

基于多维复向特征融合与CNN-GRU的转子不平衡量识别方法

王坚坚^{1,2} 廖与禾^{1,2*} 杨磊^{1,2} 薛久涛^{1,2}

1. 西安交通大学现代设计及转子轴承系统教育部重点实验室, 西安, 710049

2. 西安交通大学陕西省机械产品质量保障与诊断重点实验室, 西安, 710049

摘要: 现有的无试重不平衡量识别算法采用优化算法框架, 通过大量迭代运算以逐步逼近最优解, 这类策略普遍收敛速度迟缓且易陷入局部极值。为此, 利用神经网络直接学习并解析不平衡振动响应与不平衡量之间的复杂映射关系, 进而实现不平衡量的高精度识别。通过转子动力学模型进行仿真, 构建了带标签的足量不平衡振动数据集。针对不平衡数据的多维复向特性, 设计了一种特征融合机制。核心算法层面, 结合卷积神经网络(CNN)与门控循环单元(GRU)构建了CNN-GRU混合模型, 其中, CNN部分负责从振动数据中提取局部空间特征, GRU负责捕捉振动数据中的时序依赖关系, 通过整合空间与时间域的信息, 显著增强了模型的泛化能力和识别精度。测试集数据和实验台实验的不平衡量识别结果表明, 所提方法可以准确预估识别转子的不平衡量, 为无试重现场动平衡提供迅速准确的指导。

关键词: 转子; 无试重; 不平衡量识别; 卷积神经网络-门控循环单元; 多维复向特征融合

中图分类号: TH17

DOI:10.3969/j.issn.1004-132X.2025.09.001

开放科学(资源服务)标识码(OSID):



Rotor Unbalance Recognition Based on Multidimensional Complex Feature Fusion and CNN-GRU

WANG Jianjian^{1,2} LIAO Yuhe^{1,2*} YANG Lei^{1,2} XUE Jiutao^{1,2}

1. Key Laboratory of Education Ministry for Modern Design and Rotor-Bearing System, Xi'an Jiaotong University, Xi'an, 710049

2. Shaanxi Key Laboratory of Mechanical Product Quality Assurance and Diagnostics, Xi'an Jiaotong University, Xi'an, 710049

Abstract: The existing unbalance identification algorithm without trial weight adopted an optimization algorithm framework and approximated the optimal solution through numerous iterative operations. However, such strategies typically faced the limitations of slow convergence speed and the tendency to fall into local extrema. Therefore, neural networks were used to directly learn and analyze the complex mapping relationship between unbalance vibration response and unbalance, thus realizing high-precision unbalance identification. A sufficient unbalance vibration dataset with labels was constructed by simulating the rotor dynamics model. A feature fusion mechanism was designed to address the multi-dimensional complex-valued characteristics of unbalanced data. At the core algorithm level, a CNN-GRU hybrid model was constructed. In this model, CNN was responsible for extracting local spatial features from vibration data, while GRU captured temporal dependencies within the vibration data. By integrating information from both spatial and temporal domains, the model's generalization ability and recognition accuracy were significantly enhanced. The unbalance recognition results of test set data and experimental bench demonstrate that this method may accurately predict the unbalance of the rotors, providing a rapid and accurate guide for dynamic balancing in the field without trial weights.

Key words: rotor; without trial weight; unbalance identification; convolutional neural network-gated recurrent unit (CNN-GRU); multidimensional complex feature fusion

0 引言

不平衡故障是旋转机械中最主要的振动问题

之一^[1], 据统计, 50%以上的系统故障和设备失灵与旋转机械故障有关^[2], 超过80%的旋转机械振动故障都可以追溯到转子不平衡问题^[3]。迅速且高效地应对转子不平衡问题是设备维护中一个非常重要的问题^[4], 而研发无试重的不平衡量识别技术是该问题的关键解决方案。它能实现在设备

收稿日期: 2024-06-19

基金项目: 国家重点研发计划(2019YFB1311903); 国家自然科学基金(51575424)

运行状态下识别并解决动不平衡问题,这对提高工业现场效率与安全性具有重大意义^[5]。

近年来研究者们提出了一些无试重的不平衡识别方法,大致可归纳为以下三大类^[6]:基于动力学模型、基于影响系数法和基于优化算法。

基于动力学模型的方法通过高级的数学建模和分析手段提供了一种无需试重就能识别不平衡量的途径^[7],主要方法有:通过模态特性解析不平衡量与振动之间关系^[8-9]和对传递矩阵逆向求解^[10]。然而这些方法的实施难度、计算成本以及对专业知识的要求很高,不利于实际应用。寻找或开发更加用户友好、易于解释的算法和工具才是未来研究的一个重要方向。

基于影响系数法的方法通过经验公式或者历史测量获得的影响系数进行平衡配重的求解^[11],依赖过往的“平衡试重经验”即过往平衡过程中试重后测得的影响系数,因此这类方法不具有普适性。

相对于传统方法,智能优化算法是实现无试重不平衡识别的研究热点^[12]。刘亮等^[13]通过构建目标函数,运用果蝇优化算法进行目标函数的优化,从而成功识别出不平衡参数。WANG等^[14]针对多盘和多跨度转子轴承系统,提出了两种有效的算法:单向算法和双正交方向算法,用于从不平衡响应中识别转子的不平衡情况。SUN等^[15]提出了一种结合矩阵方程和谱修正技术(spectral correction technique, SCT)的基于时域响应的不平衡参数识别方法。张茹鑫等^[16]集成了遗传算法和粒子群优化算法来识别不平衡量。ZOU等^[17]提出了一种利用转子有限元模型结合增广卡尔曼滤波(augmented Kalman filtering, AKF)算法的不平衡载荷识别方法。TIWARI等^[18]基于虚拟试验不对中策略,开发了基于模型的识别算法。但是,优化算法在进行不平衡量识别求解时需要进行大量迭代运算以逐步逼近最优解,收敛速度缓慢,甚至陷入局部最优解或者收敛到不理想的解,影响不平衡识别精度和效率。

深度学习研究近年来备受关注,在旋转设备故障诊断等诸多领域得到应用^[19]。深度学习可以从数据中学习逆映射来解决输入识别问题,对映射的学习可以用平衡过程的数据进行处理^[20],这意味着不平衡量识别不需要额外的数据或先验知识。此外,深度学习模型经过训练并收敛到一个满意的解决方案后,该模型就可以用于不平衡识别任务,识别过程不再需要迭代。深度学习为解决转子的无试重不平衡量识别提供了新

的视角和可能性。

本文提出一种结合卷积神经网络(convolutional neural network, CNN)和门控循环单元(gated recurrent unit, GRU)的混合模型(CNN-GRU)来进行转子不平衡量的无试重识别。

1 原理及方法

不平衡量可以被视为转子系统的输入激励,振动则是输出响应。无试重不平衡量识别则需要将转子振动信号作为输入,不平衡量识别结果作为输出。这需要具体描述转子系统的传递函数,建立失衡和振动之间的联系。但是,实际中转子的不平衡量和振动响应之间的映射关系可能相当复杂,特别是在考虑到转子系统的非线性和多物理场的情况下。深度学习是一种用于数学模型不清晰或非线性系统预测的智能技术^[21],能提供一种有效的途径来捕捉二者之间的复杂映射关系,将转子不平衡量的识别归为一种多变量输入和多变量输出的回归预测问题。

1.1 转子系统的动力学建模及理论响应求解

由于实际中很难收集到足够多的带标签样本来训练一个可靠的不平衡识别深度模型,因此本研究通过构建转子动力学模型,添加模拟不平衡量进行仿真,从而生成足够多的带标签训练数据样本。

本研究采用有限元法建立转子系统动力学模型,如图1所示,转子动力学模型核心组件包括轴承、轴以及平衡配重盘等。选用Timoshenko梁单元来构造轴的动力学模型,赋予每个节点4个自由度以描述其动态特性。配重圆盘被视为刚体且具有集中质量的效应,通过一个含单一节点、4个自由度的单元来进行模拟。本研究中轴承为含油轴承,忽略轴承的质量,将轴承简化为转子系统两端具有4个自由度的刚度与阻尼组件。上述构建过程中的4个自由度为:沿 y 、 z 轴方向的平移自由度和绕 y 、 z 轴的转动自由度。轴承的刚度、阻尼由沿 y 、 z 轴方向的平移刚度、阻尼和绕 y 、 z 轴的转




图1 转子系统的有限元模型
Fig.1 Finite element model of the rotor system

动刚度、阻尼构成。

转子系统的整体动力学方程为

$$(M_r + M_d)\ddot{u} + [\omega(G_r + G_d) + (D_r + D_b)]\dot{u} + (K_r + K_b)u = F_s \quad (1)$$

式中： M 、 G 、 K 和 D 分别为质量矩阵、陀螺矩阵、刚度矩阵和阻尼矩阵； ω 为转速； F_s 为转子系统受到的不平衡外力激励矩阵； u 为转子系统整体的位移矢量；下标r、b、d分别表示轴、轴承、圆盘。

如图2所示，转子系统受到的不平衡量可以定义为y、z方向上的不平衡分量：

$$B_y = mr \cos \theta \quad (2)$$

$$B_z = mr \sin \theta \quad (3)$$

式中： m 为不平衡质量； r 为不平衡偏心距。

则y、z方向上的不平衡力为

$$F_y = B_y \omega^2 \cos \omega t - B_z \omega^2 \sin \omega t \quad (4)$$

$$F_z = B_z \omega^2 \cos \omega t + B_y \omega^2 \sin \omega t \quad (5)$$




图2 转子系统的不平衡量

Fig.2 The unbalance of the rotor system

式(4)和式(5)可以改写为

$$\begin{pmatrix} F_y \\ F_z \end{pmatrix} = \begin{bmatrix} B_y \omega^2 & -B_z \omega^2 \\ B_z \omega^2 & B_y \omega^2 \end{bmatrix} \begin{pmatrix} \cos \omega t \\ \sin \omega t \end{pmatrix} \quad (6)$$

因此转子系统受到的整体不平衡力为

$$F_s = f_c \cos(\omega t) + f_s \sin(\omega t) \quad (7)$$

$$F_s = \begin{pmatrix} F_y \\ F_z \end{pmatrix} \quad f_c = \begin{pmatrix} B_y \omega^2 \\ B_z \omega^2 \end{pmatrix} \quad f_s = \begin{pmatrix} -B_z \omega^2 \\ B_y \omega^2 \end{pmatrix}$$

对式(1)进行求解，即可得到转子系统的不平衡响应 u 关于不平衡力 F_s 的稳态解：

$$u = u_c \cos(\omega t) + u_s \sin(\omega t) \quad (8)$$

$$\begin{pmatrix} u_c \\ u_s \end{pmatrix} = \begin{bmatrix} A & B \\ -B & A \end{bmatrix} \begin{pmatrix} f_c \\ f_s \end{pmatrix}$$

$$A = K_r + K_b - \omega^2(M_r + M_d)$$

$$B = \omega[\omega(G_r + G_d) + (D_r + D_b)]$$

1.2 不平衡响应数据的多维复向特征融合

单个不平衡响应数据涉及多个测振截面与多个传感器。每个传感器测量到的振动幅值和相位构成了一个复数向量，每个传感器对应一个维度，因此形成一个多维复向量特征空间。

现有方法是将幅值和相位作为两种不同的实数特征输入模型，但二者的量纲和范围不同，即使经过归一化或标准化处理，它们固有的量纲和性质差异仍然可能对模型学习产生较大影响。

为消除幅值和相位量纲和范围的差异性，采用全息谱分析法来处理转子不平衡响应的振幅和相位。如图3所示，对转子单个测振截面y、z方向的时域信号进行快速傅里叶变换后，将不同频率分量进行合成可以得到一系列全息椭圆，用这一系列椭圆可以有效描绘转子的不平衡振动响应，实现对振幅与相位的统一表征。转子系统第 i 个测振截面上y、z方向振动的转频分量可以描述为

$$\left. \begin{aligned} y_i &= A_i \cos(2\pi\omega t + \alpha_i) \\ z_i &= B_i \cos(2\pi\omega t + \beta_i) \end{aligned} \right\} \quad (9)$$

式中： y_i 、 z_i 为第 i 个测振截面上y、z方向上的等效时域信号； t 为时间； A_i 、 B_i 为第 i 个测振截面上y、z方向上转频振动的振幅； α_i 、 β_i 为第 i 个测振截面上y、z方向上转频振动的振幅相位。




图3 全息谱与频谱的关系

Fig.3 The relation between holospectrum and spectrum

进一步分解得

$$\left. \begin{aligned} y_i &= s_{yi} \sin(\omega t) + c_{yi} \cos(\omega t) \\ z_i &= s_{zi} \sin(\omega t) + c_{zi} \cos(\omega t) \end{aligned} \right\} \quad (10)$$

式中： s_{yi} 、 s_{zi} 为第 i 个测振截面振动椭圆的正弦项系数； c_{yi} 、 c_{zi} 为第 i 个测振截面振动椭圆的余弦项系数。

所以可以对转子不平衡响应的振幅和相位作如下转换：

$$\begin{bmatrix} A_1 & \alpha_1 & B_1 & \beta_1 \\ A_2 & \alpha_2 & B_2 & \beta_2 \\ \vdots & \vdots & \vdots & \vdots \\ A_n & \alpha_n & B_n & \beta_n \end{bmatrix} \Rightarrow \begin{bmatrix} s_{y1} & c_{y1} & s_{z1} & c_{z1} \\ s_{y2} & c_{y2} & s_{z2} & c_{z2} \\ \vdots & \vdots & \vdots & \vdots \\ s_{yn} & c_{yn} & s_{zn} & c_{zn} \end{bmatrix} \quad (11)$$

式中： n 为转子系统的测振截面数量。

经过转换，转子不平衡响应的振幅和相位特征可以融合为同种量纲和范围一致的特征：测振截面振动椭圆的正、余弦项系数，实现了转子不平衡响应的多维复向量特征融合。

1.3 CNN-GRU模型构建

1.3.1 卷积神经网络

CNN擅长发掘图像及数据集中的空间特征，

而一维CNN则是针对序列数据分析的理想方案,在时序特征识别与提取任务中具有卓越效能^[22]。单维度卷积核的设计减少了模型训练所需的参数数量和算法的总体复杂度,其结构如图4所示。




图4 一维 CNN 模型结构图

Fig.4 1D-CNN model structure diagram

卷积层运算表达式可形式化为

$$C(\Phi) = \sum_{q=0}^{k-1} W(q)X(\Phi + qs) + b_c \quad (12)$$

式中: Φ 为输出序列的位置索引; $C(\Phi)$ 为输出特征序列在位置 Φ 的值; k 为卷积核大小; s 为移动步长; q 为卷积核在输入序列上滑动的位置索引; $W(q)$ 为卷积核权重向量的第 q 个元素; $X(\Phi + qs)$ 为输入序列 X 在位置 $\Phi + qs$ 的值; b_c 为卷积层的偏置项。

卷积操作完成后,ReLU激活函数介入:

$$ReLU(x) = \max(0, x) \quad (13)$$

池化层降维特征,其操作定义如下:

$$P(\Phi) = \max_{l=0}^{p-1} X(\Phi + ls) \quad (14)$$

式中: $P(\Phi)$ 为池化后输出序列在位置 Φ 的最大值; p 为池化窗口大小; l 为遍历池化窗口内的索引。

全连接层神经元的输出计算公式为

$$y_g = ReLU\left(\sum_{j=1}^N w_{gj}x_j + b_g\right) \quad (15)$$

式中: y_g 为第 g 个神经元的输出; w_{gj} 为从第 j 个输入神经元到第 g 个输出神经元的权重; x_j 为第 j 个输入特征值; N 为输入神经元总数; b_g 为第 g 个神经元的偏置项。

1.3.2 门控神经单元

GRU作为循环神经网络(RNN)的一种精妙变体,用于捕获并分析不平衡样本数据中的时序依赖特征。它结合了长短期记忆网络(LSTM)的一些设计理念,但结构更为简洁,能够以较少参数实现高速训练并保持识别精度^[23],其结构如图5所示。

GRU通过更新门(update gate)和重置门(reset gate)来解决长期依赖问题,这两个门都是使用sigmoid函数计算得到的,计算公式为

$$g_{ate,z} = sigmoid(W_z[h_{t-1}, X_t] + b_z) \quad (16)$$

$$g_{ate,r} = sigmoid(W_r[h_{t-1}, X_t] + b_r) \quad (17)$$

式中: h_{t-1} 为前一时间步的隐藏状态; X_t 为当前时间步的

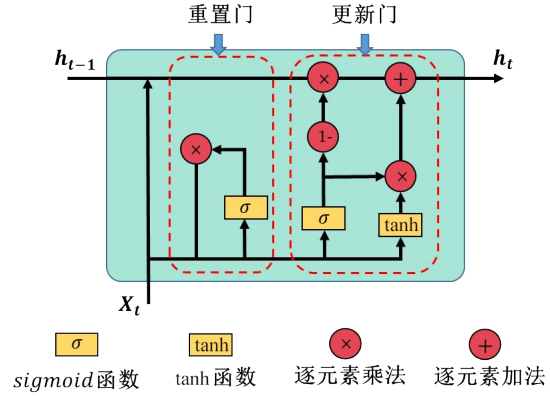


图5 GRU模型结构图

Fig.5 GRU model structure diagram

输入; W_z 和 b_z 分别为更新门相应的权重矩阵和偏置项; W_r 和 b_r 分别为重置门相应的权重矩阵和偏置项。

由上述信息可以计算候选隐藏状态 \tilde{h}_t 及隐藏状态 h_t :

$$\tilde{h}_t = \tanh(W_h(g_{ate,r} \odot h_{t-1}, X_t) + b_h) \quad (18)$$

$$h_t = (1 - g_{ate,z}) \odot \tilde{h}_t + g_{ate,z} \odot h_{t-1} \quad (19)$$

式中:“ \odot ”表示逐元素乘法; W_h, b_h 分别为模型的权重矩阵和偏置项;双曲正切函数 $\tanh(\cdot)$ 作为激活函数。

1.3.3 CNN-GRU模型结构

本研究所构建的转子不平衡量识别CNN-GRU模型如图6所示。通过由2个卷积层和2个池化层组成的CNN模块捕捉样本序列数据的空间特征。通过由2个GRU层和2个全连接层组成的GRU模块捕捉样本序列数据的时间依赖性。将转子不平衡数据样本分别输入CNN模块和GRU模块,将二者的输出结果通过拼接层进行连接,输入至全连接层,最终输出转子不平衡量的识别序列:

$$Y = f(W(y, h) + b_y) \quad (20)$$

式中: W, b_y 分别为全连接层的权重矩阵和偏置项; y, h 分别为CNN模块和GRU模块提取到的特征; f 为线性激活函数(linear)。

为加快模型收敛速度对所有数据进行归一化处理:

$$X_{sea} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (21)$$

式中: X 为原始数据; X_{sea} 为归一化后的数据; X_{max}, X_{min} 分别为数据的最大值和最小值。

需要注意的是,在模型构建的过程中,虽然进行了数据的归一化处理,但我们并没有改变数据的原有信息内容,只是进行了尺度上的调整。

确保模型识别的高准确性是本研究的核心目标,需要使识别结果和真实值的均方根误差(RMSE)和平均绝对误差(MAE)尽可能趋近于

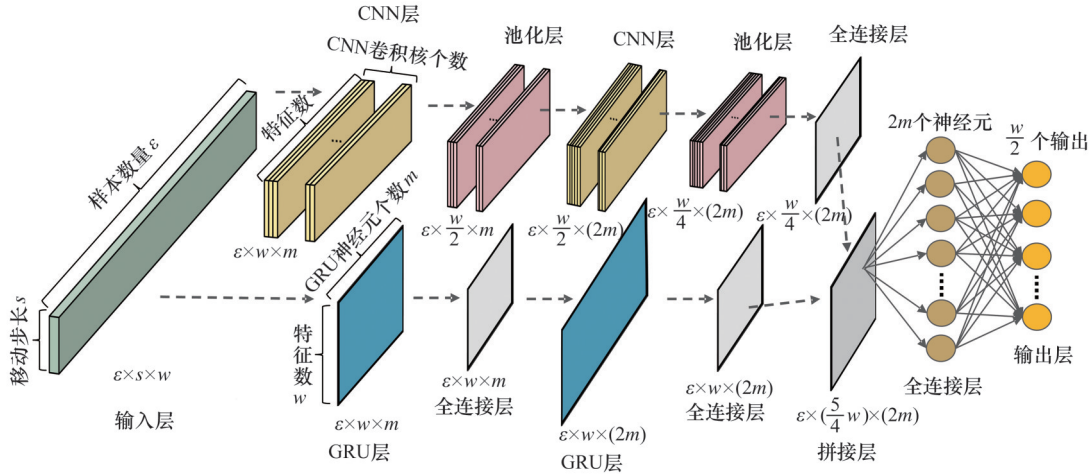


图6 CNN-GRU模型结构示意图

Fig.6 CNN-GRU model structure diagram

零,所以本研究将这两项作为模型性能的评价指标。计算公式如下:

$$E_{RMSE} = \sqrt{\frac{1}{\epsilon} \sum_{\lambda=1}^{\epsilon} (y_{\lambda} - \hat{y}_{\lambda})^2} \quad (22)$$

$$E_{MAE} = \frac{1}{\epsilon} \sum_{\lambda=1}^{\epsilon} |y_{\lambda} - \hat{y}_{\lambda}| \quad (23)$$

式中: y_{λ} 为第 λ 个识别结果的真实值; \hat{y}_{λ} 为第 λ 个模型预测值; ϵ 为样本总数量。

为了有效优化两项评价指标,选择 Huber 函数作为损失函数:

$$Huber = \begin{cases} \frac{1}{2} (y_{\lambda} - \hat{y}_{\lambda})^2 & |y_{\lambda} - \hat{y}_{\lambda}| \leq \delta \\ \delta (|y_{\lambda} - \hat{y}_{\lambda}| - \frac{\delta}{2}) & |y_{\lambda} - \hat{y}_{\lambda}| > \delta \end{cases} \quad (24)$$

式中: δ 为自定义的阈值,范围为 [0.01, 0.1]。

1.4 不平衡识别流程

图7所示为本研究提出的结合多维复向特征融合与CNN-GRU的转子不平衡量识别流程,按照以下步骤实现:

1) 依据转子的几何构造与物理属性构建精细的转子动力学模型,并实施自动化仿真模拟。生成大量带标签的转子不平衡数据样本,作为后续模型学习训练的数据集。

2) 对采集到的不平衡振动样本数据进行多维复向特征融合处理。

3) 在特征融合的基础上对整合的数据集按照预定比例分隔为训练子集、验证子集及测试子集,执行归一化预处理和时间步长堆叠处理。

4) 启动 CNN-GRU 模型的训练流程,并随之开展识别精度的评估。通过利用该训练完成的模型从输出层获取蕴含转子不平衡量信息的数据。这一过程实质上是对被检测转子不平衡状态的有效辨识与量化。

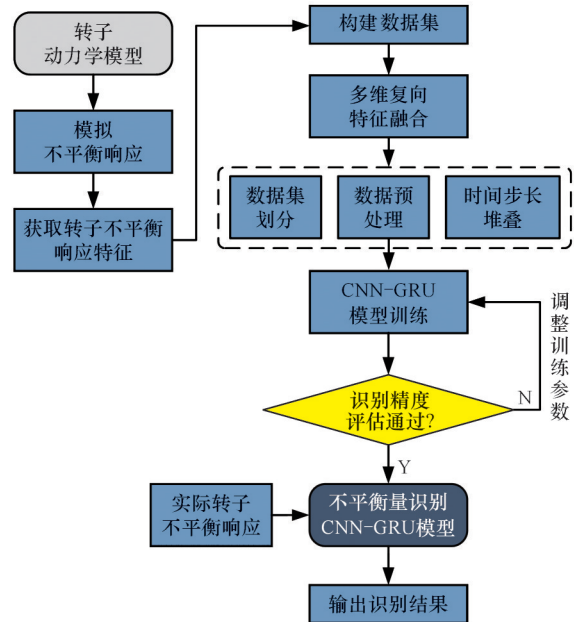


图7 转子不平衡量识别流程

Fig.7 Rotor unbalance identification process

2 实验结果与分析

2.1 实验装置与训练数据集准备

如图8所示,本研究构建了一套带有2个配重圆盘的转子系统实验平台。平台构成元件有:电机、控制器、联轴器、轴、轴承、配重圆盘、位移传感器以及用以记录数据的数据采集卡和相关线缆。在配重圆盘上按22.5°的等角度布局嵌入了16个螺孔,用于不平衡量调整螺丝的安装。

传感器布置如图9所示,集成有5个电涡流位移传感器。装置的左侧的是键相器,其功能在于提供转子转动的精确相位信息。此外,针对两个不同的横向截面分别安装了4组测振传感器,即在第一个截面上标示为1-Z、1-Y的两个传感器,以及第二个截面上对应的2-Z、2-Y传感器,这样




图8 转子系统不平衡响应实验平台

Fig.8 Unbalance response test bench of rotor system




图9 转子系统传感器布置示意图

Fig.9 Sensor layout diagram of rotor system

的布局旨在全方位监测转子的振动响应。

测量试验台几何参数并查阅试验台说明手册得到表1所示的构建参数,在MATLAB中建立了图10所示的转子系统数值模型,划分为13个轴段,14个节点,轴承位于转子系统两端。两个转盘分别置于第5和第10个节点上,测振截面设置为第2和第13个节点所对应的转子截面,每个截面设置 x,y 两个方向的测点。在配重圆盘上施加不同质量和角度的不平衡量,通过编写脚本进行自动化仿真,模拟不同不平衡量的振动响应数据,得到共9408组不平衡振动样本,每个样本的构成如表2所示。

表1 转子系统动力学模型的构建参数

Tab.1 Construction parameters of the rotor system dynamical model

参数	数值
轴长/mm	390
轴直径/mm	10
圆盘直径/mm	75
圆盘宽度/mm	26
弹性模量/GPa	210
泊松比	0.3
密度/($\text{kg}\cdot\text{m}^{-3}$)	7.8×10^3
轴承刚度/($\text{N}\cdot\text{m}^{-1}$)	1.0000×10^5
轴承阻尼/($\text{N}\cdot\text{s}\cdot\text{m}^{-1}$)	3.0000×10^3

2.2 CNN-GRU 模型训练

构建好样本数据集后,依照8:1:1的比例将数据集划分为训练子集验证子集和测试子集,然后进行数据预处理和多维复向特征融合,使用搭




图10 转子系统模型(mm)

Fig.10 Rotor system model(mm)

表2 单个转子不平衡样本数据构成

Tab.2 Data composition of a rotor unbalance sample

数据样本							
1-Z 幅值	1-Y 幅值	2-Z 幅值	2-Y 幅值	1-Z 相位	1-Y 相位	2-Z 相位	2-Y 相位
标签							
质量1		角度1		质量2		角度2	

建的CNN-GRU模型进行不平衡识别训练。

在优化模型配置的过程中,通过交叉验证实验分析与调整,制定了表3所示的模型参数配置方案。此配置细化到每一层级的输入、输出形状及其特有参数,展现了配置的灵活性与泛用性。采用Adam优化器作为学习驱动力,依赖Keras框架提供的默认策略来初始化权重与设定学习速率,以此平衡计算效率与模型收敛速度。计算机使用NVIDIA GTX 1660显卡,搭配14GB内存的

表3 CNN-GRU模型结构参数设计

Tab.3 CNN-GRU model structural parameter design

网络结构	输入形状	输出形状	参数设置
输入层		($\epsilon, 8, 1$)	
CNN层-1	($\epsilon, 8, 1$)	($\epsilon, 8, 32$)	核数量32;核大小3;激活函数ReLU
池化层-1	($\epsilon, 8, 32$)	($\epsilon, 4, 32$)	池化核大小2
CNN层-2	($\epsilon, 4, 32$)	($\epsilon, 4, 64$)	核数量64;核大小3;激活函数ReLU;
池化层-2	($\epsilon, 4, 64$)	($\epsilon, 2, 64$)	池化核大小2
CNN全连接层	($\epsilon, 2, 64$)	($\epsilon, 2, 128$)	神经元数量128;激活函数ReLU
GRU层-1	($\epsilon, 8, 1$)	($\epsilon, 8, 32$)	神经元数量32;激活函数tanh
GRU全连接层-1	($\epsilon, 8, 32$)	($\epsilon, 8, 64$)	神经元数量64;激活函数ReLU
GRU层-2	($\epsilon, 8, 64$)	($\epsilon, 8, 64$)	神经元数量64;激活函数tanh
GRU全连接层-2	($\epsilon, 8, 64$)	($\epsilon, 8, 128$)	神经元数量128;激活函数ReLU
拼接层	($\epsilon, 2, 128$) ($\epsilon, 8, 128$)	($\epsilon, 10, 128$)	拼接维度2
扁平层	($\epsilon, 10, 128$)	($\epsilon, 1280$)	
CNN-GRU全连接层	($\epsilon, 1280$)	($\epsilon, 64$)	神经元数量64;激活函数ReLU
输出层	($\epsilon, 64$)	($\epsilon, 4$)	神经元数量4;激活函数linear

硬件配置。

模型训练轮次上限设置为 5000, 为进一步增强模型的泛化能力并遏制过拟合风险, 在训练流程中融入了早期停止 (early stopping) 回调机制。该机制密切监视验证集上的性能指标, 一旦发现验证性能提高停滞, 即刻终止训练, 从而有效防护模型免于陷入过度拟合的陷阱, 保障了模型的稳健性和实用性。

训练过程中的评价指标变化如图 11 所示, 损失函数值变化如图 12 所示。训练集和验证集 RMSE 和 MAE 以及损失函数值都呈现出稳步下降的趋势, 并最终逼近零值, 趋向于一个稳定的收敛点。

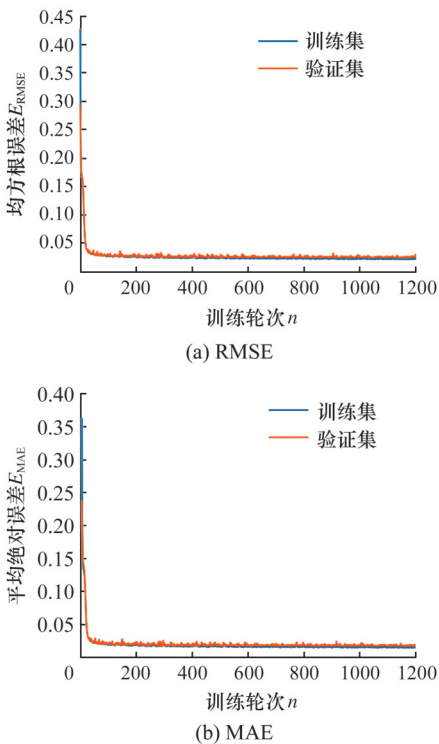


图 11 CNN-GRU 模型的评价指标变化曲线
Fig.11 Evaluation index change curve of CNN-GRU model

表 4 多维复向特征融合前后 CNN-GRU 模型预测性能

Tab.4 Prediction performance of CNN-GRU model before and after multi-dimensional complex feature fusion

	RMSE	RMSE变化率/%	MAE	MAE变化率/%	损失函数值 L_{oss}	损失函数值变化率/%
融合前	9.193×10^{-2}	71.64	4.882×10^{-2}	63.66	2.587×10^{-3}	86.87
融合后	2.607×10^{-2}		1.774×10^{-2}		3.399×10^{-4}	

表 5 不同模型结构性能分析对比

Tab.5 Structural performance analysis and comparison of different models

模型	RMSE	RMSE变化率/%	MAE	MAE变化率/%	损失函数值 L_{oss}	损失函数值变化率/%
CNN	8.123×10^{-2}	67.91	6.899×10^{-2}	74.29	1.057×10^{-3}	67.84
RNN	7.687×10^{-2}	66.09	6.046×10^{-2}	70.65	7.302×10^{-4}	53.45
LSTM	5.607×10^{-2}	53.50	5.782×10^{-2}	69.31	6.415×10^{-4}	47.01
GRU	4.956×10^{-2}	47.40	3.914×10^{-2}	54.67	5.676×10^{-4}	40.11
CNN-LSTM	3.607×10^{-2}	27.72	3.056×10^{-2}	41.95	4.311×10^{-4}	21.16
CNN-GRU	2.607×10^{-2}		1.774×10^{-2}		3.399×10^{-4}	




图 12 CNN-GRU 模型的训练损失曲线

Fig.12 Training loss curve of CNN-GRU model

这表明模型在学习训练数据方面具有高效性, 且在验证集上具有泛化能力。

2.3 模型性能分析

2.3.1 多维复向特征融合效果分析

本研究采用双轨数据集进行模型训练对比: 一组基于未经融合的多维度特征训练 CNN-GRU 模型, 另一组用多维复向特征融合方法处理后再行训练。实验结果如表 4 所示, 清晰揭示了两组实验在模型性能上的显著差异。

通过对比两组实验的评估指标和损失函数值可以发现, 采用多维度复向特征融合方法的模型, RMSE 和 MAE 分别下降了 71.64% 和 63.66%, 损失函数值下降了 86.87%, 表明该方法能够大幅度增进 CNN-GRU 模型的预测精确度与整体表现力。

2.3.2 模型结构性能分析

在统一的实验环境设置下, 采用了一致的训练集、验证集与测试集数据集, 系统地对比分析了 5 种典型模型, 具体结果如表 5 所示。结果显示, CNN-GRU 模型在多个关键的不平衡数据识别性能评价指标及降低损失率方面均显著提高, 验证了模型结构创新的有效性。

2.4 不平衡识别性能验证

将测试集中的不平衡数据输入训练好的 CNN-GRU 模型进行不平衡量识别,结果如图 13 所示,图中每个子图中横坐标的相同时间步长值表示同一个不平衡样本,纵坐标值表示不平衡质量和角度。可以看出模型识别结果与不平衡量的设置真实值有良好的一致性。本研究提出的 CNN-GRU 模型成功捕捉到转子不平衡量与转子不平衡振动响应之间的复杂映射关系,可以通过不平衡振动响应反向识别转子的不平衡量大小和角度。

为了更直观地展示 CNN-GRU 模型识别结果的准确性,在图 13 所示的数据中抽样 5 组绘制

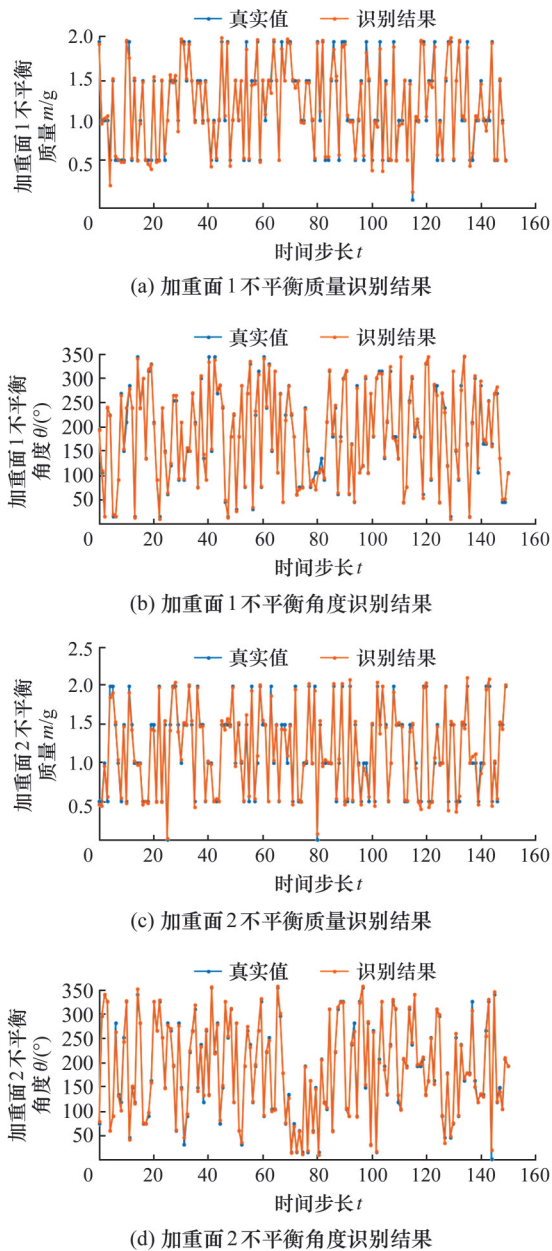


图 13 CNN-GRU 模型不平衡量识别结果
Fig.13 Unbalance identification results of CNN-GRU model

成图 14 所示的极坐标图,图中极轴长度表示不平衡质量大小,角度表示不平衡量的角度。表 6 详列了真实值与识别结果的直接比较及误差分析,质量平均相对误差为 5.56%,角度平均相对误差为 0.719%。从表 6 可以看出,模型在处理转子轻度不平衡情形时,尽管质量相对误差偏高,但识别的绝对偏差仍控制在 0.05g 以内;而面对较严重的不平衡状况,模型识别的相对误差维持在低于 5% 的水平。综上所述,该 CNN-GRU 模型在转子不平衡量识别任务上,不论不平衡程度如何,均能提供准确且稳定的结果,验证了其有效性和鲁棒性。

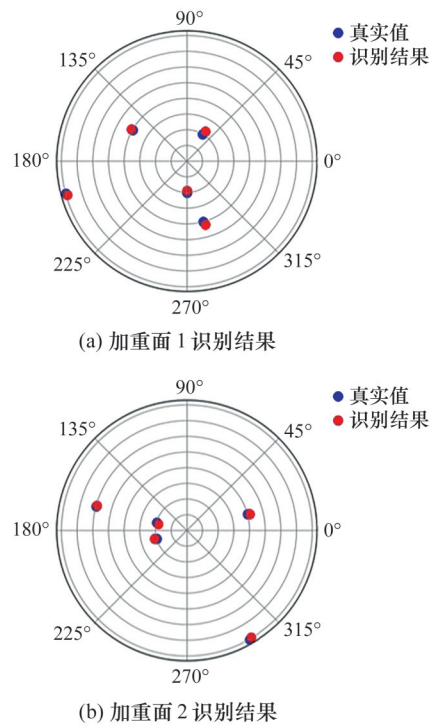


图 14 测试集数据不平衡量识别结果

Fig.14 Unbalance identification results of test set data

通过图 8 所示的双盘转子实验平台进行实验验证,在确保转子试验台处于平衡状态后,在配重圆盘上设置不同的不平衡量,将其不平衡振动数据输入 CNN-GRU 模型来识别转子的不平衡质量,如图 15 所示,识别效果仍然比较准确。真实值与识别结果对比及误差分析如表 7 所示,质量平均相对误差为 5.958%,角度平均相对误差为 4.32%,可以看出 CNN-GRU 模型在试验台上也取得了较为准确的识别效果。

对比实验台与测试集数据识别结果,实验台识别误差整体略有偏大,但仍在可接受范围内,本实验的识别结果可以认为是准确的。误差略有偏大是由于转子动力学模型相比实际转子系统有所简化,对 CNN-GRU 模型的训练效果产生影响。

表6 测试集数据不平衡量识别结果及误差


Tab.6 Unbalance identification results and errors of test set data

序号	位置	不平衡质量/g	识别质量/g	质量相对误差/%	不平衡角度/(°)	识别角度/(°)	角度相对误差/%
1	加重面1	1.0	1.02	2	150	149.93	0.047
	加重面2	1.0	1.03	3	15	14.77	1.53
2	加重面1	1.0	1.05	5	285	286.27	0.44
	加重面2	0.5	0.56	14	195	193.69	0.7
3	加重面1	0.5	0.56	12	60	59.09	1.52
	加重面2	2.0	1.98	1	300	300.94	0.31
4	加重面1	0.5	0.47	6	270	269.37	0.23
	加重面2	0.5	0.47	6	165	167.31	1.4
5	加重面1	2.0	1.98	1	195	195.57	0.29
	加重面2	1.5	1.49	0.67	165	164.70	0.18


表7 实验台不平衡量识别结果及误差

Tab.7 Unbalance identification results and errors of test bench

序号	位置	不平衡质量/g	识别质量/g	质量相对误差/%	不平衡角度/(°)	识别角度/(°)	角度相对误差/%
1	加重面1	0.8	0.85	6.25	45	48.89	8.64
	加重面2	0.8	0.84	5	135	132.45	1.85
2	加重面1	0.8	0.75	6.25	90	95.46	6.07
	加重面2	1.2	1.27	5.83	180	189.55	5.31
3	加重面1	1.2	1.14	5	180	187.56	4.2
	加重面2	1.2	1.26	5	90	85.57	4.92
4	加重面1	1.2	1.29	7.5	90	94.72	5.24
	加重面2	0.8	0.86	7.5	180	185.22	2.9
5	加重面1	0.8	0.85	6.25	180	183.55	1.97
	加重面2	0.8	0.76	5	270	275.63	2.09



(a) 加重面1 识别结果



(b) 加重面2 识别结果

图15 试验台不平衡量识别结果

Fig.15 Unbalance identification results of test bench

因此在实践应用中,建立转子动力学模型后需与实际转子进行响应比对,若响应之间有较大误差,需对转子模型进行修正来保证二者之间有良好的关联性,进而保证识别结果的精确性。

在识别效率方面,本研究所提出的CNN-GRU模型通过深度学习原理直接捕捉不平衡量与振动响应之间的关联。训练完毕的CNN-GRU模型能够在极短时间内输出不平衡量的识别结果,并且具备同时处理多个不平衡样本的能力。这种方法省略了迭代求解的过程,显著提高了计算效率。表8展示了CNN-GRU模型与两种传统的优化算法在识别效率方面的对比结果。

表8 CNN-GRU模型识别效率的对比

Tab.8 Comparison of CNN-GRU model identification efficiency

识别方法	CNN-GRU	遗传算法	粒子群优化算法
单次识别样本数	10	1	1
用时/s	0.56	406	298

3 结论

本文针对现有的无试重不平衡量识别算法采用优化算法框架,存在收敛速度迟缓与易于陷入局部极值的局限性,提出了基于多维复向特征融合与CNN-GRU的不平衡量识别方法。主要结论如下:

1)采用多维复向特征融合方法处理不平衡振动数据特征,将振动幅值和相位进行统一,消除了二者的量纲、范围的差异以及内在复杂非线性关

系,改善了模型学习能力和不平衡量识别效果。实验结果表明:经特征融合后,模型的RMSE和MAE分别下降了71.64%和63.66%,模型的损失函数值下降了86.87%。

2)将CNN-GRU与其他深度学习模型对比发现,CNN-GRU的评价指标和训练损失率表现最优。相较于其他模型,CNN-GRU的RMSE下降了27.72%~67.91%,MAE下降了41.95%~74.29%,损失函数值下降了21.16%~67.84%,CNN-GRU的不平衡识别效果最好。

3)不平衡识别验证结果表明,基于多维复向特征融合与CNN-GRU的方法成功识别出转子系统的不平衡量,与设置不平衡量高度接近,证实了本研究方法的可行性和准确性。

4)本研究提出的不平衡量识别模型在单次识别操作中无需经历传统优化算法所需的多次迭代优化步骤即可直接输出准确的识别结果,在无试重的现场动平衡评估及在线不平衡量预测场景下,实现了效率的显著提高,节约计算资源并增强了实时处理能力。

参考文献:

- [1] ZHAO Shibo, REN Xingmin, DENG Wangqun, et al. A Transient Characteristic-based Balancing Method of Rotor System without Trail Weights[J]. Mechanical Systems and Signal Processing, 2021, 148:107117.
- [2] SUN Xun, CHEN Yue, CUI Jiwen. A Balancing Method for Multi-disc Flexible Rotors without Trial Weights[J]. Energies, 2022, 15(14):5088.
- [3] 邬立建. 影响系数法在现场动平衡中的应用[J]. 冶金动力, 2005, 24(1):55-57.
- WU Lijian. Application of the Influence Coefficient Method in In-situ Dynamic Balance[J]. Metallurgical Power, 2005, 24(1):55-57.
- [4] 张雪辉, 焦瀚晖, 胡东旭, 等. 旋转机械现场动平衡方法研究进展[J]. 机电工程, 2021, 38(11):1367-1377.
- ZHANG Xuehui, JIAO Hanhui, HU Dongxu, et al. Research Progress on Field Dynamic Balancing Method of Rotating Machinery[J]. Journal of Mechanical & Electrical Engineering, 2021, 38(11):1367-1377.
- [5] 张登鹏. 高速旋转机械无试重动平衡方法与研究[D]. 北京:北京化工大学, 2021.
- ZHANG Dengpeng. Research on Dynamic Balancing Method of High Speed Rotating Machinery without Trial Weight[D]. Beijing: Beijing University of Chemical Technology, 2021.
- [6] 章云, 王晓宇, 梅雪松. 高速转子无试重动平衡方法研究现状分析[J]. 振动与冲击, 2022, 41(21):216-227.
- ZHANG Yun, WANG Xiaoyu, MEI Xuesong. Studying Status Review for High-speed Rotor Dynamic Balancing Method without Trial Weights[J]. Journal of Vibration and Shock, 2022, 41(21):216-227.
- [7] 王文宇, 吴法勇, 金彬. 基于建模仿真分析的模拟转子平衡技术[J]. 航空发动机, 2023, 49(3):147-154.
- WANG Wenyu, WU Fayong, JIN Bin. Simulated Rotor Balancing Technology Based on Mathematical Model and Simulation Analysis [J]. Aeroengine, 2023, 49(3):147-154.
- [8] WANG Tianzhu, DING Qian. Modal Balancing for Ball Bearing-rotor System Using Nonlinear Normal Modes[J]. Journal of Sound and Vibration, 2023, 547:117507.
- [9] DENG Wangqun, TONG Mengyu, ZHENG Qingyang, et al. Investigation on Transient Dynamic Balancing of the Power Turbine Rotor and Its Application [J]. Advances in Mechanical Engineering, 2021, 13(4):16878140211007325.
- [10] 王晓宇. 基于动力学分析的高速转子无试重动平衡方法研究[D]. 西安:西安电子科技大学, 2022.
- WANG Xiaoyu. Research on Dynamic Balance Method of High-speed Rotor without Trial Weight Based on Dynamic Analysis[D]. Xi'an: Xidian University, 2022.
- [11] 胡谢努. 旋转机械不平衡校正:影响系数法与全息平衡法[D]. 武汉:华中科技大学, 2009.
- HU Xienu. Unbalance Correction of Rotating Machinery: Influence Coefficient Method and Holographic Balance Method[D]. Wuhan: Huazhong University of Science and Technology, 2009.
- [12] DENG Weikun, NGUYEN K T P, MEDJAHHER K, et al. Rotor Dynamics Informed Deep Learning for Detection, Identification, and Localization of Shaft Crack and Unbalance Defects[J]. Advanced Engineering Informatics, 2023, 58:102128.
- [13] 刘亮, 姚剑飞, 高树成, 等. 基于果蝇算法的转子不平衡参数辨识研究[J]. 北京化工大学学报(自然科学版), 2018, 45(3):79-83.
- LIU Liang, YAO Jianfei, GAO Shucheng, et al. Identification of Rotor Unbalance Parameters Based on a Fruit Fly Algorithm[J]. Journal of Beijing University of Chemical Technology (Natural Science Edition), 2018, 45(3):79-83.

- [14] WANG Aiming, BI Yujie, XIA Yun, et al. Continuous Rotor Dynamics of Multi-disc and Multi-span Rotor: a Theoretical and Numerical Investigation on the Continuous Model and Analytical Solution for Unbalance Responses[J]. Applied Sciences, 2022, 12(9):4351.
- [15] SUN Xun, CUI Jiwen, CHEN Yue, et al. A Novel Method for Identifying Rotor Unbalance Parameters in the Time Domain[J]. Measurement Science and Technology, 2023, 34(3):035008.
- [16] 张茹鑫, 温广瑞, 张志芬, 等. 集成GA-PSO方法的转子系统多点不平衡量识别[J]. 振动测试与诊断, 2019, 39(4):801-809.
- ZHANG Ruxin, WEN Guangrui, ZHANG Zhifen, et al. Multi-unbalances Identification of Rotor System Integrated with GA-PSO Method[J]. Journal of Vibration, Measurement & Diagnosis, 2019, 39(4):801-809.
- [17] ZOU Donglin, ZHAO Han, LIU Gaoyu, et al. Application of Augmented Kalman Filter to Identify Unbalance Load of Rotor-bearing System: Theory and Experiment [J]. Journal of Sound and Vibration, 2019, 463:114972.
- [18] TIWARI R, KUMAR P. An Innovative Virtual Trial Misalignment Approach for Identification of Unbalance, Sensor and Active Magnetic Bearing Misalignment along with Its Stiffness Parameters in a Magnetically Levitated Flexible Rotor System [J]. Mechanical Systems and Signal Processing, 2022, 167:108540.
- [19] 康涛, 段蓉凯, 杨磊, 等. 融合多注意力机制的卷积神经网络轴承故障诊断方法[J]. 西安交通大学学报, 2022, 56(12):68-77.
- KANG Tao, DUAN Rongkai, YANG Lei, et al. Bearing Fault Diagnosis Using Convolutional Neural Network Based on a Multi-attention Mechanism[J]. Journal of Xi'an Jiaotong University, 2022, 56(12):68-77.
- [20] ZHONG Shun, LI Liqing, CHEN Huizheng, et al. A Novel Balancing Method for Rotor Using Unsupervised Deep Learning [J]. Shock and Vibration, 2021, 2021(1):1800164.
- [21] AHMED S F, ALAM M S B, HASSAN M, et al. Deep Learning Modelling Techniques: Current Progress, Applications, Advantages, and Challenges [J]. Artificial Intelligence Review, 2023, 56(11):13521-13617.
- [22] 吕阳, 廖与禾, 王报祥, 等. 基于VMD和CNN的滚动轴承故障定量诊断方法[J]. 中国科技论文, 2020, 15(7):735-742.
- LYU Yang, LIAO Yuhe, WANG Baoxiang, et al. Quantitative Diagnosis Method for Rolling Bearing Faults Based on VMD and CNN[J]. China Science-paper, 2020, 15(7):735-742.
- [23] HE Jiawen, ZHANG Xu, ZHANG Xuechang, et al. Remaining Useful Life Prediction for Bearing Based on Automatic Feature Combination Extraction and Residual Multi-head Attention GRU Network [J]. Measurement Science and Technology, 2024, 35(3):036003.

(编辑 王旻玥)

作者简介:王坚坚,男,1999年生,硕士研究生。研究方向为转子数字孪生、转子不平衡量无试重识别、转子-轴承系统智能诊断。E-mail:wangjianjian@stu.xjtu.edu.cn。廖与禾(通信作者),男,1973年生,副教授、博士研究生导师。研究方向为转子-轴承系统故障诊断、振动信号处理、早期故障诊断、智能诊断、转子动平衡。E-mail:yhliao@mail.xjtu.edu.cn。

本文引用格式:

王坚坚,廖与禾,杨磊,等. 基于多维复向特征融合与CNN-GRU的转子不平衡量识别方法[J]. 中国机械工程, 2025, 36(9):1905-1915.

WANG Jianjian, LIAO Yuhe, YANG Lei, et al. Rotor Unbalance Recognition Based on Multidimensional Complex Feature Fusion and CNN-GRU[J]. China Mechanical Engineering, 2025, 36(9):1905-1915.