

基于 ResNet-LSTM 的航空发动机性能异常检测方法

蔡舒舒¹, 殷航¹, 史涛¹, 范杰²

(1. 中国民航大学航空工程学院, 天津 300300; 2. 中国南方航空股份有限公司河南分公司, 郑州 450000)

摘要: 为了实现数据驱动的航空发动机性能异常的智能检测, 提出了一种基于残差网络(ResNet)-长短期记忆网络(LSTM)的发动机性能异常检测方法。采用发动机性能数据图像化方法, 在数据降维的同时, 完备保留数据的关联特征和时序特征; 以残差单元构建发动机性能异常检测模型, 在加深网络结构的同时, 消除深层网络梯度消失问题, 提高发动机性能图像空间关联特征的提取能力。同时, 引入 LSTM, 提出基于 ResNet-LSTM 的发动机性能异常检测模型, 通过 ResNet 与 LSTM 的融合, 强化异常检测模型对时序特征的提取, 提升发动机性能异常检测的准确率; 通过发动机运行数据进行验证。结果表明: 在训练集上, 该方法的异常检测准确率为 94.95%, 比基于 ResNet18、ResNet34、ResNet50 异常检测模型的分别提高 10.87%、8.00%、3.23%; 在测试集上, 该方法的异常检测准确率为 92.15%, 比基于 ResNet18、ResNet34、ResNet50 异常检测模型的分别提高 11.81%、9.45%、3.78%。

关键词: 异常检测; 残差网络; 长短期记忆网络; 航空发动机

中图分类号: V263.6

文献标识码: A

doi: 10.13477/j.cnki.aeroengine.2024.01.019

Aero-Engine Performance Anomaly Detection Method Based on ResNet-LSTM

CAI Shu-yu¹, YIN Hang¹, SHI Tao¹, FAN Jie²

(1. College of Aeronautical Engineering, Civil Aviation University of China, Tianjin 300300, China;

2. Henan Branch, China Southern Airlines Company Limited, Zhengzhou 450000, China)

Abstract: In order to realize the intelligent detection of data-driven aero-engine performance anomalies, a method of aero-engine performance anomaly detection based on the Residual Neural Network (ResNet) and Long Short Term Memory (LSTM) is proposed. First, the visualization method of aero-engine performance data is designed. While reducing the data dimension, the correlation features and timing features of data are completely retained. Then, the residual unit is used to construct the aero-engine performance anomaly detection model, while deepening the network structure, the problem of deep network gradient disappearance is eliminated, and the spatial correlation feature extraction ability of engine performance images is enhanced. In the meantime, LSTM will be introduced to put forward the model of aero-engine performance anomaly detection based on ResNet-LSTM. Through the integration between ResNet and LSTM, it helps intensify the ability of the anomaly detection model to extract the timing features and enhance the accuracy of this method. Finally, it is verified by the aero-engine operation data. The results show that on the training set, the anomaly detection accuracy of this method is 94.95%, which is 10.87%, 8%, and 3.23% higher than that of the anomaly detection model based on ResNet18, ResNet34 and ResNet50, respectively. On the test set, the anomaly detection accuracy of this method is 92.15%, which is 11.81%, 9.45%, and 3.78% higher than that of the anomaly detection model based on ResNet18, ResNet34 and ResNet50, respectively.

Key words: anomaly detection; residual neural network; long short term memory; aero-engine

0 引言

航空发动机作为航空器关键动力装置, 其性能状态直接影响航空器运行安全和机上人员生命安全, 因此对发动机性能进行异常检测具有重要意义。人工智能神经网络的快速发展为发动机异常诊断提供了

新的分析方法, 它能够从数据中挖掘更深层次信息, 相比传统的回归分析方法有着更高的精度和适用性, 在发动机性能分析领域应用十分广泛。

基于排气温度^[1-2]、燃油流量^[3]、转子转速^[4-5]等数据驱动的航空发动机性能分析被国内外学者广泛关注。Birnbbaum 等^[6]运用基于递归最小二乘的异常检测

收稿日期: 2022-08-03

作者简介: 蔡舒舒(1985), 女, 硕士, 副教授。

引用格式: 蔡舒舒, 殷航, 史涛, 等. 基于 ResNet-LSTM 的航空发动机性能异常检测方法[J]. 航空发动机, 2024, 50(1): 135-142. CAI Shuyun, YIN Hang, SHI Tao, et al. Aero-engine performance anomaly detection method based on ResNet-LSTM[J]. Aeroengine, 2024, 50(1): 135-142.

算法对飞行数据进行在线异常检测,在飞行过程中实现异常数据点的瞬时检测;张群岩等^[7]利用多元线性回归分析的统计学方法分析了发动机外部载荷、工作状态以及气道流场3种试验条件对发动机振动的影响,影响贡献率分别为28.91%、15.06%和17.01%,分析结果对提高飞行试验能力具有积极意义;彭军等^[8]利用深度置信网络对发动机部件性能衰退故障数据进行求解,得到更高的诊断精度;闫雪等^[9]针对现有发动机机件所存在的检测效率低、适用范围有限等缺陷,提出了一种基于ResNet(Residual Neural Network)-18算法的缺陷分类方法,使用深度残差网络提取缺陷特征,并通过修改网络结构适应于不同的缺陷种类;林海涛等^[10]采用训练后的最小二乘(Levenberg-Marquardt, LM)优化算法的反向传播(Back-Propagation, BP)神经网络进行发动机故障诊断,正确率达到94%;蔺瑞管等^[11]针对发动机剩余寿命预测准确性低的问题,提出基于长短期记忆网络(Long Short Term Memory, LSTM)的预测性维护模型,利用美国航空航天局C-MAPSS数据集验证了该模型的有效性。近几年,深度学习技术以其在目标特征提取上的显著优势,成为故障诊断领域的研究热点。然而,深度学习在发动机性能异常检测领域的应用还存在不适用性。首先,发动机性能数据具有大规模、多维度、强关联等特征,相关模型需能够同时对数据关联特征及时序特征进行提取,并有效处理大规模、多维度的数据。其次,对于深度学习网络模型,加深网络层数可以获得更好的拟合特征且简化每层网络。但是传统网络模型随着网络深度不断加大,会出现梯度退化现象,导致输出误差较大,训练效果不理想。此外,深度学习的应用很大程度上依赖于训练数据,对训练数据集的合理构建和对特征信息的充分提取,是提升异常检测准确度的关键。

针对深度学习在航空发动机性能异常检测领域的应用局限,本文考虑航空发动机数据的关联特征和时序特征,提出一种基于ResNet-LSTM的航空发动机性能异常检测方法。通过真实性能数据对其进行测试,并与其他模型进行对比,验证了该模型的有效性。

1 航空发动机性能图像化方法

利用深度学习网络模型在图像特征提取方面的优势,构建航空发动机高维性能数据时序矩阵,并将

其转换为2维性能图像,为航空发动机性能异常检测模型提供数据输入。

假设航空发动机性能数据有 n 个性能参数,数据时序长度为 m ,则航空发动机性能数据时序矩阵 D 为

$$D = \begin{bmatrix} d_1 \\ \vdots \\ d_i \\ \vdots \\ d_n \end{bmatrix} = \begin{bmatrix} d_{11} & \cdots & d_{1m} \\ \vdots & \ddots & \vdots \\ \vdots & d_{ij} & \vdots \\ \vdots & \ddots & \vdots \\ d_{n1} & \cdots & d_{nm} \end{bmatrix} \quad (1)$$

式中: d_i 为第 i 个性能参数的时序数据; d_{ij} 为第 i 个性能参数的第 j 个性能数据, $1 \leq i \leq n, 1 \leq j \leq m$ 。

对于航空发动机性能数据时序矩阵 D ,可将其各性能参数时序数据映射至RGB色彩空间的 $[0, 255]$ 区间内,实现发动机性能数据图像化。

航空发动机性能图像 P 为

$$P = \begin{bmatrix} p_{11} & \cdots & p_{1m} \\ \vdots & \ddots & \vdots \\ \vdots & p_{ij} & \vdots \\ \vdots & \ddots & \vdots \\ p_{n1} & \cdots & p_{nm} \end{bmatrix} \quad (2)$$

式中: p_{ij} 为第 i 个性能参数的第 j 个性能数据对应的RGB像素值, $1 \leq i \leq n, 1 \leq j \leq m$ 。

$$p_{ij} = \frac{(d_{ij} - d_{i,\min}) \times 256}{(d_{i,\max} - d_{i,\min})} \quad (3)$$

航空发动机性能图像化方法通过建立各发动机性能数据值域与RGB彩色空间的映射关系,将高维度的性能参数数据转换为2维性能图像,为性能参数之间关联特征提取和时序特征提取保留充分的性能数据信息。

2 基于ResNet-LSTM的航空发动机性能异常检测模型

2.1 残差单元结构

针对航空发动机性能数据所具有高维度、大规模、强关联的特点,发动机性能异常检测模型以多个残差单元构建前置特征提取模块,提取发动机性能参数间的关联性特征。

作为航空发动机性能异常检测模型前置特征提取模块的核心部分,残差单元^[12-13]基本结构如图1所示。




图1 残差单元基本结构

假设第 l 个残差单元输入性能图像特征为 x_l , 输出特征为 x_{l+1} , 则残差单元为

$$y_l = h(x_l) + F(x_l, \omega_l) \quad (4)$$

$$x_{l+1} = \text{ReLU}(y_l) \quad (5)$$

当 y_l 与 x_l 维度相同时, $h(x_l)$ 为恒等连接, 即 $h(x_l) = x_l$; 当 y_l 与 x_l 维度不同时, $h(x_l)$ 是 x_l 的线性映射, 即 $h(x_l) = \lambda \cdot x_l$, 以匹配维度; $F(x_l, \omega_l)$ 为残差函数

$$F(x_l, \omega_l) = \text{ReLU}(x_l \cdot \omega_l + b_l) \quad (6)$$

式中: ω_l 为第 l 个残差单元的权重及偏差, $\omega_l = \{w_{l,k} | 1 \leq k \leq K\}$; K 为残差单元的网络层数目, b_l 为该层偏置, 线性整流函数 (Rectified Linear Unit, ReLU) 为激活函数

$$\text{ReLU} = \text{MAX}(0, x) \quad (7)$$

假设损失函数为 ε , 任意更深层的第 L 个残差单元输入特征为 x_L , 则残差单元梯度为

$$\frac{\partial \varepsilon}{\partial x_L} = \frac{\partial \varepsilon}{\partial x_L} \frac{\partial x_L}{\partial x_L} = \frac{\partial \varepsilon}{\partial x_L} \left(1 + \frac{\partial}{\partial x_L} \sum_{i=1}^{L-1} F(x_i, \omega_i) \right) \quad (8)$$

式中: 梯度 $\frac{\partial \varepsilon}{\partial x_L}$ 能够解耦为 2 部分, $\frac{\partial \varepsilon}{\partial x_L}$ 表示信息不通过权重层直接传播, 使损失函数信息可后向传播至更浅的任意单元; 同时, 保证即使权重任意小, 亦均可避免梯度消失现象。

2.2 长短期记忆网络结构

针对航空发动机性能数据所具有的时序特征, 以 LSTM^[14] 网络构建航空发动机性能异常检测模型的时序特征提取模块, 提取航空发动机性能参数间的时序性特征。

LSTM 网络循环单元结构如图 2 所示。从图中可见, LSTM 由 3 个门^[15-16] 组成, 分别是遗忘门 f_t 、输入门 i_t 和输出门 o_t 。

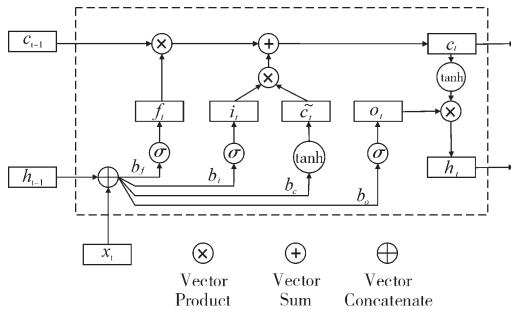


图 2 LSTM 网络循环单元结构

遗忘门运算逻辑为

$$f_t = \sigma(w_{xf} \cdot x + w_{hf} \cdot h_{t-1} + b_f) \quad (9)$$

式中: w_{xf} 和 w_{hf} 为遗忘门的权重系数; b_f 为遗忘门的偏置项。遗忘门的输出 f_t 是 n 维输出, 每个值都在 $(0, 1)$

之间, 其值接近 0 的信息被遗忘, 接近 1 的被保留。

因此, 通过遗忘门, LSTM 可以长期记忆重要信息, 并且记忆可随输入动态调整。

输入门运算逻辑为

$$\tilde{c}_t = \tanh(w_{xc} \cdot x_t + w_{hc} \cdot h_{t-1} + b_c) \quad (10)$$

$$i_t = \sigma(w_{xi} \cdot x_t + w_{hi} \cdot h_{t-1} + b_i) \quad (11)$$

式中: \tanh 为双曲正切激活函数; w_{xc} 和 w_{hc} 为 \tilde{c}_t 的权重系数; b_c 为 \tilde{c}_t 的偏置项; w_{xi} 和 w_{hi} 为输入门的权重系数; b_i 为输入门的偏置项。

输入门整合上一时刻与当前时刻信息一起作为新的输入, 有选择地保留在当前状态, 因此, 通过输入门, LSTM 可以短期记忆重要信息, 并且不断更新当前状态。

输出门运算逻辑为

$$o_t = \sigma(w_{xo} \cdot x_t + w_{ho} \cdot h_{t-1} + b_o) \quad (12)$$

式中: w_{xo} 和 w_{ho} 为输出门的权重系数; b_o 为输出门的偏置项。

输出门产生当前时刻的输出。输出门根据当前时刻 t 输入 x_t 与上一时刻 $t-1$ 隐藏层的状态 h_{t-1} 以及最新状态 c_t 决定该时刻 t 的输出 h_t 。

当前时刻 t 的状态 c_t 为

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (13)$$

当前时刻 t 的输出 h_t 为

$$h_t = o_t \cdot \tanh(c_t) \quad (14)$$

σ 为 Sigmoid 激活函数, 取值范围在 $[0, 1]$

$$\sigma = \text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (15)$$

\tanh 函数的取值范围为 $[-1, 1]$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (16)$$

2.3 基于 ResNet-LSTM 的航空发动机性能异常检测模型

基于 ResNet-LSTM 的航空发动机性能异常检测模型由前置特征提取模块、时序特征提取模块、输出模块 3 部分组成。前置特征提取模块以 ResNet 网络为核心, 用来学习发动机性能图像空间关联等特征; 时序特征提取模块以 LSTM 为核心, 用来挖掘数据的时序特征; 输出模块整合网络输出并通过 Softmax 分类器^[17] 对输出信息进行判别, 实现发动机性能异常检测功能。发动机性能异常检测模型如图 3 所示。

基于 ResNet-LSTM 的航空发动机性能异常检测模型各模块组成如下。

(1)前置特征提取模块包括Conv (Convolutional)-ReLU层、BN (Batch Normalization)层、ReLU层、Max-pooling层以及4类ResBlock组成的ResBlock层、ReLU层、Avg-pooling层。

Conv-ReLU层为卷积层与激活函数结合层,以卷积运算提取深层次的信息,运用激活函数ReLU增强非线性拟合能力。该层卷积核尺寸为 7×7 ,步长为2。第 i 层卷积层进行局部特征提取为

$$x_i = \text{ReLU}(x_{i-1} \cdot \omega_i + b_i) \quad (17)$$

式中: x_{i-1} 为该卷积层输入; ω_i 为该层权重; b_i 为该层偏置项。激活函数ReLU计算见式(7)。

BN层为批量归一化层,通过将输入强制转换为近似标准正态分布,使得前序非线性变换函数的输入值落入对输入比较敏感的区域,以此避免发生深层网络性能退化,同时保持梯度较大状态,提升网络参数优化的效率,使其高效收敛。假设第 k 个训练批次有 n 个样本 $x_i, 1 \leq i \leq n$,则第 k 个训练批次样本均值 μ_k 为

$$\mu_k = \frac{1}{n} \sum_{i=1}^n x_i \quad (18)$$

第 k 个训练批次样本方差 σ_k^2 为

$$\sigma_k^2 = \frac{1}{n} \sum_{i=1}^n x_i (x_i - \mu_k)^2 \quad (19)$$

BN层输入 x_i 为

$$\hat{x} = \frac{x_i - \mu_k}{\sqrt{\sigma_k^2 + \varepsilon}} \quad (20)$$

BN层输出 y_i 为

$$y_i = \gamma \hat{x} + \beta \quad (21)$$

式中: ε 为偏置; γ, β 均为残差网络训练归一化参数。

Max-pooling为最大池化层

$$y_i = \gamma \hat{x} + \beta \quad (22)$$

式中: y_m 为最大池化的输出值; x_i 为输入的各元素值。

最大池化层的作用是选出最大值作为池化后的值,除去冗余信息,降低特征维度,加速运算防止出现拟合现象。

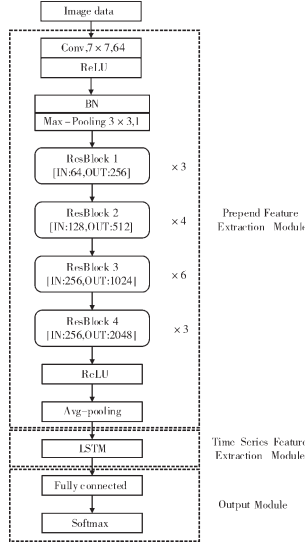


图3 航空发动机性能异常检测模型

ResBlock层的4种不同结构的ResBlock如图4所示。ResBlock层中第1部分由3个ResBlock1组成,每个ResBlock1有3层卷积层,卷积核尺寸分别为 1×1 、 3×3 、 1×1 ,步长为2;第2部分由4个ResBlock2组成,每个ResBlock2有3层卷积层,卷积核尺寸分别为 1×1 、 3×3 、 1×1 ,步长为2;第3、4部分分别由6个ResBlock3和3个ResBlock4组成,其卷积层数、卷积核尺寸和步长均相同。

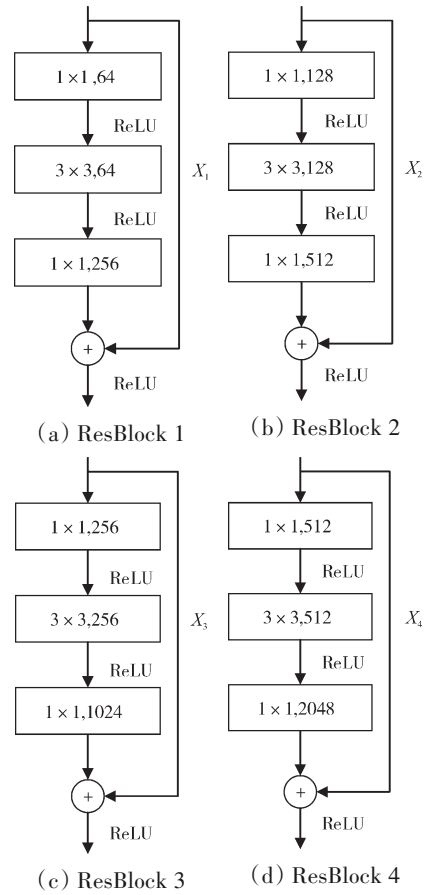


图4 4种ResBlock结构

Avg-pooling(average pooling)为平均池化层

$$y_a = \frac{1}{n} \sum_{i=1}^n x_i \quad (23)$$

式中: y_a 为平均池化的输出值; x_i 为输入的各元素值。平均池化层的作用是计算出平均值作为池化后的值,除去冗余信息,降低特征维度,加速运算防止出现拟合现象。

(2)时序特征提取模块主要由LSTM层组成。LSTM层为长短期记忆网络层,计算逻辑见式(9)~(14)。由1层LSTM网络组成,输入向量的维度为2048,选tanh函数和Sigmoid函数为激活函数。

(3)输出模块由Fully connected层与Softmax层组

成。Fully connected 为全连接层,该层量化为

$$f(x) = \sum_{i=1}^n \omega_i x_i + b \quad (24)$$

式中: x_i 、 ω_i 分别为第 i 个输入的输入值与权重; b 为偏置。

该层的作用是整合和提取之前卷积层、池化层等网络运算后的信息特征,确定其分类,提高该网络整体的鲁棒性。

Softmax 层为 Softmax 分类器层,通过 Softmax 函数,把从前面网络中输出的信息数据映射到[0,1]区间上,对航空发动机性能图像纹理片段进行判定,计算其正常或者异常的概率,最终实现航空发动机性能异常检测。Softmax 函数为

$$S_i = \frac{e^{x_i k}}{\sum_{i=1}^n e^{x_i}} \quad (25)$$

式中: S_i 为第 k 个数据的 Softmax 值; x_i 为第 k 个数据的值; n 为数据总数; $\sum_{i=1}^n e^{x_i}$ 为所有数据的指数和。

基于 ResNet-LSTM 的航空发动机性能异常检测方法具体步骤如下。

(1)航空发动机性能图像化。依据式(1)~(3),将高维度的性能参数数据转换为 2 维性能图像。

(2)航空发动机性能数据集建立。通过图像纹理分析,建立发动机性能数据集,并设定发动机性能异常检测的训练集和测试集比例。

(3)构建基于 ResNet-LSTM 网络的航空发动机性能异常检测模型。

(4)设置模型超参数,将训练集输入到性能异常检测模型中进行训练。

(5)使用训练好的检测模型对测试集进行异常检测。

2.4 模型评价指标

为了评价航空发动机性能异常检测模型,本文采用准确率 accuracy 作为模型主要评价指标,损失值 loss 作为辅助评价指标。

异常检测准确率为

$$\text{accuracy} = \frac{x_i}{N_i} \quad (26)$$

式中: x_i 为第 i 次检测中正确样本数; N_i 为第 i 次检测中的样本总数。

损失值用以计算预测值和实际值之间的差异程度,采用二分类交叉熵函数计算模型的损失值

$$\text{Loss} = -\sum_{i=1}^n (y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)) \quad (27)$$

式中: \hat{y}_i 为第 i 个样本是正确样本的概率,是模型预测的结果,由 Softmax 层中 Softmax 分类器计算得来,即 $\hat{y}_i = S_i$,见式(25); y 为样本标签,如果样本属于正确样本,取值为 1,否则取值为 0。

3 实例验证与分析

3.1 航空发动机性能图像数据集

为了验证基于 ResNet-LSTM 的航空发动机性能异常检测方法,收集航空公司机队 QAR 数据,选取 CFM56-7B 发动机性能参数,包括左发低压转子振动值、左发高压转子振动值、右发低压转子振动值和右发高压转子振动值,共计 12 组性能数据,其中正常状态数据为 10 组,振动异常状态数据为 2 组,12 组数据具体信息见表 1。

表 1 12 组数据具体信息

组别	数据量	运行状态	组别	数据量	运行状态
a	11085	正常	g	5411	正常
b	6771	正常	h	5421	正常
c	6681	正常	i	7868	正常
d	9521	正常	j	7345	正常
e	10413	正常	k	5947	振动异常
f	5936	正常	l	6840	振动异常

依据航空发动机性能图像化方法,将性能数据转化为性能图像,通过纹理分析,将性能图像划分为正常性能图像纹理片段和异常性能图像纹理片段,并分别建立发动机性能图像纹理数据集。发动机性能图像纹理数据集部分样本如图 5 所示。

3.2 验证与分析

航空发动机性能异常检测模型参数设置见表 2。以航空发动机性能图像纹理数据集的 80% 样本作为训练集,20% 样本作为测试集。

为验证本文模型的有效性,在相同的数据集、试验环境和参数设置下,以 ResNet18、ResNet34、ResNet50、ResNet-LSTM 4 种模型进行对比验证。

(1)训练集上的准确率和损失值。ResNet18、ResNet34、ResNet50、ResNet-LSTM 4 种性能异常检测模型以相同的参数设置在相同训练集上的准确率和损失值变化对比如图 6 所示。

从图 6(a)中可见,在训练初期,4 种模型的准确率均快速提高,随着训练次数 epoch 的增加,收敛速度开始变慢,准确率在一定范围内波动,随后波动减小并逐渐稳定,最终收敛。从图 6(b)中可见,在训练初

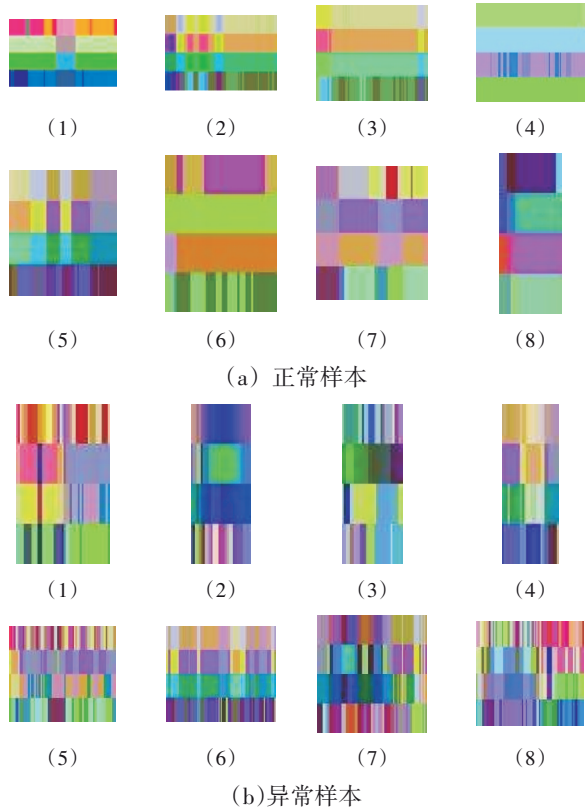



图5 发动机性能图像纹理数据集部分样本

表2 航空发动机性能异常检测模型参数设置

参数	对应设置	参数	对应设置
batch_size	16	学习率	0.001
epoch	500	优化方法	Adam



(a) 准确率变化对比 (b) 损失值变化对比

图6 4种模型的准确率和损失值变化对比

期,4种模型的损失值快速减小,随着训练次数的增加,收敛速度开始变慢,损失值在一定范围内波动,最终收敛。通过4种模型对比可见,基于ResNet-LSTM的航空发动机性能异常检测模型在训练集上的准确率高于其他异常检测模型的,损失值小于其他异常检测模型的,模型性能最好。这一结果充分说明了融合LSTM网络提取数据时序特征后提高了模型在训练集上的准确率,同时降低了损失值,这有助于之后整个发动机性能异常检测模型在测试集以及实际应用中

获得更好的检测效果。

ResNet18、ResNet34、ResNet50、ResNet-LSTM 4种模型在训练集上的训练结果见表3。

表3 4种模型的训练结果

模型	准确率/%	损失值	训练时间/min
ResNet18	84.08	1.220	41.706
ResNet34	86.95	1.165	75.104
ResNet50	91.72	1.001	116.772
ResNet-LSTM	94.95	0.722	127.128

从表3中可见,改进后的模型在训练集上取得了最好的效果。改进后ResNet-LSTM模型的准确率得到显著提升,与ResNet18模型相比准确率提高10.87%,与ResNet34模型相比准确率提高8%,与ResNet50模型相比准确率提高3.23%。改进后ResNet-LSTM模型的损失值减小,与ResNet18模型相比损失值减小0.498,与ResNet34模型相比损失值减小0.443,与ResNet50模型相比损失值减小0.279。改进后ResNet-LSTM模型训练时间有所增加,由于在单一的ResNet网络基础上融合LSTM网络,以复杂网络结构增强了模型对训练数据特征提取的能力,以增加网络参数和计算量进而增加训练时间为代价提高了训练的准确率。

(2)测试集上的准确率和损失值。将训练完成的ResNet18、ResNet34、ResNet50、ResNet-LSTM 4种性能异常检测模型在相同测试集上进行测试,测试结果见表4。

表4 4种模型测试结果

模型	准确率/%	损失值	测试时间/s
ResNet18	80.34	1.097	3.921
ResNet34	82.70	1.076	4.351
ResNet50	88.37	0.946	4.949
ResNet-LSTM	92.15	0.604	5.471

从表中可见,基于ResNet-LSTM的航空发动机性能异常检测模型在测试集上准确率最高,达到92.15%,相比ResNet50模型的提高了3.78%,主要原因是在ResNet50网络后增加了LSTM网络,在ResNet50提取特征的基础上进一步提取时间特征信息,使模型获得的性能数据特征更加充分,有效提高了发动机性能异常检测模型的检测准确率。在时间方面,与其他模型相比,改进后的模型测试时间虽有所增加,但仍保持了秒级的响应时间,说明改进后的

模型在提高检测准确率的同时,仍可在较短的时间内完成异常检测,满足工程应用对实时性的需求。

(3)在不同数据集上的试验结果对比。基于原始数据集构建 A、B、C 3 组数据集,A 组数据集是在原始数据集中随机选取 90% 的数据构成,B 组数据集是在原始数据集中随机选取 75% 的数据构成,C 组数据集是在原始数据集中随机选取 50% 的数据构成,3 组数据具体信息见表 5。

表 5 3 组数据具体信息

组别	数据量
A	80316
B	66929
C	44620

将发动机性能数据转换为 2 维性能图像后建立航空发动机性能图像纹理数据集,以发动机性能图像纹理数据集的 80% 样本作为训练集,20% 样本作为测试集。将 ResNet18、ResNet34、ResNet50、ResNet-LSTM 4 种性能异常检测模型分别在不同的数据集上进行测试,得到的结果如图 7~9 所示并见表 6~8。

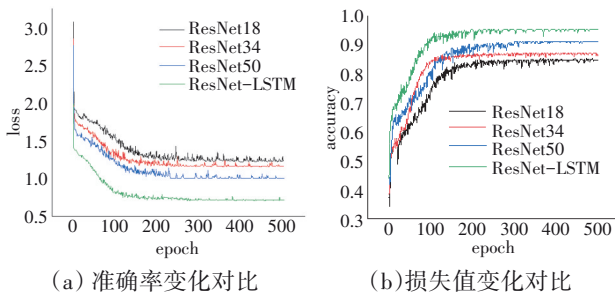


图 7 4 种模型在数据集 A 上准确率和损失值变化对比

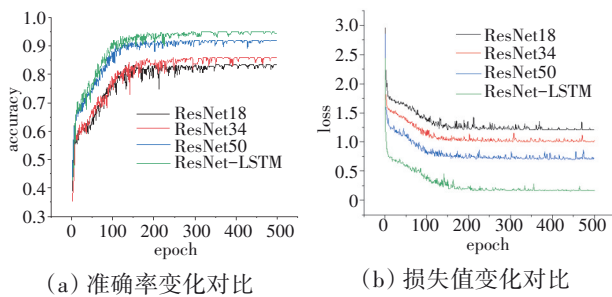


图 8 4 种模型在数据集 B 上准确率和损失值变化对比

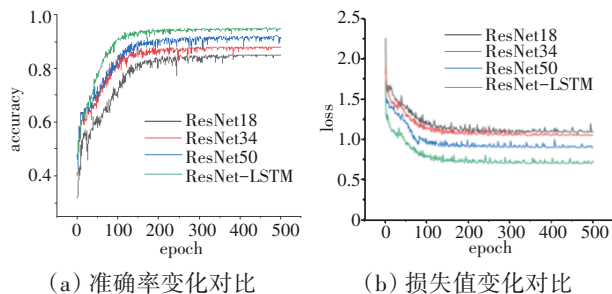


图 9 4 种模型在数据集 C 上准确率和损失值变化对比

表 6 4 种模型在数据集 A 上测试结果

模型	准确率/%	损失值
ResNet18	80.19	1.104
ResNet34	82.66	1.082
ResNet50	88.32	0.953
ResNet-LSTM	92.11	0.606

表 7 4 种模型在数据集 B 上测试结果

模型	准确率/%	损失值
ResNet18	78.83	1.112
ResNet34	82.66	1.095
ResNet50	87.86	1.003
ResNet-LSTM	91.70	0.611

表 8 4 种模型在数据集 C 上测试结果

模型	准确率/%	损失值
ResNet18	77.56	1.228
ResNet34	82.21	1.110
ResNet50	87.63	1.014
ResNet-LSTM	91.51	0.627

改进后的 ResNet-LSTM 模型在不同数据集上的准确率和损失值都优于其他模型的,证明改进后航空发动机异常检测方法的效果十分稳定。

4 种模型在不同数据集上的训练时间和测试时间如图 10 所示。从图中可见,改进后的 ResNet-LSTM 模型在运行时间上相比其他模型有所增加,这是因为 ResNet-LSTM 网络加深了 ResNet 网络深度的同时融合 LSTM 网络,提高模型网络复杂度,导致神经网络整体的时间复杂度增加,相比简单网络模型消耗更多内存,同时增加了网络参数与计算量,在运行过程中,神经网络把上一层的数据特征与下一层的数据特征在维度上进行累加,这样虽然提高了网络提取特征的能力,但会导致内存访问成本随网络深度增加而增长,进而导致模型运行时间稍有增加。

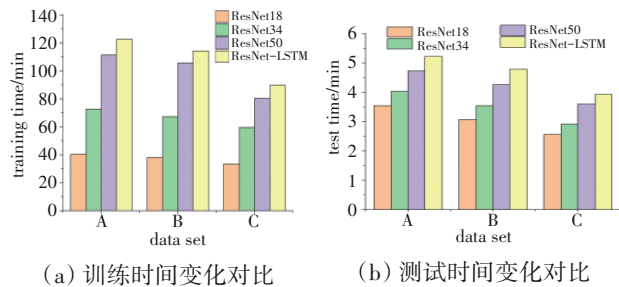


图 10 4 种模型在不同数据集上的训练时间和测试时间变化对比

基于 ResNet-LSTM 的航空发动机性能异常检测模型在测试集上的运行时间与其他网络相比增长在 2 s 以内,仍保持了秒级的响应时间。在实际工程应

用中,训练时间发生在异常检测任务之前的后台准备工作中,测试时间发生在正式异常检测任务中,代表对航空发动机性能进行异常检测时所需时间,且训练1次后可进行多次异常检测工作。因此本文方法通过牺牲少许后台训练时间换取更高的准确率在工程意义上是值得的,且秒级的测试响应时间依旧符合实际工程应用中的实时性要求。

4 结论

(1)建立了基于ResNet-LSTM的航空发动机性能异常检测模型,与基于ResNet18、ResNet34、ResNet50网络的异常检测模型相比,异常检测准确率显著提高,分别提高了11.81%、9.45%、3.78%,且损失值均明显减小。

(2)试验结果表明,针对具有大规模、高维度、强关联、时序性等特征的航空发动机性能数据,通过增加网络复杂度的方式提高网络的性能,能得到更好的异常检测效果,且改进效果较为稳定,虽然模型训练时间有所增加,但模型测试时间与其他模型的相差不大且用时较短,在工程应用可接受的时间范围内,因此改进后的模型可以满足工程应用实时性的需求。

参考文献:

- [1] Giorgi M G, Quarta M. Hybrid multigene genetic programming-artificial neural networks approach for dynamic performance prediction of an aeroengine[J]. Aerospace Science and Technology, 2020, 103: 105902-1-12.
- [2] 刘渊,余映红,田彦云,等.航空发动机排气温度基线建模新方法研究[J].推进技术,2022,43(4):16-25.
LIU Yuan, YU Yinghong, TIAN Yanyun, et al. Investigation on new method for baseline modelling of aeroengine exhaust gas temperature [J]. Journal of Propulsion Technology, 2022, 43 (4) : 16-25. (in Chinese)
- [3] 郭政波,刘振刚,雷杰.基于极限学习机的航空发动机主燃油流量预测研究[J].工程与试验,2020,60(1):21-23.
GUO Zhengbo, LIU Zhengang, LEI Jie. Prediction of aerongine main fuel flow based on extreme learning machine [J]. Engineering and Test, 2020, 60(1) : 21-23. (in Chinese)
- [4] 王世德,刘志宏,王炳辉.某型航空发动机转速摆动故障分析[J].航空维修与工程,2021(10):79-80.
WANG Shide, LIU Zhihong, WANG Binghui. Failure analysis on rotating speed swing for a certain type of engine [J]. Aviation Maintenance and Engineering, 2021(10) : 79-80. (in Chinese)
- [5] 李小彪,马庆岩,张立伟,等.航空发动机高压转子转速摆动故障分析与排除[J].航空发动机,2021,47(5):62-65.
LI Xiaobiao, MA Qingyan, ZHANG Liwei, et al. Analysis and elimination on speed swing of an aeroengine high pressure rotor [J]. Aeroengine, 2021, 47(5) : 62-65. (in Chinese)
- [6] Birnbaum Z, Dolgikh A, Skormin V, et al. Unmanned aerial vehicle security using recursive parameter estimation[C]//2014 International Conference on Unmanned Aircraft Systems (ICUAS). Orlando: IEEE, 2014:692-702.
- [7] 张群岩,史建邦,符烧.基于多元线性回归方法的试验条件对发动机振动的影响分析[J].机械研究与应用,2016,29(4):114-117.
ZHANG Qunyan, SHI Jianbang, FU Yao. Influence analysis of testing conditions on engine vibration base on MLR [J]. Mechanical Research and Application, 2016, 29(4) : 114-117. (in Chinese)
- [8] 彭军,郭晨阳,张勇,等.基于深度学习的航空发动机部件故障诊断[J].系统仿真技术,2018,14(1):20-24.
PENG Jun, GUO Chenyang, ZHANG Yong, et al. Fault diagnosis of aero engine components based on deep learning method [J]. System Simulation Technology, 2018, 14(1) : 20-24. (in Chinese)
- [9] 闫雪,张瑜,李光耀,等.基于ResNet的航空发动机机件表面缺陷分类研究[J].计算机科学与应用,2021,11(5):1256-1263.
YAN Xue, ZHANG Yu, LI Guangyao, et al. Research on surface defects classification of aeroengine parts based on ResNet [J]. Computer Science and Application, 2021, 11(5) : 1256-1263. (in Chinese)
- [10] 林海涛,朱宝全,马小涵.基于BP神经网络的发动机故障诊断算法研究[J].科学技术创新,2020(16):73-74.
LIN Haitao, ZHU Baoquan, MA Xiaohan. Research on engine fault diagnosis algorithm based on BP neural network [J]. Innovation in Science and Technology, 2020(16) : 73-74. (in Chinese)
- [11] 蔺瑞管,王华伟,车畅畅,等.基于LSTM分类器的航空发动机预测性维护模型[J].系统工程与电子技术,2022,44(3):1052-1059.
LIN Ruiguan, WANG Huawei, CHE Changchang, et al. Predictive maintenance model of aeroengine based on LSTM classifier [J]. Systems Engineering and Electronics, 2022, 44(3) : 1052-1059. (in Chinese)
- [12] He K, Zhang X, Ren S. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016:770-778.
- [13] He K, Zhang X, Ren S, et al. Identity mappings in deep residual networks[C]//Computer Vision—ECCV 2016 (Lecture Notes in Computer Science 9908). Amsterdam: ECCV, 2016:630-645.
- [14] 陈保家,郭凯敏,陈法法,等.基于残差Nested-LSTM和注意力机制的航空发动机剩余寿命预测[J].航空动力学报,2023,38(5):1176-1184.
CHEN Baojia, GUO Kaimin, CHEN Fafa, et al. Prediction of remaining useful life of aero-engine based on residual Nested-LSTM and attention mechanism [J]. Journal of Aerospace Power, 2023, 38 (5) : 1176-1184. (in Chinese)
- [15] 王坤,侯树贤.基于深度学习的辅助动力装置性能参数预测方法研究[J].推进技术,2022,43(1):290-299.
WANG Kun, HOU Shuxian. Prediction method of auxiliary power unit performance parameter based on deep learning [J]. Journal of Propulsion Technology, 2022, 43(1) : 290-299. (in Chinese)
- [16] 沈庙生,高更君.基于LSTM的短时高速公路交通量预测[J].控制工程,2023,30(11):2011-2018.
SHEN Miaosheng, GAO Gengjun. Short-term forecasting of highway traffic volume based on LSTM [J]. Control Engineering of China, 2023, 30(11) : 2011-2018. (in Chinese)
- [17] Zhang Q, Yang J B, Zhang X W, et al. SO-softmax loss for discriminable embedding learning in CNNs [J]. Pattern Recognition, 2022, 131(c) : 108877.

(编辑:刘静)