

基于 1DCNN-Resnet-LSTM 模型的 LEAP 发动机 可调静子叶片角度预测

尚玖鹏, 谭 燕

(中国民用航空飞行学院 航空工程学院, 四川 广汉 618307)

摘要:可调静子叶片(VSV)是航空发动机压气机气流控制的重要机构,能够扩大压气机稳定工作范围,提高其气动性能。依托飞机快速存取记录器(QAR)中储存的海量 LEAP 发动机数据,建立一种基于 1DCNN-Resnet-LSTM 模型对 LEAP 发动机的 VSV 角度进行预测的方法。模型的评价结果显示,模拟输出对比实际输出误差小,模拟趋势变化能够很好贴合实际数据,表明使用深度学习算法对 VSV 角度进行预测进而探索其控制规律具有可行性和显著的优势。

关键词:可调静子叶片(VSV);深度学习;快速存取记录器(QAR);控制模拟

中图分类号:V232.4 **文献标志码:**A **文章编号:**1671-1807(2023)07-0188-05

可调静子叶片(variable stator vane, VSV)是航空发动机压气机气流控制的重要机构,发动机从某一工作状态到另一工作状态时,VSV 使进气气流始终以最佳的角度进入压气机叶栅通道,气流攻角合适,前后流量匹配,这样可以有效避免出现涡流或喘振现象,扩大压气机稳定工作范围,提高其气动性能^[1-5]。

QAR(quick access recorder)意为快速存取记录器。LEAP 发动机自引入国内后,国内航班积累了海量的 QAR 数据,如果能够对这些数据加以利用,对其进行数据挖掘,将为研究 LEAP 发动机可调静子叶片的控制规律、建立其监控和故障诊断方法、探讨其未来发展方法提供助力。

深度学习主要的优势其一是深度学习强大的特征提取能力。另外,深度学习算法能够与有反馈的神经网络结合,从而进行监督学习。强大的特征提取能力使得它能够从海量的数据中自动寻找出有用的目标特征,因此它对人工提取特征的依赖性和不确定性会更低。由于 LEAP 发动机的相关资料被国外厂家高度保密,关于 LEAP 发动机可调静子叶片主要控制参数只能从机械原理分析和参考上一代发动机研究来确定,因此该特点对 LEAP 发动机的研究中有较大的优势。有航空业学者尝试将深度学习应用于民航

发动机领域,并取得了一定的成果。车畅畅等^[6]使用 1DCNN-BiLSTM 模型对航空发动机剩余寿命进行预测,证明该方法能够通过多维长时间序列数据的深度学习模型分析得到较为准确的剩余寿命预测结果,对于复杂系统剩余寿命预测有重要参考价值。李健^[7]通过实验证明 CNN-BiLSTM 网络不论是在单一气路故障还是多气路部件故障中,都具有非常高的故障诊断准确率,完全可以将其在变循环发动机气路故障诊断系统之中,在如今的大数据背景下,在发动机控制规律数据挖掘领域,有着一定的实用性、通用性以及时效性。

1 深度神经网络

1.1 卷积神经网络

日本学者在 20 世纪 80 年代提出包含 S-cells 和 C-cells 的神经认知机,其中 S-cells 和 C-cells 相当于卷积神经网络中的卷积层和池化层,普遍被认为是卷积神经网络的原型。LeNet5 是由 Lecun 等在 1988 年提出的网络结构,该网络结构能够实现多层训练,并且在训练过程中应用了 BP 算法,成为现今卷积神经网络的雏形^[8]。但是受限于当时计算机的计算能力和高昂的训练成本,卷积神经网络的应用受到了极大的限制,一度处于学术界的边缘。直到 2012 年 Alex-

收稿日期:2022-11-11

基金项目:中央高校基本科研业务费基金项目(J2022-014)。

作者简介:尚玖鹏(1997—),男,湖北随州人,中国民用航空飞行学院航空工程学院,硕士研究生,研究方向为民用航空发动机维修工程;谭燕(1975—),女,四川广汉人,中国民用航空飞行学院航空工程学院,教授,研究方向为航空发动机故障诊断和状态监控。

Net 网络结构被 Krizhevsky 等提出,依靠该网络独特的深层结构和 Dropout 方法,一度颠覆了图像识别领域^[9]。此后数年中,卷积神经网络引起了广大学者的重视,在众多领域都得到了广泛的应用,不断有学者提出诸如 Inception-V4^[10]、VGG^[11]、ResNet^[12]、DenseNet^[13]等优秀的网络结构。

1.2 RNN 循环神经网络

循环神经网络主要应用于语音识别、股票预测、轨迹预测等领域,是用于处理时序数据的一种神经网络结构。它的串联结构使得神经元能够将某个时间点的输出作为输入重新输入神经元之中,在处理时间序列数据中表现出强大性能,能够很好地保持时间序列数据的前后数据依赖问题。

在 20 多年的发展中,许多优秀的循环神经网络结构相继被提出。1997 年由 Hochreiter 和 Schmidhuber 等^[14]在原本的 RNN 网络上进行改进,提出了长短期记忆网络(LSTM);2000 年, Gers 等^[15]在原有的长短期记忆循环神经网络中增加了遗忘门;2005 年, Graves 和 Schmidhuber^[16]提出了 BiLSTM 网络;2014 年, Chung 等^[17]提出了 GRU 网络。

2 CNN-ResNet-LSTM

2.1 ResNet

卷积神经网络在众多学者应用后发现,增加卷积神经网络的深度能够很好地增强卷积神经网络的性能。不过随着网络被不断加深,梯度消失和梯度爆炸的问题逐渐显现,使得卷积神经网络在训练时很难收敛,网络退化问题严重,卷积神经网络的整体性能不断变差。为了解决这个问题,在 Highway^[18]网络的基础上 He 等^[12]提出了一种基于残差结构的卷积神经网络——残差网络(ResNet)。

与普通的卷积神经网络不同,残差神经网络增加了跳跃链接,不再是直接学习最优映射函数,而是学习它的残差: $H(X) = F(X) + X$ 。这样的结构,能够很好地缓解深度卷积神经网络梯度消失和爆炸问题,并且还能够进一步提升卷积神经网络的整体性能和训练速度。

2.2 LSTM

在大量的应用后发现,标准的循环神经网络时常会出现梯度消失和梯度爆炸的问题,实验表明造成该现象是因为其迭代性导致的。为了解决该问题,由 Hochreite 和 Schmidhuber^[14]提出了 LSTM 循环神经网络。

在标准循环神经网络的基础上,LSTM 网络加入了由输入门、输出门和遗忘门所组成的隐藏单元

结构。依靠 LSTM 网络的门操作,可以做到对信息进行更新和保存。门控操作可以简化为

$$g(x) = \sigma(Wx + b) \tag{1}$$

式中: $\sigma(x) = \frac{1}{1 + \exp(-x)}$ 为一种常被应用于深度学习领域的 Sigmoid 激活函数。通过激活函数对门操作的数据通过率进行表达,门的输出在 0~1 之间,越接近 1 则信息通过率越高,达到 1 时则数据可以全部通过^[19]。

2.3 CNN-ResNet-LSTM 网络

CNN-ResNet-LSTM 网络利用卷积层提取数据中的局部特征,利用 LSTM 单元提取数据中的时间特征,将两种特征融合起来。由于 CNN-ResNet-LSTM 网络的这种特质已经被多个领域学者运用于建立模型进行相关预测。蒲悦逸等^[20]用 CNN-ResNet-LSTM 模型,可以根据历史轨迹数据,结合外部因素对城市各个区域交通流量的变化进行预测。段宗运等^[21]用 CNN-LSTM-ResNet 组合模型可以根据历史轨迹数据、节假日和天气预测城市每个地区居民的出租车需求。刘新志等^[22]构建的 ResNet-LSTM 网络以爱尔兰某地区的真实负荷为数据集进行仿真实验,对一个月的负荷进行预测。在民航领域同样也得到应用。

3 实验与分析

3.1 数据选择与处理

本次使用的数据是由同机型不同飞机发动机所产生的数据样本,一共采集样本共 600 余万,随机抽取 5 个航班的样本数据作为验证集,其余用于模型训练。

基于原始数据情况、机械原理分析和皮尔逊相关性系数,在发动机相关的参数中选择以下 14 个参数(表 1),其中 VSV 作为输出参数,即预测值。

表 1 参数及符号

参数	符号
可调静子叶片	VSV
进气总温	T_{12}
高压压气机进口温度	T_{25}
高压压气机出口温度	T_3
马赫数	Ma
油门杆角度	TRL
高压压气机出口压力	P_{S3}
低压转子转速	N_1
高压转子转速	N_2
海拔	H
总进气口压力	P_2
大气静温	SAT
外界大气压力	P_0
大气总温	TAT

在对原始 QAR 数据进行分析时,发现有由于数据采样周期不同,原始数据缺少的情况。使用线性插值、近邻插值、二阶样条曲线插值和三阶样条曲线插值分别填补 P_0 后发现,二次和三次插值法的填补会出现极值。线性插补法能一定程度使得数据更加平滑,因此选择线性插值法对缺失值进行填补。如图 1 所示,横坐标为飞机数据采集器的频率,纵坐标为 P_0 。




图 1 插值法对比

3.2 实验设置

1DCNN-Resnet-LSTM 模型结构如图 2 所示。以配置 NVIDIA GTX1080Ti 显卡的电脑作为服务器,搭建 Pytorch、Python3.8、CUDA11.7 的开发环境。学习率为 0.0007,训练的总迭代次数(epochs)为 300, batch_size 为 1024。




图 2 1DCNN-Resnet-LSTM 模型结构

3.3 评价指标

决定系数(coefficient of determination),有的翻译为判定系数,也称为拟合优度。表征依变数 Y 的变异中有多少百分比,可由控制的自变数 X 来解释。在 Y 的总平方和中,由 X 引起的平方和所占的比例,记为 R^2 。表达式为

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \tag{2}$$

式中:SST=SSR+SSE。当 R^2 越接近 1 时,表示相关的方程式参考价值越高;相反,越接近 0 时,表示参考价值越低。

均方根误差(root mean square error, RMSE) 预测值与真实值偏差的平方与观测次数 n 比值的平方根。表达式为

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N [Y_i - f(X_i)]^2} \tag{3}$$

3.4 实验结果与分析

运用训练的模型对随机划分的验证集进行模拟输出,可调静子叶片角度预测值与实际值对比如图 3 所示。横坐标为飞机数据采集器的频率,纵坐标为 VSV 角度。




图 3 航班 1~航班 5 的 VSV 角度预测值和实际值

使用验证集进行模拟输出,与实际输出值进行对比后可以发现, R^2 为 0.994, RMSE 为 0.668,在整体输出上模型输出能够较好地拟合真实数据。数据模拟输出对比实际输出误差小,模拟趋势变化能够很好贴合实际数据。

4 结论

本文提出基于 1DCNN-Resnet-LSTM 模型对航空发动机可调静子叶片角度进行预测。该模型利用 CNN 网络的强大特征提取能力,再利用 LSTM 网络进行时间特征提取,使得在不对发动机状态进行划分时,在 VSV 角度变化的预测中依旧能表现出较好的性能。

因为在发动机的运行过程中,运行环境的差异

是相当大的,所以很难对一个不断变化的输出值设定一个合理的健康数值区间。利用足够多的健康数据样本对模型进行训练,合理利用模型输出值与航后实际采集值进行对比,能给航后检查提供一定的参考,能够直观观测到运行过程中的异常点,可以应用于对 VSV 的健康监控和故障诊断。经过实验表明,利用该模型可以较好地模拟 LEAP 发动机在实际运行中 VSV 的角度输出,对进一步研究 LEAP 发动机可调静子叶片的控制规律、建立其监控和故障诊断方法,具有重要的参考意义。

参考文献

[1] 丁凯峰,樊思齐.变几何涡扇发动机加速控制规律优化

- [J]. 推进技术, 1999, 20(2): 17-20.
- [2] 隋岩峰, 邴连喜, 施磊, 等. 某发动机高压压气机进口可调静子叶片角度控制方法[J]. 航空动力学报, 2010, 25(11): 2589-2593.
- [3] 胡君. CFM56-3 发动机启动、加速慢车故障分析[J]. 航空工程与维修, 2002(4): 25-26.
- [4] 李世林. VSV 系统对 CFM56 发动机喘振的影响分析[J]. 科学技术与工程, 2012, 12(11): 4934-4936
- [5] 曹志鹏, 刘波, 丁伟. 静叶角度调节对组合压气机性能优化机理[J]. 北京航空航天大学学报, 2007, 33(8): 878-881.
- [6] 车畅畅, 王华伟, 倪晓梅, 等. 基于 1D-CNN 和 Bi-LSTM 的航空发动机剩余寿命预测[J]. 机械工程学报, 2021, 57(14): 304-312
- [7] 李健. 基于深度学习的变循环发动机气路故障诊断[D]. 上海: 上海交通大学, 2020
- [8] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2017, 60(6): 84-90.
- [10] SZEGEDY C, OFFE S, VANHOUCKE V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning[C]//Proceedings of the 31st AAAI Conference on Artificial Intelligence. San Francisco: AAAI, 2017: 4278-4284.
- [11] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014: 1409. 1556.
- [12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[J]. Computer Science, 2015: 770-778.
- [13] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [14] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [15] GERS FA, SCHMIDHUBER J, CUMMINS F. Learning to forget: continual prediction with LSTM[J]. Neural Computation, 2000, 12(10): 2451-2471.
- [16] GRAVES A, SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural Network architectures[J]. Neural Networks, 2005, 18(5-6): 602-610.
- [17] CHUNG J, GULCEHRE C, CHO K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[J]. Eprint Arxiv, 2014: 1412. 3555.
- [18] SRIVASTAVA R K, GREFF K, SCHMIDHUBER J. Highway networks [EB/OL]. (2015-11-03). <https://arxiv.org/abs/1505.00387>.
- [19] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(S2): 1-6, 26.
- [20] 蒲悦逸, 王文涵, 朱强, 等. 基于 CNN-ResNet-LSTM 模型的城市短时交通流量预测算法[J]. 北京邮电大学学报, 2020, 43(5): 9-14.
- [21] 段宗涛, 张凯, 杨云, 等. SAURAB Bajgain. 基于深度 CNN-LSTM-ResNet 组合模型的出租车需求预测[J]. 交通运输系统工程与信息, 2018, 18(4): 215-223.
- [22] 刘新志, 刘爱莲, 李英娜. 基于 Attention-ResNet-LSTM 网络的中期负荷预测模型[J]. 化工自动化及仪表, 2021, 48(6): 575-580.

Variable Static Blade Angle Prediction of LEAP Engine Based on 1DCNN-Resnet-LSTM Model

SHANG Jiupeng, TAN Yan

(College of Aviation Engineering, Civil Aviation Flight University of China, Guanghan 618307, Sichuan, China)

Abstract: The variable stator vane (VSV) is an important mechanism for the airflow control of the aviation engine compressor, which can expand the stable working range of the compressor and improve its pneumatic performance. Based on the massive LEAP engine data stored in the aircraft quick access recorder (QAR), a method to predict the VSV Angle of LEAP engine based on 1DCNN-Resnet-LSTM model. The evaluation results of the model show that the error of the simulated output is small compared with the actual output, and the change of the simulation trend can fit the actual data well, indicating that it is feasible and significant advantages to use the deep learning algorithm to predict the VSV Angle and explore its control law.

Keywords: variable stator vane (VSV); deep learning; quick access recorder (QAR); control simulation