赖信息,提升了故障诊断的准确性.但BiLSTM参数规模约为LSTM的两倍,这意味

着需要更高的计算开销和内存占用,无益于最终工程化落地.针对以上问题,本文选取CNN+LSTM为最终诊断算法,通过CNN从多源数据中提取局部时空特征,LSTM进行时间序列建模与整合.在诊断流程方面,本文首先对某研究机构提供的油压、电流、功率数据进行预处理与特征提取,采用归一化、降噪及时空特征捕捉等技术,将原始信号转换为高维特征表示;其次,在特征级融合模块引入基于注意力机制的动态加权策略,实现对各数据源特征重要性的自适应调整,充分挖掘多模态信息之间的互补关系;最后,利用深度学习方法构建故障诊断分类器,对融合后的特征进行判别,得出诊断结果.

1　ZYJ7电液转辙机故障行为分析

ZYJ7型电液转辙机常见故障类型可分为油路故障、机械故障、电路故障、其他故障4类.详细故障类型如表1所示,正常状态以"F0"表示,典型油压、电流、功率波形如图1所示.选取卡口故障、解锁卡阻、锁闭卡阻、转换过程卡阻、延迟转极、油路缺油压力不足6种典型故障进行分析与算法验证,分别以"F1,F2,…,F6"表示,各故障模式对应的典型电流、功率波形如图2所示,油压波形如图3所示.

表1　转辙机详细类型

Tab.1　Detailed types of switch machines

故障类型	详细故障1	详细故障2	详细故障3	详细故障4	详细故障5
机械故障	**F1.卡口故障**	**F2.解锁卡阻**	**F3.锁闭卡阻**	**F4.转换过程卡阻**	密贴调整过紧
	滑床板干燥	接点转换不灵活	设备内部污染	拐臂不灵活	动作杆锁块转换错位
	动作杆解锁力过大	离合器错位	联锁板卡重启	表示缺口错位	支持辊错位
	紧固元件松动或断裂	电机机械过载	电机润滑不足	电机驱动过度或不足	电机卡死
	双机不完全同步	接点组氧化磨损或虚接	接点组动接点轴轴窜过大	接点组启动片与动作板间隙过小	接点组卡阻
电气故障	**F5.延迟转极**	二极管阻滞	继电器腐蚀	保险丝烧坏	电机电刷故障
	电路配线虚接或断裂	电机电气过载	电气接触不良	电容器恶化	异常阻抗
	启动电路线缆或保险损坏	三相电缺相	表示回路/开路	电机相位失衡	—
油路故障	**F6.油路缺油压力不足**	油泵内泄	油泵外泄	溢流阀堵塞	联轴器错位
	油路存在障碍物	空动缸内泄	油箱内泄	调节阀堵塞	电机压力过载
其他故障	天气环境	安装位置失误	人为操作失误	工务故障	—

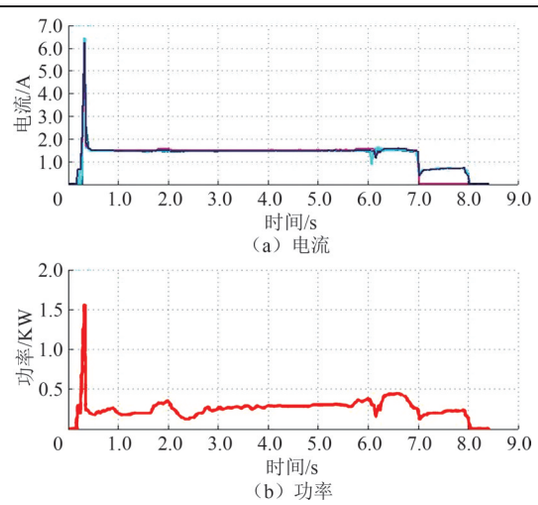


图1　ZYJ7正常工况曲线

Fig.1　ZYJ7 normal operating condition curve

2　基于注意力机制的多源数据融合

2.1　特征级多源数据融合

特征级多源数据融合通过联合油压、电流、功率不同模态的特征表征,充分利用多模态数据的互补性和多样性来生成统一表示.在特征提取前要对数据进行归一化处理,以油压数据为例,其数据密度如图4所示,数据分布不存在极限异常点,因此使用最小-最大值归一化能稳定缩放数据[13].

集合经验模态分解(Ensemble Empirical Mode Decomposition,EEMD)能够在无须预设基函数的条件下自适应地分解非平稳信号,较传统傅里叶或小波方法更能刻画转辙机运行数据中的瞬时特征.鉴于本文采集的电流、功率与油压信号均呈现明显的非平稳与多尺度特性,采用EEMD有助于提取不同时间尺度下的本征模态函数,实现对多源异构数据的有效特征表达.对第i个数据源原始信号D_i处理后,$\mathbf{FE}_i$为

$$\mathbf{FE}_i=\mathrm{FeatureExtractor}(D_i)\quad \mathbf{FE}_i\in\mathbb{R}^{d_i} \tag{1}$$

式中:FeatureExtractor()表示特征提取函数;$\mathbf{FE}_i$为提取的D_i维特征向量.

经特征提取后$\mathbf{FE}_i$矩阵的形状与大小各不相同,为了便于数据融合,需要进行进一步的整形处理.仍以油压数据为例,其以0.01 s的采样间隔抽样,一条6 s的油压数据共有600个数据点,经验模态分解后形成6个600×1的矩阵,通过矩阵增广转化为600×6矩阵,共有数据量3 600个,选用64×64的矩阵作为转换目标矩阵即可保全特征信息,电流、功率数据.矩阵整形映射原理与图片缩放拉伸类似,当矩阵从$\boldsymbol{W}_1\times\boldsymbol{H}_1$

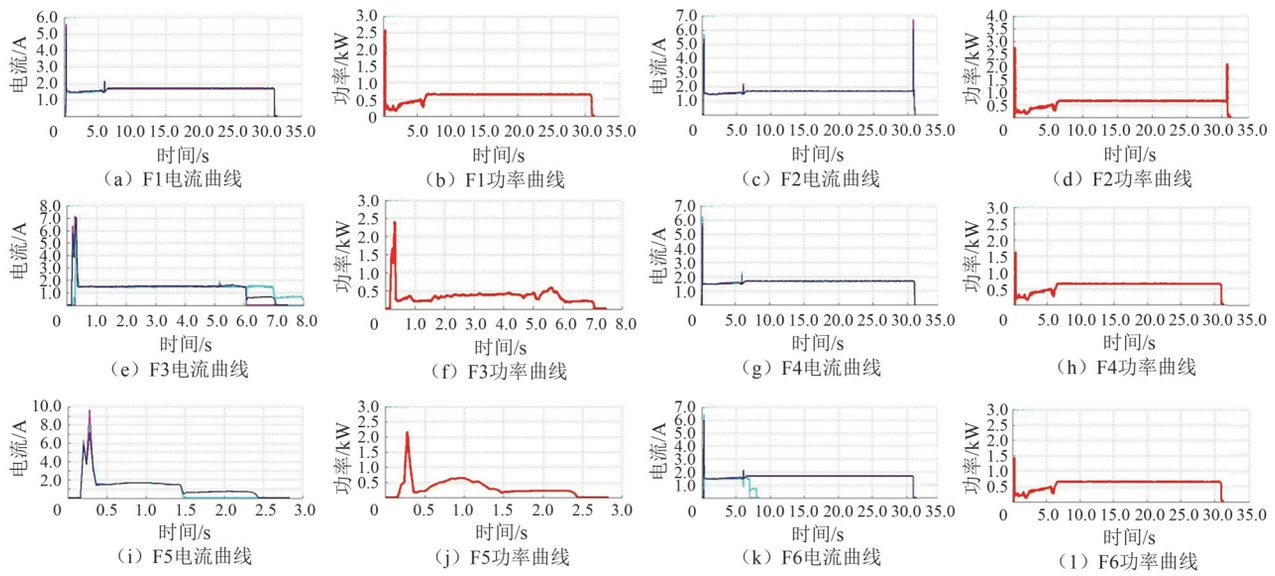


图 2　ZYJ7 转辙机各故障模式电气特性曲线

Fig.2　Electrical characteristic curves of various fault modes of ZYJ7 switch machine

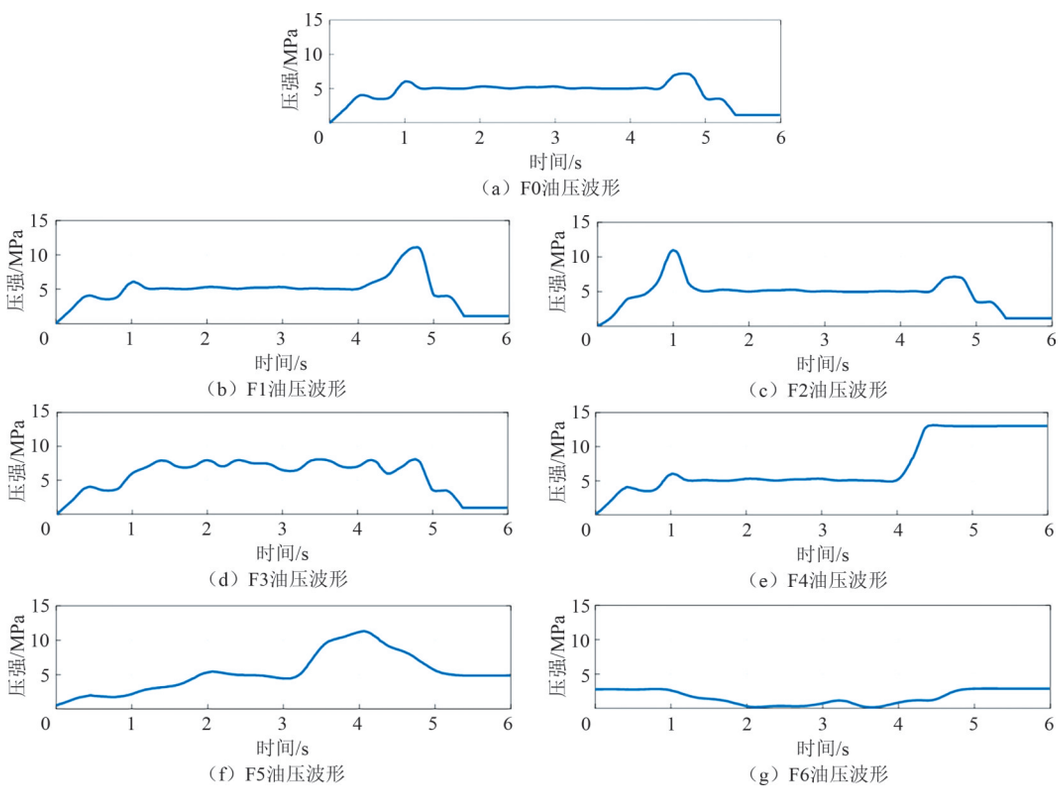


图 3　ZYJ7 各故障模式对应油压特性曲线

Fig.3　ZYJ7 oil pressure characteristic curve corresponding to each fault mode

缩放到 $\boldsymbol{W}_2\times\boldsymbol{H}_2$ 时，其中 $\boldsymbol{W}_1$、$\boldsymbol{W}_2$、$\boldsymbol{H}_1$、$\boldsymbol{H}_2$ 分别为原始矩阵、缩放后矩阵的横纵纬度数，新矩阵坐标 $(x',\ y')$ 的数值与其对应原矩阵坐标的映射关系为

$$\begin{cases} x'=\dfrac{x}{\boldsymbol{W}_1}\times\boldsymbol{W}_2 \\ y'=\dfrac{y}{\boldsymbol{H}_1}\times\boldsymbol{H}_2 \end{cases} \tag{2}$$

式中：x，y 通常为非整数，而原始数据只能在整数坐标上定义，因此需要使用双线性插值算法将原始矩阵上 (x,y) 坐标 4 个最近邻单元值进行加权平均计算得出新矩阵单元值，设原始矩阵上 4 个邻点为 (x_1,y_1)，(x_2,y_1)，(x_1,y_2)，(x_2,y_2)，则变换过后的矩阵在坐标 $(x',\ y')$ 的数值 $I'(x',y')$ 为

$$\begin{aligned} I'(x',y')=&(1-a)(1-b)I(x_1,y_1)+\\ &a(1-b)I(x_2,y_1)+(1-a)bI(x_1,y_2)+\\ &abI(x_2,y_2) \end{aligned} \tag{3}$$

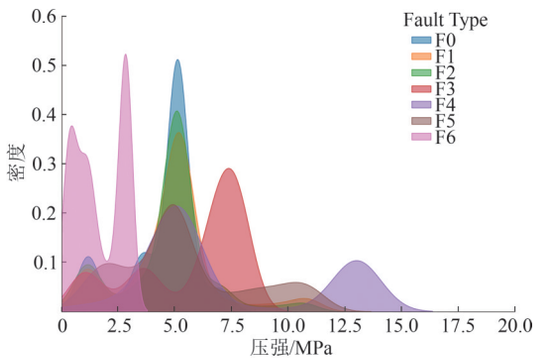


图 4　油压数据数据密度图

Fig.4　Oil pressure data density map

式中:$a=x-x_1$, $b=y-y_1$是小数部分,表示各单元的贡献度;$I(x,y)$为原始矩阵在坐标(x,y)处的数值.

将油压、电流、功率数据经整形后形成的特征矩阵进行矩阵增广拼接为

$$\left(F_{\text{fusion}}=[F_1:F_2:\cdots:F_N]\right)\quad\left(F_{\text{fusion}}\in\mathbb{R}^{\sum_{i=1}^{N}d_i}\right)\tag{4}$$

这种特征融合方式简单直观,但容易引入冗余特征[14].

2.2　基于注意力机制的动态加权融合

基于矩阵增广的特征级多源数据融合为故障诊断提供了统一的高维特征表示,但简单拼接的方式无法适应多模态数据的动态特性.为此,引入基于注意力机制的动态加权策略,进一步提升融合效果[15].

设每个数据源的经过整形变换进一步融合后的综合特征表示为F'_{fusion},为每个数据源分配权重a_i后,加权特征F'_{fusion}为

$$\begin{cases}F'_{\text{fusion}}=\sum_{i=1}^{N}a_iF_i\\\sum_{i=1}^{N}a_i=1\end{cases}\tag{5}$$

式中:a_i表示第i个数据源的权重.

注意力机制能够有效解决特征级融合中固定权重策略的局限性[16],通过计算每个数据源特征的重要性权重,动态调整其对最终融合结果的贡献,从而更灵活地适应不同任务和工况.基于注意力机制的动态加权融合过程包括以下3个步骤.

步骤1:注意力得分计算.通过一个可学习的权重矩阵$\boldsymbol{W}_a$和偏置项b_a,计算每个特征的注意力得分S_i为

$$S_i=\boldsymbol{W}_a\times F_i+b_a\tag{6}$$

步骤2:权重归一化.使用softmax函数进行归一化,将注意力得分S_i转换为权重a_i为

$$a_i=\frac{\exp(s_i)}{\sum_{j=1}^{N}\exp(s_j)}\tag{7}$$

步骤3:融合特征生成.根据权重a_i,对各数据源特征进行加权求和,生成融合特征F''_{fusion}表示为

$$F''_{\text{fusion}}=\sum_{i=1}^{N}a_iF_i\tag{8}$$

通过动态加权融合策略,模型能够自适应地突出关键信息,抑制无关或冗余特征对结果的干扰[17].相比于固定权重方法,注意力机制能够更灵活地调整不同数据源对最终任务的影响,有效提升故障诊断的准确性和鲁棒性.

3　模型构建

为了有效提升转辙机故障诊断的准确性和鲁棒性,本文提出一种基于特征级多源数据融合的故障诊断模型,并构建了多个对比模型以验证该方法的优势.多源数据融合诊断模型能够充分挖掘油压、电流、功率传感器数据的互补信息,从而提升对复杂故障模式的识别能力.为评估多源数据融合策略的有效性,本文设计单一数据源诊断模型和简单表决诊断模型作为对比实验的基准.

3.1　多源数据融合诊断模型

基于注意力机制的动态加权特征级数据融合故障诊断模型结构如图5所示.

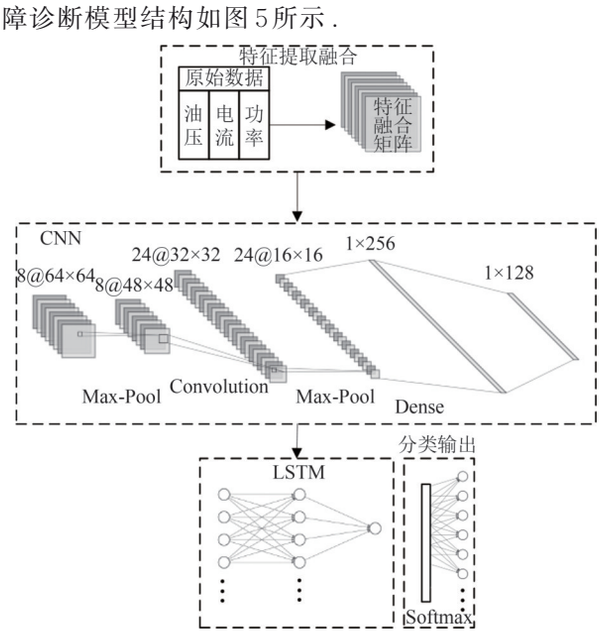


图 5　故障诊断模型

Fig.5　Fault diagnosis model

该模型主要包括特征提取融合、CNN、LSTM、分类输出部分[18-21].采用CNN提取局部空间特征,提高特征表达能力,LSTM捕捉数据的时间序列依赖关系,通过Softmax分类层输出故障类别.其中CNN+LSTM与分类输出部分为所有模型共用,基于特征矩阵增广的故障诊断模型将多维特征矩阵直

接堆叠后输入诊断模型;基于固定权重的故障诊断模型以固定权重将多维特征矩阵累加后输入诊断模型.

数据预处理中,EEMD分解获取前6个IMF分量,并经由双线性插值统一为64×64的特征图.CNN模块由两层卷积层构成,其卷积核尺寸均为3×3,输出通道数分别为32和64,每层后接2×2最大池化层.LSTM模块隐藏单元数设为128.模型使用Adam优化器进行训练,初始学习率为10^{-4},并采用指数衰减策略,批大小设置为32.为抑制过拟合,训练中引入了L2正则化(系数10^{-5})并采用早停策略.

3.2 对比模型

3.2.1 单一数据源诊断模型

单一数据源诊断模型仅依赖特定类型的传感器数据进行故障诊断,在传统转辙机故障诊断的工程实践中,通常依靠单一物理量的变化来推测设备状态,例如通过监测电流波动来判断电气故障,或基于油压变化分析液压系统的运行情况.由于不同类型故障的表现形式具有复杂的关联性,仅使用单一数据源进行故障分类存在信息不完整、诊断精度不足的问题,尤其在面对电气、机械和液压耦合的复杂故障时,该方法的局限性尤为明显.为比较多源数据融合带来的性能提升,本文分别构建了基于油压、电流和功率数据的深度学习故障诊断模型,以评估不同数据源对故障特征的表征能力,结构如图6单一数据源诊断模块所示.

3.2.2 简单表决诊断模型

为全面验证多源融合模型的性能提升,在此引入简单表决模型,简单表决诊断模型是一种基于单一数据源诊断模型的改进策略,其核心思想是利用油压、电流、功率3种不同模态数据的独立诊断结果进行投票融合,以减少单一数据源模型可能出现的误判,提高诊断的稳定性.由于转辙机的故障表现通常涉及多个物理量的变化,仅依赖单一数据源进行分类可能导致对某些故障模式的识别能力不足.通过表决机制,综合多个数据源的分类结果,有助于降低单一数据源可能存在的误诊率,提高故障诊断的准确性.对比模型采用决策级信息融合,将油压、电流、功率3种单一数据源诊断模型的诊断结果进行3取2表决,模型构造如图6所示.

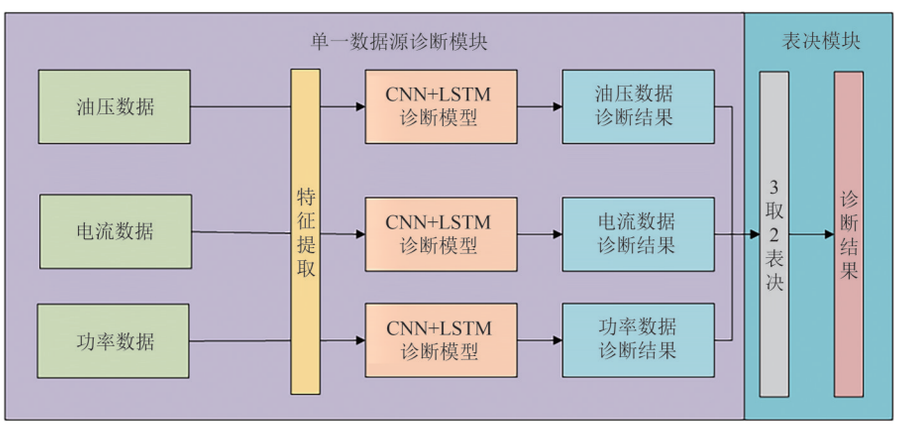


图6 表决诊断模型

Fig.6 Voting-based diagnosis model

4 验证与分析

本文以某试验中心提供的ZYJ7转辙机动作过程油压、电流、功率曲线各800条作为仿真验证数据,其中正常动作过程对应数据200条,各故障类型各有数据100条.选用单一数据源诊断模型、简单表决诊断模型、直接拼接诊断模型、固定权重诊断模型作为对比模型,全面比较动态加权诊断模型相较于四者的各项性能.由于篇幅限制,单一数据源模型仅选用效果最好的油压数据诊断模型,电流、功率单一诊断模型在此不作赘述.

4.1 评价指标设置

选取F1-Score、召回率(Recall)、精确率(Precision)、准确率(Accuracy)、AUC作为模型性能评价指标,计算式为[22]

$$\text{F1-Score}=\frac{2\text{TP}}{2\text{TP}+\text{FP}+\text{FN}} \tag{9}$$

$$\text{Recall}=\frac{\text{TP}}{\text{TP}+\text{FN}} \tag{10}$$

$$\text{Precision}=\frac{\text{TP}}{\text{TP}+\text{FP}} \tag{11}$$

$$\text{Accuracy}=\frac{\text{TP}+\text{TN}}{\text{TP}+\text{TN}+\text{FP}+\text{FN}} \tag{12}$$

$$\mathrm{AUC}=\int_0^1 \frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FN}}\mathrm{d}\frac{\mathrm{FP}}{\mathrm{FP}+\mathrm{TN}} \tag{13}$$

式中:TP即实际为正且预测为正;TN即实际为负且预测为负;FP即实际为负但预测为正;FN即实际为正但预测为负;ROC曲线是以召回率为纵坐标、漏检率为横坐标绘制在坐标系中得到的曲线,AUC是ROC曲线下方的面积,表示模型区分正负类的能力,取值在0～1之间,AUC=0.5表示模型的预测能力与随机猜测相当;AUC>0.5表示模型有一定的区分能力,AUC越大,模型越好;AUC=1表示模型能够完美区分正负类;AUC<0.5表示模型的预测结果比随机猜测还差.

4.2　结果对比与分析

为了优化模型性能,本文采用交叉熵损失函数作为目标优化函数,并使用Adam自适应优化算法进行梯度更新,以提升模型的训练稳定性.同时,为了防止过拟合问题,在训练过程中引入了L2正则化项,并设定早停策略,使训练在验证损失不再下降时自动终止.此外,通过调整学习率的指数衰减策略,确保模型在训练后期仍能保持较好的泛化能力.原始数据在特征空间中的分布情况如图7所示.

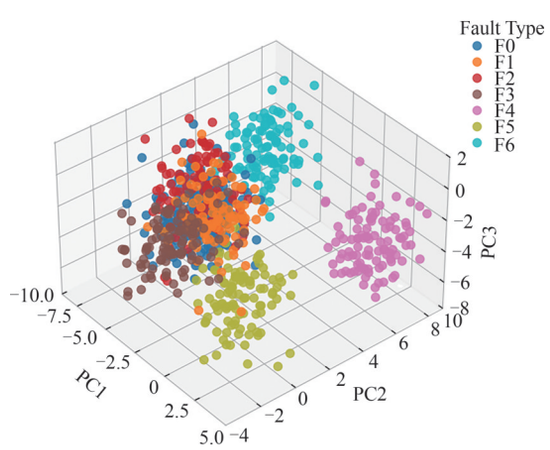


图7　原始数据特征空间分布

Fig.7　Distribution of original data features in space

实验以6:4的比例划分训练集与测试集,各故障类型数据均匀分割并充分混合,模型训练集准确率与迭代次数曲线如图8所示.当迭代次数达到30时,各模型预测准确率趋于平稳并达到理想效果,因此本文所有对各诊断模型的相关参数评估均建立在30次迭代训练的基础上.

几种诊断模型对各故障类型的分类效果如图9所示.单元格横向代表真实类别,纵向表示预测类别,其中采用油压数据的单一数据源模型出现6例将F2型故障误判为正常状态的情况,对照油压波形分析发现,F2波形在走势上与正常波形有一致性,

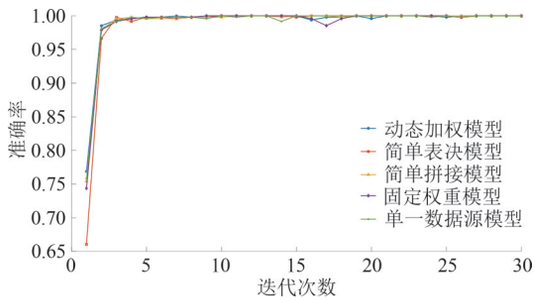


图8　各模型准确率迭代曲线

Fig.8　Accuracy iteration curves of different models

单一数据源模型对二者区分不足容易造成误判.

对比引入电气特性的简单表决模型和固定权重模型发现,在引入电流、功率数据后,简单表决模型、简单拼接模型均未出现F2-F0误判.说明利用多源信息,可以更准确地捕捉设备状态的细微差异,减少了误判现象的发生.由图9(c)与(d),固定权重模型相较于简单拼接模型避免了F3-F0误判,说明简单拼接模型会过多引入冗余特征导致预测准确率下降.由图9(e)与(d),动态加权融合模型能根据各数据源在特定故障条件下的表现自动调整权重,确保关键信息得到更充分的利用,而噪声或冗余信息则被有效抑制,利用注意力机制,模型能够捕捉到不同模态间复杂的依赖关系,提升整体诊断的准确性和鲁棒性,这种自适应特性使得模型在面对多变工况和不同故障模式时更具有灵活性和适应性,从而进一步优化故障诊断的效果.

由图9可知:①单一数据源模型在F2型故障上出现6次误判为正常状态,说明仅依赖油压特征难以区分与正常状态波形相似的异常模式,引入电流与功率特征的简单表决模型和简单拼接模型均避免了F2－F0的混淆,表明多源数据能够提供互补信息,有效弥补单一模态的不足.②对于F3型故障,简单拼接模型仍存在一定的F3-F0误判,而固定权重模型通过预设权重分配抑制了部分冗余特征,从而减少了误判现象,但其缺乏自适应调整能力,在故障样本分布复杂的情况下提升有限.③动态加权模型借助注意力机制能够根据不同工况自动分配权重,在F2型与F3型等易混淆故障的识别中表现尤为突出,显著降低了误判率,各模型在不同故障类型下均有差异化表现,而动态加权融合模型能够同时兼顾多类故障的诊断准确性与鲁棒性,表现出最强的适应性与泛化能力.

各模型测试集性能评价指标如表2所示.

由表2可知:①不同模型的故障诊断性能随着数据融合策略的不断升级呈现出显著的提升趋势,

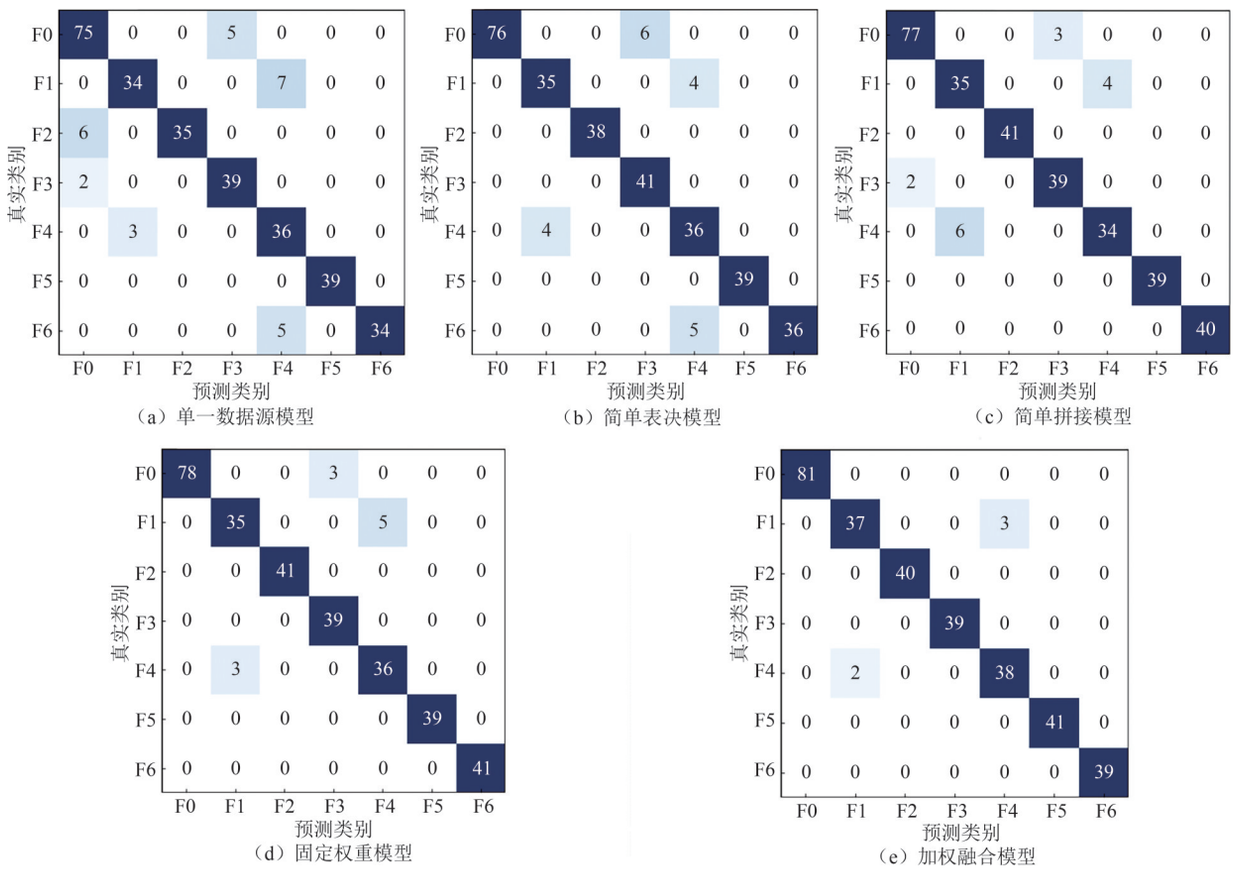


图 9 混淆矩阵

Fig.9 Confusion Matrix

表 2 模型性能指标对比

Tab.2 Comparison of model performance metrics

名称	F1-Score/%	召回率/%	精确率/%	准确率/%	AUC
单一数据源模型	91.28	90.95	92.27	91.25	0.95
简单表决模型	93.91	94.32	93.85	94.06	0.97
简单拼接模型	95.07	95.16	95.02	95.31	0.97
固定权重模型	96.31	96.59	96.11	96.56	0.98
动态加权模型	98.21	98.21	98.22	98.44	0.99

单一数据源模型仅依赖单一模态数据，其F1-Score、召回率、精确率和准确率均处于较低水平，表明在复杂故障情况下，单一数据源往往无法充分捕捉设备运行状态的多维信息.②通过简单表决方法，将多个单一模型的预测结果进行投票整合后，F1-Score提升至93.91%，准确率提升至94.06%，AUC提升至0.97，说明多源数据的引入能够一定程度上弥补单一数据源的不足，但这种方法仍然未能深入挖掘不同数据源间的互补性.③简单拼接模型则直接将不同模态数据的特征进行拼接，显著增强了特征表达能力，F1-Score与准确率进一步升至95.07%、95.31%，较简单表决模型分别提升1.16%和1.25%，但这种方式可能会引入冗余信息，从而影响模型的泛化能力.④固定权重模型在此基础上，通过为各数据源分配预先设定的权重，实现了更明确的贡献分配，F1-Score、准确率分别达到96.31%、96.56%，AUC提升至0.98.然而，由于其权重设置固定，缺乏针对不同故障工况的自适应调整能力，因此效果提升有限.⑤动态加权模型利用注意力机制，根据各数据源特征的重要性动态分配权重，既能突出关键信息，又能有效抑制噪声和冗余特征，F1-Score、召回率、精确率均达98.21%以上，准确率达98.44%，AUC提升至0.99，相比对比模型，预测准确率分别提升了7.19%、4.38%、3.13%、1.88%，在F1-Score、召回率、精确率、准确率和AUC等指标上均表现最佳.

为进一步验证本文提出模型的先进性，进一步选取目前常见的故障诊断模型，支持向量机（Support Vector Machine，SVM）、CNN、Transformer进行对比，结果如表3所示.由以上实验可知，本文提出的基于注意力机制的动态加权特征级多源数据融合模型不仅在结构设计上合理，在实际诊断性能上也显著优于多种传统及前沿的对比模型，充分验证了其在ZYJ7转辙机故障诊断任务中的有效性与优越性.

表 3　模型性能对比

Tab.3　Model performance indicator chart　　%

模型名称	F1-Score	召回率	精确率	准确率
加权融合模型	98.21	98.21	98.22	98.44
SVM	95.80	96.19	95.94	95.83
CNN	96.70	97.40	96.64	96.67
Transformer	93.97	94.29	94.75	94.17

5　结论

1）多源数据融合可显著提升故障诊断性能,相较于单一数据源模型,动态加权模型的准确率从91.25%提升至98.44%,提升幅度达7.19%,同时F1-Score、召回率、精确率和AUC分别从91.28%、90.95%、92.27%、0.95提升至98.21%、98.21%、98.22%、0.99,有效整合了油压、电流、功率3类数据的互补特性,弥补了单一数据源信息表征的局限性,增强了诊断的准确性与鲁棒性.

2）特征级信息融合策略优于决策级信息融合策略,采用特征级融合的动态加权模型,相较于决策级的简单表决模型,诊断准确率从94.06%提升至98.44%,提升幅度为4.38%,F1-Score、召回率、精确率和AUC也均有明显优势,其通过统一提取多模态数据的时空特征,有效挖掘了各数据源间的内在关联性,解决了决策级融合难以捕捉数据深层关联的问题.

3）基于注意力机制的动态加权分配方案具有显著优越性,相较于简单拼接模型和固定权重模型,动态加权模型的准确率分别从95.31%、96.56%提升至98.44%,提升幅度为3.13%和1.88%,各核心评价指标均达到最优,说明动态加权模型能够根据不同故障工况自适应调整各数据源特征的重要性,突出关键故障特征、抑制冗余噪声,提升了易混淆故障类型的识别能力,降低误判率.

未来的研究中可以考虑引入转辙机维修日志、日报表等文本信息以及振动信号、牵引力信号实现对转辙机状态的全方位表述,进一步提升对故障的细致识别能力,提升对混合故障的分辨能力.在此本文仅讨论了ZYJ7转辙机的故障诊断流程,未来可以进一步改进,提升对不同类型转辙机的泛用效果.

参考文献(References):

[1] 李建国, 刘琦. 考虑样本多样性的转辙机故障诊断决策模型[J]. 北京交通大学学报, 2024, 48(2): 165－175.
LI Jianguo, LIU Qi. Fault diagnosis decision model for switch machines considering sample diversity[J]. Journal of Beijing Jiaotong University, 2024, 48(2): 165－175. (in Chinese)

[2] 武晓春, 楚昕. 基于小波包分解与GG模糊聚类的转辙机退化阶段划分研究[J]. 铁道学报, 2022, 44(1): 79－85.
WU Xiaochun, CHU Xin. Research on division of degradation stage of turnout equipment based on wavelet packet decomposition and GG fuzzy clustering[J]. Journal of the China Railway Society, 2022, 44(1): 79－85. (in Chinese)

[3] 孔令刚, 焦相萌, 陈光武, 等. 基于Mallat小波分解与改进GWO-SVM的道岔故障诊断[J]. 铁道科学与工程学报, 2020, 17(5): 1070－1079.
KONG Linggang, JIAO Xiangmeng, CHEN Guangwu, et al. Turnout fault diagnosis based on Mallat wavelet decomposition and improved GWO-SVM [J]. Journal of Railway Science and Engineering, 2020, 17(5): 1070－1079. (in Chinese)

[4] 郑启明, 姚新文, 陈光武, 等. 基于改进对抗网络与自适应数据对齐的转辙机故障诊断研究[J]. 铁道学报, 2023, 45(10): 96－104.
ZHENG Qiming, YAO Xinwen, CHEN Guangwu, et al. Research on fault diagnosis method for switch machine based on improved generative adversarial networks with adaptive data alignment[J]. Journal of the China Railway Society, 2023, 45(10): 96－104. (in Chinese)

[5] 胡小晨, 郭宁, 沈拓, 等. 基于主成分分析和深度森林算法的S700K转辙机故障诊断[J]. 同济大学学报(自然科学版), 2024, 52(1): 35－40.
HU Xiaochen, GUO Ning, SHEN Tuo, et al. PCA-gcForest-based fault diagnosis of S700K switch machine [J]. Journal of Tongji University (Natural Science), 2024, 52(1): 35－40. (in Chinese)

[6] LI W Q, XU Z W, MEI M, et al. A semi-supervised adaptive matrix machine approach for fault diagnosis in railway switch machine[J]. Sensors, 2024, 24(13): 4402.

[7] LAO Z P, HE D Q, SUN H M, et al. Few-shot fault diagnosis of switch machine based on data fusion and balanced regularized prototypical network[J]. Engineering Applications of Artificial Intelligence, 2024, 135: 108847.

[8] 刘琦, 李建国. 基于时空特征组合模型的转辙机故障诊断[J]. 科学技术与工程, 2024, 24(13): 5538－5545.
LIU Qi, LI Jianguo. Fault diagnosis of switch machine based on spatiotemporal feature combined model [J]. Science Technology and Engineering, 2024, 24(13): 5538－5545. (in Chinese)

[9] WEN W G, LIU Y, BAI Y H, et al. A feature pseudo-fusion method for intelligent fault diagnosis of electro-hydraulic switch machine inspired by contrastive learning [J]. Proceedings of the Institution of Mechanical Engi-

neers, Part F: Journal of Rail and Rapid Transit, 2023, 237(10): 1308－1319.

[10] 杨喜旺, 王智超, 黄晋英, 等. 基于可视图特征与CatBoost的转辙机故障诊断[J]. 中北大学学报(自然科学版), 2024, 45(1): 58－65.
YANG Xiwang, WANG Zhichao, HUANG Jinying, et al. Fault diagnosis of switch machine based on visibility graph feature and CatBoost[J]. Journal of North University of China (Natural Science Edition), 2024, 45(1): 58－65. (in Chinese)

[11] 付雅婷, 温世明, 杨辉, 等. 基于多通道输入和1DCNN-LSTM的道岔转辙机故障诊断[J]. 铁道学报, 2023, 45(11): 98－106.
FU Yating, WEN Shiming, YANG Hui, et al. Fault diagnosis of switch machine based on multi-channel input and 1DCNN-LSTM[J]. Journal of the China Railway Society, 2023, 45(11): 98－106. (in Chinese)

[12] 王瑞峰, 李扬. 基于1DCNN-BiLSTM组合模型的S700K转辙机故障诊断[J]. 电子测量与仪器学报, 2022, 36(11): 193－200.
WANG Ruifeng, LI Yang. Fault diagnosis of S700K switch machine based on 1DCNN-BiLSTM hybrid model[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(11): 193－200. (in Chinese)

[13] HUANG L, QIN J, ZHOU Y, et al. Normalization techniques in training DNNs: Methodology, analysis and application[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(8): 10173－10196.

[14] AZCARATE S M, RÍOS-REINA R, AMIGO J M, et al. Data handling in data fusion: Methodologies and applications[J]. TrAC Trends in Analytical Chemistry, 2021, 143: 116355.

[15] LI M G, WANG F, JIA X J, et al. Multi-source data fusion for economic data analysis[J]. Neural Computing and Applications, 2021, 33(10): 4729－4739.

[16] NIU Z Y, ZHONG G Q, YU H. A review on the attention mechanism of deep learning[J]. Neurocomputing, 2021, 452: 48－62.

[17] LUO Y, SHAO F, MU B Y, et al. Dynamic weighted fusion and progressive refinement network for visible-depth-thermal salient object detection[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2024, 34(11): 10662－10677.

[18] 李梅, 宁德军, 郭佳程. 基于注意力机制的CNN-LSTM模型及其应用[J]. 计算机工程与应用, 2019, 55(13): 20－27.
LI Mei, NING Dejun, GUOJIA Cheng. Attention mechanism-based CNN-LSTM model and its application[J]. Computer Engineering and Applications, 2019, 55(13): 20－27. (in Chinese)

[19] ZHA W S, LIU Y P, WAN Y J, et al. Forecasting monthly gas field production based on the CNN-LSTM model[J]. Energy, 2022, 260: 124889.

[20] LU W J, LI J Z, LI Y F, et al. A CNN-LSTM-based model to forecast stock prices[J]. Complexity, 2020, 2020(1): 6622927.

[21] KIM T Y, CHO S B. Predicting residential energy consumption using CNN-LSTM neural networks[J]. Energy, 2019, 182: 72－81.

[22] SABORIDO R, RUIZ A B, GONZÁLEZ-GALLARDO S, et al. Performance assessment of population-based multiobjective optimization algorithms using composite indicators[J]. IEEE Transactions on Evolutionary Computation, 2025, 30(1): 214－225.