

# 控制与决策

Control and Decision

## 多变量时序标记Transformer及其在电潜泵故障诊断中的应用

李康, 李爽, 高小永, 李强, 张来斌

引用本文:

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.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2024.0266>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### [周围神经MicroCT图像中神经束轮廓获取算法的改进](#)

An improved approach to obtain contours of fascicular groups from MicroCT images of peripheral nerve  
控制与决策. 2021, 36(7): 1601-1610 <https://doi.org/10.13195/j.kzyjc.2019.1664>

#### [l<sub>p</sub>-范数约束下MKL-OC-ELM的装备故障检测](#)

MKL and OC-ELM fault detection based on l<sub>p</sub>-norm constraint  
控制与决策. 2021, 36(10): 2379-2388 <https://doi.org/10.13195/j.kzyjc.2020.0443>

#### [改进集成深层自编码器在轴承故障诊断中的应用](#)

Application of improved ensemble deep auto-encoder in bearing fault diagnosis  
控制与决策. 2021, 36(1): 135-142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

#### [基于强化学习的倒立摆分数阶梯度下降RBF控制](#)

Reinforcement learning based fractional gradient descent RBF neural network control of inverted pendulum  
控制与决策. 2021, 36(1): 125-134 <https://doi.org/10.13195/j.kzyjc.2019.0816>

#### [脉冲神经网络研究进展综述](#)

Spiking neural networks A survey on recent advances and new directions  
控制与决策. 2021, 36(1): 1-26 <https://doi.org/10.13195/j.kzyjc.2020.1006>

# 多变量时序标记 Transformer 及其在电潜泵 故障诊断中的应用

李康<sup>1,3†</sup>, 李爽<sup>1</sup>, 高小永<sup>1</sup>, 李强<sup>1</sup>, 张来斌<sup>2,3</sup>

- (1. 中国石油大学(北京)人工智能学院, 北京 102249;  
2. 中国石油大学(北京)安全与海洋工程学院, 北京 102249;  
3. 中国石油大学(北京)应急管理部油气生产安全与应急技术重点实验室, 北京 102249)

**摘要:** 电潜泵故障诊断对于确保安全可靠采油至关重要, 但是, 电潜泵数据呈现出的多变量、非线性和动态变化等复杂特性为该任务带来了严峻挑战. 近年来, 深度学习在复杂数据特征提取方面表现出的强大能力催生了一系列基于神经网络的电潜泵故障诊断方法. 然而, 多数方法忽略了电潜泵数据的动态特性以及长时依赖特征提取困难的问题. 针对上述问题, 提出一种多变量时序标记 Transformer 神经网络来实现电潜泵故障诊断. 该模型设计新的多变量时间序列标记策略, 继承引入多头注意力机制和残差连接的传统 Transformer 神经网络编码器在长时依赖特征提取方面的优势, 用前向神经网络替代传统 Transformer 神经网络解码器来简化模型复杂度. 通过对油田现场故障数据分析, 验证所提出方法的有效性. 实验结果表明, 所提出方法实现了 10 类电潜泵故障的精确诊断, 相比于流行的深度学习方法诊断性能更优.

**关键词:** 电潜泵; Transformer 神经网络; 深度学习; 特征提取; 故障诊断; 多变量时序标记

**中图分类号:** TP206.3; TP18 **文献标志码:** A

**DOI:** 10.13195/j.kzyj.2024.0266

**引用格式:** 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.

## Multivariate time series tokenized Transformer and its application in fault diagnosis of electric submersible pump

LI Kang<sup>1,3†</sup>, LI Shuang<sup>1</sup>, GAO Xiao-yong<sup>1</sup>, LI Qiang<sup>1</sup>, ZHANG Lai-bin<sup>2,3</sup>

- (1. College of Artificial Intelligence, China University of Petroleum (Beijing), Beijing 102249, China; 2. College of Safety and Ocean Engineering, China University of Petroleum (Beijing), Beijing 102249, China; 3. Key Laboratory of Oil and Gas Safety and Emergency Technology, Ministry of Emergency Management, China University of Petroleum (Beijing), Beijing 102249, China)

**Abstract:** Fault diagnosis of electric submersible pumps is crucial to ensure safe and reliable oil recovery, but the complex characteristics of electric submersible pump data, such as multivariate, nonlinear, and dynamic changes, pose a great challenge to this task. In recent years, the powerful capabilities of deep learning in feature extraction of complex data have spawned a series of neural network-based fault diagnosis methods for electric submersible pumps. However, most of the methods ignore the dynamic characteristics of the electric submersible pump data as well as the difficulty of long-term dependency feature extraction. To address the above issues, a multivariate time-series tokenized Transformer neural network is proposed for fault diagnosis of electric submersible pumps. This model designs a new multivariate time series tokenization strategy and inherits the advantages of the traditional Transformer neural network's encoder which introduces multi-head attention mechanisms and residual connections in long-term dependency feature extraction. In addition, this model replaces the traditional Transformer neural network's decoder with a forward neural network to simplify the model's complexity. The effectiveness of the method is verified by analyzing the field's faulty data. The experimental results show that the proposed method can accurately diagnose ten types of electric submersible

收稿日期: 2024-03-14; 录用日期: 2024-09-12.

基金项目: 国家自然科学基金重点项目 (52234007); 国家自然科学基金面上项目 (22178383); 北京市自然科学基金面上项目 (2232021); 中国博士后科学基金项目 (GZB20230861); 中国石油大学(北京)科研基金项目 (2462023YJRC036).

责任编辑: 吴立刚.

†通信作者. E-mail: kangli@cup.edu.cn.

pump faults, and it outperforms the popular deep learning methods.

**Keywords:** electric submersible pump; Transformer neural network; deep learning; feature extraction; fault diagnosis; multivariate time series tokenization

## 0 引言

电潜泵 (ESP) 是一种重要的人工举升采油设备, 因其提液能力强、排量大、扬程高, 被广泛应用于海上油田、沙漠油田以及复杂井况中后期油田的采油任务<sup>[1]</sup>. 然而, 由于其结构复杂、组件繁多, 长期运行在高温、高压、高杂质、高腐蚀的恶劣环境下, 故障发生频率高且类型多, 如沉积物和固体颗粒对泵造成磨损和堵塞<sup>[2]</sup>, 电缆的绝缘和防水出现问题<sup>[3]</sup>等, 及时准确地诊断电潜泵故障对于保证采油系统安全稳定运行至关重要.

传统电潜泵故障诊断方法主要分为两类: 电流卡片法<sup>[4]</sup>和憋压法<sup>[5]</sup>. 电流卡片法是对电潜泵运行 24 h 的电流进行记录, 通过分析电流变化趋势来诊断故障; 憋压法则是利用关闭生产阀后气压变化情况进行故障诊断. 这两类传统方法均仅对单一变量 (电流、压力) 的变化趋势进行分析, 未充分利用电潜泵数据的多变量、非线性、动态变化等特性, 而这些特性对于建立精确的电潜泵故障诊断模型至关重要. 随着易采原油的枯竭, 传统方法越来越无法满足油田安全开采需求, 现代潜油电泵故障诊断方法逐渐站上历史舞台.

现代电潜泵故障诊断方法主要分为如下 4 类: 1) 基于故障树的方法. 利用“树”形结构来表示电潜泵工况, 并引入各部件发生故障的概率, 通过定性或定量分析方法判断电潜泵状态<sup>[6-7]</sup>. 2) 基于模糊理论的方法. 利用模糊数学理论对电潜泵故障发生情况进行推理, 得到故障集合<sup>[8-9]</sup>. 3) 基于机器学习的方法. 利用机器学习方法, 如支持向量机、极限学习机、K 近邻等对电潜泵故障进行特征提取和分类<sup>[10-11]</sup>. 4) 基于深度学习的方法. 设计端到端的神经网络模型, 对电潜泵数据进行抽象特征提取和故障诊断<sup>[12-13]</sup>.

尽管现代电潜泵故障诊断方法已取得了不错表现, 但是, 大部分工作未考虑电潜泵的动态特性. 动态特性指电潜泵变量在不同时刻的采样值具有时序依赖关系. 为了处理该问题, 递归神经网络 (RNN)<sup>[14]</sup>提供了一种可行思路, 即利用神经元递归运算实现隐层特征对时序变化的记忆. 然而, 随着时间序列长度的增加, 该方法易出现梯度消失或爆炸等问题, 限制了它的推广和应用<sup>[15]</sup>. 幸运的是, 长短时记忆网络 (LSTM)<sup>[16]</sup>、门控循环单元网络 (GRU)<sup>[17]</sup>及其它们的变种<sup>[18-19]</sup>通过融合历史与未来时刻的信息避免了梯

度消失和爆炸问题, 被广泛应用于时序依赖建模. 但是, 这些方法在长时依赖特征提取方面的表现仍然差强人意.

事实上, 随着时间的推移, 电潜泵故障可能会引起一系列连锁反应, 因此, 对电潜泵数据进行长时依赖建模可能会有助于改善故障诊断精度. Transformer 神经网络<sup>[20]</sup>是一种常用的引入注意力建模长时序列的方法, 其摒弃卷积神经网络 (CNN)<sup>[21]</sup>和 RNN 系列<sup>[14-17]</sup>的网络架构, 仅采用全连接层和注意力机制, 在自然语言处理<sup>[22]</sup>、计算机视觉<sup>[23]</sup>等领域取得了不错的表现. 然而, 大多数已有 Transformer 神经网络是对自然语言或二维图像进行处理, 而电潜泵故障数据是多变量时间序列, 因此, 无法直接应用于电潜泵故障诊断任务. 此外, 传统 Transformer 神经网络通常是处理将序列映射为序列的问题, 而电潜泵故障诊断本质上是将序列映射为故障类别的问题, 因此需要对其结构进行调整, 保留其长时依赖特征提取能力的同时, 实现精简高效的电潜泵故障诊断. 最近, 文献 [24] 提出了一种 Gated-Transformer 网络, 结合了双塔结构的 Transformer 分别建模通道和步长维度的相关性; 文献 [25] 通过在 Transformer 架构引入层次多尺度表示学习开发了 FormerTime 模型. 上述两种最新的 Transformer 变体取得了有竞争力的多变量时间序列分类表现, 但是其设计思路相对复杂, 未必适用于电潜泵故障诊断的实际应用需求.

基于上述考虑, 本文提出一种新的多变量时序标记 Transformer 神经网络来实现电潜泵故障诊断, 其主要内容如下.

1) 提出多变量时序标记 Transformer 神经网络来处理电潜泵故障诊断问题, 其沿用传统 Transformer 神经网络的多头注意力和残差连接机制, 有利于捕捉故障相关的长时依赖特征.

2) 区别于大多数 Transformer 神经网络处理自然语言或二维图像数据, 提出新的多变量时间序列标记策略, 用于处理具有多变量、非线性、动态变化等特性的电潜泵数据.

3) 区别于经典 Transformer 神经网络, 采用简单高效的前向神经网络替换解码器来实现故障分类.

4) 在真实海上油田现场收集的电潜泵故障数据上进行故障诊断性能对比实验, 通过与先进的 CNN、LSTM、CNN-LSTM、FormerTime 和 Gated-Transformer 五种深度学习方法在 4 种不同的评价指

标上进行对比,验证所提出方法的有效性和优越性.

### 1 问题描述

数据驱动的电潜泵故障诊断本质上是对多变量时间序列片段样本进行分类识别的问题. 具体而言,其一般包括 3 个步骤:首先是对多变量时间序列片段样本进行预处理得到嵌入表示,然后对嵌入表示进行长时依赖特征提取,最后设计分类器辨识故障类型. 由于电潜泵故障数据是多变量时间序列片段样本,具有多变量、非线性、动态变化等特性,故障信息往往隐含在数据复杂交织的时间和变量维度中,如何从反映电潜泵运行状态的多变量时间序列信号中提取长时依赖特征成为准确诊断电潜泵故障的难点和关键. 本文将针对这一挑战问题进行探索,开发多变量时序标记 Transformer 神经网络来实现更优的电潜泵故障诊断性能.

## 2 基于多变量时序标记 Transformer 神经网络的电潜泵故障诊断方法

如图 1 所示,基于多变量时序标记 Transformer 神经网络的电潜泵故障诊断方法包括 3 部分:多变量时间序列标记、Transformer 特征提取以及故障分类. 其中:多变量时间序列标记模块主要对输入进行预处理,兼顾数据的多变量、非线性和动态变化等特性,将其合理地表示为标记嵌入序列;Transformer 特征提取模块从标记嵌入序列中提取长时依赖特征;故障分类模块则基于长时依赖特征辨识故障类型. 模型整体是一个端到端的神经网络,其学习机制如下:以区分不同故障类型为目标设计交叉熵损失,通过优化损失学习网络模型参数来实现对电潜泵故障的精确辨识. 下文将详细阐述每部分的设计.

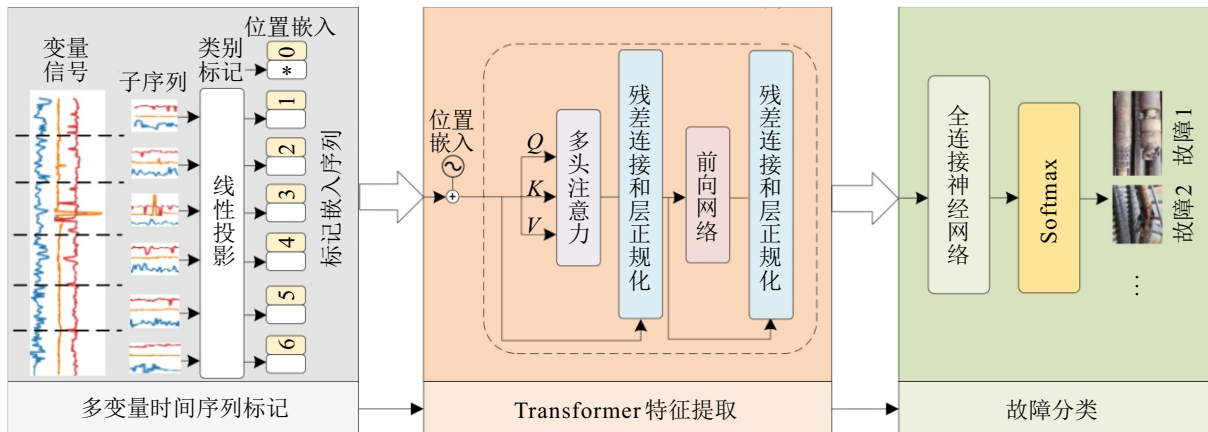


图1 基于多变量时序标记 Transformer 神经网络的电潜泵故障诊断方法框架

### 2.1 多变量时间序列标记

传统 Transformer 神经网络的输入或是 RGB 三通道的二维图像,或是自然语言分词后的文本片段,均无法直接处理表现为多变量时间序列形式的电潜泵故障数据. 因此,提出了适用于处理电潜泵故障数据的多变量时间序列标记方法.

如图 1 中多变量时间序列标记模块所示,每条电潜泵故障数据可表示为一个多变量时间序列片段样本,不同颜色的曲线表示不同变量随时间变化的测量值. 为了提取多变量时序片段样本中时间维度和变量维度反映故障类型的有效信息,便于后续提取长时依赖特征,首先,将多变量时间序列沿着时间维度划分为多个子序列,并利用线性投影层并行学习子序列嵌入特征;然后,引入故障类别标记特征,标记样本的故障类型;最后,融合不同时间步的位置嵌入和子序列嵌入,得到可学习的标记嵌入序列,以便 Transformer 编码器进一步提取长时依赖特征. 值得注意的是,多变量时序标记 Transformer 神经网络

的标记策略处理的多通道信息并非图像中具有空域相关性的多个彩色分量通道的像素信息,也非自然语言中具有上下文关系的多个词嵌入向量,而是融入时空关系的多个子序列嵌入特征. 多变量时间序列标记模块能够有效地将具有多变量、非线性和动态变化等特性的电潜泵故障数据转化为适合 Transformer 特征提取的模型输入,提供适用于电潜泵故障诊断的数据样本表达方式,为后续提取长时依赖特征奠定基础.

具体地,假设多变量时间序列批次数据为  $x \in \mathbb{R}^{b \times p \times l}$ . 其中:  $b$  为批次大小,  $p$  为变量数,  $l$  为时间片段长度. 类似于自然语言处理中的文本分割和计算机视觉中的分块,首先将  $x$  分为多个时间子序列,即

$$x_{\text{seq}} = [x_1, x_2, \dots, x_n] \in \mathbb{R}^{b \times p \times n \times (l/n)}, \quad (1)$$

这里  $n$  为子序列个数. 然后利用一个线性投影层将子序列映射至高维嵌入空间,表示为  $x_{\text{seq}} \cdot W \in \mathbb{R}^{b \times p \times n \times d}$ , 其中  $W \in \mathbb{R}^{(l/n) \times d}$  为一个可学习的权重矩阵. 采用这种方式,可以实现对不同时序片段的特

征提取. 考虑到多变量时序标记 Transformer 神经网络最终要提取全时序特征, 将引入一个可学习的类别标记  $x_0 \in \mathbb{R}^{p \times 1 \times d}$  来聚合所有子序列特征. 这个类别标记  $x_0$  将与子序列  $x_{\text{seq}}$  连起来生成一个标记嵌入序列  $X_{\text{seq}}$ , 有

$$X_{\text{seq}} = [x_0; x_{\text{seq}} \cdot W] \in \mathbb{R}^{b \times p \times (n+1) \times d}. \quad (2)$$

在多变量时序标记 Transformer 编码器从  $X_{\text{seq}}$  提取特征后,  $x_0$  将被连接到所有的子序列特征后用来实现全时序特征提取. 至此, 仅提取了无序的全时序特征嵌入  $X_{\text{seq}}$ , 而现实情况是在发生故障后, 变量会随时间变化而改变, 因此时间步信息也应被考虑. 为此, 引入批次重复的位置嵌入  $P_{\text{seq}} \in \mathbb{R}^{b \times p \times (n+1) \times d}$  来表示  $X_{\text{seq}}$  的对应时间步信息. 由于  $X_{\text{seq}}$  与  $P_{\text{seq}}$  具有相同的维度, 可将两者相加生成标记嵌入序列  $T_{\text{seq}}$ , 即

$$T_{\text{seq}} = X_{\text{seq}} + P_{\text{seq}} \in \mathbb{R}^{b \times p \times (n+1) \times d}. \quad (3)$$

基于上述前向运算, 将得到作为后续 Transformer 编码器输入的标记嵌入序列  $T_{\text{seq}}$ .

## 2.2 Transformer 特征提取

Transformer 特征提取层为整个算法的核心部分, 该层栈式堆叠了多个独立的基础学习模块. 具体地, 每个基础学习模块中包含一个多头注意力机制和一个前向网络, 残差连接和层正规化也被用来改善模型精度和泛化能力.

### 2.2.1 多头注意力机制

多头注意力机制可通过给不同时序片段分配学习到的不同权重, 使得标记嵌入序列  $T_{\text{seq}}$  中每个标记从其他标记中提取有用信息, 这对于建模长时序依赖更加有效. 如图 2 所示, 注意力机制中采用缩放的内积注意力模块来计算特征嵌入的注意力权重, 公式化表示为

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{Q \cdot K^T}{\sqrt{d_k}}\right), \quad (4)$$

$$Q = T_{\text{seq}} W^Q, \quad (5)$$

$$K = T_{\text{seq}} W^K, \quad (6)$$

$$V = T_{\text{seq}} W^V. \quad (7)$$

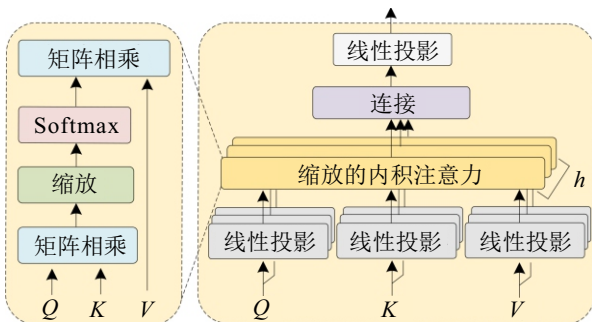


图2 多头注意力机制

其中:  $Q \in \mathbb{R}^{(n+1) \times d_\xi}$ ,  $K \in \mathbb{R}^{(n+1) \times d_\xi}$ ,  $V \in \mathbb{R}^{(n+1) \times d_\xi}$  分别为查询矩阵、关键矩阵和值矩阵, 它们将通过 3 个不同的线性变换  $\{W^Q, W^K, W^V\} \in \mathbb{R}^{d \times d_\xi}$  作用于标记嵌入序列  $T_{\text{seq}}$  来得到. 然而, 式 (4) ~ (7) 中描述的注意力机制仅在一个表示空间强调特征的差异性, 多头注意力机制能够在多个不同的表示子空间不同位置对特征进行加权运算, 因此其特征表达能力更强. 具体地, 将对每个不同的注意力头进行组合, 并采用线性映射来得到多头注意力值, 公式化表示为

$$\text{MH}(Q, K, V) = \text{Concat}(H_1, H_2, \dots, H_h) \cdot W^O, \quad (8)$$

$$H_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V). \quad (9)$$

这里:  $W_i^Q \in \mathbb{R}^{d_\xi \times d_v}$ ,  $W_i^K \in \mathbb{R}^{d_\xi \times d_v}$ ,  $W_i^V \in \mathbb{R}^{d_\xi \times d_v}$  分别为第  $i$  个注意力头中  $Q$ 、 $K$ 、 $V$  的权值矩阵,  $W^O \in \mathbb{R}^{hd_v \times d}$  为多头注意力的权值矩阵,  $\text{Concat}$  表示连接,  $h$  为注意力头数,  $d_v$  为注意力值的维度.

### 2.2.2 前向网络

前向网络用来将多头注意力提取到的特征映射为更加抽象的特征. 具体地, 前向网络包含两个线性变换层和一个非线性激活层. 为了改善网络的收敛能力, 采用高斯误差线性单元 (GeLU) 激活函数取代传统的 ReLU 激活函数, 具体表示为

$$\text{GeLU}(x) = x \cdot \frac{1}{2}(1 + \text{erf}(x/\sqrt{2})). \quad (10)$$

其中:  $x$  为输入,  $\text{erf}(\cdot)$  为高斯误差函数. 区别于 ReLU 激活函数存在大量导数不连续的情况, GeLU 更加平滑. 此外, GeLU 在负值部分有梯度, 避免了 ReLU 存在死区的情况. 另外, Dropout 机制也被引入至前向网络来避免模型过拟合.

### 2.2.3 残差连接和层正规化

在 Transformer 层, 残差连接和层正规化被用于多头注意力机制和前向网络的输出部分. 具体地, 可将多头注意力机制模块和前向网络视作子层 Sublayer, 它们的输出表示为

$$o = \text{LayerNorm}(x + \text{Sublayer}(x)). \quad (11)$$

采用上述方式, 模型精度和泛化能力将得以提升.

综上, 多变量时序标记将通过栈式堆叠的 Transformer 层来实现长时依赖特征提取, 最终用于故障分类.

## 2.3 故障分类

考虑到传统 Transformer 神经网络解码器的输出是对编码器输入的重构, 不适用于电潜泵故障诊断这一下游任务, 而前向神经网络能够更加简单、高

效地实现电潜泵故障分类,因此,设计了基于前向神经网络的故障分类器,其结构包含1个全连接层和1个 softmax 层,用于将由 Transformer 层提取的长时依赖特征转化为独热码.假设  $y^f \in \mathbb{R}^d$  为最后一个 Transformer 层的类别标记特征,每个故障类别  $y^c \in \mathbb{R}^{n_c}$  的概率值将通过下式计算得到:

$$y^c = \text{softmax}(y^f W^c + b^c). \quad (12)$$

其中:  $W^c \in \mathbb{R}^{d \times n_c}$  和  $b^c \in \mathbb{R}^{n_c}$  分别为可学习权值矩阵和偏置向量,  $n_c$  为故障类别个数.基于多变量时间序列所属故障类别的概率值,利用极大似然准则即可实现故障类别的诊断结果.

### 3 电潜泵故障诊断流程

图3为基于多变量时序标记 Transformer 神经网络的电潜泵故障诊断流程,如红色和蓝色箭头标记所示,整个故障诊断流程分为离线训练阶段和在线诊断阶段.

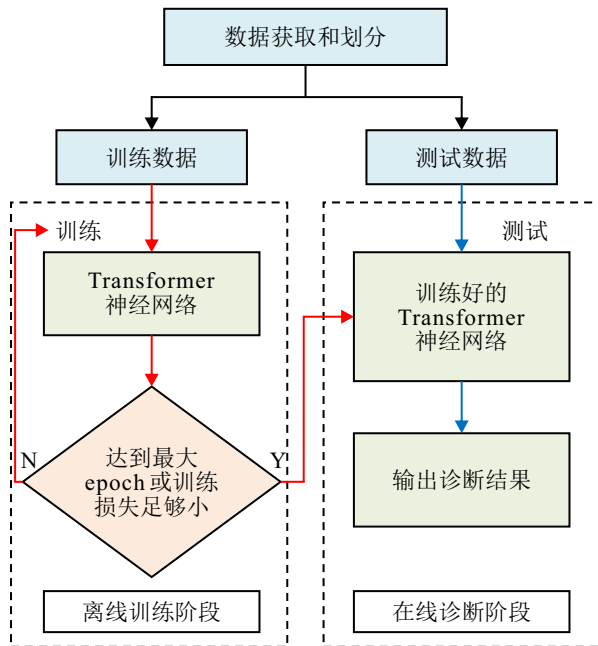


图3 基于多变量时序标记 Transformer 神经网络的电潜泵故障诊断流程

在离线训练阶段:首先,收集历史数据  $\mathcal{D}_{\text{train}} = \{(x_i, y_i)\}_{i=1}^N$ , 其中  $y_i \in \{1, 2, \dots, n_c\}$  为第  $i$  个样本的类别.然后,将数据  $x$  送入多变量时序标记 Transformer 神经网络模型中生成属于故障类别的概率  $y^c$ .接着,采用交叉熵损失训练多变量时序标记 Transformer 神经网络,有

$$\mathcal{L}_{\text{ce}} = -\frac{1}{b} \sum_{i=1}^b \sum_j^{n_c} \mathcal{I}\{y_i = j\} \log(y_i^c(j)). \quad (13)$$

这里:  $\mathcal{I}(\cdot)$  为示性函数,  $y_i^c(j)$  表示第  $i$  个样本属于第  $j$  个故障类别的概率值.最后,通过训练将得到较优

的模型参数,用于实现电潜泵故障诊断.

在在线诊断阶段:来自于测试集  $\mathcal{D}_{\text{test}}$  中的未知故障类别的样本  $x_{\text{test}}$  将被送入训练好的故障诊断模型,通过最大后验概率实现对其故障类别的诊断,即

$$\hat{y}_{\text{test}} = \arg \max_j y_{\text{test}}^c(j). \quad (14)$$

## 4 案例分析:电潜泵故障诊断

### 4.1 数据描述

本文采用中海油某公司某真实油田电潜泵故障数据来验证所提出方法的有效性和优越性.如表1所示,共包含10类常见故障,分别为管柱漏失、流道堵塞、油管堵塞、过载停泵、产液低、稠油、电机故障、电缆击穿、电气故障和反转故障.表2为21种电潜泵数据变量描述.在所提出方法中,采用滑窗操作构造时序片段作为多变量时序标记 Transformer 神经网络的输入数据样本,每种故障类型的数据包含868个时序片段样本,共8680个时序片段样本.此外,随机选取了80%的时序片段样本作为训练集,剩余20%作为测试集.

表1 海上油田电潜泵的故障编号、模式以及发生时间

电潜泵编号	故障类型		发生故障时间
	中文描述	英文描述及其缩写	
XX3	管柱漏失	Leakage of Pipe-column (LP)	2020-11
XXT1	流道堵塞	Channel Blockage (CB)	2019-01
XXST1	油管堵塞	Oil-pipe Blockage (OB)	2019-11
XXH2	过载停泵	Overload Pump-stop (OP)	2020-04
XX7	产液低	Low Liquid-production (LL)	2018-09
XX2	稠油	Heavy Oil (HO)	2018-08
XXST6	电机故障	Motor Fault (MF)	2020-03
XX9ST5	电缆击穿	Cable Breakdown (CB)	2019-01
XX9ST1	电气故障	Electrical Fault (EF)	2017-03
XXST2	反转故障	Reverse Fault (RF)	2017-10

### 4.2 实验设置

为了验证所提出方法的有效性和优越性,将其与5种代表性的深度学习方法,包括CNN、LSTM、CNN-LSTM、FormerTime 和 Gated-Transformer 进行对比实验.值得注意的是,在处理电潜泵多变量时序数据时,不同方法有其各自的特点.CNN采用卷积运算直接对多变量的局部时序数据提取特征,随着网络层数的加深扩张感受野,从而实现长时序特征提取,该方式更适合处理具有空域相关性的图像处理,对长时依赖关系的特征捕捉能力有限;LSTM通过输入门、遗忘门和输出门来控制信息的流动,实现对多变量时序片段间依赖关系的捕捉,相比于CNN, LSTM 更适合处理时序数据,但是,其按照时间步进行推移和记忆的方式学习特征,无法实现对多个时

表2 海上油田电潜泵的21种过程监测变量

变量名称			变量名称		
中文描述	英文描述及其缩写	单位	中文描述	英文描述及其缩写	单位
套管扼流圈流量	Casing Choke (CC)	-	进气温度	Intake Temp (IT)	°C
套管线压力	Casing Line Pres (CLP)	MPa	电机电流	Motor Current (MC)	A
套管压力	Casing Pres (CP)	MPa	电机泄漏电流	Motor Leak Current (MLC)	mA
油管气体流量	Casing Gas Rate (CGR)	m <sup>3</sup> /d	电机功率	Motor Power (MP)	HP
压降	Draw Down (DD)	MPa	电机温度	Motor Temp (MT)	°C
差压	Diff Pres (DP)	MPa	电机扭矩电流	Motor Torque Current (MTC)	A
进口压力	Intake Pres (IP)	MPa	电机振动	Motor Vibration (MVI)	A
排出压力	Discharge Pres (DP)	MPa	电机电压	Motor Voltage (MVO)	V
管线压力	Flow Line Pres (FLP)	MPa	管道节流流量	Tubing Choke (TC)	-
管线温度	Flow Line Temp (FLT)	°C	变频驱动器	VFD Frequency (VDFD)	Hz
管内压力	Flow Tubing Pres (TP)	MPa			

间步的并行化处理,效率较低;CNN-LSTM兼顾了CNN和LSTM的特点,通过CNN提取多变量时间序列局部特征,并利用LSTM捕捉时序依赖关系,但是,其模型设计相对更加复杂;FormerTime和Gated-Transformer均是Transformer为处理多变量时间序列分类所做的变体工作,前者设计层次多尺度表示学习机制提取多变量时序特征,后者则引入双塔结构分别对多变量时间序列的通道和时间维度进行特征提取再门控调整,两种方法均继承了Transformer基于多头注意力机制来捕获多变量时间序列长时依赖关系方面的优势,但是,其为处理多变量时间序列引入了很多额外的模块,增加了模型复杂度;区别于上述方法,所提出方法在沿用Transformer编码器提取特征的基础上,引入了多变量时序标记策略,能够以多个时间步并行化处理方式来提升效率,更适合处理电潜泵多变量时序数据。

在模型结构方面,CNN采用4个卷积模块堆叠的网络实现,具体结构描述如下:Conv(16,3,1,1)-BatchNorm-ReLu-MaxPool(2,2)-Conv(32,3,1,1)-BatchNorm-ReLu-MaxPool(2,2)-Conv(64,3,1,1)-BatchNorm-ReLu-MaxPool(2,2)-Conv(64,3,1,1)-BatchNorm-ReLu-MaxPool(2,2)-Flatten-FC(192,10)。其中:Conv( $a, b, c, d$ )分别表示卷积层包含 $a$ 个输入核大小为 $b$ ,填充数为 $c$ ,步长为 $d$ 的滤波器;BatchNorm为批次归一化;MaxPool( $e, f$ )表示输入核大小为 $e$ ,步长为 $f$ 的最大池化;FC( $g, h$ )为 $g$ 个输入神经元和 $h$ 个输出神经元的全连接层。而LSTM的结构包含了4个LSTM时序分析层和1个全连接层,具体结构如下:LSTM(64)-LSTM(32)-LSTM(16)-LSTM(8)-FC(400,10),这里LSTM( $j$ )表示时序分析层中含有 $j$ 个LSTM隐层单元。CNN-LSTM则包含2个卷积模块和2个LSTM层,其结构描述如下:Conv(16,3,1,1)-BatchNorm-ReLu-MaxPool(2,2)-Conv(32,3,1,1)-

BatchNorm-ReLu-MaxPool(2,2)-LSTM(64)-LSTM(8)-FC(256,10)。FormerTime模型中多头注意力模块的注意力头数、隐层神经元数、全连接层维度和Dropou率分别设置为4、64、32和0.1;Gated-Transformer中多头注意力模块的注意力头数、隐层神经元数、全连接层维度和Dropou率分别设置为4、32、32和0.2;所提出方法中多头注意力模块中的注意力头数、隐层神经元数和Dropout率分别设置为4、256和0.1;多变量时间标记序列中的参数 $b, p, l, n$ 和 $d$ 分别设置为8、21、50、5、32;前向神经网络中的隐层神经元数设置为64,并采用学习率为 $5e-5$ 的Adam优化器优化模型。为了消除随机噪声的影响,进行5次独立重复实验,并用测试结果的平均值评估所提出方法的诊断性能。所有实验基于Pytorch 1.8.0来实现,实验设备为装配GeForce RTX 3060 GPU的笔记本电脑。

本文采用准确率Acc、精度Pre、召回率Rec和 $F_1$ 分数4个指标来综合评估算法性能。具体地,定义TP和TN分别为诊断正确的正样本和负样本数。其中:FP为误报的负样本数,FN为漏报的正样本数。基于上述定义,4个评价指标表示为

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}}, \quad (15)$$

$$\text{Pre} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \quad (16)$$

$$\text{Rec} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (17)$$

$$F_1 = \frac{2(\text{Pre} \times \text{Rec})}{\text{Pre} + \text{Rec}}. \quad (18)$$

### 4.3 结果和分析

不同算法在4种不同评价指标上的对比结果如表3所示。由表3可见,CNN和LSTM的表现略差于CNN-LSTM的综合表现,这表明在CNN特征提

取的基础上融合 LSTM 时序依赖特征提取的效果更好。此外,两种用于处理多变量时间序列分类的 Transformer 变体方法 FormerTime 和 Gated-Transformer 均呈现出优于上述 3 种方法的表现,表明 Transformer 相比于传统深度学习方法 (CNN 和 LSTM 等) 在长时依赖特征提取方面更具优势。更重要的观察是,所提出方法的综合表现优于所有对比方法,表明所提出方法中设计的多变量时序标记策略更适于处理在电潜泵故障诊断任务。

表3 不同方法在 4 种不同评价指标上的对比结果 %

算法	准确率Acc	精度Pre	召回率Rec	F <sub>1</sub> 分数
CNN	98.958	98.983	99.127	99.055
LSTM	98.906	98.929	99.106	99.017
CNN-LSTM	99.219	99.129	99.418	99.273
FormerTime	99.226	99.138	99.424	99.281
Gated-Transformer	99.219	99.273	99.418	99.345
多变量时序标记Transformer	<b>99.479</b>	<b>99.419</b>	<b>99.709</b>	<b>99.564</b>

为了更细致地分析不同方法的电潜泵故障诊断表现,在图 4 中绘制了不同方法的混淆矩阵。其中:行表示样本故障类别的预测值,列表示样本故障类别的真实值。由图 4 可见,大多数诊断失败的情况发生在管柱漏失 LP、产液低 LL 和电气故障 EF 等几种故障,表明这 3 种故障模式相对比较复杂,是较难诊断的故障。多变量时序标记 Transformer 神经网络与其他方法相比在其余故障上的诊断表现更优。此外,考虑到不同方法提取到的数据特征的分布是评估模型泛化表现的重要指标,将不同方法提取到的特征进行了可视化。具体地,采用 t 分布随机近邻嵌入 (t-SNE) 方法<sup>[26]</sup> 对特征进行降维,如图 5 所示。由图 5 可见,相比于其他方法,多变量时序标记 Transformer 神经网络展现了更优的类内紧凑性和类间可分性,进一步验证了所提出方法的优秀特征提取能力和泛化表现。

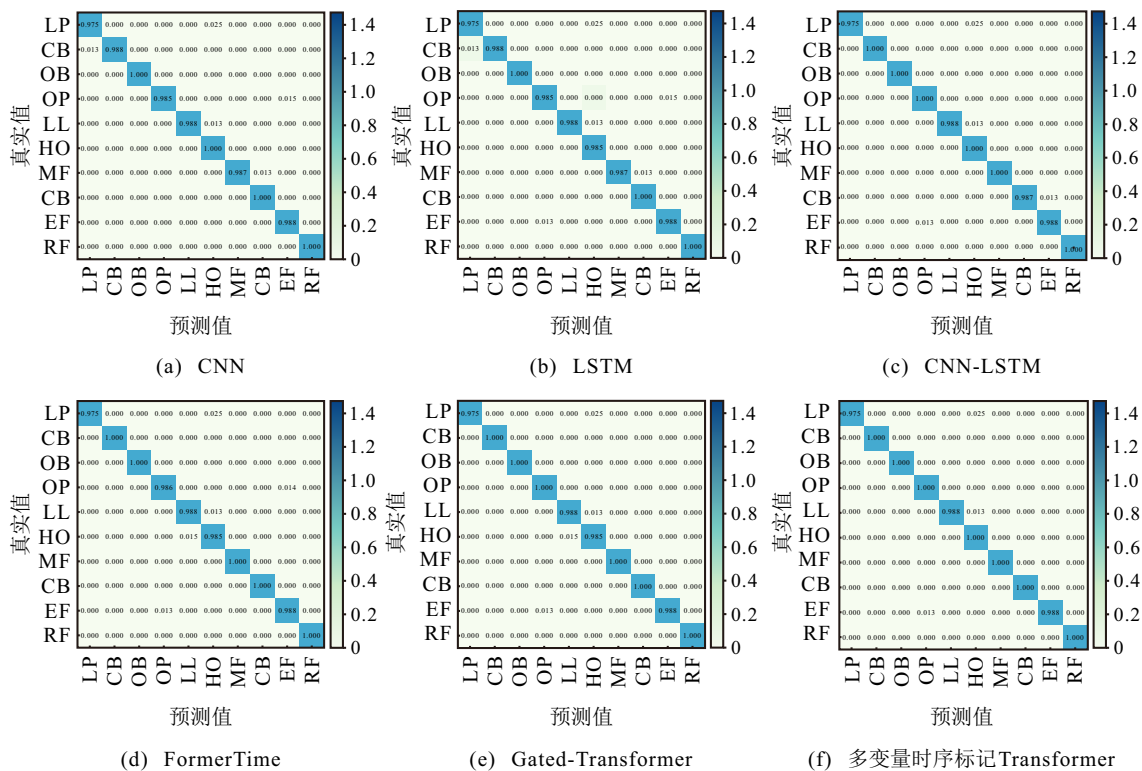


图4 不同方法诊断结果的混淆矩阵

为了评价算法的时间复杂度和程序开销,在表 4 中对比了不同方法的测试时间和模型参数量。由表 4 对比结果可以看出:所提出方法的测试时间最短,每执行一次测试仅需花费约 0.22 s,在实时性上足以满足油田现场电潜泵故障诊断的在线/离线实际应用需求;此外,参数量相较于其他方法少了 1 倍以上,对现场硬件的运算能力要求更低。

表4 不同方法的测试时间和模型参数量

算法	测试时间/s	模型参数量/k
CNN	0.2444	62.506
LSTM	0.3742	42.858
CNN-LSTM	0.3707	27.194
FormerTime	0.3518	27.817
Gated-Transformer	0.3713	46.422
多变量时序标记Transformer	<b>0.2224</b>	<b>12.970</b>

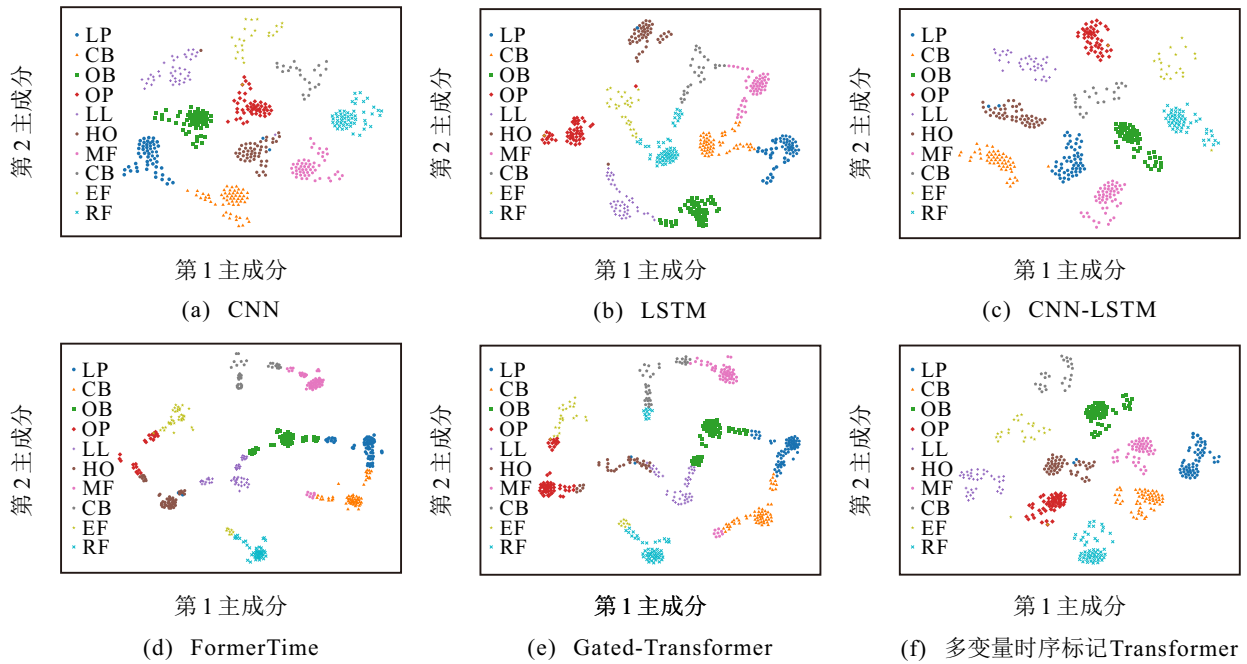


图5 不同方法对应特征的 t-SNE 可视化结果

图6 为不同方法在训练过程中的损失变化情况,并用不同颜色对不同方法的损失变化曲线进行标记。由图6可见,所有损失随着迭代次数的增加呈下降趋势并趋于收敛,验证了所有方法训练的有效性。此外,除 Gated-Transformer,所提出方法相比于其他方法实现了较快收敛,也表明在模型训练收敛速度方面所提出方法更具优势。




图6 不同方法训练过程中的损失变化情况

### 5 结论

本文提出了一种多变量时序标记 Transformer 神经网络,并将其应用于电潜泵故障诊断。区别于已有 Transformer 神经网络模型,多变量时序标记 Transformer 神经网络设计了新的多变量时序标记策略用于处理具有多变量、非线性、动态变化等特性的电潜泵数据,沿用传统 Transformer 神经网络引入多头注意力和残差连接机制,实现了更优的长时依赖特征提取效果,并用前向网络取代了传统 Transformer 神经网络的解码器,实现了模型简化,使其更适于处理电潜泵故障诊断任务。最后,在真实油田现场电潜泵故障数据上验证了所提出方法的有效性和优越性。

### 参考文献 (References)

- [1] 梅思杰, 邵永实, 刘军, 等. 潜水电泵技术[M]. 北京: 石油工业出版社, 2004.  
(Mei S J, Shao Y S, Liu J, et al. Submersible pump technology[M]. Beijing: Petroleum Industry Press, 2004.)
- [2] 刘星, 万泊宏, 李强. 电潜泵采油及其发展趋势研究[J]. 中国石油和化工标准与质量, 2020, 40(1): 108-109.  
(Liu X, Wan B H, Li Q. Study on oil recovery by electric submersible pump and its development trend[J]. China Petroleum and Chemical Standard and Quality, 2020, 40(1): 108-109.)
- [3] Brasil J, Maitelli C, Nascimento J, et al. Diagnosis of operating conditions of the electrical submersible pump via machine learning[J]. *Sensors*, 2022, 23(1): 279.
- [4] 陈治国, 冯定, 朱木秀, 等. 基于模式识别的电流卡片特征提取方法研究[J]. 石油机械, 2004, 32(2): 38-41.  
(Chen Z G, Feng D, Zhu M X, et al. A character pick-up method of current cards based on pattern recognition[J]. China Petroleum Machinery, 2004, 32(2): 38-41.)
- [5] 杜林辉, 丁磊, 田景, 等. 电潜泵井憋压法计算动液面技术及其应用[J]. 石油钻采工艺, 2011, 33(3): 116-118.  
(Du L H, Ding L, Tian J, et al. Pressure-out method to calculate dynamic liquid level in electric submersible pump well and its application[J]. Oil Drilling & Production Technology, 2011, 33(3): 116-118.)
- [6] 卢运娇, 冯定, 余继华, 等. 用故障树分析法研究潜水电机的故障[J]. 机械, 2005, 32(2): 15-17.  
(Lu Y J, Feng D, Yu J H, et al. Study on the fault of submersible motor by fault tree analysis[J]. Machinery, 2005, 32(2): 15-17.)
- [7] 盖蕾. 潜水电泵系统的安全评价[D]. 青岛: 中国石油大学(华东), 2007: 7-13.  
(Gai L. Safety evaluation of electric submersible pump

- system[D]. Qingdao: China University of Petroleum(EastChina), 2007: 7-13.)
- [8] Farokhzad S. Vibration based fault detection of centrifugal pump by fast Fourier transform and adaptive neuro-fuzzy inference system[J]. *Journal of Mechanical Engineering and Technology*, 2013, 1(3): 82-87.
- [9] 张雪松, 檀朝东, 张杰, 等. 基于模糊数学理论的电流卡片识别方法[J]. *中国石油和化工*, 2009(11): 59-61. (Zhang X S, Tan C D, Zang J, et al. Current card recognition method based on fuzzy mathematics theory[J]. *China Petroleum and Chemical Industry*, 2009(11): 59-61.)
- [10] Castellanos M B, Serpa A L, Biazussi J L, et al. Fault identification using a chain of decision trees in an electrical submersible pump operating in a liquid-gas flow[J]. *Journal of Petroleum Science and Engineering*, 2020, 184: 106490.
- [11] Yang P H, Chen J R, Zhang H R, et al. A fault identification method for electric submersible pumps based on DAE-SVM[J]. *Shock and Vibration*, 2022(1): 5868630.
- [12] Li Q, Li K, Gao X Y, et al. Anomaly detection based on temporal attention network with adaptive threshold adjustment for electrical submersible pump[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 3526214.
- [13] Bonella V B, Ribeiro M P, Mello L H S, et al. Deep learning intelligent fault diagnosis of electrical submersible pump based on raw time domain vibration signals[C]. *IEEE the 31st International Symposium on Industrial Electronics*. Anchorage, 2022: 156-163.
- [14] 刘建伟, 宋志妍. 循环神经网络研究综述[J]. *控制与决策*, 2022, 37(11): 2753-2768. (Liu J W, Song Z Y. Overview of recurrent neural networks[J]. *Control and Decision*, 2022, 37(11): 2753-2768.)
- [15] 胡丹, 孟新, 路帅, 等. 一种并行 LSTM-FCN 模型在船舶航迹预测中的应用[J]. *控制与决策*, 2022, 37(8): 1955-1961. (Hu D, Meng X, Lu S, et al. Parallel LSTM-FCN model applied to vessel trajectory prediction[J]. *Control and Decision*, 2022, 37(8): 1955-1961.)
- [16] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [17] Cho K, van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J/OL]. 2014, arXiv: 1406.1078.
- [18] 赵小强, 脱奔奔, 惠永永, 等. 基于 ISTA-LSTM 模型的间歇过程质量预测[J]. *控制与决策*, 2023, 38(11): 3279-3289. (Zhao X Q, Tuo B B, Hui Y Y, et al. Batch process quality prediction based on ISTA-LSTM model[J]. *Control and Decision*, 2023, 38(11): 3279-3289.)
- [19] Dey R, Salem F M. Gate-variants of gated recurrent unit neural networks[C]. *IEEE the 60th International Midwest Symposium on Circuits and Systems*. Boston, 2017: 1597-1600.
- [20] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[J/OL]. 2017, arXiv: 1706.03762.
- [21] Lecun Y, Bengio Y. Convolutional networks for images, speech, and time series[J]. *The Handbook of Brain Theory and Neural Networks*, 1998, 3361(10): 255-258.
- [22] Wolf T, Debut L, Sanh V, et al. Transformers: State-of-the-art natural language processing[C]. *Proceedings of the Conference on Empirical Methods in Natural Language Processing: System Demonstrations*. Stroudsburg, 2020: 38-45.
- [23] 侯志强, 郭凡, 杨晓麟, 等. 基于混合注意力的 Transformer 视觉目标跟踪算法[J]. *控制与决策*, 2024, 39(3): 739-748. (Hou Z Q, Guo F, Yang X L, et al. Transformer visual object tracking algorithm based on mixed attention[J]. *Control and Decision*, 2024, 39(3): 739-748.)
- [24] Liu M H, Ren S Q, Ma S Y, et al. Gated transformer networks for multivariate time series classification[J/OL]. 2021, arXiv: 2103.14438.
- [25] Cheng M Y, Liu Q, Liu Z D, et al. FormerTime: Hierarchical multi-scale representations for multivariate time series classification[C]. *Proceedings of the ACM Web Conference*. Austin, 2023: 1437-1445.
- [26] Van D M L, Hinton G. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9: 2579-2625.

## 作者简介

李康 (1992-), 男, 助理研究员, 博士, 主要研究方向为故障诊断与容错控制, E-mail: kangli@cup.edu.cn;

李爽 (2000-), 男, 硕士生, 主要研究方向为故障诊断与容错控制, E-mail: shuangli\_cup@outlook.com;

高小永 (1985-), 男, 教授, 博士, 主要研究方向为故障诊断、过程控制及调度优化, E-mail: x.gao@cup.edu.cn;

李强 (1995-), 男, 博士生, 主要研究方向为故障诊断与容错控制, E-mail: liqiang.cup@gmail.com;

张来斌 (1961-), 男, 教授, 博士, 主要研究方向为油气安全理论、方法和技术, E-mail: zhanglb@cup.edu.cn.