

# 基于深度残差网络的接转站工艺流程异常工况诊断

张蕊<sup>1,2</sup>, 侯磊<sup>1\*</sup>, 刘珈铨<sup>1</sup>, 孙省身<sup>1</sup>, 张坤<sup>3</sup>, 杜鑫<sup>3</sup>, 李兴涛<sup>4</sup>

1 中国石油大学(北京)机械与储运工程学院, 北京 102249

2 中国石油长庆油田分公司长庆工程设计有限公司, 西安 710021

3 中国石油长庆油田分公司第十二采油厂, 合水 745000

4 中国石油国际勘探开发有限公司, 北京 102249

\* 通信作者, houleicup@126.com

收稿日期: 2021-05-28

中国石油天然气集团有限公司—中国石油大学(北京)战略合作科技专项: “一带一路”海外长输管道完整性关键技术研究与应用(ZLZX2020-05)资助

**摘要** 油气集输站场是油气田地面工程的核心部分。接转站作为集输系统的重要节点, 既有设备集中、运行连续性强的生产特点, 还容易出现来流比例剧烈波动和设备运行故障等工况异常。接转站运行工况的诊断对油气生产系统至关重要, 对于简单设备的异常数据, 站场员工尚能进行初步诊断, 但对整个站场的大量 SCADA 实时监测数据, 仅靠经验和知识难以实现快速分析处理。与油田现有的阈值报警方法相比, 基于数据驱动的诊断方法更加准确智能。在数据驱动的方法中, 深度学习方法能够自动提取数据非线性特征, 善于处理海量高维数据。根据某油田接转站数据采集与监视控制系统(SCADA)数据的多元时间序列特性, 提出一种基于深度残差网络(DRN)的诊断方法, 以接转站 SCADA 系统监测数据为模型输入, 工况类别为模型输出建立诊断模型, 对接转站异常工况进行分类识别。现场数据的噪声会降低模型对少数类样本的识别能力, 通过小波分解对接转站数据进行降噪处理, 减弱设备采集干扰, 增强模型诊断性能; 采用朴素重采样进行数据扩容, 缓解现场数据样本量不足, 模型难以训练问题; 利用正则化方法对大数值权重向量进行惩罚, 避免模型对个别变量的依赖。在此基础上提出 8 种不同 DRN 架构, 确定适用于接转站的最优诊断模型, 通过多元互信息值量化各类样本间的相关程度, 证明诊断结果的有效性。油田现场的实际数据验证表明, 该方法能够用于对接转站工艺流程运行状况进行快速准确的诊断, 诊断准确率达 97.3%, 显著高于支持向量机(93%)、多层感知机(65%)等经典机器学习方法。该诊断方法对其他油气站场的故障诊断和异常识别具有指导意义。

**关键词** 工况诊断; 集输工艺; 接转站; 深度残差网络; 小波降噪

## Abnormal operation condition diagnosis of block station based on deep residual network

ZHANG Rui<sup>1,2</sup>, HOU Lei<sup>1</sup>, LIU Jiaquan<sup>1</sup>, SUN Xingshen<sup>1</sup>, ZHANG Kun<sup>3</sup>, DU Xin<sup>3</sup>, LI Xintao<sup>4</sup>

1 College of Mechanical and Transportation Engineering, China University of Petroleum-Beijing, Beijing 102249, China

2 Changqing Engineering Design Co., Ltd., PCOC, xi'an 710021, China

引用格式: 张蕊, 侯磊, 刘珈铨, 孙省身, 张坤, 杜鑫, 李兴涛. 基于深度残差网络的接转站工艺流程异常工况诊断. 石油科学通报, 2023, 06: 832-844

ZHANG Rui, HOU Lei, LIU Jiaquan, SUN Xingshen, ZHANG Kun, DU Xin, LI Xintao. Abnormal operation condition diagnosis of block station based on deep residual network. Petroleum Science Bulletin, 2023, 05: 832-844. doi: 10.3969/j.issn.2096-1693.2023.06.076

3 PetroChina ChangQing Oilfield Company No.12 Oil Production Plant, Heshui 745000, China

4 China National Oil and Gas Exploration and Development Co., Beijing 102249, China

**Abstract** Oil and gas gathering station is the core part of oilfield ground engineering construction. As the important link of gathering and transportation system, the block station has the production characteristics of centralized equipment and successional production chain, and it is also prone to severe fluctuation of the inflow proportion and equipment operation faults. The diagnosis of the operation condition for block station is crucial to the oil and gas production system, for the abnormal data of simple equipment, the station staff can make a preliminary diagnosis, but for a large number of real-time SCADA monitoring data of the whole station, it is difficult to realize rapid analysis and processing only by experience and knowledge. Compared with the existing threshold alarm method in oil field, data-driven diagnostic approach is more accurate and intelligent. Among the data-driven methods, deep learning method which is good at processing massive high-dimensional data, can automatically extract the nonlinear features of data. Aimed at multiple time series characteristics of data (SCADA) in block station, a fault diagnosis method is proposed by use deep residual network (DRN). In order to identify and classify the abnormal working conditions of block station, a diagnostic model was established by taking 36 monitoring variables of the SCADA system in block station as model input and 5 working conditions as model out. The noise of field data will reduce the ability of the model to identify the working conditions with fewer samples, wavelet decomposition is used to de-noise the data of the block station to reduce the interference of equipment acquisition, enhance model diagnostic performance. Naive resampling is used to enlarge the data capacity to alleviate the difficulty in training the model caused by insufficient sample size of field data. The regularization method is used to punish the weight vector with large values to avoid the dependence of the model on individual variables. On this basis, eight different DRN architectures has proposed to select the optimal diagnostic model for the block station, and the correction between various samples is quantified according to the mutual information method, ensured the validity of the diagnosis results. Verification of real data in field shows that the method can be used quickly and accurately diagnose process status of block station. The average accuracy is 97.3%, which are significantly higher than other machine learning method like support vector machine (93%) and multilayer perceptron (65%). The method has guiding significance for fault diagnosis and anomaly identification of other oil and gas stations.

**Keywords** operation conditions diagnosis; gathering and transportation process; block station; deep residual network; Wavelet Denoising

doi: 10.3969/j.issn.2096-1693.2023.06.076

## 0 引言

接转站作为油气田地面集输系统的关键节点,既有设备集中、运行连续性强的生产特点<sup>[1]</sup>,还容易出现来流比例剧烈波动和设备运行故障等工况异常<sup>[2]</sup>。目前油田生产现场对接转站场的工况诊断主要依靠操作员工经验。对于简单设备的异常数据,操作员工尚能进行初步诊断,但对整个站场的大量SCADA实时监测数据,仅靠经验和知识难以实现快速分析处理<sup>[3]</sup>。阈值报警系统本应及时准确地反馈异常信号<sup>[4]</sup>,但实际应用中其对多模态过程适应性差,“假报警”“不报警”问题突出,亟待发展适用于接转站场的智能诊断方法。

油气处理工艺流程的诊断方法包括基于知识的方法、基于模型的方法及数据驱动方法<sup>[5]</sup>。目前站场应用较多的是基于知识的方法。赵自愿<sup>[6]</sup>利用模糊故障树分析法对原油集输系统关键设备进行异常分析,用CAFTA软件对现场集输流程进行仿真,求取关键设备在一定工作时间内的可靠度。方一字<sup>[7]</sup>采用QRA法对接转站中的压力容器进行风险评价,对接转站系统的危害因素进行有效识别,量化了接转站系统风险等级。

上述基于知识的方法虽能用于对油气站场的异常模式及危害度进行定量分析,但难以在系统输入与输出之间建立精确数学模型。数据驱动方法只需建立具有分类功能的数学模型<sup>[8]</sup>,就能直接对SCADA数据进行处理,以实现站场状态的实时诊断与评估。

在数据驱动方法中,异常工况诊断被视为时间序列数据的分类<sup>[9]</sup>,具体包括统计分析方法、浅层学习方法和深度学习方法。统计分析方法、浅层学习方法均需要丰富的专业领域知识来确定时频域特征<sup>[10]</sup>,在复杂学习任务中的信息表征能力存在局限性<sup>[11]</sup>,不适用于具有非高斯分布、非线性特性的储运站场过程数据。深度学习方法是一种用多个隐含层对特征数据进行逐层非线性转换从而实现数据特征抽象提取的算法<sup>[12]</sup>,适于处理高维海量数据,能够自动提取非线性数据特征,通过组合足够多的变化,理论上可以无限逼近任意复杂函数。

Zhao<sup>[13]</sup>利用基于批归一化(BN)的长短时记忆神经网络(LSTM),自适应学习原始数据的时间动态信息。Xie<sup>[14]</sup>利用阶层深度神经网络(HDNN)对田纳西-伊斯曼过程(TE过程)进行故障诊断。Chao等<sup>[15]</sup>利用改进

的贝叶斯优化和DRN的异常诊断模型,对变电站的异常进行诊断。Jiang<sup>[16]</sup>将堆栈式稀疏自编码器(SSAE)用于故障诊断,实现了半监督学习策略。

从网络架构角度而言,针对其他分类任务设计的高深度模型<sup>[13-16]</sup>直接应用于接转站场数据时,易出现在训练集表现良好但验证集精度降低的过拟合现象。从数据特性角度而言,接转站场收集数据相比公开时间序列数据集,样本量小且维度高,模型存在学习不足,难以训练风险。从训练成本角度而言,高深度且多核的模型在学习过程中耗时长,硬件要求高,训练难度加剧。

深度残差网络(DRN)<sup>[17]</sup>于2015年被首次提出,是一种先进的深度学习模型,它在卷积神经网络(CNN)结构中加入恒等映射快捷连接,解决了深层网络梯度弥散和精度下降的问题,缓解了训练困难,使网络在加深过程中既保证精度,又控制速度<sup>[18]</sup>。

本文以某油田接转站流程为例,将多元时间序列数据(MTS)分类方法<sup>[19]</sup>融入异常诊断体系中,提出一种基于DRN的接转站异常工况诊断方法,能够自动提取异常特征,实现高精度异常诊断,通过油田生产现场SCADA数据对该方法进行有效性验证。

## 1 基于DRN的异常工况诊断方法

### 1.1 卷积层

卷积层的主要作用是从输入数据中提取特征,对一个有 $M$ 个特征映射的作为输入的卷积层,当有 $N$ 个过滤器时,按下式计算第 $K$ 层的输出特征<sup>[20]</sup>:

$$x_j^k = f \left( \sum_{i=1, \dots, M} x_i^{k-1} * g_{ij}^k + l_j^k \right), j=1, \dots, N \quad (1)$$

其中, $g_{ij}^k$ 表示与第 $i$ 个输入连接的第 $j$ 个卷积核, $x_i^{k-1}$ 代

表第 $i$ 个输入, $x_j^k$ 表示第 $j$ 个输出图, $l_j^k$ 表示与第 $j$ 个滤波器的偏置项, $f$ 表示激活函数,\*表示卷积运算。

如图1所示,卷积层的局部感知能够提取监测变量的局部特征,接转站过程数据中不同时间点,不同变量间的相同变化特性能够被卷积的权值共享模式捕获<sup>[21]</sup>。

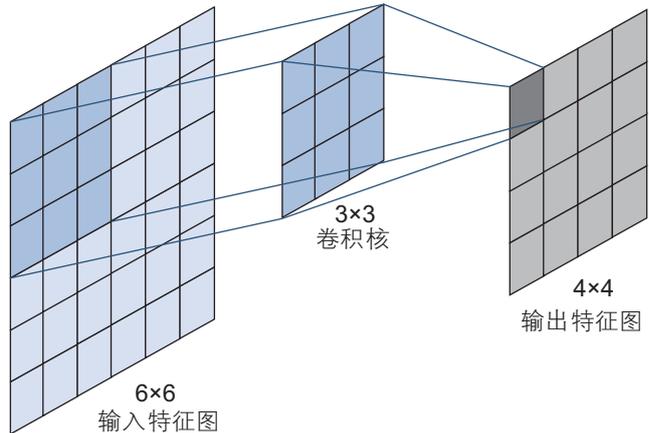


图1 卷积核示意图

Fig. 1 diagram of convolution kernel

### 1.2 激活层

激活层通过对加权输入进行非线性组合以产生非线性决策边界,非线性变换能够使网络存储信息量大大增加<sup>[20]</sup>。如图2所示,常见激活函数包括逻辑函数(Sigmoid)、双曲正切函数(tanh)、线性校正单元(ReLU)等。

Sigmoid型函数定义见下式,它是两端饱和的S型曲线函数。

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (2)$$

Sigmoid型激活函数的优点是神经元输出可以直

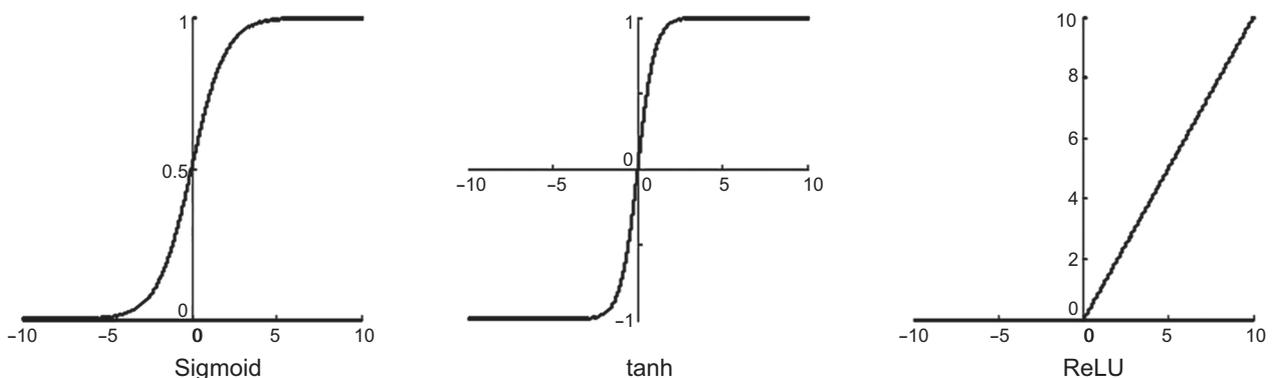


图2 激活函数示意图

Fig. 2 Schematic diagram of activation function

接看作概率分布,神经网络可以更好地和统计学习模型相结合,并且它将不同尺度的特征挤压到一个受限空间<sup>[20]</sup>,适应于特征相差较复杂的场景,本文采用 Sigmoid 作为激活函数。

### 1.3 残差连接

残差连接是 DRN 的核心部分。残差结构如图 3 所示, DRN 在卷积神经网络 (CNN) 的基础上通过卷积层之间的残差连接实现多层网络的直接输出,避免了卷积神经网络的梯度消失问题。

假设多个残差块堆叠,则从第  $i$  个残差块到第  $j$  个残差块的信息向前传递如下式<sup>[17]</sup>:

$$x_j^{out} = x_i^{in} + \sum_{k=i}^j F(x_k^{in}, \{W_k\}) \quad (3)$$

式中,  $x_k^{in}$ 、 $x_k^{out}$  分别表示第  $k$  个残差块的输入和输出,  $W_k$  表示第  $k$  个残差块中的权重,  $F$  为残差映射。

在误差反向传播过程中,网络优化的梯度见下式<sup>[18]</sup>:

$$\begin{aligned} \frac{\partial L}{\partial x_i^{in}} &= \frac{\partial L}{\partial x_j^{out}} \frac{\partial x_j^{out}}{\partial x_i^{in}} \\ &= \frac{\partial L}{\partial x_j^{out}} \left[ 1 + \frac{\partial}{\partial x_i^{in}} \sum_{k=i}^j F(x_k^{in}, \{W_k\}) \right] \end{aligned} \quad (4)$$

式中,  $L$  为损失函数,  $\partial L / \partial x_j^{out}$  项保证了底层网络都能接收到这个梯度,缓解训练困难问题。

### 1.4 全局平均池化层

GAP 层 (Global Average Pooling) 对最后一层卷积

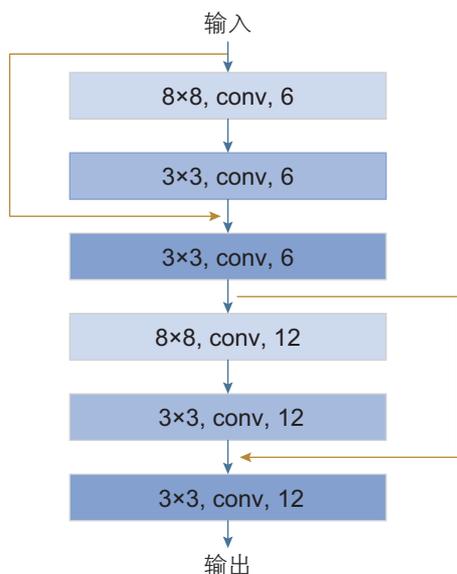


图 3 残差结构示意图

Fig. 3 Diagram of residual structure

的特征图进行平均池化操作。如图 4, 当有  $K$  个特征图时,池化结果为  $K$  个  $1 \times 1$  的特征图,这些特征图直接输入 Softmax 层后产生  $K$  个类别的置信度,起到取代传统全连接层的效果<sup>[22]</sup>。

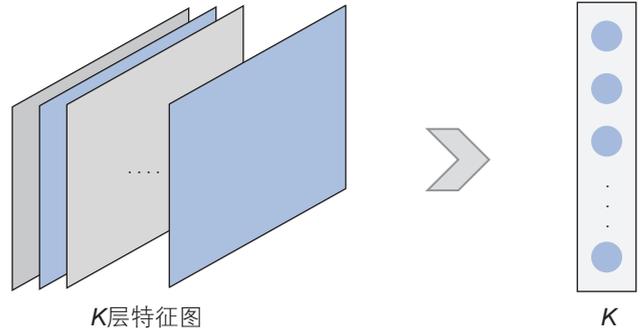


图 4 GAP 示意图

Fig. 4 Schematic diagram of GAP

全局平均池化层能够简化模型训练参数,避免传统全连接层过拟合风险,提高模型泛化能力。

### 1.5 批量归一化层

批量归一化 (BN) 层对模型上一层进行归一化操作,通过特征映射将输出数据转化为具有相同尺度的标准正态分布,保证样本特征在同一量纲范围,缓解模型内部协方差偏移问题<sup>[20]</sup>,可表示为

$$a^{(l)} = f(BN(z^{(l)})) = f(BN_{\gamma, \beta}(Wa^{(l-1)})) \quad (5)$$

$$BN(z^{(l)}) = \frac{z^{(l)} - E[z^{(l)}]}{\sqrt{\text{var}(z^{(l)}) + \epsilon}} \quad (6)$$

式中,第  $l$  层的经过 BN 操作后的输入为  $BN(z^{(l)})$ ,  $a^{(l)}$  为神经元的输出,  $f()$  为激活函数。  $BN(z^{(l)})$  为净输入  $z^{(l)}$  的标准正态分布。

## 2 接转站工艺流程数据集

### 2.1 接转站工艺流程

某油田接转站位于甘肃区块,于 2015 年建成投运,设计年处理原油  $20 \times 10^4$  t。主要功能包括原油加热、油气分离、原油脱水、净化油外输、污水处理及回注等。接转站接收上游 5 个输油点来流,来流通过加热炉加热后分别进入溢流沉降罐和三相分离器进行分离。分离油经加压、加热达到外输压力温度要求,过滤计量后输往下站。沉降罐和三相分离器的分离水输往水处理模块。各设备分离出的气体与井场采出气经过气液分离后作为燃料输往加热炉,剩余气体通过火炬燃烧。

## 2.2 数据集

由接转站自动化监控终端采集原始参数，调取2020年7月至10月的2001组数据，整套流程共采集到36个参数，采集间隔1h。去除采集异常后形成有5种工况的36×1800组数据。所有工况如表1所示。

接转站流程的36个监测变量如表2所示。

## 3 基于DRN的接转站工艺流程异常工况诊断

基于深度残差网络的接转站流程异常工况诊断流程如图5所示，具体步骤如下：

(1) 数据降噪：对原始数据进行逐维离散小波降噪。

(2) 入模前处理：重采样扩容数据集形成时间序列

表1 接转站流程工况列表

Table 1 List of operation conditions for block process

标号	工况类型	变化类型	数据大小/组
1	正常工况	—	1308
2	溢流沉降罐液位超出极限值	突变	39
3	1号三相水室液位超低	突变	126
4	2号输油点来油异常	阶跃变化	389
5	2号三相分离器故障	突变	128

表2 接转站流程监测参数

Table 2 Block station process monitoring parameters

序号	参数	序号	参数
1	1号输油点来油瞬时流量/(m <sup>3</sup> /h)	19	含水分析仪温度/°C
2	溢流沉降罐液位/m	20	外输瞬时流量/(m <sup>3</sup> /h)
3	缓冲罐液位/m	21	外输温度/°C
4	溢流沉降罐油温度/°C	22	外输压力/MPa
5	压缩机二排压力/MPa	23	总机关来油温度/°C
6	压缩机进气压力/MPa	24	总机关收油桶压力/MPa
7	压缩机润滑油压力/MPa	25	2号来油瞬时流量/(m <sup>3</sup> /h)
8	1号三相分离器压力/MPa	26	2号来油温度/°C
9	1号三相水室液位/m	27	2号来油压力/MPa
10	1号三相油室液位/m	28	3号来油瞬时流量/(m <sup>3</sup> /h)
11	1号输油泵出口压力/MPa	29	3号来油温/°C
12	1号输油泵进口压力/MPa	30	3号来油压力/MPa
13	2号三相油室液位/m	31	4号来油瞬时流量/(m <sup>3</sup> /h)
14	2号输油泵出口压力/MPa	32	4号来油温度/°C
15	2号输油泵进口压力/MPa	33	5号来油瞬时流量/(m <sup>3</sup> /h)
16	2号三相分离器压力/MPa	34	5号来油温度/°C
17	2号三相水室液位/m	35	5号来油压力/MPa
18	含水分析仪含水/%	36	外输点接收瞬时流量/(m <sup>3</sup> /h)

样本，通过正则化手段均衡数据分布，划分训练集和验证集。

(3) 入模诊断：建立基于DRN的接转站流程诊断模型，根据诊断评价指标进行模型优化，得出最优模型。

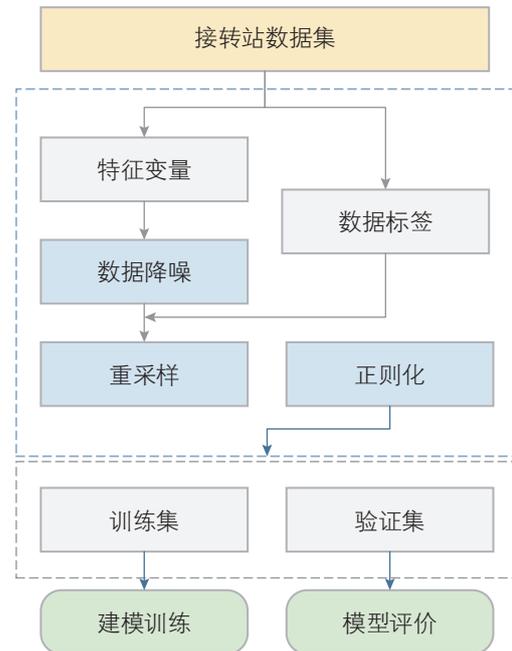


图5 接转站异常工况诊断流程

Fig. 5 Abnormal operation condition diagnosis process of block station

### 3.1 数据降噪

由于现场信号采集器性能不稳定或工况波动, SCADA数据往往存在强噪声。数据噪声会掩盖监测变量的真实波动, 降低模型对少数类样本的识别能力, 模型存在同时学习噪声和少数类的风险<sup>[23]</sup>。由此, 需要对数据进行降噪处理, 减弱采集干扰, 增强模型诊断性能。

常用去噪方法有高斯滤波、中值滤波、傅里叶变换等, 但它们不能区分有效信号的高频部分和噪声引起的高频干扰。小波变换的时频局部化特性能够保留信号尖峰和信号突变, 将高频信息和高频噪声区分开来

并抑制高频噪声的干扰<sup>[24]</sup>, 适于转油流程的数据降噪。

小波变换的时频局部化特性可以线性表示如下式<sup>[25]</sup>:

$$W_x = W_f + W_e \quad (7)$$

$W_x$ 表示含噪混合信号,  $W_f$ 代表纯净信号,  $W_e$ 表示噪声信号。

采用一维小波离散去噪(DTW1), 得到细节分量(高频)与近似分量(低频), 对细节分量进行阈值处理, 用处理后的各分量进行小波重构, 得到去噪后的信号。降噪处理前后数据变化如图6所示。

图7表示同一网络架构下数据降噪对诊断准确率

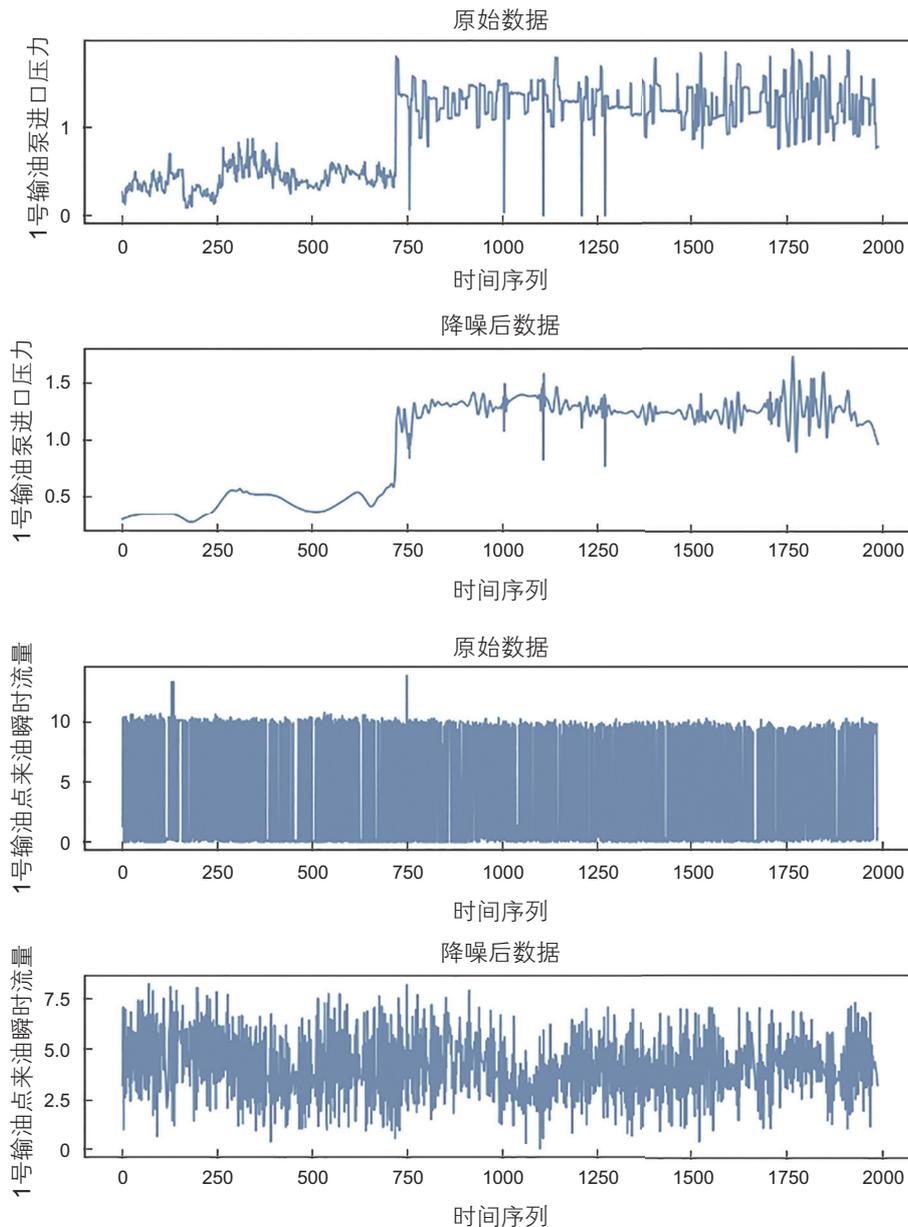


图6 降噪处理前后数据

Fig. 6 Data before and after noise reduction

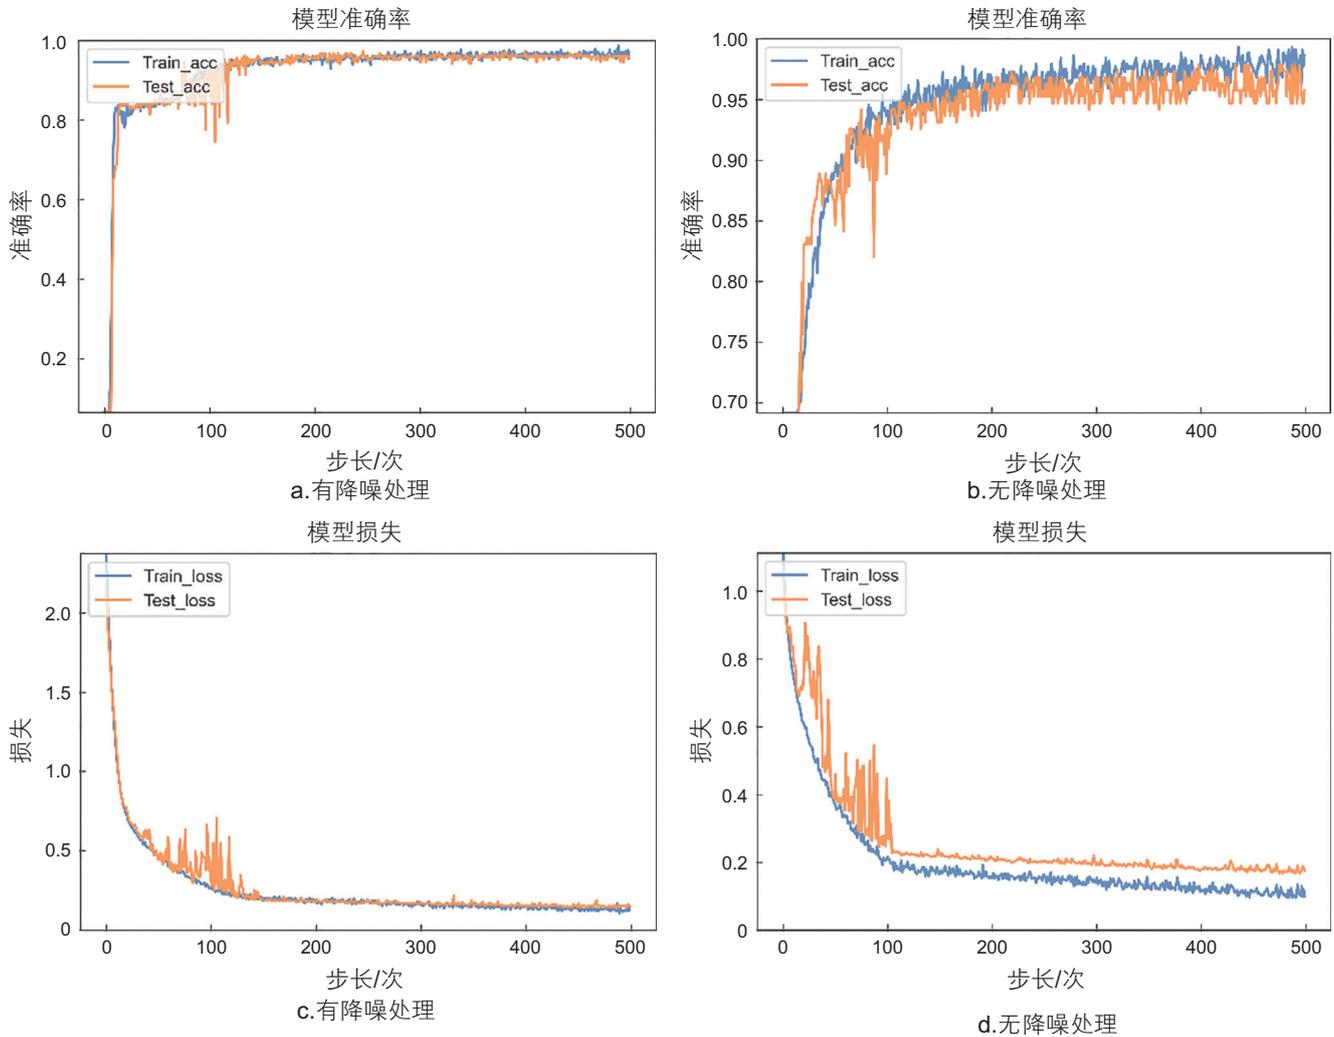


图7 降噪对模型准确率、损失的影响

Fig. 7 Influence of noise reduction on model accuracy and loss

和模型损失的影响。未降噪数据在训练时,随着叠代次数增加,噪声特征被模型学习并不断扩大,模型准确率出现剧烈扰动,并出现过拟合现象。数据降噪后模型准确率提升2.1%,损失下降0.03,过拟合得到纠正,稳定性大幅提升。

### 3.2 重采样与正则化

接转站工艺流程的数据采集间隔为1小时,设定1个样本包含10个数据点,共形成180个样本。但样本量少易导致模型训练不足,由此本研究采用朴素重采样方法,朴素重采样以一定的采样间隔在时间序列上移动,读取数据形成多个样本。采样间隔越小则样本相似度越高,模型越容易出现过拟合现象;采样间隔越大则样本扩容幅度越小,对模型训练能力提升有限。经实验确定最佳采样间隔为3个时间点,最终形成大小为 $10 \times 36$ 的630个样本,如图8所示。

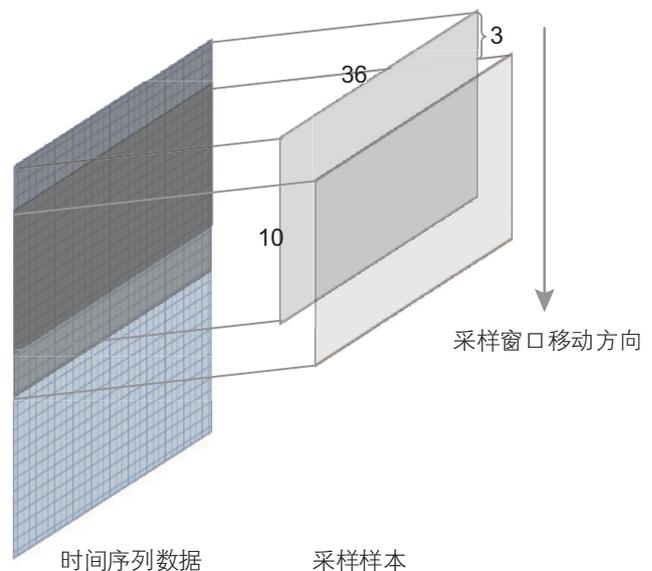


图8 朴素重采样原理

Fig. 8 The principle of naive resampling

L2 正则化通过对大数值的权重向量进行惩罚,使模型倾向于使用所有输入特征,而不是依赖输入特征中的小部分特征<sup>[20]</sup>。L2 正则化可表示为:

$$\theta^* = \operatorname{argmin}_{\theta} \frac{1}{N} \sum_{n=1}^N L(y^{(n)}, f(x^{(n)}; \theta)) + \lambda L2(\theta) \quad (8)$$

其中L()为损失函数, N为训练样本数量, f()为待学习的神经网络,  $\theta$ 为参数,  $e_2$ 为L2范数函数,  $\lambda$ 为正则化系数。

如图9所示,对转油流程数据集,36维数据单位、幅值均不一致,L2正则化通过权重惩罚,能够有效均衡数据分布,避免模型对个别维度的依赖,增强模型特征利用率,提高模型泛化能力,降低过拟合风险。

重采样与正则化后以7:3的比例将数据集划分为

训练集和验证集,训练集用于模型学习,验证集用于验证模型诊断性能。训练集、验证集样本数分别为441、189。

### 3.3 DRN 诊断模型

为探索适宜接转站流程特点的诊断模型,设计8种DRN模型架构,见表3,调整参数包括卷积层层数、卷积核数量、激活函数类型、分类层类型,以训练集数据对模型进行训练。

以模型4为例进行说明。1个样本矩阵的输入大小为10×36,其中“10”代表样本时间长度,即系统运行10h进行1次诊断;“36”表示过程变量的数量,对应为转油流程的36个监测变量。模型4的网络架构为2个残差块,1个全局平均池化层和1个全

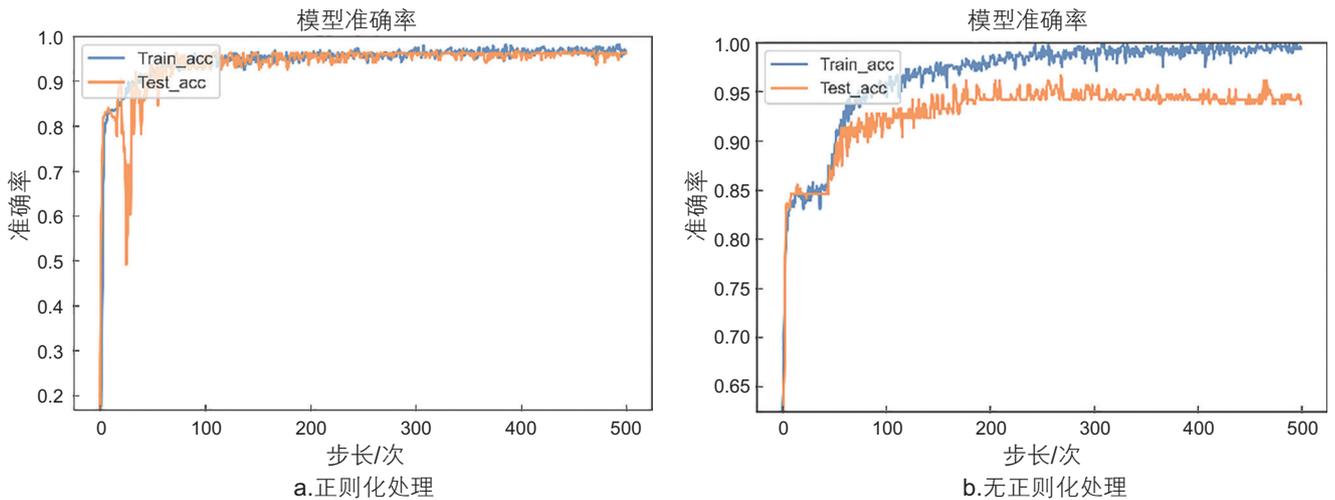


图9 正则化对模型准确率的影响  
Fig. 9 Influence of regularization on model accuracy

表3 DRN 诊断模型  
Table 3 DRN diagnosed model

layer	Model-1	Model-2	Model-3	Model-4	Model-5	Model-6	Model-7	Model-8
	8×8, 6	8×8, 6	3×3, 6	8×8, 6	8×8, 6	3×3, 32	8×8, 6	3×3, 6
conv1d_1	5×5, 6	—	3×3, 6	3×3, 6	3×3, 6	3×3, 32	3×3, 6	3×3, 6
	3×3, 6	3×3, 6	3×3, 6	3×3, 6	3×3, 6	3×3, 32	3×3, 6	3×3, 6
conv1d_2	—	8×8, 12	3×3, 12	8×8, 12	8×8, 12	3×3, 64	8×8, 12	3×3, 12
	—	—	3×3, 12	3×3, 12	3×3, 12	3×3, 64	3×3, 12	3×3, 12
	—	3×3, 12	3×3, 12	3×3, 12	3×3, 12	3×3, 64	3×3, 12	3×3, 12
conv1d_3	—	—	—	—	—	—	8×8, 12	3×3, 24
	—	—	—	—	—	—	3×3, 12	3×3, 24
	—	—	—	—	—	—	3×3, 12	3×3, 24
dense	Global average pool							
	Softmax							
activation	Relu	sigmoid	sigmoid	sigmoid	Relu	Relu	sigmoid	Relu

连接层, 每个残差块包含 3 个卷积层, 3 个标准化层和 1 个残差连接结构。残差块中的卷积层卷积核大小分别为  $8 \times 8$ ,  $3 \times 3$ ,  $3 \times 3$ , 步幅设为 1; 第 1 个残差块中的卷积层包含 6 个过滤器, 第 2 个包含 12 个过滤器。通过全局平均池化层输出大小为  $1 \times 12$  的样本, 使用“Softmax”的全连接层将输出转化为  $1 \times 5$  向量。

Softmax 函数即归一化指数函数, 能将任意  $K$  维向量  $Z$  转换为 0 至 1 范围内的实数,  $K$  维向量  $\sigma(Z)$  总和为 1<sup>[21]</sup>, Softmax 函数定义见下式。

$$\sigma(Z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}, j=1, 2, \dots, K \quad (9)$$

Softmax 函数使模型输出一个长度为 5 的向量, 每个值代表对应类别的可能性, 其中可能性最高的值即为诊断结果。

### 3.4 诊断结果分析

完成 DRN 模型构建后, 在以下开发环境中实现诊断过程: Windows10 操作系统, 软件平台 Python 3.6。硬件开发环境为: PC 机一台, Intel(R)Core(TM)I7-6700HQ-CPU-2.60GHz, 8G 的 DDR3 内存、英伟达 NVIDIA-GeForce-GTX-960M 显卡。

用准确率 (ACC)、精确率 (PRE) 和敏感性 (TPR) 3

表 4 工况的混淆矩阵

Table 4 Confusion matrix of working conditions

Confusion matrix	Diagnosed Sick	Diagnosed Healthy
Sick	True positive (TP)	False negative (FN)
Healthy	False positive (FP)	True negative (TN)

表 6 模型 4 完整架构参数 (输入大小为一个样本矩阵)

Table 6 Model 4 complete architecture parameters (input size is a sample matrix)

编号	网络层	卷积核大小	滤波器数目	输出大小	零补	BN 层
1	input	—	—	$10 \times 36$	—	—
2	conv1d	$8 \times 8$	6	$10 \times 6$	是	是
3	conv1d	$3 \times 3$	6	$10 \times 6$	是	是
4	conv1d	$3 \times 3$	6	$10 \times 6$	是	是
5	residual	$1 \times 1$	6	$10 \times 6$	是	是
6	conv1d	$8 \times 8$	6	$10 \times 12$	是	是
7	conv1d	$3 \times 3$	6	$10 \times 12$	是	是
8	conv1d	$3 \times 3$	6	$10 \times 12$	是	是
9	residual	$1 \times 1$	6	$10 \times 6$	是	是
10	GAP	—	1	$1 \times 12$	—	—
11	dense	5	1	$1 \times 5$	—	—

个指标来评价模型诊断性能。表 4 为定义的总体工况混淆矩阵。

准确率 (ACC) 评估模型的全局准确程度; 精确率 (PPV) 表示模型对异常数据识别的准确程度; 敏感性 (TPR) 表示模型对异常数据的敏感程度, 敏感性越高, 漏诊概率越低。ACC、PPV 和 TPR 可定义为:

$$ACC = \frac{TP + TN}{ALL} \quad (10)$$

$$PPV = \frac{TP}{TP + FP} \quad (11)$$

$$TPR = \frac{TP}{TP + FN} \quad (12)$$

每次诊断导入一个样本矩阵, 每个样本矩阵包含从时刻  $t-1$  到时刻  $t$  的 36 个变量的时间序列数据, 以诊断  $t$  时刻的转油流程的运行状态。

表 5 中列出了表 4 中各模型的验证集总准确率、敏感性和精确率。模型 4 具有最高的验证集总准确率和敏感性, 为最佳模型。模型 4 的完整网络参数如表 6 所示, 网络结构如图 10 所示。

表 5 测试集诊断结果

Table 5 Diagnostic result on testing set

编号	ACC	PRE	TPR	迭代次数
1	91.53	73.26	67.07	132.27
2	93.65	72.98	73.23	196.50
3	94.17	92.56	92.03	198.10
4	97.35	95.29	96.46	197.59
5	95.23	92.46	94.46	219.15
6	94.70	92.86	90.15	200.04
7	96.29	95.38	93.38	263.65
8	94.70	94.95	88.76	276.36

图 11 为模型 4 训练和验证阶段的准确率曲线及损失曲线。在 441 个训练样本矩阵中，训练数据集的准确率为 97.50%，模型损失为 0.113。对于包含 189 个样本矩阵的验证数据集，模型准确率为 97.35%，模型损失为 0.139。

所有 5 类工况的诊断结果混淆矩阵如图 12 所示。5 类工况分别取得了 99.2%、100%、85.7%、100%、92.3% 的精确率。其中，第 3 类工况的诊断精度最低，在 14 个测试样本中 2 个样本被划分为第 1 类工况；第 5 类工况的 13 个测试样本中 1 个样本被划分为第 1 类工况。

### 3.5 工况相关性分析

多元互信息值可以反映两个矩阵之间共享信息量的大小，定义如下<sup>[26]</sup>：

$$I(X;Y) = \frac{1}{2} \left[ \log(|\Sigma|) - \sum_{y=1}^k P(y) \log(|\Sigma_y|) \right] \quad (13)$$

其中， $Y$  是有  $k$  个可能值的多项式随机变量， $P(y)$  是它对应值的概率分布， $X$  是一个多元随机变量。在  $Y=y$  条件下， $X$  遵循参数为  $\mu_y$  和  $\Sigma_c$  的多元正态密度分布。

为量化接转站各工况间的相关性大小<sup>[27]</sup>，计算工况间的多元互信息值，如图 13 所示。工况 1 与工况 3

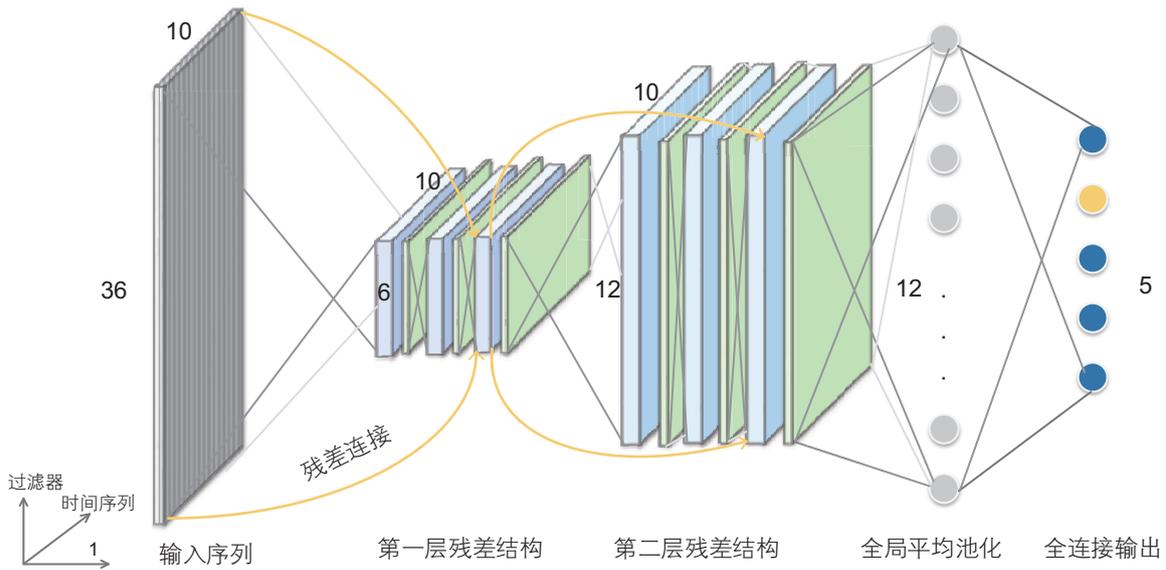


图 10 模型 4 结构示意图

Fig. 10 Model 4 structure diagram

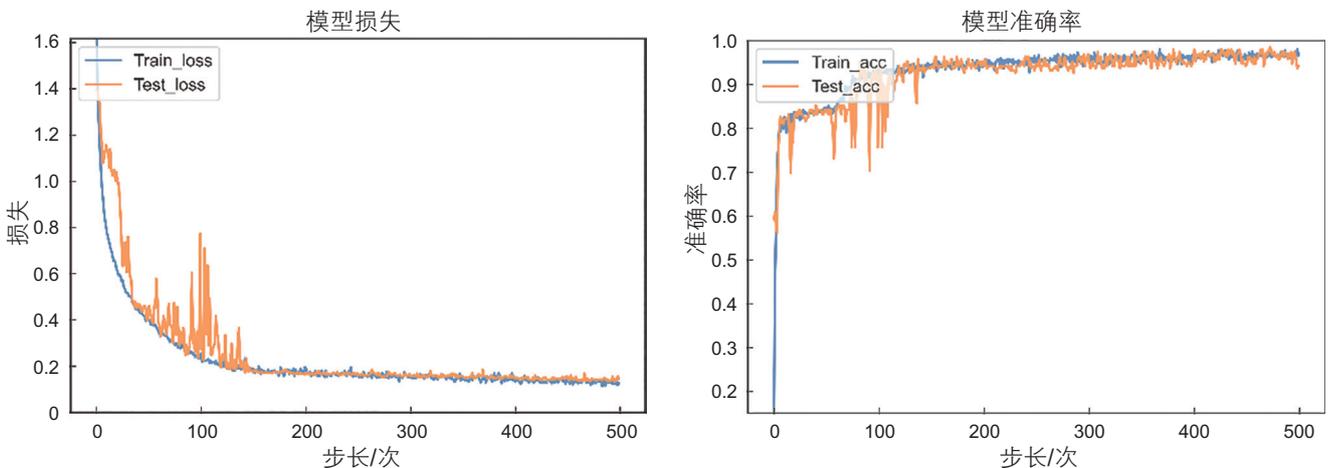


图 11 模型损失和准确率图

Fig. 11 Model loss and accuracy diagrams

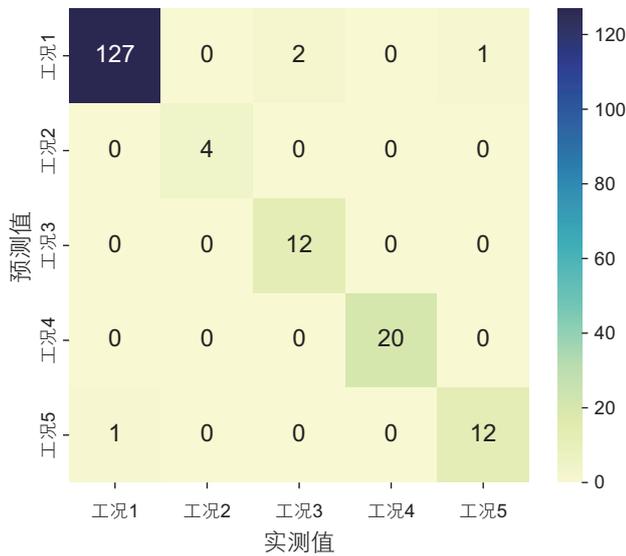


图 12 验证集诊断结果混淆矩阵图

Fig. 12 confusion matrix of test diagnostic result

及工况 5 的相关程度最低, 证明其在网络诊断过程中最易发生误诊。工况 2 与其他工况间的相关程度最高, 证明其在网络诊断过程中最易于识别, 这验证了上述 DRN 的诊断结果。同时, 模型对样本量最少的工况 2 达到了 100% 的准确率, 证明本模型有效避免了各类样本的不均衡性限制。

### 3.6 与其他模型的对比

为验证所提出模型在接转站的应用优势, 分别采用支持向量机(SVC)、卷积神经网络(CNN)、全卷积神经网络(FCN)、多层感知机(MLP)与残差神经网络(DRN)进行比较。最终诊断结果为各模型参数调整后的最优结果, 诊断结果见表 7。

与浅层模型SVC及MLP相比, 所提出的DRN模型的总精确率有显著提升, 表明模型能够有效学习小

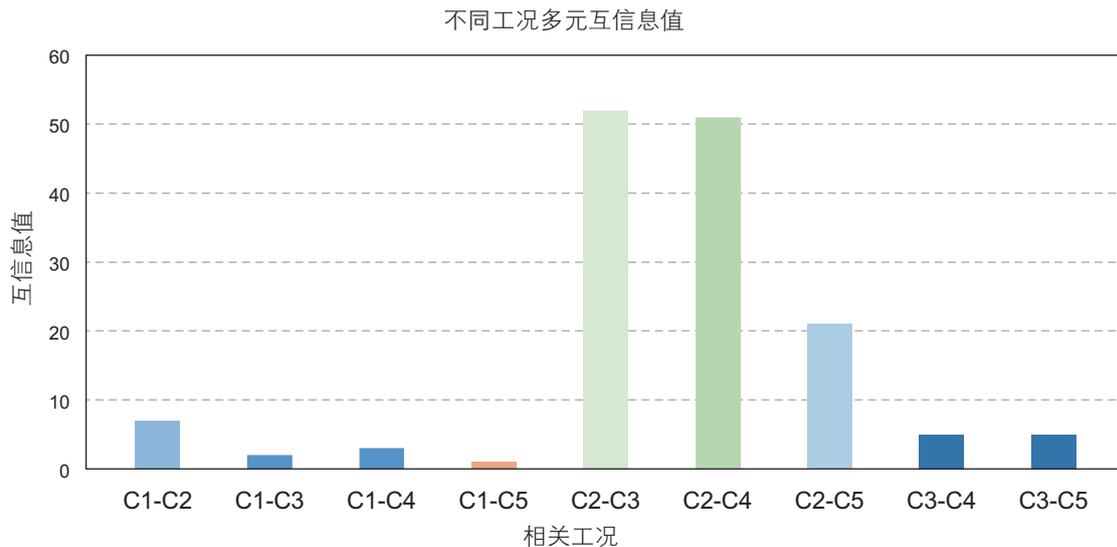


图 13 各工况间的多元互信息值

Fig. 13 Mutual information values among different conditions of samples

表 7 机器学习算法诊断结果对比

Table 7 Comparison of diagnostic results of machine learning algorithms

precision	DRN		SVC		CNN		FCN		MLP	
	train	test								
1	0.98	0.97	0.96	0.95	0.94	0.91	0.98	0.93	0.66	0.66
2	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	0.00	0.00
3	0.92	0.85	1.00	1.00	1.00	0.92	1.00	0.85	0.00	0.00
4	1.00	1.00	0.93	0.96	1.00	0.96	0.99	0.81	0.00	0.00
5	0.93	0.92	0.95	0.81	0.83	0.64	0.98	0.92	0.00	0.00
total	0.97	0.97	0.95	0.93	0.94	0.80	0.99	0.90	0.65	0.65

样本工况的特征；与深度模型CNN及FCN相比，所提出的DRN模型在测试集中未出现过拟合现象，表明模型泛化能力较强。

## 4 结论

(1)针对接转站数据噪声强、干扰大、数据量小的问题，采用小波方法进行降噪，根据重采样方法进行样本扩容，通过正则化手段均衡各维数据分布，有效提升了模型准确率和泛化能力。

(2)提出8种不同的DRN架构，以测试集ACC、

PRE与TPR作为评价指标，确定适用于接转站流程的最佳DRN诊断模型，实现对异常工况97.35%的诊断精度，证明了诊断模型的准确性。

(3)通过基于多元互信息值的相关性分析方法，量化5类样本间的相关程度，表明互信息值的大小能够反映诊断难易程度，证明了诊断结果的可靠性。

(4)与经典机器学习模型SVC、CNN、FCN及MLP对比，DRN模型精确率分别提升4%、17%、10%、32%，表明模型能够对小样本工况的特征进行有效学习，诊断模型的泛化性显著提升，该方法对其他油气站场的异常诊断具有一定意义。

## 参考文献

- [1] 刘正伟, 蒋燕, 史传坤, 闫胜奎. 陆上油田油气集输站场安全现状评价探讨[J]. 中国安全生产科学技术, 2009, 5(02): 169-173. [LIU Z W, JIANG Y, SHI C K, et al. Study on safty assessment in operation of oil and gas gathering and transportation station in onshore oil and gas field[J]. Journal of Safety Science and Technology, 2009, 5(02): 169-173.]
- [2] ANDOW P K. Fault detection and diagnosis in chemical and petrochemical processes[M], Elsevier Scientific Publishing, 1978.
- [3] 柴天佑. 工业人工智能发展方向[J]. 自动化学报, 2020, 46(10): 2005-2012. [CHAI T Y. Development directions of industrial artificial intelligence[J]. Acta Automatica Sinica, 2020, 46(10): 2005-2012.]
- [4] 朱益飞. 联合站生产动态监视及预警系统[J]. 工业计量, 2002(03): 23-25. [ZHU Y F. System of production dynamic monitoring and early warning in joint station[J]. Measurement & Control System, 2002(03): 23-25.]
- [5] VENKATASUBRAMANIAN V K, RENGASWAMY R, YIN K W, et al. A review of process fault detection and diagnosis: Part I: Quantitative model-based methods[J], Computers & Chemical Engineering, 2003, 27(3): 293-311.
- [6] 赵自愿. 原油集输系统故障诊断方法与技术研究[D]. 西安石油大学, 2013. [ZHAO Z Y. Research on fault diagnosis method and technology based on gathering and transportation of crude oil[D]. Xi'an Shiyu University.2013]
- [7] 方一宇. 基于QRA的某转油站系统风险评价及控制研究[D]. 重庆科技学院, 2017. [FANG Y Y. Research on risk evaluation and control of a certain oil transfer station system based on QRA[D]. Chongqing University of Science and Technology, 2017]
- [8] VENKATASUBRAMANIAN V, RENGASWAMY R, KAVURI S N, et al. A review of process fault detection and diagnosis Part III: Process history based methods[J]. Computers & Chemical Engineering, 2003, 27(3): 327-346.
- [9] KVIST L, MARTIN, KARLSSON L, et al. A review of unsupervised feature learning and deep learning for time-series modeling[J]. Pattern Recognition Letters, 2014, 42(1): 11-24
- [10] LAZZERI, FRANCESCA. Machine learning for time series forecasting with python[M]. Indiana: John Wiley & Sons, 2020.
- [11] LEI Y G, YANG B, JIANG X W, et al. Applications of machine learning to machine fault diagnosis: A review and roadmap[J]. Mechanical Systems and Signal Processing, 2020, 138.
- [12] HINTON G E, SALAKHUTDINOV. Reducing the dimensionality of data with neural networks[J]. Science, 2006. 313(5786): 504-7.
- [13] ZHAO H T, SUN S Y, FU J. Sequential fault diagnosis based on LSTM[J]. Neural Network. IEEE Access, 2018. 6: 12929-12939.
- [14] XIE H F, LI B. A hierarchical deep neural network for fault diagnosis on Tennessee-Eastman process[C]. ICMLA, 2015: 745-748
- [15] CHAO W, FENG B T, LIN Y D, et al. Substation equipment thermal fault diagnosis model based on ResNet and improved bayesian optimization[C]. ICPEs. 2019: 1-5.
- [16] JIANG L, GE Z Q, SONG Z H. Semi-supervised fault classification based on dynamic sparse stacked auto-encoders model[J]. Chemo-metr Intell Lab Syst, 2017, 168: 72-83.
- [17] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision & Pattern Recognition. IEEE Computer Society, 2016: 770-778.
- [18] 衷路生, 夏相明. 基于深度残差网络的化工过程故障诊断[J]. 过程工程学报, 2020, 20(12): 1483-1490. [ZHONG L S, XIA X M. Fault diagnosis for chemical processes based on deep residual network[J]. The Chinese Journal of Process Engineering, 2020, 20(12): 1483-1490.]
- [19] WANG Z, YAN W, OATES T. Time series classification from scratch with deep neural networks: A strong baseline[C]. USA: IGCNN. Anchorage, AK. 2017: 1578-1585.

- [20] 邱锡鹏. 神经网络与深度学习[M]. 北京: 机械工业出版社, 2020. [QIU X P. Neural networks and deep learning[M]. Beijing: China Machine Press, 2020.]
- [21] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature. 2015, 521: 436–444.
- [22] LIN M, CHEN Q, YAN S. Network in network[C]. ICLR, 2014.
- [23] 徐玲玲, 迟冬祥. 面向不平衡数据集的机器学习分类策略[J]. 计算机工程与应用, 2020, 56(24): 12–27. [XU L L, CHI D X. Machine learning classification strategy for imbalanced data sets[J]. Computer Engineering and Applications, 2020, 56(24): 12–27.]
- [24] 张玉红, 李晓峰, 张树清. 基于MATLAB的扎龙湿地归一化差值指数时间变化分析[J]. 东北林业大学学报, 2008(03): 39–40+50. [ZHANG Y H, LI X F, ZHANG S Q. Temporal change of normalized difference vegetation index based on MATLAB in Zhalong Wetland[J]. Journal of Northeast Forestry University, 2008(03): 39–40+50.]
- [25] 张新建, 刘锋, 李贤功. 基于小波降噪和循环神经网络的煤矿瓦斯浓度预测[J]. 煤炭技术, 2020, 39(09): 145–148. [ZHANG X J, LIU F, LI X G. Coal mine gas concentration prediction based on wavelet denoising and recurrent neural network[J]. Coal Technology, 2020, 39(09): 145–148.]
- [26] SYLVAIN V, TEODOR T, ABDESSAMAD K. Fault detection and identification with a new feature selection based on mutual information[J]. Journal of Process Control, 2007, 18(5): 479–490.
- [27] ZHANG Z P, ZHAO J S. A deep belief network based fault diagnosis model for complex chemical processes[J]. Computers & Chemical Engineering, 2017, 107: 395–407.

(责任编辑 王雨墨 编辑 马桂霞)