

基于卷积自编码器的综合传动异常检测研究

贾然¹, 吴傲¹, 陈涛^{1†}, 郝乃芃¹, 王立勇¹, 赵津²

(1. 北京信息科技大学 现代测控技术教育部重点实验室, 北京 100192;

2. 北京福田康明斯发动机有限公司, 北京 102206)

摘要:针对特种车辆工作过程中综合传动装置的数据复杂性、正常与异常数据不平衡、传统统计学方法对综合传动传感器监测数据异常波动的漏报率和误报率较高等问题,提出一种基于注意力机制卷积自编码器(attention mechanism convolutional autoencoder, ACA)与支持向量机(support vector machine, SVM)耦合的 ACA-SVM 异常数据检测方法。根据履带装甲实车运行数据,对传感器监测数据进行数据预处理,采用注意力机制识别并聚焦检测数据中的核心元素,利用卷积自编码器(convolutional autoencoder, CAE)将原始数据降维提取特征,实现数据检测并得到重构误差和特征值。通过支持向量机进行分类和计算训练集数据样本的异常分数并与传统异常检测模型进行检测效果对比实验。实验结果表明,所提 ACA-SVM 方法在特种车辆综合传动数据上比 CAE、门控循环单元(gated recurrent unit, GRU)等模型检测效果更优异,异常检测准确率为 97.2%, F_1 值为 0.976。

关键词:异常检测;传动装置;漏油故障;卷积自编码器;注意力机制

中图分类号:TP277

文献标志码:A

Research on Integrated Transmission Anomaly Detection Based on Convolutional Autoencoder

JIA Ran¹, WU Ao¹, CHEN Tao^{1†}, HAO Naipeng¹, WANG Liyong¹, ZHAO Jin²

(1. Key Laboratory of Modern Measurement and Control Technology of the Ministry of Education, Beijing Information Science and Technology University, Beijing 100192, China;

2. Beijing Foton Cummins Engine Co., Ltd., Beijing 102206, China)

Abstract: To address the challenges in the integrated transmission devices of special vehicle working process, including complex data, the imbalance between normal and abnormal data and the high false alarm and underreporting rates of traditional statistical methods in detecting sensor anomalies, a new method, called ACA-SVM anomaly detection method, combining an attention mechanism convolutional autoencoder (ACA) with a support vector machine (SVM) is proposed. Using operation data from armored tracked vehicles, the monitoring data from integrated transmission sensors is preprocessed. Key features in the transmission data are identified and

* 收稿日期:2024-07-11

基金项目:北京市教委科研计划科技一般项目(KM202311232006), Beijing Municipal Commission of Education Science Research Program General Science and Technology Project(KM202311232006); 国家自然科学基金资助项目(52175074), National Natural Science Foundation of China (52175074)

作者简介:贾然(1989—),男,河北保定人,北京信息科技大学副研究员,博士

[†] 通信联系人, E-mail: chentao@bistu.edu.cn

focused by the attention mechanism. The convolutional autoencoder (CAE) then reduces the dimensionality of the original data and extracts features to facilitate data detection, resulting in the calculation of reconstruction errors and eigenvalues. The support vector machine classifies and calculates the abnormal scores of the training set data samples, and the detection performance is compared with the traditional anomaly detection models. Experimental results show that the proposed ACA-SVM method outperforms CAE, gated recurrent unit (GRU), and other models in detecting anomalies in the integrated transmission data of special vehicles, achieving a detection accuracy of 97.2% and an F_1 of 0.976.

Key words: anomaly detection; transmission device; oil leakage; convolutional autoencoder; attention mechanism

以装甲运兵车、装甲侦察车、步兵战斗车为代表的特种车辆装备是我国陆军现代化建设和国家安全战略的重要保障之一^[1]。其中,综合传动装置是实现特种车辆装备动力传输的关键设备。传动装置发生异常就会直接导致车辆的整体性能下降,进而造成严重损失^[2]。然而,综合传动装置运行状态数据量大、维度高且工况复杂多变,导致对其异常状态的准确判断尤为困难^[3]。为了及时发现综合传动装置运行过程中的潜在问题,确保其在执行任务过程中的安全性和可靠性,提高装备智能运维水平,研究数据驱动的综合传动装置异常检测方法具有十分重要的现实意义^[4]。

近年来,随着深度学习和大数据技术的快速发展,国内外学者针对基于数据驱动及深度学习的综合传动装置异常检测方法开展了大量的研究^[5]。徐峰等^[6]针对综合传动装置磨损过程中部分元素出现异常增长的情况,提出了一种基于油液光谱数据的异常磨损分析方法。该方法利用时间窗函数分离装备内部不同零部件磨损状态元素并实现了初步的故障定位,为综合传动装置磨损故障检测提供了方法。张丽霞等^[7]针对综合传动装置液压系统非线性、多耦合等工作特性导致的故障检测困难问题,建立了全局解析冗余关系和故障特征矩阵的对应关系,实现了故障检测和隔离,验证了采用全局解析冗余关系方法的混合系统在典型液压故障检测的可行性。刘勤等^[8]针对复杂装备机械结构复杂、故障模式多的问题,系统地梳理了多类典型机械故障机理,构建了故障物理模型和随机性分析模型,分析了故障模式间的相关性,实现了复杂机械系统可靠度和寿命的准确评估。马波等^[9]针对复杂机械装备运行状态特征信号呈现非平稳性导致单特征的异常检测及预

警方法存在准确率低的问题,提出了一种基于变分自编码器的故障预警方法。该方法利用变分自编码器学习高维特征的分布模型,将正常工况模型作为基准,通过计算实时工况与基准间的差异度,实现装备异常状态的检测与预警。吴锐等^[10]构建了履带车辆动力学模型并进行仿真,在加速、刹车与转向等工况下与履带车辆仿真工具包ATV进行对比实验,为履带车辆控制算法开发、测试与标定奠定基础。李贝贝等^[11]针对工业数据庞大、训练效率较低、异常检测效果差等问题,提出结合马氏距离和自编码网络的异常检测方法,将马氏距离作为特征加入训练中提升网络异常检测效果。实验结果表明,提出的方法较其他检测方法检测效果更好且具有一定的稳定性。李昊奇等^[12]针对高维数据异常检测困难问题,提出一种基于深度信念网络和单分类支持向量机的高维异常检测算法。实验结果表明,该算法在检测正确率和计算复杂度上均有明显优势。何家辉等^[13]引入字典学习改进一类支持向量机对多参数关联关系异常的识别性能,提出联合优化学习机制,以提升模型的检测效果和泛化能力。齐咏生等^[14]针对样本不足的问题,提出一种基于中心损失-改进卷积自编码器的异常检测方法,实现了在少量标记样本下的准确异常检测。宁子俊等^[15]针对综合传动装置运行过程中,工况变化等引起的数据异常难以有效区分的问题,提出了一种利用深度降噪自编码网络与支持向量数据描述的耦合模型对综合传动数据异常检测的方法,该方法为综合传动装置早期健康管理奠定基础。虽然深度学习在综合传动异常检测领域引起了广泛研究,但受限于数据分布和复杂的异常模式,难以适应多变的现实环境,仍存在复杂环境下多工况数据

检测困难等问题^[16]. 面对更高的检测需求,需要对特种车辆数据进行深度分析.

针对综合传动数据复杂且工况多变导致难以检测的问题,本文提出了一种基于注意力机制的卷积自编码器结合 SVM 的深度学习模型,用于特种车辆综合传动装置的异常检测. 该方法采取以卷积自编码器为主体结构,解码器输出端用注意力机制以突出重要特征,由深层编码器来提供分类器输入以检测数据异常的结构. 这种结构提取的特征具有高独立性和低耦合性的优点,解决了异常检测多维数据特征表达能力弱、噪声敏感的问题. 通过现场车辆运行实例数据验证表明,所提出的方法能够快速准确检测综合传动中的异常数据,异常检测的准确率为 97.2%,取得了较好的检测结果.

1 异常检测方法

1.1 算法框架

综合传动装置异常检测方法流程图如图 1 所




图 1 综合传动装置异常检测方法流程图

Fig.1 Flow chart of anomaly detection method for comprehensive transmission device

1.2 基于递归特征消除法的综合传动装置传感数据选择

针对综合传动装置异常检测面临的传感数据种类多、特征复杂、冗余特征多等问题,提出采用基于支持向量机的递归特征消除(support vector machine recursive feature elimination, SVM-RFE)法对装备异常状态的数据特征进行有效筛选. 该方法适合处理综合传动装置复杂工况下的非线性传感器数据,并通过对系统油压、车速等反应综合传动装置运行状态的影响因子进行重要性比较,剔除次要因子,提取最主要变量,减小后续特征提取的计算量并缩短模

型训练时间. 具体流程为:以综合传动装置各类传感数据为基础构建原始数据集,该数据集包括转速、压力、温度、档位、阀状态等 70 余种信息,存在明显的信息冗余. 为了方便后续对数据异常特征进行提取与检测,考虑到综合传动装置数据相关传感器间的相互作用,提出使用基于支持向量机的递归特征消除算法对冗余传感器信息进行剔除并降低数据维度,以获取更简洁有效的检测数据. 将筛选得到的综合传动检测数据使用离差标准化进行归一化处理,作为输入传递给后续的异常检测模型. 该模型基于注意力机制的 CAE 对输入传感器数据进行异常检测. 模型通过采用多个卷积层和池化层结构,逐步从传感器数据中提取重要特征并捕捉复杂关系,使模型更具鲁棒性,减少过拟合,提升泛化能力,从而减小模型的计算复杂度,同时保留主要特征,最终得到一个低维的特征表示. 通过利用注意力机制增强对重要信息的关注,提高处理效果,进一步得到最相关的综合传动数据特征,最后将综合传动数据特征输出给分类器进行数据检测以及对模型进行效果评估.

型训练时间.

本文采用 SVM-RFE 法对影响特征因子进行排序,得到最优影响特征因子组合;通过不断训练模型并消除不重要的特征,选择最优特征子集. SVM-RFE 特征选择算法如表 1 所示.

首先,输入训练数据集 $D = \{(\mathbf{x}_i, y_i)\}_{i=1}^n$, 其中 $\mathbf{x}_i$ 为综合传动装置传感器数据特征向量, y_i 为类别标签(正常传感器数据标签为零,异常数据标签为 1). 其次,使用训练集训练支持向量机,通过决策函数 $f(x)$ 进行特征重要性评估,可以表示为 $f(x) = \omega x +$

表 1 SVM-REF 特征选择算法
Tab.1 SVM-REF feature selection algorithm

Algorithm.1 SVM-RFE 特征选择算法
Input: 训练数据集 $D = \{(\mathbf{x}_i, y_i)\}_{i=1}^n$
Output: 最优传动检测数据集 S
1. 初始更新特征数据集为所有特征;
2. 使用当前特征数据集, 训练 SVM 模型, 计算每个特征的重要性并进行排序;
3. 删除最不重要的一个特征 i , 更新特征集;
4. 跳转至步骤 2, 直到完成所有特征重要性排序;
5. 选择性能最好的特征子集作为最终传动检测数据集 S

b, b 为偏置项, 按照特征因子权重向量 ω 大小排序, 权重向量 ω 越大则对目标函数的影响越大, 具有的信息越多, 对模型的贡献越高. 为了得到最优的决策函数 $f(x)$, 需要对 SVM 的目标函数 J 进行优化. 目标函数 J 由两个部分组成: 优化间隔的最大化和松弛变量的最小化. 目标函数为:

$$J = \min_{\omega, b, \xi} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \quad (1)$$

式中: ξ_i 为松弛变量; C 为正则化参数, 用来控制间隔最大化和误分类之间的权衡. 若第 i 特征被移除, 对目标函数的影响由泰勒展开可知:

$$\Delta J(i) = \frac{\delta J}{\delta \omega_i} \Delta \omega_i + \frac{\partial^2 J}{\partial \omega_i^2} (\Delta \omega_i)^2 \quad (2)$$

在目标函数的最优解上, 对其只考虑第二阶, 故有:

$$\Delta J(i) \approx (\Delta \omega_i)^2 \quad (3)$$

SVM-RFE 采用核函数的排序系数为:

$$\begin{cases} \text{Rank}(i) = (\omega_i)^2 \\ \omega = \sum_{i=1}^l \alpha_i y_i x_i \end{cases} \quad (4)$$

使用该核函数将原问题的解析形式简化为更容易处理的形式, 通过拉格朗日对偶性质来求解对应的最优决策函数和支持向量, 具有计算效率高、适用性强的特点.

1.3 基于卷积自编码器的综合传动数据特征提取

在综合传动系统中, 设备运行数据多为正常状态, 导致数据分布高度不均衡. 由于缺乏标签, 监督学习方法难以应用. 为了提高异常检测准确性, 需要采用有效方法处理综合传动数据.

自编码器是一种无监督学习模型, 能够直接有效地提取输入数据特征. 本文针对综合传动数据进

行特征提取, 使用卷积自编码器学习传感器数据的压缩表示, 并通过数据重构误差来判断模型特征提取效果^[17]. 主要思想是将输入信息压缩, 在中间隐层提取出最具代表性的信息, 目标是使重构误差逼近零, 使重构数据与原始数据尽量相似.

基于 CAE 的综合传动数据特征提取框架结构如图 2 所示. 该框架由编码器 (Encoder) 和解码器 (Decoder) 两部分组成. 编码器将车辆传动装置特征选择数据 x (压力、流量、温度等) 映射到潜在空间中的低维表示, 而解码器将潜在表示映射回原始数据维度, 得到车辆传动重构数据 x' . 编码和解码之间隐藏空间 Z 中的特征值是所提取到的原始数据特征信息.




图 2 基于 CAE 的综合传动数据特征提取框架

Fig.2 Feature extraction framework for integrated transmission data based on CAE

自编码器算法公式为:

$$h = f(x) = s(W_{in}x + B_{in}) \quad (5)$$

$$x' = f'(h) = s(W_{out}h + B_{out}) \quad (6)$$

式中: h 为隐藏特征值; $f(x)$ 为编码器的输入映射函数; $s(\cdot)$ 为激活函数, $x = (x_1, x_2, x_3, \dots, x_n)$ 输入至编码器的车辆传动装置传感数据; W_{in} 与 W_{out} 为设置的神经网络权重, B_{in} 与 B_{out} 为设置的神经网络偏置; x' 为解码器输出的重构数据; $f'(h)$ 为解码器映射函数.

在自编码器检测模型中, 使用大量正常数据来训练自编码器模型. 正常数据被用作训练样本, 通过最小化输入数据与重构数据之间的重构误差来调整自编码器的参数, 通常通过最小化原始数据和重构数据之间的损失函数来实现.

$$L(x, x') = L(x, f(h)) \quad (7)$$

式中: L 表示损失函数, 结合数据的不同形式选择均方误差 (mean square error, MSE) 或交叉熵误差. 均方误差对综合传动装置连续数据更为适用, 故选择均方误差为损失函数:

$$J_{MSE}(W, B) = \frac{1}{m} \left(\frac{1}{2} \|x - y\|^2 \right) \quad (8)$$

通过反向传播算法,训练集输入自编码器用于重构新样本,并计算其重构误差,CAE 依靠其重构误差不断调整网络中的权重 W ,使重构误差逐步减小,从而提高重构数据 x' 的质量.

综合传动数据具有异常样本少、标签缺乏的特性,自编码器异常检测方法无须标记异常样本,只需使用正常数据训练,学习数据内在结构,利用重构误差识别异常数据.可以有效降低输入信息维度,同时保证重要特征不丢失.但在复杂环境下,特征提取面临挑战,例如无法在处理长序列数据时有效捕捉长距离依赖关系;无法动态调节关注的焦点,而是对输入数据进行全局压缩并不加区分地处理所有部分.在这种情况下,模型无法充分提取局部的重要特征,本文采用注意力机制帮助模型关注重要输入信息.

1.4 注意力机制

在综合传动数据处理任务中,需要考虑整体评判.通过在模型中引入注意力机制,计算各传感器信息间的相关性,用于处理传感器序列数据,并从多个传感器信息中选取对任务目标最重要的特征信息,使模型在处理输入数据时能够更加关注不同位置的信息.根据输入数据中不同位置的重要性,注意力机制通过动态调整权重,使得模型能够在处理序列时更加灵活地关注重要信息.通过计算每个输入位置的权重,将位置信息加权求和,作为模型当前时刻的输入.

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (9)$$

式中: Q 表示查询向量,是当前处理的部分序列数据; K 表示关键字,是用于与查询向量 Q 匹配的键向量; V 表示权重数值,为键向量 K 对应包含序列元素的信息数据; d_k 为向量 K 的维度; Softmax 为激活函数.

注意力机制通过关注不同传感器数据,更好地捕捉综合传动装置运行状态的关键信息,利用隐藏层输出向量作为注意力层的输入,使用全连接层进行训练,对全连接层输出使用 Softmax 函数进行归一化,得出每一个隐藏层向量的分配权重,权重大小表示每个时间步的隐状态对于预测结果的重要程度.权重训练过程如下:

$$S_i = \tanh(WH_i + b_i) \quad (10)$$

$$\alpha_i = \text{Softmax}(S_i) \quad (11)$$

式中: H_i 为最后一层神经网络输出; W 为线性变换矩阵,用于将输入的隐藏状态 H_i 映射到一个新的特征空间; S_i 为每个隐藏层输出得分; b_i 为注意力计算相关的偏置向量; α_i 为权重系数.

使用训练出的权重对隐藏层输出向量求加权平均和:

$$C_i = \sum_{i=1}^k \alpha_i H_i \quad (12)$$

2 实例分析

2.1 数据集

本次实验所使用数据集是由某型履带装甲车辆综合传动装置车载传感器采集的不同维度的传感器及状态数据.根据数据信号来源不同,将采集的数据分为综合传动装置的机械系统数据、液压系统数据、电控系统数据.其中,机械系统数据包含发动机转速、转向机伺服压力、车速等传感器信息;液压系统数据包含操纵油压、液黏压力、传动出油温等传感器信息;电控系统数据包含脚踏板电压、制动闭解锁等传感器信息.考虑综合传动装置实际运行过程中,因油路管道损坏或密封圈老化等现象引起液压系统油液泄漏,从而直接引起装备液压系统出力不足、传动效率下降甚至传动失效的严重后果.本文主要针对综合传动油液泄漏故障开展深入研究,并通过开展综合传动装置实验测试,分别获取装置正常运行状态以及发生油液泄漏故障状态下的数据集(共约 30 000 组实测数据),依据专家经验初步筛选得到与综合传动装置油液泄漏故障相关的 22 种传感器数据项,如表 2 所示.

表 2 综合传动装置传感器名称

Tab.2 Comprehensive transmission device sensor name			
数据项	简写	数据项	简写
损失功率	Loss_P	风扇转速	nF
输入转矩	Tor_In	输入转速	RPM_In
传动出油温	Tem_O	控制压力	Pre_Con
传动回油温	Tem_R	主轴转速	nV
转向高压	Pre_S_H	油箱温度	Tem_Tank
操纵油压	Pre_CZ	伺服压力	Pre_SL
右控压力	Pre_C_R	CHL 压力	Pre_CHL
转向伺服压力	Pre_S_SF	C3L 压力	Pre_C3L
主轴转矩	nT	液黏压力	Pre_YN
左控压力	Pre_C_L	润滑油压	Pre_Lub
系统流量	Flow	涡轮转速	nB

依赖物理经验得到的油液泄漏故障相关的传感器数据项仍有特征冗余,这些特征难以通过专家经验进行选择,通过递归特征消除法来确定所选特征.图3(a)为上述方法得到的各传感数据特征评分图,不同传感器数据加权值存在明显差异.在每次特征消除的步骤后,使用交叉验证方法将数据集分割成多个部分并轮流使用其中的一部分作为测试集,其余作为训练集进行多次训练和验证,得到传感数据选择特征数量图如图3(b)所示,评估模型性能全面性,并计算验证集上的准确率作为交叉验证分数.由图3(b)可知,随着选择特征数量的增加,交叉验证分数先增加后减少,选择综合传动状态最相关变量:系统流量、涡轮转速、主轴转矩、主轴转速、控制压力、伺服压力、输入转速作为输入数据.部分综合传动数据信息如表3所示.综合传动装置传感数据时间序列图如图4所示.




图3 SVM-RFE 特征变量图

2.2 模型构建及训练

本文模型基于 Pytorch 框架,实验所采用的硬件环境为:3.1 GHz Intel Core i5 处理器,8 GB 2 133 MHz

表3 部分综合传动数据信息表

Tab.3 Integrated transmission system information table

数据项	均值	最小值	最大值	标准差
系统流量/(L·min ⁻¹)	139.8	0.0	324.0	116.6
涡轮转速/(r·min ⁻¹)	677.6	0.0	4 958.0	492.7
主轴转矩/(N·m)	1 513.0	0.0	3 102.0	1 110.0
主轴转速/(r·min ⁻¹)	273.6	0.0	561.0	196.0
控制压力/MPa	1.6	0.01	2.1	0.7
伺服压力/MPa	0.1	0.01	0.21	0.06
输入转速/(r·min ⁻¹)	1 099.9	-2.0	2 205.0	775.2




图4 综合传动装置传感数据时间序列图

LPDDR3 内存, Intel Iris Plus Graphics 650 1 536 MB GPU 显卡,程序环境为 Torch: 1.13.1, Python: 3.10.9, Anaconda: 4.12.0.

基于注意力机制的卷积自编码器模型通过宽卷积核提高特征提取能力,编码器的潜在空间编码模块由3层卷积层构成,用于分离车辆传动数据正常特征与异常特征,采用 ReLU 函数作为每层网络的激活函数,单次训练的训练轮数为 200. 模型训练选用较小学习率设为 0.000 5. 考虑到模型和数据的情况,模型的丢弃率设为 0.25,优化器为 Adam. 训练轮数、批次大小分别为 150、700. 调用 sklearn 机器学习库中的 SVM 函数进行分类建模. 使用高斯核函数作为 SVM 的核函数. 验证后保存效果最佳的 SVM 模型作为最终测试集使用的分类模型. 为了使较大差异对

损失函数的贡献更大,更关注传感数据的重构误差,采用均方差损失函数衡量预测值与目标值之间的差异。

基于注意力机制的卷积自编码器模型使用编码器将原始输入映射到潜在空间中的特征表示,并使用解码器使用特征表示重建原始输入。在本研究中,综合传动实验数据利用卷积自编码器进行特征提取,通过将隐藏空间大小(提取特征)设置为2,将原始传感器数据转化为2维特征向量,提取综合传动装置运行特征,并对综合传动数据进行可视化。使用综合传动数据集进行训练,将数据集按照训练集(约12 000个正常数据),测试集(约6 000个传动数据),验证集(约15 000个传动数据)的比例划分。在训练完之后,保存模型用于提取数据特征。

2.3 结果分析

为评估本文提出算法的有效性,使用主成分分析(principal component analysis, PCA)方法、传统CAE和GRU-AE方法在相同数据集下进行数据降维对比实验检测。在履带装甲车辆运行阶段,采用不同方法对综合传动装置传感数据进行特征空间可视化分析,如图5所示。

由图5(a)(b)(c)可以看出,由于综合传动数据本身关系复杂,采用PCA、CAE、GUR-AE方法对传动数据进行特征提取的效果较差,无法有效区分综合传动装置正常及异常状态下复杂的非线性数据特征。由图5(d)可知,ACA-SVM方法可以从综合传动装置传感器数据中提取更具代表性的装备运行状态特征,在特征空间上能够对正常和异常状态进行明显区分。通过比较图5(d)与图5(b)可以看出,注意力机制的引入显著促进了CAE模型更加清楚地划分综合传动装置的运行状态。图5(d)中的数据特征划分相较于图5(c)更加清晰,表明所提出的模型对于GRU-AE方法在装备状态特征提取方面更有优势。总体而言,本文所提出的模型可以提取更具代表性的传动数据特征,可极大地提高模型对装备异常状态检测与分类的效果。

为了进一步验证这些特征提取方法在综合传动异常检测任务中的实际性能,本文以综合传动漏油故障数据为例,开展对比实验,利用混淆矩阵验证并评估各算法的分类准确率。分别采用CA、GRU-AE、ACA-SVM方法对综合传动装置运行状态进行检测,通过混淆矩阵图展示不同算法在实际分类任务中的




图5 综合传动装置特征空间可视化分布

Fig.5 Visualization distribution of characteristic space for transmission devices

表现,其混淆矩阵如图6所示,其行和列分别代表真实标签和预测标签.矩阵的主对角线单元格表示正确检测的情况,即真阳例(TP)和真阴例(TN).非对角线上的单元格代表错误检测的情况,包括假阳例(FP)和假阴例(FN),依靠分析混淆矩阵中的FP和

FN,可以识别模型的类型分类表现,指导模型调整.通过各模型的混淆矩阵可以计算准确率 P_r (Precision)、召回率 R_c (Recall)和 F_1 值等性能指标.模型二分类混淆矩阵表如表4所示.




图6 综合传动数据的混淆矩阵

Fig.6 Confusion matrix for transmission data

表4 模型二分类混淆矩阵表

Tab.4 Model two classification confusion matrix table

状态	判断为异常	判断为正常
实际为异常	TP	FN
实际为正常	FP	TN

通过上述3个常用评估指标对各模型检测效果进行对比,其数学定义如下:

$$\left\{\begin{aligned}F_1 &= \frac{2 \times P_r \times R_c}{P_r + R_c} \\ R_c &= \frac{N_{TP}}{N_{TP} + N_{FN}} \\ P_r &= \frac{N_{TP}}{N_{TP} + N_{FP}}\end{aligned}\right. \quad (13)$$

式中: N_{TP} 为正样本被正确检测数; N_{FP} 为负样本被正确检测数量; N_{FN} 为正样本被误检数量.

利用混淆矩阵计算各模型的准确率、召回率及 F_1 值,如表5所示,其中准确率表示模型检测中正确检测的比例,召回率反映模型检测异常样本的能力, F_1 值综合考虑了精确率和召回率,更全面地反映模型性能.实验结果表明,基于CAE方法的异常检测模型得到了最高的准确率(0.991),但 F_1 值较低,表明该方法总体正确分类能力最佳但整体性能不佳.ACA-SVM综合传动装置异常检测模型得到了最高的召回率和 F_1 值,表明其正确识别出异常样本的能力和整体性能最佳,模型对传动数据检测准确率达到0.972,召回率达到0.981, F_1 值达到0.976.在实车运行过程中,要求模型对异常数据进行严格检测,并确保对整体数据的检测性能保持在较高水平,故本

文所构建模型可满足综合传动装置异常状态在线检测的实际需求.

表5 模型准确度对比

Tab.5 Model accuracy comparison

模型	准确率	召回率	F_1 值
ACA-SVM	0.972	0.981	0.976
GRU-AE	0.953	0.970	0.961
CAE	0.991	0.901	0.944

3 结论

针对目前车辆综合传动装置数据复杂、传统检测方法准确率低和误报率高的问题,本文提出了一种基于注意力机制的卷积自编码器检测模型,采用注意力机制集中捕捉到重要传感信息,突出数据重要特征来提高模型性能;利用卷积自编码器对高维稀疏数据进行特征提取,与SVM算法结合,成功对特种车辆综合传动装置传感器数据进行异常检测.该方法具有以下优势:

- 1) 采用基于支持向量机的递归特征消除法,筛选得到了与综合传动装置油液泄漏故障紧密相关的传感器信息,包含系统流量、涡轮转速、主轴转矩、主轴转速、控制压力、伺服压力、输入转速共7组信息.
- 2) 采用PCA、CAE和GRU-AE模型以及ACA-SVM模型对综合传动装置传感数据的特征空间进行可视化分析对比,表明ACA-SVM方法可有效对综合传动数据进行特征提取.

3) 提出了一种基于注意力机制的卷积自编码器异常检测模型,以综合传动装置漏油故障数据为例,开展实例验证,表明所提模型优于其他模型,准确率达到97.2%, F_1 值达到0.976,证明了该模型可以有效检测综合传动装置设备异常状态。

参考文献

- [1] 徐保荣, 张金乐, 万丽, 等. 基于多传感器数据关联的综合传动装置服役状态辨识方法[J]. 兵工学报, 2024, 45(2): 574-583.
XU B R, ZHANG J L, WAN L, et al. A service status identification method of comprehensive transmission based on multi-sensor data association[J]. Acta Armamentarii, 2024, 45(2): 574-583. (in Chinese)
- [2] 闫书法, 马彪, 郑长松. 基于油液光谱分析的综合传动视情维护研究[J]. 光谱学与光谱分析, 2019, 39(11): 3470.
YAN S F, MA B, ZHENG C S. Condition-based maintenance for power-shift steering transmission based on oil spectral analysis[J]. Spectroscopy and Spectral Analysis, 2019, 39(11): 3470. (in Chinese)
- [3] 周锐, 蒋觉义, 乔丽. 综合传动装置一体化模型评价与验证研究[J]. 计算机测量与控制, 2020, 28(4): 246-250.
ZHOU R, JIANG J Y, QIAO L. Research on integrated model evaluation and verification of integrated transmission[J]. Computer Measurement & Control, 2020, 28(4): 246-250. (in Chinese)
- [4] 闫书法, 马彪, 郑长松, 等. 非线性状态监测数据下的磨损定位与状态识别[J]. 吉林大学学报(工学版), 2019, 49(2): 359-365.
YAN S F, MA B, ZHENG C S, et al. Wear localization and identification under nonlinear condition monitoring data[J]. Journal of Jilin University (Engineering and Technology Edition), 2019, 49(2): 359-365. (in Chinese)
- [5] 于晓升, 许茗, 王莹, 等. 基于卷积变分自编码器的异常事件检测方法[J]. 仪器仪表学报, 2021, 42(5): 151-158.
YU X S, XU M, WANG Y, et al. Anomaly detection method based on convolutional variational auto-encoder[J]. Chinese Journal of Scientific Instrument, 2021, 42(5): 151-158. (in Chinese)
- [6] 徐峰, 张倩倩, 季文龙, 等. 油液光谱数据诊断综合传动装置异常磨损定位方法[J]. 光谱学与光谱分析, 2024, 44(5): 1398-1404.
XU F, ZHANG Q Q, JI W L, et al. Study on abnormal wear location of integrated transmission components based on oil spectral data[J]. Spectroscopy and Spectral Analysis, 2024, 44(5): 1398-1404. (in Chinese)
- [7] 张丽霞, 冯辅周, 刘相波, 等. 典型液压系统故障诊断与隔离方法研究[J]. 系统仿真学报, 2018, 30(5): 1818-1825.
ZHANG L X, FENG F Z, LIU X B, et al. Research on fault detection and isolation method for typical hydraulic system[J]. Journal of System Simulation, 2018, 30(5): 1818-1825. (in Chinese)
- [8] 刘勤, 姬广振, 曹璞琳, 等. 基于故障物理的复杂机械系统可靠性设计分析技术[J]. 兵工学报, 2022, 43(增刊1): 189-195.
LIU Q, JI G Z, CAO P L, et al. Reliability design and analysis method for complex mechanical system based on physics of failure[J]. Acta Armamentarii, 2022, 43(Sup.1): 189-195. (in Chinese)
- [9] 马波, 赵伟, 齐良才. 变分自编码器在机械故障预警中的应用[J]. 计算机工程与应用, 2019, 55(12): 245-249.
MA B, ZHAO Y, QI L C. Application of variational auto-encoder in mechanical fault early warning[J]. Computer Engineering and Applications, 2019, 55(12): 245-249. (in Chinese)
- [10] 吴锐, 于会龙, 董昊天, 等. 履带式特种车辆精细化动力学建模与仿真[J]. 兵工学报, 2024, 45(5): 1384-1401.
WU R, YU H L, DONG H T, et al. Refined dynamics modeling and simulation of special tracked vehicles[J]. Acta Armamentarii, 2024, 45(5): 1384-1401. (in Chinese)
- [11] 李贝贝, 彭力. 基于改进自编码网络的轴承振动异常检测[J]. 计算机科学与探索, 2022, 16(1): 163-175.
LI B B, PENG L. Bearing vibration abnormal detection based on improved autoencoder network[J]. Journal of Frontiers of Computer Science and Technology, 2022, 16(1): 163-175. (in Chinese)
- [12] 李昊奇, 应娜, 郭春生, 等. 基于深度信念网络和线性单分类SVM的高维异常检测[J]. 电信科学, 2018, 34(1): 34-42.
LI H Q, YING N, GUO C S, et al. High-dimensional outlier detection based on deep belief network and linear one-class SVM[J]. Telecommunications Science, 2018, 34(1): 34-42. (in Chinese)
- [13] 何家辉, 程志君, 郭波. 联合字典学习与OCSVM的遥测数据异常检测方法[J]. 航空学报, 2023, 44(13): 207-219.
HE J H, CHENG Z J, GUO B. Telemetry anomaly detection method based on joint dictionary learning and OCSVM[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(13): 207-219. (in Chinese)
- [14] 齐咏生, 巩育瑞, 高胜利, 等. 基于中心损失-改进卷积自编码器的滚动轴承半监督故障诊断[J]. 振动与冲击, 2023, 42(7): 301-311.
QI Y S, GONG Y R, GAO S L, et al. Semi-supervised fault diagnosis of rolling bearing based on CL-ICAE[J]. Journal of Vibration and Shock, 2023, 42(7): 301-311. (in Chinese)
- [15] 宁子俊, 陈涛, 徐峰, 等. 复杂工况下综合传动装置状态监测数据异常检测方法[J]. 机电工程, 2023, 40(9): 1387-1394.
NING Z J, CHEN T, XU F, et al. Abnormal detection method of integrated transmission device condition monitoring data under complex working conditions[J]. Journal of Mechanical & Electrical Engineering, 2023, 40(9): 1387-1394. (in Chinese)
- [16] HOOSHMAND M K, HOSAHALLI D. Network anomaly detection using deep learning techniques[J]. CAAI Transactions on Intelligence Technology, 2022, 7(2): 228-243.
- [17] LIU Y Z, ZOU Y S, WU Y, et al. A novel abnormal detection method for bearing temperature based on spatiotemporal fusion[J]. Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit, 2022, 236(3): 317-333.