

文章编号:1001-2060(2023)03-0164-10

基于深度学习的汽水分离再热数字孪生 系统故障诊断研究

王克璇,邢天阳,朱小良

(东南大学 能源与环境学院,江苏 南京 255052)

摘要:针对汽水分离再热系统等复杂工业系统,为解决传统故障诊断模型准确率受限于故障样本稀缺和故障数据时间维度与变量维度耦合的问题,提出一种基于深度学习的故障诊断方法。首先,构建汽水分离再热数字孪生系统,用以建立故障诊断数据仓库,解决数据样本层面稀缺性的问题。其次,进一步构建基于深度残差网络的故障诊断模型,用以诊断汽水分离再热系统典型故障,包括流量不均、破口、传热恶化和阀门特性变化,从而解决数据变量层面时变、多维度的问题。结果表明:数字孪生系统能够实现汽水分离再热系统稳态、动态和故障工况的精确仿真,满足后续深度学习模型的数据需求;基于深度残差网络的故障诊断模型能够实现时变、多维工业数据的故障诊断;采用T分布随机邻域嵌入(TSNE)方法对模型可视化,可对不同故障类型的数据进行明显区分。

关键词:故障诊断;深度残差网络;数字孪生体;汽水分离再热系统

中图分类号:TL48 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2023.03.022

[引用本文格式]王克璇,邢天阳,朱小良.基于深度学习的汽水分离再热数字孪生系统故障诊断研究[J].热能动力工程,2023,38(3):164-173. WANG Ke-xuan, XING Tian-yang, ZHU Xiao-liang. Deep learning-based fault diagnosis of moisture separator and reheat digital twin system[J]. Journal of Engineering for Thermal Energy and Power, 2023, 38(3): 164-173.

Deep Learning-based Fault Diagnosis of Moisture Separator and Reheater Digital Twin System

WANG Ke-xuan, XING Tian-yang, ZHU Xiao-liang

(School of Energy and Environment, Southeast University, Nanjing, China, Post Code: 255052)

Abstract: In order to solve the problem that the accuracy of traditional fault diagnosis model is limited by the scarcity of fault samples and the coupling of time dimension and variable dimension of fault data, a fault diagnosis method based on deep learning is proposed for complex industrial systems such as moisture separator and reheat system. Firstly, the digital twin system of moisture separator and reheat is constructed to establish the fault diagnosis data warehouse and solve the problem of scarcity of data samples. Secondly, based on the previous step, a fault diagnosis model based on deep residual network is constructed to diagnose the typical faults of steam water separation and reheat system, including uneven flow, break, deterioration of heat transfer and change of valve characteristics, so as to solve the problem of time-varying and multi-dimensional data variables. The simulation results show that the digital twin system can realize the accurate simulation of the steady-state, dynamic and fault conditions of the steam water separation and reheat system, and meet the data requirements of the subsequent in-depth learning

收稿日期:2022-08-19; 修订日期:2022-10-26

基金项目:核反应堆系统设计技术重点实验室资助项目(HT-WDZC-02-20020007)

Fund-supported Project: Science and Technology on Reactor System Design Technology Laboratory of China (HT-WDZC-02-20020007)

作者简介:王克璇(1996-),男,东南大学硕士研究生。

model; the fault diagnosis model based on deep residual network can realize the fault diagnosis of time-varying and multi-dimensional industrial data. The T-distributed stochastic neighborhood embedding (TSNE) method is used to visualize the model and verify that the suggested diagnostic model distinguishes significantly between different fault types of data.

Key words: fault diagnosis, deep residual network, digital twin, moisture separator and reheater system

引言

汽水分离再热系统(Moisture separator and reheater, MSR)是核电二回路系统的主要子系统,其安全、高效运行对核电机组的安全性、经济型具有重要意义。由于在建核电机组数量的增加、间歇性可再生能源的大量并网,核电机组需要深度参与调峰调频,导致汽水分离再热系统在时变工况下,容易出现多种典型故障。因此,对汽水分离再热系统典型故障的准确诊断对于核电机组在时变工况下安全稳定运行具有重要意义。

近年来,以深度学习为代表的基于数据驱动的故障诊断方法得益于计算机算力提升、大数据和计算模型进步而发展迅速,应用前景广阔^[1]。然而,针对汽水分离再热系统等复杂工业系统故障诊断方法在实际应用中受两方面限制:一是样本层面,即样本数据的质量和数量问题;二是变量层面,即监测变量维度高和时变性^[2]。

对于样本问题,以往的故障诊断研究多以公开故障数据库为基础。Zhang 等人^[3]以凯斯西储大学(CWRU)轴承数据库为基础,提出一种改进卷积神经网络 CNN 的故障诊断模型;少有建立物理实验平台,如 Han 等人建立一套风力发电机实验平台,在此基础上提出一种适用于工业系统的故障诊断模型^[4]。但是,对于汽水分离再热系统等复杂工业系统,公开故障数据稀缺,且物理实验平台建设成本高昂,而构建符合系统实际运行特性的数字孪生,可以方便获取故障数据、降低数据采集的成本。如 Jain 等人^[5]建立了 PV 系统数字孪生的数学分析,通过仿真研究和实验验证,有效提高了故障诊断模型的准确率、增加了故障诊断类型。

对于变量问题,以往的故障诊断模型多对静态系统进行诊断,如 Xuan 等人^[6]提出一种基于多尺

度神经网络的城市供水管网泄漏检测模型,其模型的特点是基于守恒方程、变量维度单一、时序无关;部分针对振动机械系统,将时域数据转变为频域数据,如刘子铭等人^[7]提出一种基于频域数据注意力机制的核电厂水泵故障诊断模型,这类模型的特点是针对高频数据,将时域数据转变为频域数据。

本文提出一种数字孪生系统构建与深度学习结合的故障诊断方法。该方法构建汽水分离再热系统数字孪生体,验证其稳态特性和动态特性,实现流量不均、破口、传热恶化和阀门特性变化等汽水分离再热系统典型故障的仿真。在汽水分离再热系统数字孪生基础上,搭建基于深度残差网络的深度学习模型,实现对多维、时变工业数据的故障诊断。

1 深度残差网络

1.1 深度残差网络特性

深度残差网络(Deep residual shrinkage network, DRSN)是一种特殊的卷积神经网络(Convolutional neural network, CNN),该网络可以对二维平面图像进行卷积操作,提取其特征^[8]。而工业数据时序、多维的特点,使得其容易通过时间窗口剪裁操作,转化为二维平面图形的数据结构^[9]。同时卷积核在时间维度和变量维度的卷积操作,能够提取数据在不同时间点之间和不同维度之间的结构信息。深度残差网络的基本思想是在不同的卷积层之间添加一条旁路,使得输入信号可以直达更深的卷积层。残差网络可以保证输入信号从任意低层传播到高层,从而避免了输入信号退化为白噪声^[10]。深度残差网络的这一结构特点恰好可以应用于工业数据的特征提取中,构建足够深层的神经网络,有效提取高维度输入数据的特征,从而诊断故障。

1.2 深度残差网络结构

深度残差网络的基本结构主要包括数据输入层、卷积层、激活层、池化层和全连接层^[11]。在卷积

神经网络的基础上添加残差单元即可构成残差网络,其基本结构如图 1 所示。

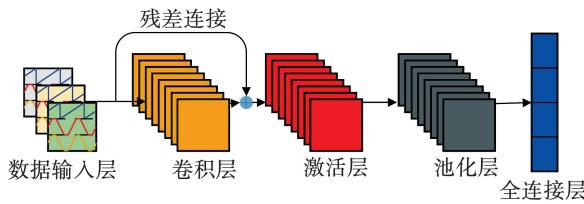


图 1 深度残差网络结构图

Fig. 1 Depth residual network structure

首先定义一个样本数据集 $\mathbf{X} = [X_1, X_2, \dots, X_n], \{X_i \in \mathbb{R}^d | i = 1, 2, \dots, n\}$ (其中 n 为样本个数, d 为变量维度)。

卷积层是指,一定尺寸的卷积核对输入数据的局部区域进行卷积运算,并且通过不断滑动卷积核的位置,遍历输入数据,最终得到的特征图。卷积过程为:

$$y^{m(a,b)} = K_a^m X^{m(r^b)} = \sum_{b'=0}^{W-1} K_a^{m(b')} X^{m(a+b')} \quad (1)$$

式中: $y^{m(a,b)}$ — 第 m 层卷积层输出值; $K_a^{m(b')}$ — 第 m 层的第 a 个卷积核的第 b' 个权重; $X^{m(r^b)}$ — 第 m 层的第 b 个局部卷积野; W — 卷积核的宽度。

在卷积层处理后,通常使用激活层对每个卷积输出值进行非线性变换,从而增强网络对特征的表达能力。使用 Leaky ReLU 作为激活函数,公式为:

$$f(y^{m(a,b)}) = \begin{cases} \xi_a y^{m(a,b)}, & y \leq 0 \\ y^{m(a,b)}, & y > 0 \end{cases} \quad (2)$$

式中: ξ_a — $(0, 1)$ 区间的固定参数; $f(y^{m(a,b)})$ — 卷积层输出值的激活值。

池化层对激活层之后的数据进行降维操作,一方面能够抽取特征,另一方面可以减少神经网络的参数,从而方便优化网络。一般常用的池化方法为最大池化法,公式为:

$$\text{Pool}^{m(a,b)} = \max_{(b-1)W+1 \leqslant i \leqslant bW} \{f(y^{m(a,b)})\} \quad (3)$$

式中: $\text{Pool}^{m(a,b)}$ — 池化层输出值。

全连接层用以接受上一层的输入,并使用 Softmax 分类器进行分类,将多个神经元的输出映射到 $(0, 1)$ 区间内,输出最终分类结果:

$$\text{Softmax}(\lambda_n) = e^{\lambda_n} / \sum_{c=1}^C e^{\lambda_c} \quad (4)$$

式中: λ_n — 第 n 种分类的上层输出值; C — 分类数量。

深度网络通常存在多层卷积层和池化层。由于网络深度的增加,神经网络出现退化现象,训练误差增大,导致网络难以训练、分类结果难以提升。因此,何凯明^[11]提出了一种残差学习单元实现层间残差传递解决退化问题。残差学习单元如图 2 所示。

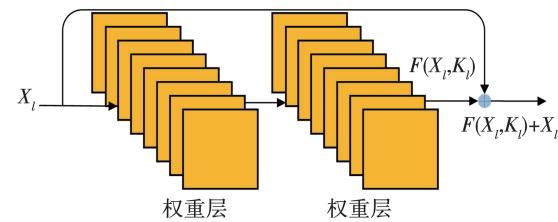


图 2 残差单元示意图

Fig. 2 Residual element

图 2 中 $F(X_l, K_l)$ 为 l 层输入数据 X_l 在经过网络前向传播后的输出值, K_l 为该层网络权重。由图可知, $l+1$ 层的输入值为:

$$X_{l+1} = X_l + F(X_l, K_l) \quad (5)$$

任意一层网络的输入值为:

$$X_L = X_1 + \sum_{i=1}^{L-1} F(X_i, K_i) \quad (6)$$

利用反向传播更新神经网络,假设损失函数为 ε ,根据反向传播链式法则可得:

$$\frac{\partial \varepsilon}{\partial X_L} = \frac{\partial \varepsilon}{\partial X_L} \frac{\partial X_L}{\partial X_l} = \frac{\partial \varepsilon}{\partial X_L} \left(1 + \frac{\partial \varepsilon}{\partial X_l} \sum_{i=1}^{L-1} F(X_i, K_i) \right) \quad (7)$$

训练损失信号可以分为两部分,一部分不经过权重层传递: $\frac{\partial \varepsilon}{\partial X_L}$, 一部分经过权重层传递 $\frac{\partial \varepsilon}{\partial X_L} \left(\frac{\partial \varepsilon}{\partial X_l} \sum_{i=1}^{L-1} F(X_i, K_i) \right)$ 。因此,在反向传播时,不经过权重层传递的部分可以保证损失信号能够传至任意层,同时保证不会出现梯度消失的现象。

2 基于深度学习的汽水分离再热数字孪生系统故障诊断模型

基于深度学习的汽水分离再热数字孪生系统故

障诊断模型流程如图3所示。模型主要分为两步:第一步构建汽水分离再热系统数字孪生体;第二步在第一步基础上构建基于深度残差网络的故障诊断模型。

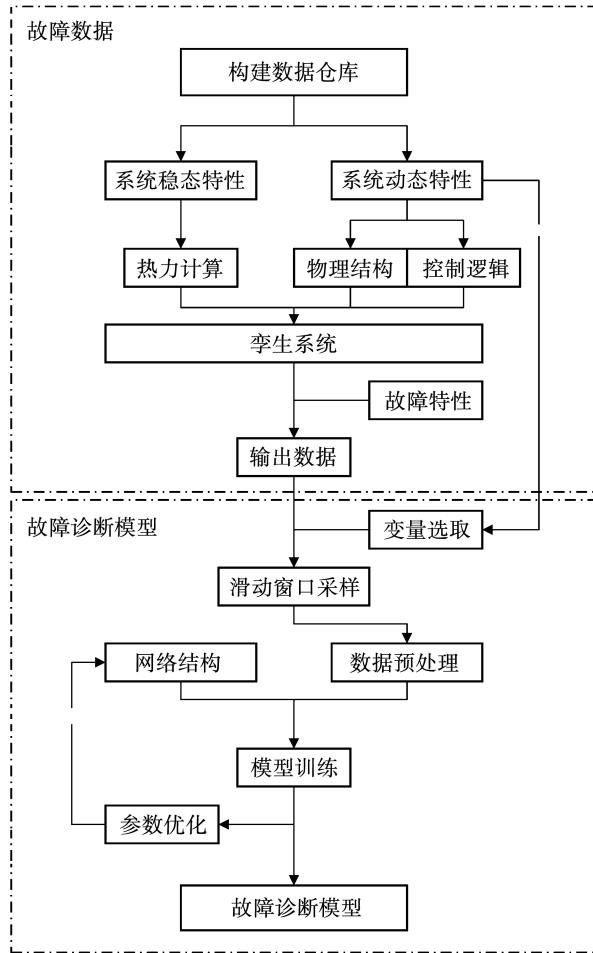


图3 方法流程图

Fig. 3 Flow chart of method

2.1 数字孪生体构建

以某核电站汽水分离再热系统为研究对象。该系统由分离器、高压抽汽再热器、新蒸汽再热器和疏水系统组成,主要设计参数如表1所示。

采用模块化建模方法,建立汽水分离再热系统数字孪生,并通过结构热力计算和建模校准的方法,实现汽水分离再热系统典型故障的动态仿真。为了校准汽水分离再热数字孪生的稳态准确性,选取汽水分离再热系统典型热力参数进行热平衡校准,其中,汽轮机最大连续出力工况(TMCR)下,主要热力

参数设计值与仿真值如表2所示。为了校准汽水分离再热数字孪生的动态准确性,对比数字孪生系统和实际机组的变负荷阻力特性曲线,其中,TMCR至30%指示工况(FP)变负荷阻力特性曲线如图4~图7所示。

表1 主要设计参数

Tab. 1 Main design parameters

参数	1号再热器		2号再热器	
	管程	壳程	管程	壳程
工作压力/MPa	2.749	1.002	6.350	0.987
工作温度/°C	229.0	180.0	279.3	220.9
流量/t·h⁻¹	126.39	2 073.57	151.98	2 073.57
程数	4	-	4	-
传热面积/m²	6 653	-	6 653	-

表2 TMCR工况下MSR主要热力参数

Tab. 2 Main thermal parameters of MSR under TMCR condition

参数	设计值	仿真值	相对误差%
主蒸汽入口流量/kg·s⁻¹	1 340.01	1 340.01	0
一级再热蒸汽流量/kg·s⁻¹	70.21	70.21	0
二级再热蒸汽流量/kg·s⁻¹	84.43	84.43	0
主蒸汽出口流量/kg·s⁻¹	1 151.98	1 151.98	0
分离器疏水流量/MPa	188.03	188.03	0
主蒸汽入口压力/MPa	1.012	1.012	0
汽水分离后压力/MPa	1.002	1.002	0
分离器疏水压力/MPa	0.997	0.930	7.24
主汽出口压力/MPa	0.972	0.972	0
一级再热蒸汽压力/MPa	2.749	2.749	0
一级再热疏水压力/MPa	2.694	2.693	0.04
二级再热压力/MPa	6.35	6.347	0.05
二级再热疏水压力/MPa	6.226	6.224	0.03
主蒸汽入口焓/kJ·kg⁻¹	2 493.8	2 493.9	0
分离器出口蒸汽焓/kJ·kg⁻¹	2 776.4	2 776.4	0
分离器疏水焓/kJ·kg⁻¹	762	763	0.13
主蒸汽出口焓/kJ·kg⁻¹	2 990.9	2 991.0	0
一级再热蒸汽焓/kJ·kg⁻¹	2 641.4	2 641.4	0
一级再热疏水焓/kJ·kg⁻¹	986.3	986.6	0.03
二级再热蒸汽焓/kJ·kg⁻¹	2 772.1	2 772.1	0
二级再热疏水焓/kJ·kg⁻¹	1 167.6	1 167.1	0.04

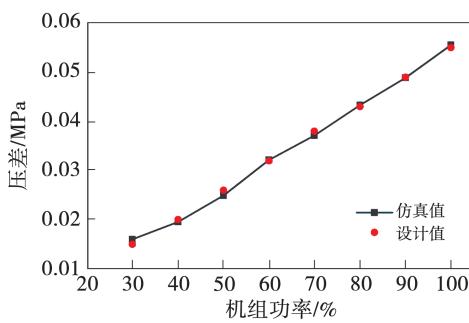


图 4 1号再热器管侧阻力特性曲线

Fig. 4 Resistance characteristic curve of No. 1 reheatertube side

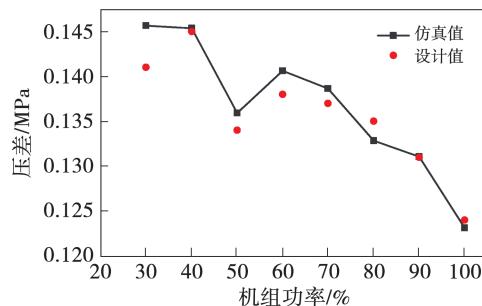


图 5 2号再热器管侧阻力特性曲线

Fig. 5 Resistance characteristic curve of No. 2 reheatertube side

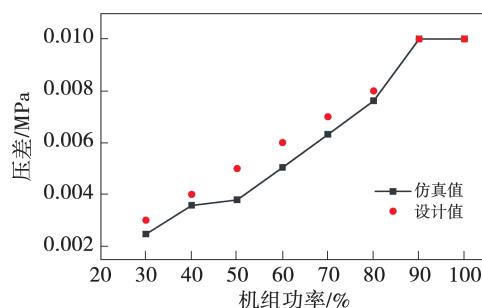


图 6 主蒸汽分离段壳侧阻力特性曲线

Fig. 6 Shell side resistance characteristic curve of main steam separation section

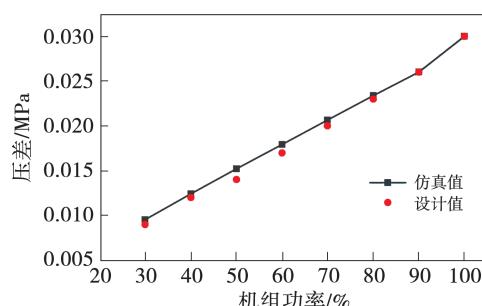


图 7 主蒸汽再热段壳侧阻力特性曲线

Fig. 7 Shell side resistance characteristic curve of main steam reheat section

基于建立的汽水分离再热数字孪生系统进行典型故障实验,其中汽水分离再热系统典型故障主要包括流量不均^[12-13]、破口^[14-15]、传热恶化^[16-17]以及阀门特性变化^[18]导致的压力变化,故障特征如表 3 所示。

表 3 故障特征表

Tab. 3 Fault characteristics

故障种类	故障特征
流量不均	分离器入口流量分配不均导致分离效率下降
破口	再热器换热管破口导致主汽参数抬升,抽汽量下降
传热恶化	再热器过冷导致传热恶化
阀门特性变化	疏水阀门特性变化导致管路压力特性改变,疏水箱水位异常

2.2 残差网络结构设计

3 层深度残差网络 DRSN 结构如图 8 所示。深度残差网络由输入层、3 个首尾相接的网络块、输出层构成。

第 1 个网络块由 3 层卷积层、1 层激活层和 1 层池化层组成。每层卷积层都设置了 q 个卷积核,由浅到深,卷积核的尺寸分别为 $[7 \times 7]$ 、 $[5 \times 5]$ 、 $[3 \times 3]$ 。卷积块内部构建了一条从输入数据到第 3 层卷积层出口的残差通道,实现残差传播功能。最终,经过激活、池化的数据传入到第 2 个网络块。

第 2 个和第 3 个网络块的结构与第 1 个网络块的结构基本相同,只有卷积核数目设置不同。为了进一步增强网络对数据特征的提取能力,第 2 个网络块的卷积层设置了 $2q$ 个卷积核,从而使得特征图的数量翻倍。

输出层为采用全连接的 Softmax 层,最终输出的数据是系统状态类型,分为正常运行状态和表 3 所述 4 类典型故障。

2.3 残差网络训练

针对时序数据,建立深度残差网络模型,利用汽水分离再热数字孪生系统建立的数据仓库,对上述 3 层深度残差网络进行训练。

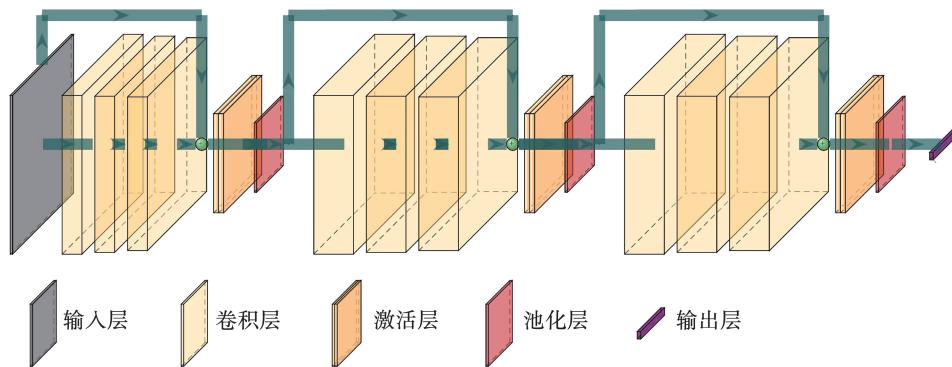


Fig. 8 Structure diagram of DRSN model

2.3.1 数据预处理

数据预处理阶段分为两部分,一是构建数字孪生系统与深度残差网络之间的数据传输,采用滑动窗口的方式进行采样;二是对训练数据进行标准化处理,以消除量纲影响。

滑动窗口操作是指,将连续时间相关数据转化为时序图,如图9所示。同时,采集 q 个系统状态变量在 p 个时间长度内的数据,然后将输入数据保存为 $p \times q$ 的矩阵。

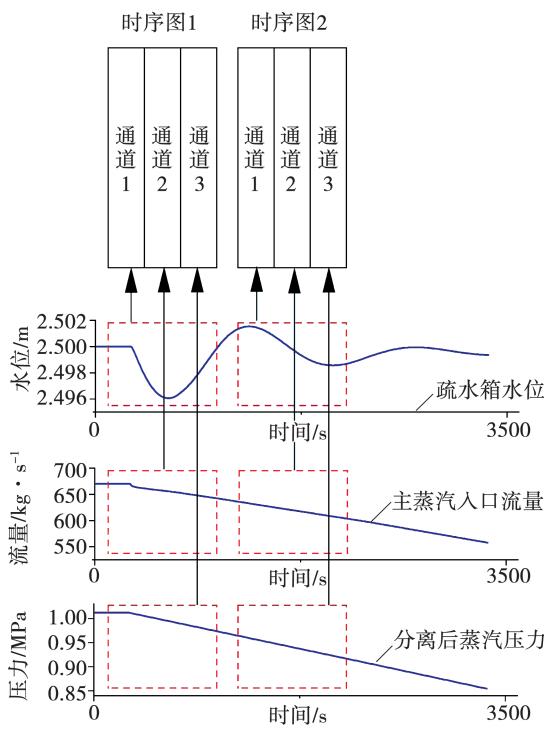


图 9 滑动窗口示意图

Fig. 9 Schematic diagram of sliding window

由于多维变量在量纲上不统一,容易使得网络模型忽略某些值域较小的特征,从而产生精度损失,降低训练精度。因此,在数据预处理阶段对样本数据集进行标准化处理^[19],如式(8)所示:

$$X^* = \frac{X - \mu}{\sigma} \quad (8)$$

式中: μ —所有样本数据的均值; σ —所有样本数据的标准差。标准化处理后数据符合标准正态分布,即均值为0,标准差为1,且是针对每一个特征维度来做的,而不是针对样本。

2.3.2 模型训练

模型训练的基本过程为前向传播、计算损失函数、反向传播更新网络参数。在训练前需要确定梯度下降模型、训练样本批量、损失函数和学习率等超参数。

采用 Adam(Adaptive moment estimation)优化算法来更新网络权重。Adam 算法的优势在于自适应性学习率^[20],该算法利用梯度的一阶矩和二阶矩动态调整学习率。Adam 算法的迭代过程为:

$$\left\{ \begin{array}{l} g_t \leftarrow \nabla_w f_t(w_{t-1}) \\ m_t \leftarrow \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t \leftarrow \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \\ \hat{m}_t \leftarrow m_t (1 - \beta_t^1) \\ \hat{v}_t \leftarrow v_t (1 - \beta_t^2) \\ w_t \leftarrow w_{t-1} - \alpha \hat{m}_t / (\sqrt{\hat{v}_t} + \epsilon) \end{array} \right. \quad (9)$$

式中: t —迭代次数; $f_t(w_{t-1})$ —损失函数; w_t —权重参数; g_t —损失函数的梯度; m_t —梯度的一阶矩估

计; v_t —梯度的二阶矩估计; m_t —修正后的一阶矩估计; \hat{v}_t —修正后的二阶矩估计; ϵ —极小值, 防止学习率为 0。

训练样本采用小批量梯度下降法 (Mini-batch gradient descent, MBGD), MBGD 在训练迭代中用小批量样本来计算梯度和更新网络参数, 从而降低训练量、提高训练速度。

网络训练模型采用交叉熵损失函数。交叉熵损失函数适用于计算多分类模型的损失值, 公式为:

$$L = -[y \log \hat{y} + (1 - y) \log(1 - \hat{y})] \quad (10)$$

式中: L —损失值; y —真实值; \hat{y} —模型输出值。

3 基于 DRSN 的汽水分离再热系统故障诊断结果

基于汽水分离再热数字孪生系统建立的数据仓库, 进行故障诊断实验。采集汽水分离再热系统正常运行和 4 种故障类型的运行故障数据集。故障程度分为轻度 (1% 偏离设计参数)、中度 (2% 偏离设计参数) 和重度 (5% 偏离设计参数)。实验数据如表 4 所示。

表 4 故障数据表

Tab. 4 Fault data

编号	故障类型	故障程度	故障编号
0	正常	-	9
1	流量不均	轻度	1
		中度	2
		重度	3
2	破口(1号再热器)	轻度	4
		中度	5
		重度	6
3	破口(2号再热器)	轻度	7
		中度	8
		重度	9
4	传热恶化(1号再热器)	轻度	10
		中度	11
		重度	12
5	传热恶化(2号再热器)	轻度	13
		中度	14
		重度	15
6	阀门特性变化	轻度	16
		中度	17
		重度	18

3.1 DRSN 故障诊断结果

针对上述故障数据, 随机选取 70% 的故障数据作为训练集, 30% 的故障数据作为测试集, 其中训练集用于网络模型的训练, 测试集用于检验网络模型的准确率。从图 10 可以看出, 在经过 410 个训练周期后, 深度残差网络的故障诊断准确率不断提高, 并且以较低的训练周期, 最终实现 90.323% 的诊断准确率。

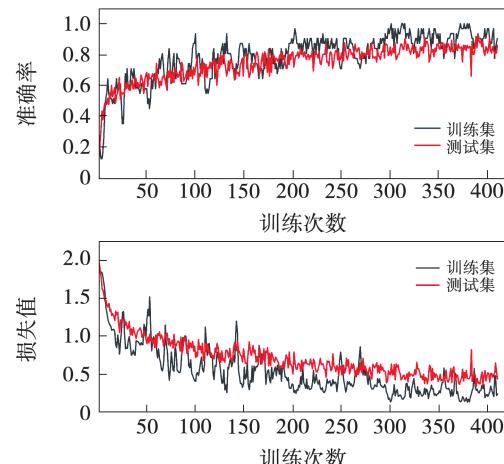


图 10 DRSN 模型训练结果

Fig. 10 Training results of DRSN

具体到各故障类型的诊断准确率, 每隔 10% FP 采集 30% FP ~ 100% FP 共 8 个工况点下, 如表 4 所示。19 个系统故障类型的故障数据作为验证集, 检验模型对各个故障类型的诊断准确率, 验证结果如图 11 所示。图中, 横坐标表示预测故障类型, 纵坐标表示实际故障类型。除 1 号再热器破口和 2 号再热器破口外, 其他故障诊断准确率都较高。观察模型对实际故障类型为 1 号再热器破口的诊断结果发现, 在诊断结果出错时, 模型预测的系统状态均为 2 号再热器破口状态。考虑到 1 号再热器与 2 号再热器在汽水分离器壳体内部前后串联, 因此 2 号故障和 3 号故障的耦合性较强, 导致两种故障难以区分。如图 12 所示, 由于 2 号再热器流量在较低负荷时大于 1 号再热器流量, 因此 2 号再热器破口的特征表现强于 1 号再热器, 导致 2 号故障被误识别为 3 号故障。由于 1 号再热器与 2 号再热器共同组成再热器系统, 因此考虑再热器系统的故障诊断时, 模型诊断的准确率为 100%。

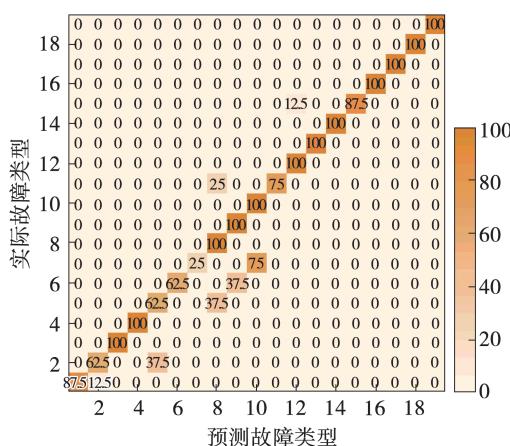


图 11 DRSN 模型故障诊断性能

Fig. 11 Fault diagnosis performance of DRSN model

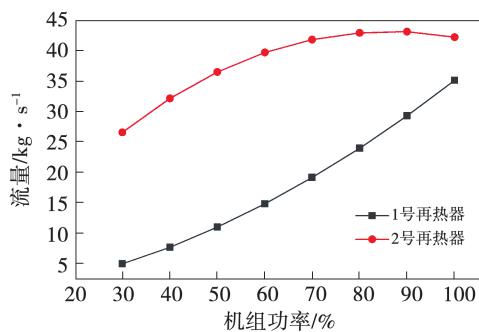


图 12 再热器流量特性曲线

Fig. 12 Reheater flow characteristic curve

设置训练周期 410 次,将 DRSN 故障诊断模型结果与卷积神经网络^[21] (Convolutional Neural Network, CNN)、深度神经网络^[22] (Deep Neural Network, DNN) 这两类传统的故障诊断模型进行对比,结果如表 5 所示。

表 5 模型对比

Tab. 5 Model comparison

模型	准确率/%	损失值	单步训练时长/ms
DRSN	90.32	0.2361	12
CNN	62.28	0.2753	8
DNN	47.83	1.2315	2

由表 5 可知,深度残差网络的故障识别准确率最高为 90.32%,CNN 和 DNN 故障识别准确率分别为 62.28% 和 47.83%。因此,针对多维度、时变的工业数据集,采用的深度残差网络能够发挥其残差

传播优势,通过深层次网络来挖掘时序维度和变量维度的特征关系。

3.2 DRSN 故障模型可视化

如图 13 所示,利用 TSNE 方法对 DRSN、CNN 和 DNN 3 种训练完毕的故障诊断模型进行可视化,从而表征各类故障在不同模型下的聚类特征。可以发现,DRSN 模型和 CNN 模型基本实现不同故障的完全分类,并且同类故障数据实现明显聚合;DNN 模型则只能区分部分故障类型,同种故障的聚合度也不甚理想。因为 DNN 通常用于非时变数据,相比 DRSN 和 CNN 在时间维度上的卷积计算,缺乏对时序相关特征的提取能力,本文采用的残差网络模型更适合工业时序数据集。

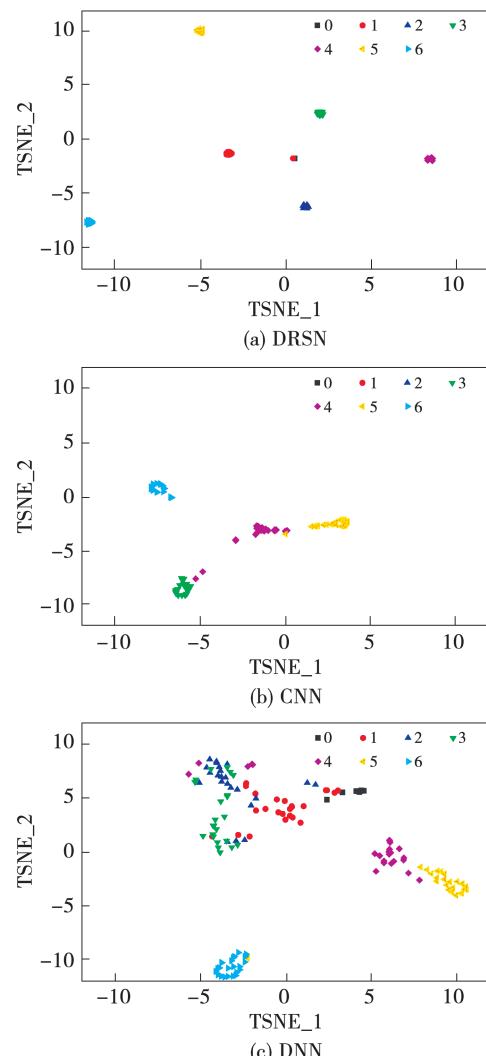


图 13 TSNE 聚类分析图

Fig. 13 TSNE cluster analysis

4 结 论

(1) 采用模块化建模方法,自下而上构建物理级、设备级和系统级模型,能够实现汽水分离再热系统全工况动态仿真,从而构建汽水分离再热系统数字孪生体。仿真系统主要参数相对误差均小于1%;仿真系统管侧和壳侧阻力特性在30% FP~100% FP工况下与实际数据基本保持一致。

(2) 利用深度残差网络建立基于深度残差网络的故障诊断模型,在数据预处理部分采用滑动窗口提取的方法对时序数据进行提取,从而在保证时序数据实时性的前提下实现了时序数据时间维度特征的提取;在模型训练部分所建立的深度残差网络由于残差传播结构的优势得以建立深度网络,从而针对工业数据多维、时变的特征,有效提取其变量维度和时间维度的特征;在模型检验部分,利用TSNE可视化,表明所建立的深度残差网络能够实现不同故障类别的有效区分。

所建立的故障诊断模型对上述4种典型故障识别准确率达到90.32%,相同训练次数下训练准确度更高,优于CNN和DNN模型,可以实现多维、时变工业数据的故障诊断。

参 考 文 献:

- [1] 刘旭婷,李益国,孙栓柱,等.基于稀疏局部嵌入深度卷积网络的冷水机组故障诊断方法[J].化工学报,2018,69(12):5155~5163.
- LIU Xu-ting, LI Yi-guo, SUN Shuan-zhu, et al. Fault diagnosis of chillers using sparsely local embedding deep convolutional neural network[J]. CIESC Journal, 2018, 69(12): 5155~5163.
- [2] HUANG K,WU Y,WANG C,et al. A projective and discriminative dictionary learning for high-dimensional process monitoring with industrial applications[J]. IEEE Transactions on Industrial Informatics,2020,17(1):558~568.
- ZHANG J,SUN Y,GUO L,et al. A new bearing fault diagnosis method based on modified convolutional neural networks[J]. Chinese Journal of Aeronautics,2019,33(2):439~447.
- [4] HAN T,LIU C,YANG W,et al. Deep transfer network with joint distribution adaptation:a new intelligent fault diagnosis framework for industry application[J]. ISA Transactions,2020,97:269~281.
- JAIN P. A digital twin approach for fault diagnosis in distributed

photovoltaic systems[J]. IEEE Transactions on Power Electronics, 2020,35(1):940~956.

- [6] XUAN H. Novel leakage detection and water loss management of urban water supply network using multiscale neural networks[J]. Journal of Cleaner Production,2021,278:123611.
- [7] 刘子铭,罗能,艾琼.基于频域数据注意力机制的核电厂水泵故障模式识别模型研究[J].核动力工程,2021,42(6):203~208.
- LIU Zi-ming, LUO Neng, AI Qiong. Research on fault pattern recognition model of nuclear power plant water pump based on frequency-domain data attention mechanism[J]. Nuclear Power Engineering,2021,42(6):203~208.
- [8] HE K,ZHANG X,REN S,et al. Deep residual learning for image recognition[C]//Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas:IEEE,2016:770~778.
- [9] XU X,TAO Z,MING W,et al. Intelligent monitoring and diagnostics using a novel integrated model based on deep learning and multi-sensor feature fusion[J]. Measurement,2020,165:108086.
- [10] ZHAO M,ZHONG S,FU X,et al. Deep residual shrinkage networks for fault diagnosis[J]. IEEE Transactions on Industrial Informatics,2020,16(7):4681~4690.
- [11] HE K. Identity mappings in deep residual networks[C]//European Conference on Computer Vision (ECCV). Amsterdam:Springer,2016,9908:630~645.
- [12] 徐彩英.原子能电站的汽水分离-中间再热器[J].核动力工程,1981,1:61~66.
- XU Cai-ying. Steam water separation intermediate reheat in atomic power plant[J]. Nuclear Power Engineering,1981,1:61~66.
- [13] 曹孟浩.汽水分离再热器内蒸汽流动特性的数值模拟研究[D].大连:大连理工大学,2020.
- CAO Meng-hao. Numerical simulation of steam flow characteristics in moisture separator reheat[D]. Dalian:Dalian University of Technology,2020.
- [14] 鲍旭东,颜铁光.再热蒸汽温度控制对核电机组运行可靠性的影响[J].热力发电,2019,48(6):102~107.
- BAO Xu-dong, YAN Tie-guang. Effect of reheat steam temperature control on operation reliability of nuclear power units[J]. Thermal Power Generation,2019,48(6):102~107.
- [15] 凌星.结合核电站运行进行汽水分离再热器分析[C]//中国核能论坛.南宁:中国核学会,2004:151~155.
- LING Xing. Analysis of steam water separator reheat combined with the operation of nuclear power plant [C]//China Nuclear Energy Forum. Nanning:China Nuclear Society,2004:151~155.
- [16] MANABE J,KASAHARA J, KOJIMA T, et al. Recent design technologies of moisture separator reheat [C]//International Conference on Nuclear Engineering. American Society of Me-

- chanical Engineers,2009.
- [17] 付元钢.某核电厂汽水分离再热器管内凝结传热试验研究[J].产业技术创新,2019(30):28-29.
FU Yuan-gang. Experimental study on condensation heat transfer in steam water separator reheatert of a nuclear power plant[J]. Industrial Technology Innovation,2019(30):28-29.
- [18] 郭轶波.汽水分离再热器疏水改进提升热效率探析[C]//中国核学会2019年学术年会.包头:中国核学会,2019.
GUO Yi-bo. Thermal efficiency promoting from moisture separator and reheater drainage system improvement[C]//2019 Academic Annual Meeting of China Nuclear Society. Baotou: China Nuclear Society,2019.
- [19] MISHKIN D, SERGIEVSKIY N, MATAS J. Systematic evaluation of convolution neural network advances on the ImageNet[J]. Computer Vision and Image Understanding,2017,161:11-19.
- [20] KINGMA D, BA J. Adam: a method for stochastic optimization [C]//San Diego: International Conference for Learning Representations (ICLR),2015.
- [21] KAREN S, ANDREW Z. Very deep convolutional networks for large-scale image recognition[C]//San Diego: International Conference for Learning Representations (ICLR),2015.
- [22] 司风琪,李欢欢,徐治皋.基于鲁棒输入训练神经网络的非线性多传感器故障诊断方法及其应用[J].东南大学学报,2011,41(3):574-578.
SI Feng-qi, LI Huan-huan, XU Zhi-gao. Nonlinear multi-sensor fault diagnosis method and its application based on robust input-training neural network[J]. Journal of Southeast University (Natural Science Edition),2011,41(3):574-578.

(姜雪梅 编辑)



日本 Eneos 株式会社将通过油轮运输氢

据官网报道,日本 Eneos 株式会社在澳大利亚布里斯班建立了一个绿色氢能示范工厂,生产液氢载体甲基环己烷(MCH)。

通常使用合成设备使储存在罐中的氢与甲苯(一种有机化合物)发生反应来生产 MCH。Eneos 株式会社正在开发一种电解槽,可以直接将水和甲苯合为一体转化为 MCH。MCH 到达最终目的地后,氢气很容易被提取出来。该电解槽将由太阳能供电,这意味着该工厂生产绿色氢气,且不会释放二氧化碳。通过 Eneos 的开创性工艺,不需要氢罐或额外的合成设备,大幅降低了成本。Eneos 示范工厂的电解槽容量将达到 150 kW,规模约是原型机的 150 倍。Eneos 计划对电解槽进行 8 个月的现场测试,以确定最佳的操作和控制技术。该公司计划在截至 2026 年 3 月的财政年度之前开发出 5 MW 的电解槽,然后开始大规模生产氢气。

氢本身必须储存在 -253 °C 才能保持液化。Eneos 表示,MCH 可以在常温下储存在油轮中,这将降低运输成本。通过这种方法,Eneos 预计到 2030 年氢气的售价约为 330 日元(2.54 美元)/kg,低于日本政府 2021 年估值的 30%。

(孙嘉忆摘译自 <https://hydrogen-central.com>)