

基于 BiSNet 的航天发动机转子智能健康监控

李鹏程¹, 陈海东², 李世鹏¹, 连彦泽¹
(1 北京宇航系统工程研究所 北京 100076
2 中国运载火箭技术研究院 北京 100076)

摘要: 航天发动机某部件转子健康监控, 对检测发动机能否正常工作进而影响航天发射任务的成败至关重要。传统健康监控方法需要依赖经验和专业知识, 在对故障机理深入理解后才能构建相应的健康监控模型。针对传统转子健康监控手段效率低、适应性差、过度依赖专家经验等不足, 结合海量转子振动健康监控历史数据, 提出并设计采用神经网络 BiSNet 的人工智能方法, 对航天领域运载火箭发动机某部件转子的健康状态进行智能建模并完成监控。通过与传统监控手段和主流基准神经网络方式对照实验得出结论, 基于历史数据驱动的神经网络 BiSNet 可为航天转子智能健康监控提供便捷准确的建模预测。

关键词: 运载火箭; 神经网络; 健康监控; 振动信号

中图分类号: TP18 文献标识码: A 文章编号: CN11-1780(2021)02-0022-07

Intelligent health monitoring of aerospace engine rotor based on BiSNet

LI Pengcheng¹, CHEN Haidong², LI Shipeng¹, LIAN Yanze¹
(1. Beijing Institute of Astronautical Systems Engineering, Beijing 100076, China;
2. China Academy of Launch Vehicle Technology, Beijing 100076, China)

Abstract: Health state monitoring of certain rotor portion in the aerospace engine is critical to the aerospace engine working normally, which effects launch task success further. Traditionally, health state monitoring depends on subjective experience and professional knowledge, so the corresponding health monitoring model is built after studying and understanding the failure mechanism behind. In view of the low efficiency, poor adaptability and over-reliance on expert experience of traditional rotor health state monitoring means, combined with massive amounts of rotor vibration health state monitoring historical data, neural network BiSNet is proposed and designed as an artificial intelligent method to model the certain rotor portion in the aerospace engine health monitoring model and monitor the health status timely. Compared with the traditional monitoring method and the mainly general baseline intelligent method, the conclusion is drawn that the historical data-driven intelligent neural network BiSNet could provide convenient and accurate modeling and prediction for the health monitoring of aerospace rotors.

Key words: Launch vehicles; Neural network; Health monitoring; Vibration signal

引 言

2020 年是中国“航天大年”, 伴随着北斗三号全球卫星导航系统、新一代载人飞船试验船、首次火星探测、嫦娥五号等计划的展开, 运载火箭设计研制、生产试验已进入密集期。对运载火箭发射可靠性的高要求与火箭(包括发动机在内)的各部件生产测试周期短之间形成了矛盾, 而其中发动机的健康状态对火箭可靠性的影响极大, 如在美国航天运载器发生的故障事件中 60%以上是由发动机的健康状态异常引发的^[1]。火箭发动机机构组件复杂、工作环境恶劣, 可看作是在高温高压、强腐蚀、高能级的极端物理条件下的复杂流体热动力系统。发动机故障会导致严重的后果, 使得火箭发射失利。以往对发动机健康状态的监控手段十分有限, 通常为基于振动传感器采集的发动机关键部位(如转子)的历史振动信号特征或故障信号机理来构建物理数学模型, 根据模型和采集到的振动信号来推断发动机健康状态。传统分析手段主要为基于信号处理的方法和基于数学模型的方法^[2]。

基于信号处理的方法主要是选取健康状态评估特征量, 并通过判断特征量的信号特征是否满足预设

规则来实现健康监控，包括数理统计分析法、特征量降维分析法、性能特征独立分量分析法、融合小波分析法和羽流光谱分析法。基于数学模型的方法需要根据发动机符合的物理规律和故障机理来构建反映其健康状态的数学模型，并将外测量和模型先验信息做残差分析以实现健康监控的目的，具体可分为动态模型方法和静态模型方法^[2]。基于信号处理的方法过度依赖数据样本的数量和质量，且需要对信号特征量有较深入的理解。基于数学模型的方法要求建立的数学模型有较高的准确性，能够尽量反映发动机系统的实际行为状态，但火箭发动机的复杂性、高维非线性等特性导致难以建立用于健康监测、故障诊断的发动机精确数学模型，由此可见，传统的分析手段有其局限性。

近年来，人工智能领域的模式识别、专家系统、机器学习、深度学习等快速发展^[3]。模式识别根据发动机的工作历史经验数据构建状态参数模板，评估健康状态时将待评估工作状态与模板对比分析；专家系统依赖健康监控领域专家的先验经验规则构建的知识库，推理机在预设推理机制下进行知识推理诊断；机器学习、深度学习是通过机器学习算法或神经网络的自组织自学习能力来实现数据驱动下的故障识别分类预测，无需预先构建模板库和依赖专家先验知识，克服通用性不足以及难以处理新型故障状态信息的问题。因此，本文研究设计搭建神经网络来对航天发动机某部件转子实现智能健康监控以克服传统分析手段的局限性。

国内外学者关于人工智能方法在健康监控故障诊断领域中的应用研究，近几年正处于上升趋势。LIU Ruonan 等人对 AI (Artificial Intelligence) 算法如最近邻、支持向量机、贝叶斯方法、神经网络在工业故障诊断的应用进行了优势、局限性和实践性的讨论^[4]，展示了 AI 算法的未来应用可能性；SHAO Siyu 等人使用深度信念网络 DBN (Deep Belief Networks) 对感应电动机的振动信号进行特征提取^[5]，克服传统提取特征量过度依赖专家经验的不足；ZHANG Tianfan 等在电机驱动振动信号领域提出三种数据融合方式并应用到混合深度信念网络的特征提取中^[6]，可提高训练性能和模型性能；周步祥等融合快速相关向量机 FRVM (Fast Relevance Vector Machine) 与深度信念网络，提出一种智能变压器故障诊断方法，构建了油中溶解气体的比值与故障类型之间的映射模型^[7]；范彬研究了飞行器复杂工况下基于相关向量机的自适应阈值模型，用于预测部件的退化特性随工况参数变化的情况^[8]，根据参数变化情况来推断设备当前健康状态；ZHAO Minghang 等提出了网络嵌入方法来学习不同振动工作状况下振动信号的差异^[9]，以解决在振动信号故障诊断中，通常使用单一神经网络对振动信号特征进行提取时，存在的非线性变换不区分振动件运行状况的不足。

虽然，国内外学者在将人工智能算法应用到设备部件的健康监控领域已有一定的研究成果，但针对航天发动机部件转子的实践极少，且多依赖传统的振动信号处理，如通过时域分析、频域分析、时频域分析等^[10]，存在模型构建和信号处理流程繁琐、效率低下的问题；传统 BP 网络、深度信念网络或支持向量机等存在单模型训练效果障碍，即人为设定的模型训练超参数可能导致使用的单一模型算法不适用待解决问题，模型性能差，需要多次尝试更换模型算法寻找适合问题的算法。因此，本文通过设计实现融合回归与分类网络结构的端到端 BiSNet 神经网络，将神经网络应用到航天发动机某部件转子振动信号特征提取中，以达到健康监测和故障诊断预警的目的。

1 研究方法

1.1 总体研究方法

总体研究方法以发动机某部件转子振动信号模拟数据集的健康状态监控预警为应用背景，经预处理后将振动信号和对应的健康状态等级编码后，分别作为 BiSNet 网络训练的输入特征和映射输出分类标签，经过反复迭代后得到发动机某部件转子健康监控模型，将待测振动信号输入健康监控模型，模型输出相应的预测健康状态等级评估结果。其对应的总体研究流程如图 1 所示。

1.2 数据集介绍

采用发动机某部件转子的振动信号模拟数据集进行算法模型验证，数据集包含四种工况（GK1、

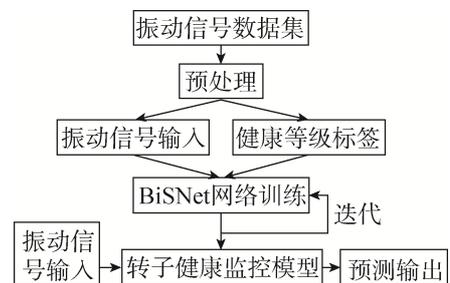


图 1 总体研究流程框图

Fig. 1 Overall research flow chart

GK2、GK3、GK4) 下的转子横向振动和纵向振动加速度数据, 以 mat 格式存储, 包含 “_header_” 头描述信息、“_version_” 版本描述信息、“_globals_” 全局描述信息以及两自由度方向的振动加速度数据。其中, 振动传感器的采样频率为 51 200 Hz。每种给定工况下, 对某部件转子从健康状态到故障状态全生命周期的各阶段进行分阶段代表性数据采样, 每种工况 GK_i(*i*=1,2,3,4) 各阶段采样时长合计为 11 s, 对应 563 200 条数据采样记录/工况, 根据 *i* 取值不同, 共计 44 s 各阶段数据采样时长, 算法模型验证数据集包含的数据采样记录共 2 252 800 条, 如表 1 所示。

对振动数据对应的健康监控状态和用于网络训练的健康状态等级分类编码标签如表 2 所示, 标注样本标签的标准参考文献[11]应用 ISO2631 规则计算加权加速度均方根值指标, 将振动加速度按照式(1)求取加权均方根值后, 为方便模型算法验证, 将该特征值的范围按人为预设 0.315、0.615、1.000、1.600、2.500 临界点划分为六段区间, 分别对应 5、4、3、2、1、0 六类标签。

$$a_{vi} = \sqrt{k_x^2 a_{vix}^2 + k_y^2 a_{viy}^2} \quad (1)$$

式中, k_x 与 k_y 为横向和纵向自由度方向上振动加速度数据的加权系数, 取值为 1; a_{vix} 与 a_{viy} 分别表示沿横向和纵向自由度方向滑动时间窗口(窗口长度固定为 100)计算出的振动加速度数据均值。

1.3 健康状态等级分类网络

设计实现端到端^[12]BiSNet (Bi-Stacking Net) 双分支集成神经网络模型结构如图 2 所示, 图中 128 和 64 表示全连接层神经元单元数。BiSNet 网络模型输入为两路并行输入, 分别经过回归特征提取网络分支和分类特征提取网络分支, 得到健康状态特征后并联为组合特征, 经 BiSNet 分类层输出为 6 类的 Softmax 输出健康状态等级分类预测向量。

其中, 回归特征提取网络分支和分类特征提取网络分支为加载预训练的分支网络模型, 需预先由转子振动模拟数据集训练得到两分支网络 h5 模型文件, 经模型加载后配置为不可训练网络层, 堆叠模型集成算法对两分支模型提取的健康状态特征进行组合, 经两层全连接层网络后进一步提取分类特征后输出分类预测向量。

表 1 数据集概览表
Table 1 Data set overview table

工况	数据量
GK1	563 200
GK2	563 200
GK3	563 200
GK4	563 200

表 2 健康状态和标签映射表
Table 2 Health status and label mapping table

健康状态	标签
非常平稳	0
一般平稳	1
正常	2
略微振动	3
一般振动	4
严重振动	5

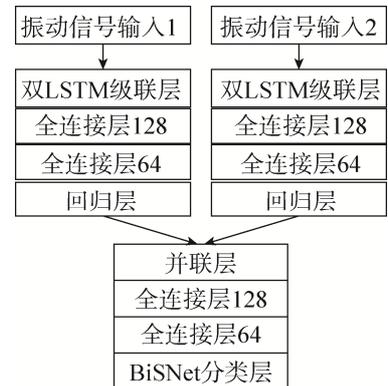


图 2 BiSNet 网络结构
Fig. 2 BiSNet net architecture

2 结果及讨论

2.1 实验结果

为对比 BiSNet 与常用模型在本模拟数据集上的性能, 根据文献[12]调研的现阶段常用故障诊断网络——全连接神经网络、卷积神经网络和循环神经网络, 结合本数据集为序列振动数据特点, 因此选用主流循环神经网络——长短期记忆网络 LSTM

(Long Short Term Memory Network)^[12]组合全连接神经网络作为对比 BiSNet 的基准神经网络, 在发动机某部件转子振动信号模拟数据集上采用传统常用的阈值判定法^[13]与四种基准对比神经网络模型(单 LSTM 回归、双 LSTM 回归、单 LSTM 分类、双 LSTM 分类)以及 BiSNet 网络共 6 种模型进行训练评估, 得到实验结果对照如表 3 所示。

表 3 6 种模型对照实验结果表

Table 3 Results of 6 models control experiments

模型	训练参数量	迭代次数	准确率/%	单步速度
传统阈值法	6	无	66	0.03
单 LSTM 回归	9 793	50	56	1
双 LSTM 回归	18 113	32	62	3
单 LSTM 分类	10 118	38	80	1
双 LSTM 分类	18 438	36	81	3
BiSNet 网络	9 670	18	87	9

其中，模型字段对应不同的模型种类，训练参数量字段表示模型确定所需的参数数量，迭代次数字段指达到最优模型性能所需要的模型训练次数，准确率字段采用随机切分法首先对原始数据集随机打乱^[14]，然后按照预设比例8:2切分出测试集（共对应45万余条数据记录作为评估模型泛化性能的样本集）上20%比例的模型预测准确率，单步速度字段以单LSTM回归网络模型训练的单步训练速度为基准，其余网络模型相对该网络单步训练速度的相对单步速度，用于衡量算法模型的单步训练快慢；传统阈值法不需要神经网络似的迭代过程，故单步速度即阈值规则构建速度。

可视化各模型在测试集上预测效果时，为便于直观观察，仅等间隔选取了100个样本点参与预测效果图的绘制，其中蓝色虚线由实际健康状态等级分类标签节点连接而成，红色实线由模型预测的健康状态等级分类标签节点连接而成。传统阈值规则法对应的测试集预测结果如图3所示；单LSTM回归、双LSTM回归、单LSTM分类、双LSTM分类四种网络对应的测试集预测结果分别绘制于图4的(a)(b)(c)(d)中；四种网络模型训练指标变化情况如图5所示。

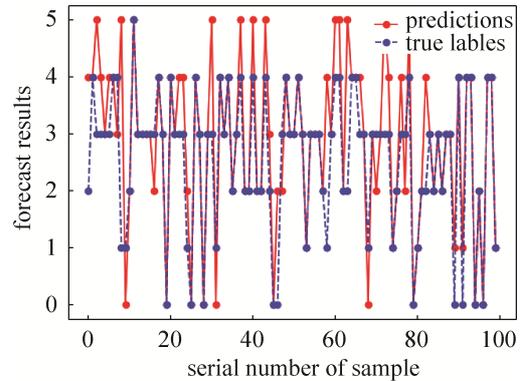
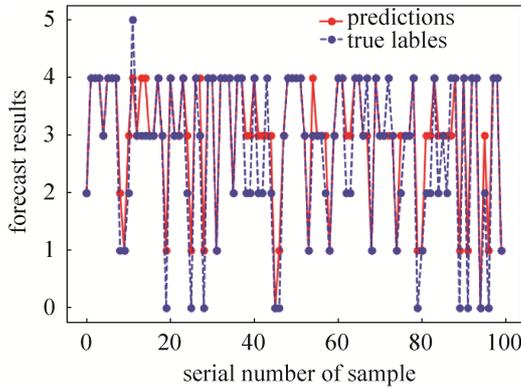
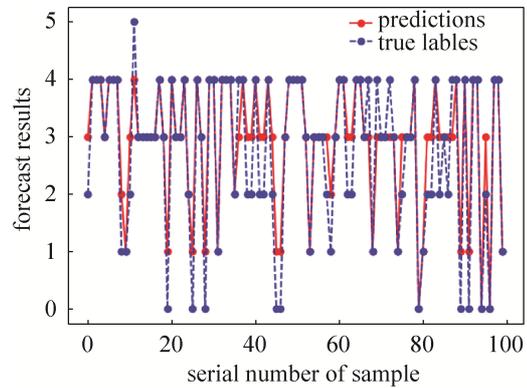


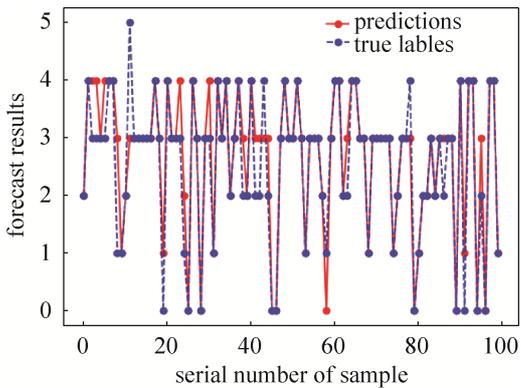
图3 传统阈值法测试集预测结果图
Fig. 3 Prediction results of traditional threshold method on test data set



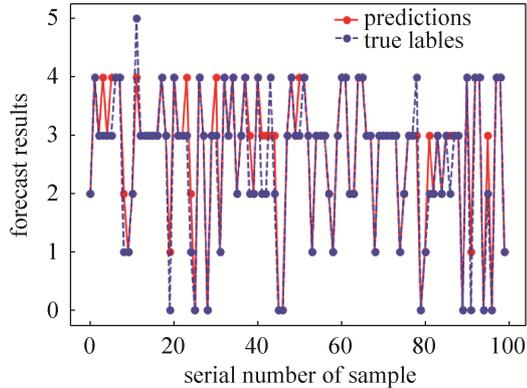
(a) 单LSTM回归网络测试集预测结果图
(a) Prediction results of single LSTM regression net



(b) 双LSTM回归网络测试集预测结果图
(b) Prediction results of double LSTM regression net



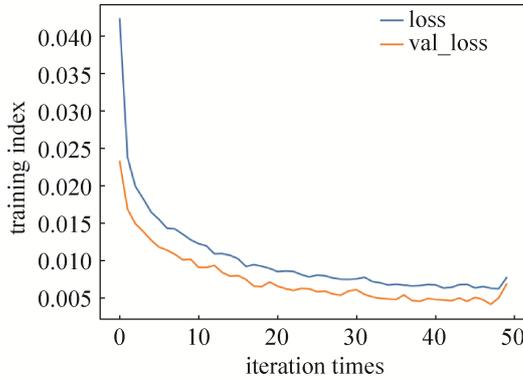
(c) 单LSTM分类网络测试集预测结果图
(c) Prediction results of single LSTM classify net



(d) 双LSTM分类网络测试集预测结果图
(d) Prediction results of double LSTM classify net

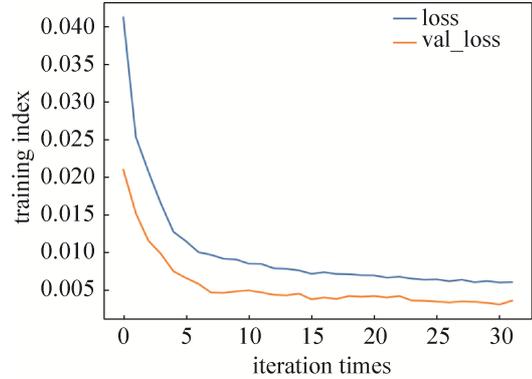
图4 四种网络测试集预测结果图

Fig. 4 Prediction results of four network on test data set



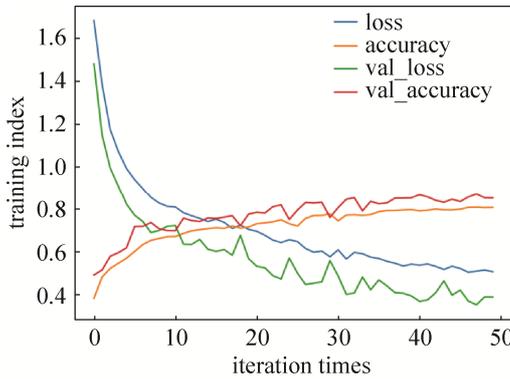
(a) 单 LSTM 回归网络模型训练指标曲线图

(a) Training index curves of single LSTM regression net



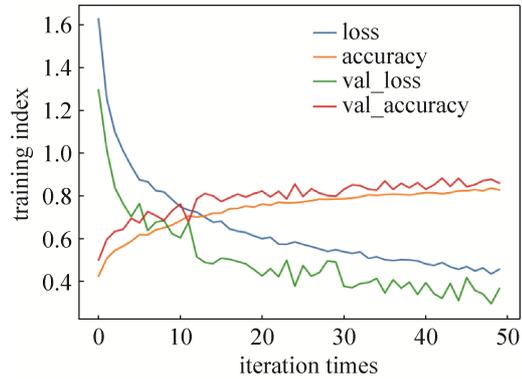
(b) 双 LSTM 回归网络模型训练指标曲线图

(b) Training index curves of double LSTM regression net



(c) 单 LSTM 分类网络模型训练指标曲线图

(c) Training index curves of single LSTM classify net

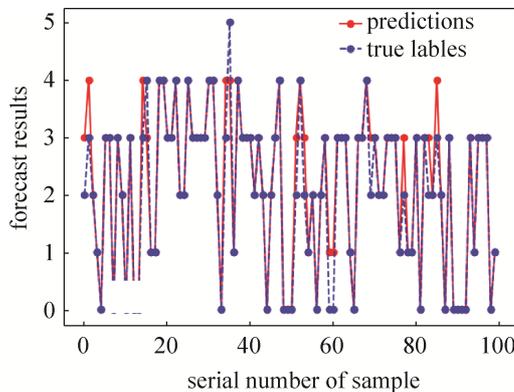


(d) 双 LSTM 分类网络模型训练指标曲线图

(d) Training index curves of double LSTM classify net

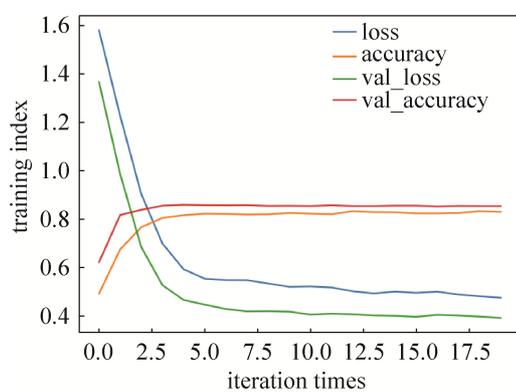
图 5 四种网络模型训练指标曲线图

Fig. 5 Training index curves of four network on test data set



(a) BiSNet 网络测试集预测结果图

(a) Prediction result of BiSNet network



(b) BiSNet 网络模型测试集训练指标曲线图

(b) Training index curves of BiSNet network

图 6 BiSNet 网络模型测试集预测结果和训练指标曲线图

Fig. 6 Prediction result and training index curves of BiSNet network on test data set

BiSNet 网络模型在测试集上的预测结果和训练模型过程训练指标变化情况如图 6 所示, 方便与上述四种常见网络模型进行对照。在图 4 和图 6 中, 预测结果分为以下六类: 非常平稳、一般平稳、正常、略微振动、一般振动、严重振动, 分别对应标签 0~5。

2.2 结果讨论

从表 3 分析可知, 传统阈值法所需要的训练参数最少, 且算法训练时间最短, 准确率可达 66%, 高

于单或双 LSTM 回归网络,但低于单或双 LSTM 分类网络和 BiSNet;单 LSTM 回归或分类网络相较双 LSTM 网络训练参数量少 9 000 个左右,但单 LSTM 网络只提取一层时间序列特征,因此,达到稳态收敛效果时所需要的最少迭代次数更多,单步所需训练时间更短,但准确率不如双 LSTM 网络;自设计的 BiSNet 网络虽然包含了两种 LSTM 分支网络的参数量,但其可训练的参数量仅集中在模型集成部分,因此,可训练参数量在五种神经网络模型中最少仅为 9 670 个,训练过程需要前端两分支网络的推理过程,所以需要最长的单步训练速度,但其达到收敛的模型效果所需要的训练迭代次数最少,仅需迭代 18 次即可达到五种神经网络模型中最高的准确率 87%,远远高于传统阈值法下能达到的准确率 66%。

从图 4 和图 6 (a) 对比可知,测试集上 BiSNet 的预测分类曲线与实际健康状态等级分类标签曲线重合度最高,说明 BiSNet 预测准确率最优;对照图 5 和图 6 (b) 的训练过程指标变化曲线可知,回归网络的指标变化曲线较平缓,分类网络指标变化曲线波动较大,而 BiSNet 融合了两种分支网络,训练过程指标变化曲线平缓,说明 BiSNet 是易于训练收敛的。

经过与传统阈值法和四种主流基准神经网络模型的对比实验,综合分析结果可知,传统阈值法虽然训练速度极快、训练参数量少,同时也具有一定的准确率,但其过度依赖数据集质量,阈值规则变化对噪声十分敏感,准确率上限不高。而设计实现的 BiSNet 网络参数量在五种神经网络模型中最少,虽单步训练速度较慢,但该网络参数易于训练,只需最少的迭代次数即可达到五种神经网络模型中最优的模型性能,综合训练效率、模型性能、易训练性等指标^[15,16],BiSNet 神经网络模型在航天发动机某部件转子振动信号数据集上性能最优。

3 结束语

在运载火箭发动机某部件转子振动信号模拟数据集上,提出了适用该专业数据集的 BiSNet 网络模型算法。综合可训练参数量、训练所需最少迭代次数、模型训练性能和单步训练速度等指标,对比传统算法和四种主流基准神经网络模型,验证了 BiSNet 网络模型算法性能,展示出该网络用于航天运载火箭发动机转子振动健康状态监控领域的可能性,进一步可将该网络模型应用到运载火箭其他领域的健康监控中,为智慧航天添砖加瓦。

参考文献

- [1] 夏鲁瑞. 液体火箭发动机涡轮泵健康监控关键技术及系统研究[D]. 长沙: 国防科技大学, 2010.
XIA Lurui. Research on key technology and system of health monitoring for turbo pump of liquid rocket engine[D]. Changsha: National University of Defense Technology, 2010.
- [2] 吴建军, 黄强, 程玉强, 等. 液体火箭发动机故障监测诊断理论与方法[M]. 北京: 国防工业出版社, 2013.
WU Jianjun, HUANG Qiang, CHENG Yuqiang, et al. Theory and method of fault monitoring and diagnosis for liquid rocket engine[M]. Beijing: National Defense Industry Press, 2013.
- [3] 邓婕, 李舜酩. 基于深度学习的故障诊断方法研究综述[J]. 电子测试, 2020(18): 43–47, 51.
DENG Jie, LI Shunming. Review of fault diagnosis methods based on deep learning[J]. Electronic Test, 2020(18): 43–47, 51.
- [4] LIU Ruonan, YANG Boyuan, ZIO E, et al. Artificial intelligence for fault diagnosis of rotating machinery: a review[J]. Mechanical Systems and Signal Processing, 2018, 108: 33–47.
- [5] SHAO Siyu, SUN Wenjun, YAN Ruqiang, et al. A deep learning approach for fault diagnosis of induction motors in manufacturing [J]. Chinese Journal of Mechanical Engineering, 2017, 30(6): 1347–1356.
- [6] ZHANG Tianfan, LI Zhe, DEND Zhenghong, et al. Hybrid data fusion DBN for intelligent fault diagnosis of vehicle reducers [J]. Sensors (Basel, Switzerland), 2019, 19(11):2504.
- [7] 周步祥, 袁岳, 林楠, 等. 一种融合 FRVM 和 DBN 的变压器故障诊断方法[J]. 水电能源科学, 2019, 37(9): 188–191, 158.
ZHOU Buxiang, YUAN Yue, LIN Nan, et al. A transformer fault diagnosis method based on FRVM and DBN[J]. Water Resources and Power, 2019, 37(9): 188–191, 158.

- [8] 范彬. 面向飞行器关键部件健康管理的故障预测方法研究[D]. 长沙:国防科技大学, 2015.
FAN Bin. Research on fault prediction method for health management of aircraft key components[D]. Changsha: National University of Defense Technology, 2015.
- [9] ZHAO Minghao, ZHONG Shisheng, FU Xuyun, et al. Deep residual networks with adaptively parametric rectifier linear units for fault diagnosis[J]. IEEE Transactions on Industrial Electronics, 2020, 68(3): 2587–2597.
- [10] 池永为, 杨世锡, 焦卫东, 等. 基于 EMD-DCS 的滚动轴承伪故障特征识别方法[J]. 振动与冲击, 2020(9): 10–16.
CHI Yongwei, YANG Shixi, JIAO Weidong, et al. Feature recognition method of rolling bearing pseudo fault based on EMD-DCS[J]. Journal of Vibration and Shock, 2020(9): 10–16.
- [11] 张丙强, 李亮. 人-车-路耦合系统振动分析及舒适度评价[J]. 振动与冲击, 2011, 30(1): 1–5.
ZHANG Bingqiang, LI Liang. Vibration analysis and comfort evaluation of human-vehicle-road coupling system[J]. Journal of Vibration and Shock, 2011, 30(1): 1–5.
- [12] 文成林, 吕菲亚. 基于深度学习的故障诊断方法综述[J]. 电子与信息学报, 2020, 42(1): 234–243.
WEN Chenglin, LYU Feiya. Survey of fault diagnosis methods based on deep learning[J]. Journal of Electronics & Information Technology, 2020, 42(1): 234–243.
- [13] 王宁. 行星齿轮箱健康状态监测方法的研究[D]. 西安: 西安工业大学, 2019.
WANG Ning. Research on health monitoring method of planetary gearbox[D]. Xi'an: Xi'an Technological University, 2019.
- [14] ABADI M, AGARWAL A, BARHAM P, et al. TensorFlow: large-scale machine learning on heterogeneous distributed systems[J]. arXiv:1603.04467, 2016.
- [15] 郝少鹏, 张雨果, 胡俊, 等. 电机振动信号的模糊聚类分析与故障诊断[J]. 科技与创新, 2019(9): 134–136.
HAO Shaopeng, ZHANG Yuguo, HU Jun, et al. Fuzzy clustering analysis and fault diagnosis of motor vibration signal[J]. Science and Technology & Innovation, 2019(9): 134–136.
- [16] MA Meng, MAO Zhu. Deep-convolution-based LSTM network for remaining useful life prediction[J]. IEEE Transactions on Industrial Informatics, 2020, 17(3): 1658–1667.

[作者简介]

李鹏程 1997 年生, 在读硕士研究生, 主要研究方向为大数据智能处理。

陈海东 1972 年生, 博士, 研究员, 主要研究方向为信息和数据分析。

李世鹏 1978 年生, 博士, 研究员, 主要研究方向为力学。

连彦泽 1985 年生, 硕士, 高级工程师, 主要研究方向为信息化和软件工程。