

基于改进的 SENet 航空发动机振动预测

夏存江, 詹于游

(中国民用航空飞行学院 航空工程学院, 四川 广汉 618307)

摘 要: 为实时监测和预警航空发动机振动状态, 基于气路及振动参数, 提出一种使用改进的 SENet(squeeze-and-excitation network)模型, 对航空发动机近未来的振动进行预测。该研究相比以往采用的实验室模拟数据和仿真数据, 使用了真实的 QAR(quick access recorder)数据并进行随机采样, 以求更能表征发动机振动和工作参数之间的关系。同时, 不仅使用其他振动信号进行验证, 还在其他型号的发动机上进行测试。结果表明: 针对航空发动机的振动进行预测是可行的, SENet 模型可以有效并实时追踪振动的突变和波动。此外, 该方法对于其他振动信号和不同类型的发动机具有一定的适用性。而且相较于以往采用的其他经典的深度模型, SENet 模型在振动的预测中得到更小的误差。实验证明, 相较于以往只使用振动这个单参数进行预测, 并行使用与振动相关的多参数融合进行研究更能提高预测的准确性。

关 键 词: 振动预测; 数据驱动; 卷积神经网络; 注意力机制; 多参数融合

中图分类号: V239

文献标志码: A

Vibration prediction of aeroengines based on enhanced SENet model

XIA Cunjiang, ZHAN Yuyou

(College of Aviation Engineering,

Civil Aviation Flight University of China, Guanghan Sichuan 618307, China)

Abstract: In order to monitor the vibration status of aeroengines and acquire warning signals in real-time, an enhanced SENet (squeeze-and-excitation network) model was proposed based on gas path and vibration parameters. Compared with the previous research which used datasets generated from specific lab situations and simulation data, actual QAR (quick access recorder) data were adopted for random sampling of the datasets. This technique could characterize the real operation status and the interaction of parameters better in vibration systems. The results showed that it is possible to forecast the vibration of aeroengines, and the SENet model could effectively and timely track sudden changes and the fluctuation of vibration. In addition, the applicability of this method into other vibration parameters and different types of aeroengines was tested. Furthermore, compared with other classical learning algorithms, the SENet model may obtain a smaller error in vibration forecasting. At the same time, the experiments showed that compared with previous research only focusing on the vibration, using the fusion of multi parameters could improve the accuracy of the forecast.

Keywords: vibration prediction; data-driven; convolutional neural network; attention mechanism; multi-parameter fusion

收稿日期: 2022-03-04

基金项目: 四川省科技基金(2022YFG0356); 西藏科技厅重点研发计划(XZ202101ZY0017G); 民航局教育培训项目(0252001);

中央高校基本科研业务费基金项目(J2022-014)

作者简介: 夏存江(1971—), 男, 教授、硕士生导师, 硕士, 研究方向为航空发动机控制与维修技术。E-mail: xia-cunjiang@aemtc.com

通信作者: 詹于游(1997—), 男, 硕士生, 研究方向为航空宇航推进理论与工程。E-mail: zyyskma@163.com

引用格式: 夏存江, 詹于游. 基于改进的 SENet 航空发动机振动预测[J]. 航空动力学报, 2022, 37(12): 2807-2817. XIA Cunjiang, ZHAN Yuyou.

Vibration prediction of aeroengines based on enhanced SENet model[J]. Journal of Aerospace Power, 2022, 37(12): 2807-2817.

在民用航空领域,保障航空发动机的安全适航和稳定工作对于保证飞机整体系统的安全航行具有重要意义。但在使用的过程中,发动机的性能会随着工作循环的增加而不断退化^[1],甚至会由于设备老化、气流通道的腐蚀和侵蚀、部件之间的碰磨损伤和脱落等导致严重的航空事故^[2]。而通过飞行数据可以有效诊断、分析航空发动机故障的发生以及预测重要部件和系统参数的发展趋势。即通过数据驱动的方法对部件或系统的状态进行分析、判断和预测,有效避免了传统方法中人为因素所引起的判断准确性有限等问题^[3-4]。

振动是航空发动机的重要参数之一,由多参数共同作用,变化复杂,其发展趋势则可以很好地作为当前发动机状态的参考,但利用传统仿真建模或实验室模拟等^[5-6]方法所获得的振动基线预测模型很难与实际飞行中的发动机振动状态相拟合。所以基于快速访问记录器(quick access recorder, QAR)所记录的真实的飞行数据,且利用数据驱动方法研究发动机的振动,对于保障飞行安全、研究振动故障和相关重要参数的发展规律等有重要意义。

在航空发动机相关部件或系统的基线建模、故障诊断和趋势预测等相关研究中,许多有意义的成果都是利用了数据驱动法。如:曹惠玲等^[7]利用支持向量机建立快速诊断航空发动机是否喘振的方法。付旭云等^[8]利用时变模糊网络提高了发动机排气温度的气路参数预测精度。李书明等^[9]使用高斯牛顿迭代法对发动机基线做非线性回归预测,并将成果应用在发动机运行维修领域。但以上方法都是利用早期机器学习算法进行相关研究,这些研究方法具有模型精度相对不高,且不适用于大规模、多参数数据集等问题。

随着机器学习领域的不断地发展,深度学习方法逐渐具有越来越大的影响力。深度学习使用数以万计的大规模数据集来训练复杂的深度神经网络,以得到高精度、高鲁棒的模型。同时大多深度学习模型都可以避免需要针对特定问题设计特定特征工程的问题,直接进行端到端学习,节约了人工抽取特征的复杂过程,且泛化能力强,从图片、文本等非结构型数据可迁移应用到表格、时间序列等结构型数据^[10-14]。近年来,随着深度学习在计算机视觉和自然语言领域的研究不断拓展,因为卷积神经网络具有可以提取空间特征和多通道可以识别与组合不同模式的特点,所以将卷积神经网络应用在自然语言处理领域也是一个重要突破。特别是加入注意力(attention)机制后,

在将序列特征抽取的同时,给予重要特征更好的权重(注意力),以达到理想的特征抽取效果。

而航空发动机中与振动直接相关的重要参数则具有时间序列的特点。将卷积神经网络和注意力机制应用在振动研究上不仅达到多参数融合的效果使模型精度更高,更可能拟合存在真实的振动函数,而且在特征抽取时会更加注重重要特征,滤去噪声的效果。如今已有许多将卷积神经网络应用在振动的研究如轴承故障诊断等方向上。如杨洁等^[15]利用一维卷积神经网络通过多通道输入将多参数结合对发动机轴承故障进行诊断达到100%的准确率。董永峰等^[16]将改进一维卷积神经网络和双向长短期记忆网络(1DCNN-BiLSTM)相结合,在凯斯西储大学轴承数据集上表现出96.87%的故障识别率。王奕惟等^[17]基于全航段QAR数据采用卷积神经网络对发动机的不同衰退状态进行识别,达到98%的准确率。而注意力机制的加入则进一步改善了模型的性能。如莫仁鹏等^[18]将残差网络与注意力机制结合进一步降低了设备剩余寿命预测的误差。杨永灿等^[19]等将注意力机制加入一维卷积网络应用于行星齿轮箱的故障诊断证明优于其他深度模型。

但总体而言,目前国内民用航空发动机对于振动相关的研究还有以下问题:①目前国内针对发动机振动相关的研究大都采用实验室仪器模拟、软件仿真和开放数据集获取数据,并未采用真实飞行过程中发动机所产生的数据。②虽然有从以往的简单机器学习模型向广泛利用深度学习的复杂模型研究的趋势,但大部分研究只针对振动本身进行建模,并未考虑其他相关的重要参数,如高、低压转子转速、压气机各级温度等。如文献^[15-16,19]等,没有考虑气流对发动机振动的综合影响。须知,航空发动机振动是一个复杂的、相互作用、相互影响的多参系统,振动虽可在一定程度上表征发动机的状态,但也是由许多重要参数如低、高压转子转速、温度、压力等共同作用。③有些研究虽然使用了飞行数据,但所建立的是分航段的模型。虽然飞机飞行过程中的确有航段之分,但是发动机的运行却是统一整体,共同作用。并非根据航段变化,而是依据相关参数的变化而变化。所以研究一个统一的整体性的模型就尤为必要。④除此之外,很多研究中的研究对象是单一的不变的,无法充分探讨所研究方法的适用能力。同一型号发动机的不同振动参数是否可以直接应用,不同型号发动机的振动是否也可以预测。这些问题也需要进行探讨。

针对以上问题, 本文利用实际运行中, 民用航空发动机所产生的 QAR 数据, 选取了不同飞行时间、不同飞行地点和不同发动机类型的复杂数据, 力求建立具有高精度且有一定适用性的振动预测模型。本文采用改进的残差网络即 SENet (squeeze-and-excitation network), 因其具有注意力机制的特性, 所以在进行特征提取阶段可注意到关键特征和数据波动。忽略不重要的噪声影响, 同时以期在振动突变时可及时地跟进。此外本文采用多参数融合的方法, 将与发动机振动相关的重要参数一同输入, 力求提取出特征之间重要的关联以提升模型预期的精度, 该实验结果也将与单振动参数的预测结果进行对比。最后, 在证明预测初步可行的基础上, 本文也将探索在其他振动参数和不同型号发动机上的可行性以及预测效果。

1 数据集处理

1.1 数据获取

民用飞机飞行数据获取主要有根据飞机维修日志和记录数据、飞机通讯寻址和报告系统即 ACARS (aircraft communications addressing and reporting system) 等。本文研究中所使用数据来源于两种不同型号的发动机实际飞行使用中所产生的 QAR 数据, 数据量经处理后接近百万。相比于传统的仿真模拟获取数据、使用公开数据集获取数据和在实验室特定环境下所产生的 QAR 数据, 本文所使用的数据更能表征目前主流型号发动机实际的运行状态, 且具有记载参数丰富详实、数据连续、易导出处理等优点^[20], 还有记录频率高, 同一时间步无缺失数据的特点, 保证了研究所依赖数据的可靠性、完整性。

1.2 参数筛选



本文对振动的研究主要以预测 1 号轴承支撑振动传感器所采集的振动为目标, 同时也会对其其他振动参数和其他型号发动机的振动进行研究, 以验证该研究方法的适用性。以传感器采集频

率 1 Hz 为 1 时间步, 基于当前所采集的 100 个时间步来预测未来 10 个时间步的变化规律。须知, 本文所研究的振动信号为机载振动计算机处理后的数据, 计算机本身会首先将无关的振动信号过滤, 所以后期 QAR 所记录的振动参数就无法获得振动的频率分布, 只能得到整机转子的振动, 所得的振动为本文的预测目标值。虽无法获得其他振动信息, 但通过对振动突变和大幅度波动的预测和跟踪, 在振动预警方面也具备一定的研究价值和实用意义。

由于航空发动机振动的影响因素复杂, 多参数相互作用, 参考发动机相关原理所以研究中特征的选择为: ①1 号轴承支撑振动传感器获取的低压转子的振动数据; ②1 号轴承支撑振动传感器获取的高压转子的振动数据; ③涡轮后框架振动传感器获取的低压转子的振动数据; ④涡轮后框架振动传感器获取的高压转子的振动数据; ⑤低压转子转速(N_1); ⑥高压转子转速(N_2); ⑦高压压气机出口压力(p_{s3}); ⑧风扇进口温度(t_{12}); ⑨高压压气机进口温度(t_{25}); ⑩高压压气机出口温度(t_3)。标签(label)的选择为 1 号轴承支撑振动传感器获取的低压转子的振动数据。即输入为不同航段随机抽取的连续 100 时间步(time step)内 1 号轴承支撑振动传感器获取的低压转子的振动, 以及其他有关联参数数据。输出为模型所预测的未来 10 个时间步的 1 号轴承支撑振动传感器的低压转子的振动。

1.3 缺失值处理

本文在缺失值处理中比较了线性插值、最近邻插值、阶梯插值、二阶样条曲线插值、三阶样条曲线插值和重心坐标插值。发现各个插值法从整体趋势看对样本的影响问题不大, 但线性插值法在连续性上有更好的表现, 所以本文采用线性插值法。各插值法对比如图 1 所示。缺失值补全后和补全前对比图如图 2 所示, 可以看出箭头处数据更平滑。都采用 t_3 为例。






图 1 各插值法对比

Fig. 1 Comparison results of interpolation methods




图 2 缺失值补全前后对比图

Fig. 2 Comparison results of complete data and missing data

1.4 数据抽取随机化

数据驱动法即使用机器学习或者深度学习的算法,根据输入参数进行建模,内部抽象或学习出与真实条件类似的特征并输出^[21-22]。所以为了建立更加精确的预测模型,更加贴近真实的多参数相互作用的振动模型,本文采用随机抽取训练集中连续的 100 个时间步特征数据和后 10 步标

签数据作为一个 batch 进行训练。之所以这样选取,是为了让模型分析足够多的数据,以取得较好的预测效果。此外,本文后续的研究部分也对不同时间步的预测结果做出了探讨。

本文以随机采样的方法抽取时间序列数据训练模型,以求训练出的模型更注重多参数之间的时序关系和相关影响关系,并能学习到对振动参

数的影响。这种不分航段的训练方式,可能让模型更加整体化,更注重实际中因参数变化而使振动发生变化的情况。通过这种操作,使得模型可能变得更加整体化并且注重参数的时序和相关影响。

2 模型架构

He 等^[23]提出了残差神经网络(residual neural network, Resnet)的架构,通过残差学习来优化复杂深度神经网络的性能,有效解决了由于网络深度增加反而导致网络性能退化的问题。而 Hu 等^[24]提出了 SENet,其核心在于关注特征通道(channel)之间的关系,希望模型可以自动学习到不同特征特征的重要程度。为此,SENet 提出了 SE(squeeze-and-excitation)模块。将 SE 模块和 Resnet 相结合不仅可以通过残差学习有效解决网络深度的问题,还可以在得到 Resnet 中各参数通过卷积核提取特征之后的特征通道,即不同参数之间相互组合的关联函数的高维特征抽取,并分别赋予权重以提高重要特征对模型的影响。但网络原用于图像处理领域,其内部的卷积核大小(kernel size)不适用于结构化的时间序列数据。所以在后续工作中本文将对所使用的 SENet 模型进行改进,以期适用于结构化的时间序列数据的相关研究。

2.1 残差网络

在深度学习领域,从经验上看网络的深度越深,网络的参数越多,模型越复杂,则越具备提取更加复杂的特征模式的能力。但随着更加深入的研究发现,网络深度增加模型却表现出了退化问题(degradation problem),即网络深度增加,网络准确度出现饱和甚至下降。但这种退化却不是由于过拟合所导致,因为在合适的模型中如果添加更多的层则会导致更高的训练误差^[25-26]。在理想环境下,更深层的网络训练结果不会比浅层网络结果差,如果前面的浅层网络已训练好结果,后面深层网络只需要作为恒等变换(identity mapping),即输入 x 等于输出 x 。等价于将权重学习为简单的 $1/n$ 使得输入与输出对应。但实际通过实验发现 SGD(stochastic gradient descent)随机梯度下降找不出理论最优解。而残差网络则提出了一个 deep residual learning framework 显示地构造出了一个恒等变换,解决了网络深度增加时出现的退化问题。将期望函数表示为 $H(x)$,已学习到

的结果表示为 x ,则下一层的网络并非如以往新学习一个 x ,而是去学习 $H(x)$ 与 x 的残差 $F(x)$,所以下一层的输出就为 $F(x)$ 与 x 的捷径连接(shortcut connections)和。如图 3 所示。




图 3 残差学习: 构建残差块

Fig. 3 Residual learning: a building block

残差网络中的捷径连接没有增加新的参数也不会增加计算复杂度。而通过学习 $F(x)$ 去拟合残差也解决了当 x 已经与 $H(x)$ 近似时 $F(x)$ 可以为学习到 0 的问题。这样基于较深的 Resnet 对大规模的 QAR 数据进行研究将得到比常规深度网络更优的结果。

2.2 压缩和激励网络

以往对于网络性能的提升是从空间维度层面开始研究,比如 Inception^[27] 结构嵌入多尺度信息以聚合不同感受野的特征来使性能增益。Inside-Outside^[28] 网络考虑了空间中的上下文信息,以及一些将注意力机制应用到空间维度上等。而 SENet 从特征通道入手,通过压缩和激励两个操作显示地构建特征通道之间的相互关系,通过学习的方式自动获取每个特征通道的重要程度,即权重,然后依照学习到的权重去提升有用的特征并抑制对当前任务用处不大的特征。

2.2.1 压 缩

压缩操作,顺着空间维度进行特征压缩,将每个二位特征通道转换为一个实数,这里使用 global average pooling 作为压缩操作。这样这个实数在某种程度上就具备全局的感受野,并且输出的维度和输入的特征通道数相匹配,表征着在特征通道上响应的全局分布,而且使得靠近输入的层也可以获得全局的感受野。如式(1)^[24],其中 H 、 W 为空间维度, C 为特征通道数, c 为当前特征通道。

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j), z \in R^C \quad (1)$$

2.2.2 激励

激励(excitation)操作,通过两个全连接(fully connected, FC)层去构建通道间的相关性并输出和输入特征相同数量的权重,如式(2)^[24]所示:

$$s = F_{\text{ex}}(z, W) = \sigma[W_2 \text{ReLU}(W_1 z)] \quad (2)$$

式中 $W_1 \in R^{r \times c}$, $W_2 \in R^{c \times r}$ 。为了降低模型复杂度以及提升泛化能力,这里采用包含两个 FC 层的 bottleneck 结构,其中第一个 FC 层起到降维的作用,降维系数 r 为超参数,然后采用线性整流函数 ReLU 激活,最后的 FC 层恢复原始的维度。双 FC 层的好处在于使模型具有更多的非线性便于更好地拟合通道间复杂的相关性,同时极大减少了模型参数和计算量。最后通过 Sigmoid 函数时权重归一化到 0~1 之间,并通过一个 Scale 操作,即乘法逐通道加权,将归一化后的权重加权到每个通道的特征上。整个操作可以看作通过 SE 模块学习到了各个特征通道之间权重系数,并通过 Scale 对各特征通道逐项加权从而使得模型对各个通道的特征更具有辨识能力,是注意力机制在特征通道上的应用。注意力机制如图 4 这样通过 SE 模块便可以提取出各通道中各振动参数之间对模型具有重要影响的组合。如图 5。




图 4 注意力机制

Fig. 4 Attention mechanism




图 5 SE-ResNet 模块

Fig. 5 SE-ResNet module

2.3 模型建立

本文所建立的改进 SENet 模型是在原来 18 层 SENet 的基础上,对每一层的卷积核大小和步幅(stride)以及填充(padding)进行改进,以便适用于航空发动机的结构化的 QAR 时间序列数据。并且在网络最后输出部分改变 FC 层的输出维度,使之等于所需要预测的时间步数。因为研究中所使用的数据仅为百万级,为避免模型过于复杂而数据量不够导致模型过拟合。本文选用原模型所提供的 18 层网络即 4×2 个 SE 模块,而非过于复杂的百层网络。每个块包含两个卷积层(conv),再加上输入的卷积层和最后一层 FC 层,作为验证以探究振动 T 步预测的可行性。并且改进了输入输出的维度,以及内部部分层卷积核大小、步幅大小和填充大小,以更适应多参数数据输入的维度和研究的目的。输入维度(10, 100)即 10 个特征和 100 个时间步,并采用 64 个批量,输入通道为 1 个特征通道,整体维度为(64, 1, 10, 100)。模型参数设置如表 1。

表 1 神经网络模型参数

Table 1 Parameters of neural network model

层号	参数	其他
1	$7 \times 7, 64$	步幅:1, 填充:3
2	$3 \times 3, \text{Max pool}$	步幅:2, 填充:1
3	$\begin{pmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{pmatrix} \times 2$	所有卷积层: 步幅:1, 填充:1
4	$\begin{pmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{pmatrix} \times 2$	第 1 个卷积层: 步幅:(1, 2), 填充:1
5	$\begin{pmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{pmatrix} \times 2$	第 1 个卷积层: 步幅:(1, 2), 填充:1
6	$\begin{pmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{pmatrix} \times 2$	第 1 个卷积层: 步幅:(1, 2), 填充:1
7	Global average pooling	(1, 1)
8	FC	512×10

最终搭建的模型整体架构如图 6 所示。Size 代表单通道输出维度,即总体维度的第 3、4 维。




图 6 网络架构示例

Fig. 6 Example network architectures

3 实验结果分析

3.1 超参数设置

本文训练集和测试集均按文中第 1.4 节的方式进行随机抽取, 且由于数据规模庞大所以按 49 : 1 进行划分。在保证模型能充分学习的同时, 留有大致 3 个航班的数据以供预测。本文使用文中第 1.2 节所提的 10 个参数, 并主要以对众多振动中的 1 号轴承支撑振动传感器低压转子的振动作为研究对象进行预测, 在后续实验中也会对不同振动信号和不同类型发动机的振动进行研究, 同时也会讨论不同时间步对预测效果的影响。在主要研究对象中, 采集时间步为 100, 预测时间步为 10, 共 64 个批量进行训练。使用 AdamW (adaptive moment estimation with decoupled weight decay) 优化算法, 相比于以往使用的 SGD (stochastic gradient descent) 算法, AdamW 经过偏执校正后, 每次迭代学习率都有一个确定范围, 使得参数比

较平稳^[29]。为保证所有模型都充分训练, 所设学习率为 0.001, 迭代次数为 100。此外, 本文采用余弦退火学习率 (cosine annealing learning rate) 对学习率进行衰减控制, 以保证模型尽量收敛到足够好的局部最小值, 其变化趋势如图 7 所示。




图 7 余弦退火学习率

Fig. 7 Cosine annealing learning rate

3.2 结果分析

因为本文的研究目的是预测未来步振动的变化, 所以归属于回归问题并采用均方误差 (ε) 作为模型的评价指标, 如式 (3), 真实值 y_i 与模型输出值 $\hat{y}_i$ 之差平方的期望值。

$$\varepsilon = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (3)$$

为进一步验证模型可靠性, 选取了多层感知机、Resnet、Vggnet (visual geometry group) 和只输入振动的单参数 SENet 的结果进行对比。

3.2.1 振动参数 1 的结果分析

模型的训练损失 (loss) 和测试损失前期随迭代次数 (iteration) 的变化如图 8 所示。可以看出随着迭代次数的增加, 训练损失和测试损失逐步下降, 随后平缓, 说明模型收敛迅速, 学习效果显著, 训练结果较好。

1 号轴承支撑振动传感器 N1 的振动的预测值与真实值对比如图 9、图 10 (从第 1.556×10^5 步开始) 和图 11 (从第 1.564×10^5 步开始) 所示。分别从宏观和微观层面展示了预测效果, 其中图 12 为最后 2 000 个样本的误差统计。可以看出模型对于振动信号的未来发展具备一定的预测能力, 从微观角度看误差较小, 并对振动的突变有迅速的反应能力。从宏观可以看出还是有一定的误差, 但以初步探索预测性的角度来说在可接受范围内。

且从图 12 的误差分布中可以看出,误差基本成正态分布,中心接近于 0,虽存在离群值但几乎可以忽略。

此外,本文研究的 SENet 模型与其他模型的测试集损失对比如表 2 所示,本文选取迭代次数中前 10 个最小的损失并取均值作为结果。这样




图 8 SENet 训练效果

Fig. 8 Training effect of SENet




图 9 总体预测结果

Fig. 9 Overall prediction results




图 10 局部预测效果 (1)

Fig. 10 Partial prediction results (1)




图 11 局部预测结果 (2)

Fig. 11 Partial prediction results (2)




图 12 1 号轴承支撑振动传感器 N1 的预测误差分布
(同一类型发动机)

Fig. 12 Prediction error distribution of bearing No.1 support vibration sensor N1 (same type of aeroengine)

表 2 多模型损失对比

Table 2 Comparison of multi model loss

模型	测试集损失
SENet	0.020 3
单参数 SENet	2.507 0
ResNet	0.021 0
VggNet	0.026 1
MLP	0.024 3

可以尽量保证模型间对比的准确。可以看出多参数融合的 SENet 相比于单参数 SENet 和其他多参数模型,损失有明显的降低,表现出更好的预测能力,说明了多参数融合的 SENet 模型在发动机的振动预测方面有良好的效果。也说明了对于振动这个复杂的多参数相互影响的系统,多参数研究比单参数研究更能精确预测振动的发展趋势。同时实验也初步证明了 SENet 模型对于航空发动机振动 T 步预测的可行性。

3.2.2 研究适用性的结果分析

为探究该研究方法的适用性,本文还在 1 号轴承支撑振动传感器获取的高压转子的振动数据和另一型号发动机上进行了相关实验,其总体和局部预测结果如图 13 所示。

可以看出在其他振动参数上的预测,该研究方法也表现出了很好的预测能力,甚至误差更小。此外对于振动信号的阶跃和突变也表现出了很好的追踪和预测效果。其误差分布如图 14 所示。可以看出,其预测误差更集中且离群值更少也更小,同时也表现出了正态分布的趋势。说明该方法也能应用在同一型号发动机的不同振动参数上。

此外,本文还在其他型号的发动机上进行了

该研究,其结果如图 15 所示。由于此类型发动机用于本研究的 QAR 数据量较少,只有约 30 多万条样本,所以预测结果与真实结果相比存在一定的误差,但是同样表现出可接受的预测能力。

此类型发动机振动预测的误差分布如图 16 所示。由于样本数少,所以取后 1 000 个样本,可以看出整体成正态分布,且约 80% 的样本误差接近于 0。




图 13 其他振动参数预测结果

Fig. 13 Prediction of the other vibration parameters




图 14 1 号轴承支撑振动传感器高压转子预测误差分布 (同一类型发动机)

Fig. 14 Prediction error distribution of bearing No.1 support vibration sensor for high pressure rotor (same type of aeroengine)




图 15 不同类型发动机预测结果

Fig. 15 Prediction results of different types of aeroengine




图 16 1 号轴承支撑振动传感器 N1 的预测误差分布 (不同类型发动机)

Fig. 16 Prediction error distribution of bearing No.1 support vibration sensor N1 (different types of aeroengine)

3.2.3 其他步长预测和误差分析

除了在同一机型上研究不同振动参数的预测和不同类型发动机上研究外,本文还对不同步长的预测做出了初步探索。其中预测未来 15 步和 20 步的结果分别如图 17 和图 18 所示。可以看出,虽然还能对振动进行总体预测,但是已经出现了较大的误差。且随着步数增大,面对突然的阶跃有时甚至不能做出正确的预测,如图 18。所以可

以得出,所要预测的未来步数越大,模型的预测能力越低,预测精度越差。本文推测此现象发生的原因因为发动机的振动系统是一个复杂的多参数相互影响的系统,将不同的振动参数和其他重要参数输入模型后,在做出预测时,模型不仅在计算目标值的预测值,同时也在计算其他参数的未来变化趋势,所以当步数越长,未来的其他参数变化无法窥视,则对目标值的预测效果就开始捉襟见肘。因此在将来的研究中,如何将其他参数的未来信息加入模型的预测中是一个重要的研究方向。




图 17 未来 15 步的预测结果

Fig. 17 Prediction results for the next 15 steps




图 18 未来 20 步的预测结果

Fig. 18 Prediction results for the next 20 steps

此外,对于以上研究中出现的误差除文中第 3.2.3 节外,本文认为主要还是由于数据量不足所导致,甚至影响到了研究时对于模型深度的选择。须知最新的残差网络已达上百层,且层数越多效果越好,但所需训练数据就更庞大。本文对要研究对象的数据量训练虽已有百万,但只是初步达到了深度学习的训练标准,因此如果能真正应用航空公司日常积累的 QAR 数据,那对于模型的预测能力可能有显著的提升。另外,本文未考虑机械原因对振动的影响。所以也有部分误差属于机械原因导致。

4 结 论

本文提出利用改进的 SENet 网络对航空发动机振动进行预测的方法,基于飞机飞行所采集的

真实的 QAR 数据并通过随机抽取的方法对模型建模。实验结果表明:

1) 对于航空发动机振动的 T 步预测有效。模型能较好预测出未来 T 步的振动变化,并且对于振动的突变和波动能立刻追踪和预测。由于所建立模型为正常运行模型,当发动机振动异常,出现偏离正常范围的波动和变化,通过与所预测的正常运行数据对比则能够起到一定的预警作用,辅助飞行安全。

2) 实验证明本文所使用的 SENet 模型通过将注意力机制和残差网络融合使用,相较于一般的 Resnet 模型和其他常用模型,在振动预测方面表现出较好的实验结果,且适用于结构化的时间序列 QAR 数据研究,说明了使用本文改进的 SENet 模型对振动进行预测有较好的性能表现。

3) 通过将多参数融合研究和只针对振动单参数进行研究得知,多参数融合模型所表现的性能优于单参数模型所表现的性能。说明在针对航空发动机中复杂的振动系统进行研究时,需尽量考虑多参数的影响,发动机的振动是由多因素共同作用。而以往大多只针对振动进行考虑,简化了发动机的振动系统。

4) 通过在同一发动机的不同振动参数和不同类型发动机上进行研究,其结果表现出了良好的预测能力,证明了该研究方法的适用性。

5) 本文也对不同的时间步数进行了初步探讨,所需预测步数越长,预测误差越大,对于振动的突变和阶跃的预测效果越低。

最后在未来的进一步研究中,如何将未来其他参数对于目标参数的影响考虑进模型中,将是下一步的研究重点。

参考文献:

- [1] 李书明,李世栋,张莹.航空发动机压气机性能衰退影响因子定量分析[J].科学技术与工程,2015,15(32):74-78,86.
LI Shuming, LI Shidong, ZHANG Ying. Quantitative analysis of aircraft engine compressor performance deterioration impact factor [J]. Science Technology and Engineering, 2015, 15(32): 74-78, 86. (in Chinese)
- [2] 民航资源网.2018年1-6月中国民航安全信息统计报告[EB/OL].[2022-03-06].<http://news.carnoc.com/list/461/461183.html>.
- [3] WANG H. A survey of maintenance policies of deteriorating systems[J]. *European Journal of Operational Research*, 2002, 139(3): 469-489.
- [4] CHO D I, PARLAR M. A survey of maintenance models for multi-unit systems[J]. *European Journal of Operational Research*, 1991, 51(1): 1-23.
- [5] WANG R, LIU M, MA Y. Fault estimation for aero-engine LPV

- systems based on LFT[J]. *Asian Journal of Control*, 2021, 23(1): 351-361.
- [6] 谢晓龙. 航空发动机性能评价与衰退预测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2016.
- XIE Xiaolong. Research on aero engine performance evaluation and recession prediction method[D]. Harbin: Harbin Institute of technology, 2016. (in Chinese)
- [7] 曹惠玲, 罗立霄, 曲春刚, 等. 基于LS-SVM的航空发动机喘振故障诊断研究[J]. *热能动力工程*, 2013, 28(1): 23-27, 107.
- CAO Huiling, LUO Lixiao, QU Chungang, et al. Aero engine surge fault diagnosis based on LS-SVM[J]. *Thermal Power Engineering*, 2013, 28(1): 23-27, 107. (in Chinese)
- [8] 付旭云, 陕振勇, 李臻, 等. 时变模糊神经网络及其在航空发动机排气温度预测中的应用[J]. *计算机集成制造系统*, 2014, 20(4): 919-925.
- FU Xuyun, SHAN Zhenyong, LI Zhen, et al. Time varying fuzzy neural network and its application in aeroengine exhaust temperature prediction[J]. *Computer Integrated Manufacturing System*, 2014, 20(4): 919-925. (in Chinese)
- [9] 李书明, 任沛, 黄燕晓. 航空发动机基线方程的拟合[J]. *机械工程与自动化*, 2016, 1(1): 153-154, 157.
- LI Shuming, REN Pei, HUANG Yanxiao. Fitting of aero engine base-line equation[J]. *Mechanical Engineering and Automation*, 2016, 1(1): 153-154, 157. (in Chinese)
- [10] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. *机械工程学报*, 2018, 54(5): 94-104.
- LEI Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of mechanical intelligent fault diagnosis under big data[J]. *Journal of Mechanical Engineering*, 2018, 54(5): 94-104. (in Chinese)
- [11] KOHONEN T. An introduction to neural computing[J]. *Neural Networks*, 1988, 1(1): 3-16.
- [12] GREFF K, SRIVASTAVA R K, KOUTNÍK J, et al. LSTM: a search space odyssey[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 28(10): 2222-2232.
- [13] FU R, ZHANG Z, LI L. Using LSTM and GRU neural network methods for traffic flow prediction[C]//2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC). Wuhan: IEEE, 2016: 324-328.
- [14] ALBAWI S, MOHAMMED T A, AL-ZAWI S. Understanding of a convolutional neural network[C]//2017 International Conference on Engineering and Technology (ICET). Bali Island, Indonesia: IEEE, 2017: 1-6.
- [15] 杨洁, 万安平, 王景霖, 等. 基于多传感器融合卷积神经网络的航空发动机轴承故障诊断[J]. *中国电机工程学报*, 2022, 42(13): 4933-4942.
- YANG Jie, WANG Anping, WANG Jinglin, et al. Aeroengine bearing fault diagnosis based on convolutional neural network for multi-sensor information fusion[J]. *Proceedings of the CSEE*, 2022, 42(13): 4933-4942. (in Chinese)
- [16] 董永峰, 孙跃华, 高立超, 等. 基于改进一维卷积和双向长短期记忆神经网络的故障诊断方法[J]. *计算机应用*, 2022, 42(4): 1207-1215.
- DONG Yongfeng, SUN Yuehua, GAO Lichao, et al. Fault diagnosis method based on improved one-dimensional convolutional and bidirectional long short-term memory neural networks[J]. *Journal of Computer Applications*, 2022, 42(4): 1207-1215. (in Chinese)
- [17] 王奕惟, 莫李平, 王奕首, 等. 基于全航段QAR数据和卷积神经网络的航空发动机状态辨识[J]. *航空动力学报*, 2021, 36(7): 1556-1563.
- WANG Yiwei, MO Liping, WANG Yishou, et al. Aero-engine status identification based on full-segment QAR data and convolutional neural network[J]. *Journal of Aerospace Power*, 2021, 36(7): 1556-1563. (in Chinese)
- [18] 莫仁鹏, 李天梅, 司小胜, 等. 采用残差网络与卷积注意力机制的设备剩余寿命预测方法[J]. *西安交通大学学报*, 2022, 56(4): 1-9.
- MO Renpeng, LI Tianmei, SI Xiaosheng, et al. Remaining useful life prediction for equipment using residual network and convolutional attention mechanism[J]. *Journal of Xi'an Jiaotong University*, 2022, 56(4): 1-9. (in Chinese)
- [19] 杨永灿, 刘韬, 柳小勤, 等. 基于注意力机制的一维卷积神经网络行星齿轮箱故障诊断[J]. *机械与电子*, 2021, 39(10): 3-8.
- YANG Yongcan, LIU Tao, LIU Xiaojin, et al. Fault diagnosis of gearbox based on one-dimensional convolutional neural network with attention mechanism[J]. *Machinery Electronics*, 2021, 39(10): 3-8. (in Chinese)
- [20] XU J, XU L. Health management based on fusion prognostics for avionics systems[J]. *Journal of Systems Engineering and Electronics*, 2011, 22(3): 428-436.
- [21] JALIL N A, HWANG H J, DAWI N M. Machines learning trends, perspectives and prospects in education sector[R]. Nagoya, Japan: the 2019 3rd International Conference on Education and Multimedia Technology, 2019.
- [22] MITCHELL T. Key ideas in machine learning[M]. Pittsburgh, US: Carnegie Mellon University, 2017.
- [23] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2016: 770-778.
- [24] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2018: 7132-7141.
- [25] HE K, SUN J. Convolutional neural networks at constrained time cost[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2015: 5353-5360.
- [26] SRIVASTAVA R K, GREFF K, SCHMIDHUBER J. Highway networks[EB/OL]. (2015-11-03)[2022-03-01]. arxiv.org/abs/1505.00387.
- [27] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2015: 1-9.
- [28] BELL S, ZITNICK C L, BALA K, et al. Inside-outside net: detecting objects in context with skip pooling and recurrent neural networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2016: 2874-2883.
- [29] LOSCHILOV I, HUTTER F. Decoupled weight decay regularization[EB/OL]. (2019-01-04)[2022-03-01] arxiv.org/abs/1711.05101.

(编辑: 陈 越)