

# 基于改进 ConvNeXt 模型的压气机变几何系统 T-step 预测方法

旷典, 詹于游, 谭燕

(中国民用航空飞行学院 工程技术训练中心, 四川广汉 618300)

**摘要:**为了实时监控航空发动机压气机变几何系统的状态并获取警告信号,提出一种基于改进 ConvNeXt 模型的 T 步(T-step)预测方法。与仿真数据和特定试验条件下生成的数据集相比,T-step 预测方法采用了飞机数据采集系统记录的实际飞行数据。证实了采用改进 ConvNeXt 模型预测压气机变几何系统参数的可行性,并在发动机过渡状态和稳态下分别进行了试验验证。结果表明:采用改进 ConvNeXt 模型的 T 步(T-step)预测方法能精准地预测压气机 VSV 角度和 VBV 开度的变化,最低可达  $2.132^{\circ}$  和  $7.077^{\circ}$ ,预测误差在可接受范围内。该方法能识别和预测各类型航空发动机不同运行状态的变几何系统参数的角度,获得相对准确的结果。

**关键词:**压气机变几何系统;改进卷积神经网络模型;预测方法;航空发动机

**中图分类号:** V239

**文献标识码:** A

**doi:** 10.13477/j.cnki.aeroengine.2023.06.004

## T-step Prediction Method for Compressor Variable Geometry System Based on Enhanced ConvNeXt Model

KUANG Dian, ZHAN Yu-you, TAN Yan

(Engineering Techniques Training Center, Civil Aviation Flight University of China, Guanghan Sichuan 618300, China)

**Abstract:** In order to monitor the status of the compressor variable geometry system and acquire warning signs in real-time, a T-step prediction method based on an enhanced ConvNeXt model was proposed. Compared to simulation data and the datasets generated in specific lab conditions, the T-step prediction method adopts the actual flight data recorded by aircraft data acquisition systems. The feasibility of using the enhanced ConvNeXt model to predict the compressor variable geometry system parameters was demonstrated, and experimental verification was conducted under the transient state and the steady state respectively. The results show that the T-step prediction method based on the enhanced ConvNeXt model can accurately predict the changes in compressor VSV angle and VBV opening, with the lowest prediction errors of  $2.132^{\circ}$  and  $7.077^{\circ}$ , respectively, which are within acceptable ranges. The method is applicable to different types of aeroengines and can identify and predict the angles of variable geometry system parameters under different operating states, and obtain relatively accurate results.

**Key words:** compressor variable geometry system; enhanced ConvNeXt model; prediction method; aeroengine

## 0 引言

提高航空发动机的维护效率、保障其安全适航和优化关键系统功能,对提高中国发动机的自主设计能力、保障飞行安全具有重要意义<sup>[1-2]</sup>。而压气机变几何系统作为发动机中的基本控制系统,具有稳定气路

通道和气流状态的重要作用。一旦压气机对气流状态的调控失稳,则会出现失速现象<sup>[3]</sup>,在严重情况下,发动机因此受损甚至毁坏<sup>[4-5]</sup>。因此,研究航空发动机压气机几何变量系统的发展和变化规律,对压气机流量状态预警和发动机设计及优化具有重要意义。

压气机变几何系统主要由可调静子叶片(Vari-

收稿日期:2021-05-26 基金项目:中央高校基本科研业务费专项基金(J2022-014)、中国民航飞行学院科研基金(青年基金)(Q2019-056)资助  
作者简介:旷典(1990),男,硕士,实验师。

引用格式:旷典,詹于游,谭燕.基于改进 ConvNeXt 模型的压气机变几何系统 T-step 预测方法[J].航空发动机,49(6):19-26.Kuang Dian, Zhan Yuyou, Tan Yan. T-step prediction method for compressor variable geometry system based on enhanced ConvNeXt model[J]. Aeroengine, 2023, 49(6): 19-26.

able stator vane, VSV)和可变放气活门(Variable bleed valve, VBV)系统组成,通过改变VSV角度和VBV开度来调控流体状态,确保发动机稳定有效地工作<sup>[6-7]</sup>。因此对压气机变几何系统的预测研究可细化到对VSV角度和VBV开度的准确预测。由于航空发动机的复杂性和保密原则,作为非原始设备制造商(Original Equipment Manufacturer, OEM),为了深入理解和仔细研究发动机基本系统的运行规律,采用常规手段存在无法解决的技术障碍。近年来,人工智能(Artificial Intelligence, AI)在各方面的引入<sup>[8-9]</sup>极大地促进了科学技术的发展。可利用数据驱动对发动机系统进行快速建模,并尽快验证内在因素的作用关系,实现利用数据可初步讨论理论可行性的重大应用。张振兴等<sup>[10]</sup>利用故障树的方法对压气机静叶角度位置进行故障诊断;Li等<sup>[11]</sup>利用神经网络对民用发动机静叶位置进行建模优化;Wang等<sup>[12]</sup>利用人工免疫算法对发动机可变放气活门的故障检测进行建模。但这些课题大多局限于故障诊断、故障预测和基线建模。目前对重要子系统或重要参数的变化规律的预测研究尚未完善,甚至还未与AI技术结合。由于相关研究多采用仿真模拟软件和开源数据,无法建立高度符合发动机真实运行状态的模型。采用的模型多为性能不足,有些研究欠考虑在复杂控制系统情况下多参数融合对试验结果适用性的影响,如高低压转子转速、压气机各级温度等所带来的综合影响。发动机压气机系统是1个各种因素相互作用、相互影响的复杂关键系统。这些使模型无法学习到研究所需的重要特征,如诱发航空发动机状态改变的关键信号,大部分研究采用了不同的飞行航段建立不同模型的方法。尽管在飞机飞行过程中存在航段之分,但发动机的运行并非根据航段所变化,而是依据相关参数的变化而变化。如果根据航段建立模型,在实际应用中则存在困难,如何自动识别航段改变信号,将带来考验。

本文在最新的卷积神经网络(Convolutional Neural Networks, ConvNeXt)模型基础上加入SENet网络的具备注意力机制能力的SE模块(SE block),以2种不同类型的民用航空发动机为研究对象,分别在稳态和过渡态的单状态试验中建立了具有一定适用性的可靠航空发动机压气机变几何系统预测模型。可对保障飞行安全、研究压气机变几何系统的设计优化和相关重要参数的发展规律等提供参考。

## 1 数据预处理

### 1.1 数据获取

随着机器学习的深入研究和发 展,数据集质量的重要性越发显著。在机器学习项目中,数据是构建项目的关键基石,且使用高质量数据集也是项目的基础要求,基于输入输出(Garbage In Garbage Out, GIGO)原则<sup>[13]</sup>,对模型输入低质量的数据进行训练,模型同样只能输出类似的结果。因此需要对数据集的使用进行筛选和预处理。

使用数据驱动法对航空发动机进行相关研究时主要使用以下数据源:仿真数据、开源数据集、实验室和飞机数据采集系统生成的数据集。本文选用由飞机数据采集系统从实际飞行中采集的数据作为研究支撑。与前3种数据集相比,飞机数据采集系统实时采集飞机的各种关键参数,能更好地映射压气机真实的运行状态,具有各种参数翔实、连续存储、易于导出和处理等各项优势<sup>[14]</sup>。为此,对于发动机的研究更加可信,结果更符合真实发动机的情况。

本文研究对象及数据集均为双转子涡扇发动机,其运行状态分为过渡态和稳态。这2种状态涉及整个发动机变化的始终,飞机数据采集系统记录了整个飞行过程。为了使模型根据输入数据识别当前发动机状态,数据集将随机提取并输入到模型中。稳态和过渡态数据以及处于二者间的数据都将随机抽取并输入到模型中。当模型复杂时,可在训练任务中学习这2种状态的模式,并在预测过程中根据输入数据识别其状态。这种随机性抽取数据训练模型,将赋予模型具有通用性,不需要分态建模。为了证明预测2种航空发动机状态的可行性和通用模型的可能性,本文将在试验的最后部分进行讨论。

### 1.2 输入参数选择

本文的研究目标是尽可能准确预测VSV和VBV的变化。预测目标值分别是VSV的角度和VBV的开度。此外,本文在试验中使用的术语“step”指的是使用时间序列数据进行研究的基本单位。step即步长定义为记录数据的频率。本文中1 step代表1 Hz的传感器采集数据的频率。基于当前所采集的100个时间步来输入模型,以模型输出的10个时间步表示所需预测参数的10个时间步的未来变化。当输入的时间跨度足够长时,模型将更精确地识别输入数据中

的状态和变化信息。以此提高了预测的准确性。不同的输入范围和预测范围对预测精度的影响不在本文的讨论范围之内,本文的研究重点是针对压气机变几何系统预测的可行性和适用性。所以不同时间范围的讨论将在以后的研究中进行详细研究。

在参数选择过程中,将考虑各参数间的相互作用、航空发动机技术理论和数据采集能力,基于参考发动机相关手册和数据驱动方法的相关研究<sup>[15-16]</sup>,将选择参数(见表 1)对 A 型航空发动机压气机变几何系统进行研究。

表 1 A 型和 B 型航空发动机参数选择

参数	单位	发动机型号	
大气压力 $P_0$	PSIA	A	
高压压气机出口压力 $P_{S3}$	PSIA	A	B
油门杆角度 $T_{RL}$	(°)	A	B
风扇进口温度 $T_{I2}$	°C	A	B
高压压气机进口温度 $T_{25}$	°C	A	
大气总温 $T_{AT}$	°C	A	B
低压转子转速 $N_1$	%	A	B
高压转子转速 $N_2$	%	A	B
可调静子叶片角度 $V_{SV}$	(°)	A	B
可变引气活门角度 $V_{BV}$	(°)	A	B
海拔高度 $H_{AL}$	km		B
高压压气机出口温度 $T_3$	°C		B

本文的试验将在不同类型的航空发动机上进行测试,且飞机数据采集系统也略有不同。但 B 型航空发动机基本参数的选择保持不变(表 1)。

输入值将是随机采样的连续 100 个 step 即 100 s 的数据作为学习中的 1 个 batch,输出值是接下来 10 个 step 即未来 10 s 的 VSV 的角度或 VBV 的开度。

### 1.3 缺失值插值处理

本文比较了线性插值、最近邻插值、阶梯插值、2 阶样条曲线插值、3 阶样条曲线插值和重心坐标插值。利用 1 个航班数据中使用  $P_0$  进行上述插值方法的研究,各插值法对比如图 1 所示。从图中可见,每种方法都不会影响总体趋势,但线性插值更为平滑,且不会出现极值。因此,采用线性插值对存在缺失值的参数如  $P_0$  进行插值将是 1 个相对良好的方式。同样基于 1 个航班的数据使用  $P_0$  进行插值后的数据与原始数据的比较如图 2 所示。

### 1.4 随机抽取批量数据

为了构建精确的模型,本文采用了对数据进行随

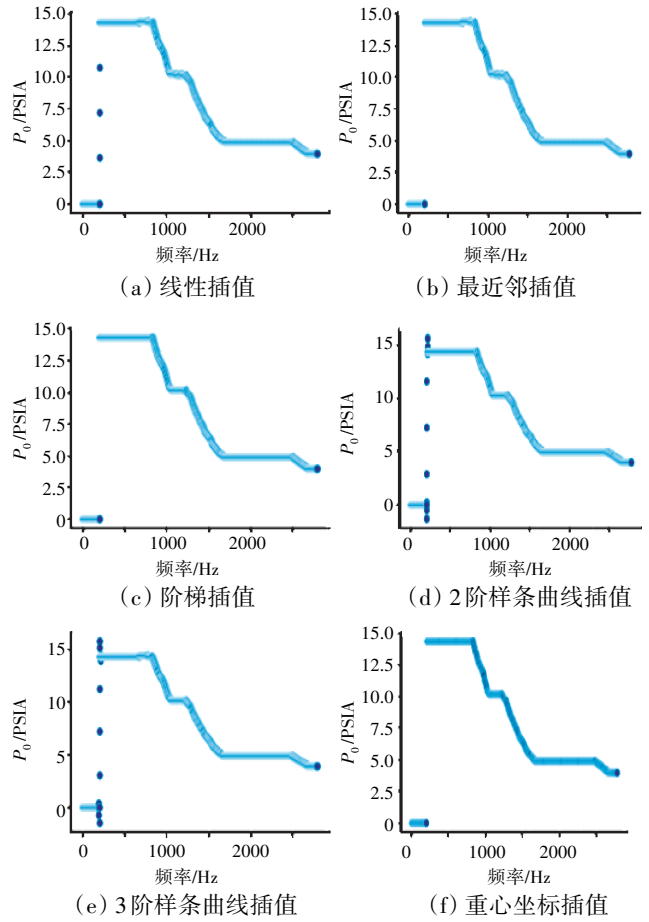


图 1 各插值法对比

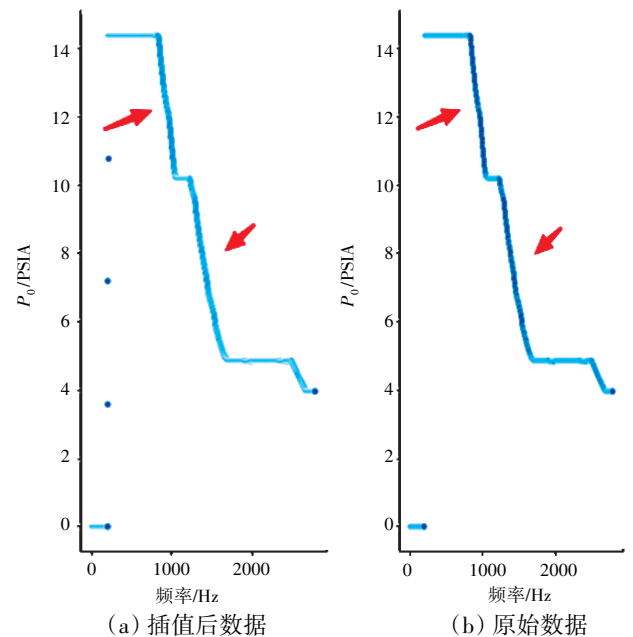


图 2 缺失值对比

机批量抽样试验。该技术有助于模型更好地拟合真实的潜在控制函数。以便模型能够预测参数未来的

变化和参数之间的相互作用,而非模型学习到能够区分不同飞行航段的时间关系特征<sup>[17-18]</sup>。1个batch的训练数据将由100个连续的step作为输入值和10个连续的step作为真实值(作为与模型预测值进行对照计算误差)组成。在试验中,随机抽取64个batch作为1个epoch训练的输入。

## 2 模型架构

在深度学习发展早期,模型性能并非随网络深度的增加而提高,相反随着模型复杂度增加而出现性能退化。He等<sup>[19]</sup>提出了经典的残差神经网络(Residual Neural Network, ResNet)的架构,使模型学习的方向为贴近理论最优解与当前解的残差,拟合出现实中得到的实际最优解。这种残差学习的方式可以解决模型深度退化的问题。因此,在各种最优的算法上可利用残差网络架构的思想来解决网络深度问题,并且能提升模型的性能。随着注意力机制(Attention mechanism)即模拟人类视觉注意力的一种技术的提出,深度学习模型得到了极大的发展。通过该方式,可有选择地赋予所学到的特征的权重。在计算时使模型能精炼出适应当前任务的重要特征,而忽略非重要特征。Hu等<sup>[20]</sup>提出了曾获得2017年ImageNet冠军的SENet(Squeeze-and-Excitation Network)。这个架构除了使用残差结构外还添加了类注意力机制即SE block(Squeeze-and-Excitation block)。利用任务学习特征重要性的能力加强了残差结构。最近由FAIR实验室提出的现代化残差网络即ConvNeXt模型更具有超越Transformer类网络的卓越能力<sup>[21]</sup>。

基于以上背景,提出一种改进的ConvNeXt轻型网络,并将ConvNeXt模型轻量化与SE block结合,赋予ConvNeXt注意力机制的能力,以提升原模型的性能,便于更好地应用在航空发动机压气机变几何系统的预测应用上,学习到重要的控制特征。

### 2.1 残差网络

在深度学习领域,模型的复杂度随着模型的深度增加而增加。而复杂度高的模型能抽象出更复杂、更强大的高维特征。在早期,模型的性能并未随着模型深度增加而增强,而是出现了性能退化的现象。该现象并非因为复杂度过高数据量过少的过拟合导致,模型过拟合会使训练误差小而测试误差大,退化现象的出现反而导致训练误差增大<sup>[22-23]</sup>。在理想条件下,更

深层的网络训练结果不会比浅层网络结果差,浅层网络已训练好结果,深层网络只需作为identity mapping恒等变换,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。通过试验发现SGD(Stochastic gradient descent)随机梯度下降找不出理论最优解。

残差网络的提出则优先解决了这个问题,其结构思想也一直延续至今。Res block构造出1个identity mapping,解决了在网络深度增加时出现的退化问题。将理论最优解表示为 $E(x)$ ,已学习到的结果表示为 $X$ 。在残差结构中下一层的网络不像传统深度网络去学习1个新的 $X$ ,而是去学习 $H(x)$ 与 $X$ 的残差 $F(x)$ ,因此下一层的输出为 $F(x)$ 与 $x$ 的捷径连接(shortcut connections),即 $F(x)$ 和 $X$ 的和。通过该思想拟合理论最优解和LightGBM模型。残差学习(构建残差块)如图3所示。




图3 残差学习(构建残差块)

Residual block中 $F(x)$ 与 $X$ 的加和未增加新的参数,模型整体的计算复杂度也未增加。通过学习 $F(x)$ 拟合残差可解决当 $X$ 与 $H(X)$ 近似,则下层不需要重新学习新 $X$ 而 $F(X)$ 近似为0。该思想解决了模型深度的局限性,使模型即便深度增加,也可在已近似理论最优解后停止学习。

### 2.2 压缩和激励网络

#### 2.2.1 压缩(Squeeze)

本文使用global average pooling作为Squeeze操作,在操作时,顺着空间维度进行特征压缩,将每个2维特征通道转换为1个实数,这个实数在某种程度上具备全局的感受野,且输出的维度和输入的特征通道数相匹配,表征在特征通道上响应的全局分布,使得靠近输入的层也可获得全局的感受野<sup>[20]</sup>

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

式中: $H/W$ 为空间维度; $C$ 为特征通道数; $u_c$ 为输入数据; $z_c$ 为输出不同类别的概率。

2.2.2 激励(Excitation)

在 Excitation 操作时,通过 2 个 Fully Connected, 全连接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<sup>[20]</sup>

$$s = F_{ex}(z, W) = \sigma(W_2 R_{ELU}(W_1 z)) \quad (2)$$

式中: $W_1 \in R^{c_r \times c}$ ,  $W_2 \in R^{c \times c_r}$ 。其中,降维系数  $r$  是个超参数; $R_{ELU}$  为线性整流激活函数; $z = [z_1, z_2, \dots, z_c]$ 。

为降低模型的复杂度,提升泛化能力,使用包含 2 个全连接层的 bottleneck 结构。其中第 1 个全连接层起到降维的作用,然后采用  $R_{ELU}$  激活,最后的全连接层恢复原始的维度。双全连接层的应用使得模型的非线性拟合能力得到提升,以便更好地学习各 channel 之间的相关性和重要性。使用 Sigmoid 函数将学习到各 channel 间的权重归一化至 0~1,通过 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特征上。通过 channel 学习的不同特征,在模型训练中识别和分辨各特征对任务的贡献程度来赋予被赋予相应的权重。整个模块如图 4 所示。




图 4 压缩和激励残差模块

2.3 ConvNeXt 模型

ConvNeXt 模型是由 FAIR (Facebook AI 研究室) 提出的现代化残差网络,在一定程度上达到了超越 Swin Transformer 模型<sup>[24]</sup>的效果。基于 ResNet 的思想,该模型使整体结构更加现代化并更新了相关组件,优化了模型的结构,使整体架构更加合理、优化。基于 ViT 模型将 Transformer 结构引入计算机图像领域, MAE 模型和 Swin Transformer 模型均在此基础上进行衍生和发展。而 ViT 模型是将图片分割为每个 patch,即每个不同的区域<sup>[25]</sup>,分块处理。而传统 ResNet 模型则是使用 1 个 7×7 的卷积加最大池化层对图像进行直接整体处理。ConvNeXt 采用了这类思想,使用 4×4 的卷积先处理输入,每次处理 1 个 patch 的信息,都有效地减少了下次采样的倍数,增加了模型性能。此外将通道数从 64 增加到 96 提升了网络宽度。使每个卷积核单独处理 1 个通道,这样也类似于自注意力机制,在单个通道内做空间信息的混合加权。另外,将残差模块从 1×1 大通道-3×3 小通道-1×1 大通道改为

7×7 小通道-1×1 大通道-1×1 小通道的大小模式如图 5 所示,使信息在不同维度特征空间之间转换时避免压缩维度带来的信息损失。如用高斯误差线性单元激活函数  $G_{ELU}$  代替  $R_{ELU}$  的一些小模块,会减少激活层数量等。




图 5 ConvNeXt 模块

基于上述背景,本文提出一种改进的 ConvNeXt 网络,将 ConvNeXt 模型与 SE 模块结合,以提升模型性能,使改进的 ConvNeXt 模型在航空发动机压气机变几何系统预测中具有更高的预测准确率。为满足快速建模达到验证理论思想的需求,本文采用标准的 18 层残差网络组合即内部模块 [2, 2, 2, 2] 的组合形式,建立 1 个轻量级 ConvNeXt 模型。该模型不仅能满足快速建模的要求,也因其自身复杂度适当、内部参数规模合适与本文具有的真实飞机飞行数据量相契合。

2.4 优化器和学习率控制策略

本文将自适应矩阵估计权重衰减优化器 AdamW (Adaptive Moment Estimation with decoupled weight decay)<sup>[26]</sup>作为试验所使用的优化器,相比于 SGD、Adam 等算法,AdamW 经过偏执校正后,每次迭代学习率都有 1 个确定范围,因此使得参数较稳定。其超参数  $\beta_1$ 、 $\beta_2$  及权重衰减分别为 0.9、0.999 和 0.05。为更好地训练模型,防止模型在目标函数周围来回振荡不收敛,本文采取了一种余弦退火学习率 (Cosine Annealing LR) 的策略来控制 and 调整模型训练过程中的学习率变化。其变化规律为

$$\eta_{LR} = \eta_{min}^i + 0.5 \times (\eta_{max}^i - \eta_{min}^i) \times (1 + (\cos \frac{T_{cur}}{T_i} \pi)) \quad (3)$$

式中: $\eta_{max}^i$ 、 $\eta_{min}^i$  分别为最大、最学习率; $T_i$ 、 $T_{cur}$  分别为总的、当前迭代次数; $\eta_{LR}$  为余弦退火学习率。

余弦退火学习率如图 6 所示。试验中所使用的超参数  $T_{max}$  等于训练周期即 100 次。




图 6 余弦退火学习率 ( $T_{max}$  设置为 25 次迭代)

### 3 试验分析

本文通过构建新模型并进行试验,证明了对航空发动机压气机变几何系统预测的可行性,及其他类型发动机的适用性。此外,为证明模型经随机批量抽取可学习成为通用模型,本文还将测试集分状态对模型进行测试。为直接输出与实际情况相符的结果,未将数据集进行归一化和标准化处理。VSV的角度和VBV的开度可直接用输出结果进行表示。本文将使用均方误差(Mean squared error, MSE)作为模型间性能的对比参照。结果是角度和开度的平方。模型对比结果取训练过程中最优的模型,然后在有偏置的测试集上测试一百次结果取平均值,以保证结果的充分性。以图形展示最优的预测结果。此处设置偏置的含义是为了让每次测试所抽取的数据即1个batch的数据均不同,但每次所使用的均为相同测试集内的数据。

#### 3.1 可行性分析

对于预测可行性的分析,本节将在A型发动机上进行试验,VSV和VBV在测试集中分别展示整体的预测趋势如图7、8所示。图7的局部展开和误差分布如图9、10所示,图8的局部展开和误差分布如图11、





图7 A型发动机VSV总预测趋势

图8 A型发动机VBV总预测趋势



(a) 局部预测1

(b) 局部预测2

图9 VSV局部预测(A型发动机)

12所示。从图中可见,使用改进的ConvNeXt模型可很好地预测A型航空发动机的压气机变几何系统。模型能及时准确地追踪和预测系统未来的突变





图10 VSV角度预测结果误差数值分布(A型发动机)

和发展趋势。尽管存在一些误差,但在接受范围内,误差分布均呈正态分布趋势可通过加大数据量微调模型解决。最为核心的和直观的结论可直接从预测趋势图中获得,并可较为准确地预测A型航空发动机变几何系统。

各模型之间的对比见表2。从表中可见,改进的ConvNeXt模型较原模型有提升,确实为最优模型。说明本文对原ConvNeXt的改进是有效的,对A型航空发动机压气机变几何系统的预测也是相适应的。



(a) 局部预测1

(b) 局部预测2

图11 VBV局部预测(A型发动机)




图12 VBV开度预测结果误差数据分布(A型发动机)

表2 模型对比(A型发动机)

模型	VSV角度 MSE/(°)	VBV开度 MSE/(°)
改进的 ConvNeXt18	2.132	7.077
ConvNeXt18	2.451	7.231
ResNet18	2.819	7.361
VggNet16	5.840	10.042

#### 3.2 适用性分析

本节以B型航空发动机的压气机变几何系统为试验对象。其中对于VSV的预测结果如图13、14所示;对于VBV的预测结果如图15、16所示。均方误差(MSE)分别为7.187和138.751。相较于A型发动机,




图13 B型发动机VSV总预测趋势




图14 VSV角度预测结果误差数据分布(B型发动机)




图15 B型发动机VBV总预测趋势




图16 VBV开度预测结果误差数据分布(B型发动机)

B 型发动机的预测结果相对不精准。尤其是 VBV 预测,其标准误差(Root mean squared error, RMSE)为 11.78,即均方误差为 11.78。B 型发动机 VBV 的开度变化范围较大,最高可接近 140°,虽然存在一定的误差,但在可接受范围之内。仍能对 VBV 的发展趋势和突变进行较为准确的预测。

B 型航空发动机的 VBV 和 VSV 预测结果虽存在一定的误差,但其预测结果仍是可接受的且较为准确的。说明改进的 ConvNeXt 模型对发动机压气机变几何系统的预测具有一定的适用性,并可应用于其他类型的发动机。因此对发动机压气机的研究具有一定的意义和价值。

相对 A 型航空发动机,以下 2 点为主要影响预测精度的因素。

(1)未能学习到更为精准的预测特征。由于参数的选取不足,导致预测的相关性不够。但参数选取并不是本文的主要研究内容,在此不作赘述。

(2)数据不足。数据量不足导致模型不能完全从数据中学习到精确预测所需的重要特征。

### 3.3 航空发动机状态分析

为研究模型的通用性,并使结论更加可靠,本文在 A 型航空发动机上进行发动机分态试验。将测试集分为稳态和过渡态,分别进行试验。VSV 的预测结果和箱型如图 17~19 所示。从图中可见,当飞机飞行




图 17 稳态预测结果 (VSV, A 型发动机)




图 18 过渡态预测结果 (VSV, A 型发动机)

时,航空发动机处于稳定状态的比处于过渡状态的时间长。因此,稳态数据集大于过渡态数据集,所系稳态的 X 轴长于过渡态的。VBV 的预测结果和箱型如图 20~22 所示。箱型图中三角形为误差均值。




图 19 过渡态稳态箱型分布 (VSV, A 型发动机)

从图中可见,在模型复杂度和数据量足够的情况下,模型被训练为同时预




图 20 稳态预测结果 (VBV, A 型发动机)




图 21 过渡态预测结果 (VBV, A 型发动机)

测稳态和过渡态的通用模型。此外,不论 VSV 还是 VBV 模型,因过渡态变化复杂,预测过渡态高于稳态的预测误差,符合预测逻辑。且预测较为精准,改进的 ConvNeXt 模型较好地预测未来的变化规律,及时追踪突变情况。

## 4 结论

(1)压气机变几何系统的预测是可行的,模型可较为准确地预测 VSV 角度的变化和 VBV 开度的变化,且预测误差在可接受范围内。

(2)压气机变几何系统的预测方法具有一定的适用性,在不同类型的航空发动机上可获得相对准确的结果。

(3)模型可识别不同的航空发动机运行状态并做出准确地预测,并得以验证。因此,当数据量充足时,复杂度适当的算法模型可同时学习不同发动机状态的重要特征。

在未来的研究中为进一步优化提升,将最优的深度学习算法应用到航空发动机领域,对快速建模确实取得很好的效果。但需提供优质和足够的的数据量,如果数据量不足,数据质量不高可使试验结果难以满足研究需求,所以数据的预处理极为重要。本文所研究的 2 种类型的航空发动机数据为百万级,刚好达到模型阈值。随着未来学习模型先进性和复杂性的提升,需更多高质量数据。是否能建立 1 个开源的发动机数据库并不断补充数据量,是 1 个待思考的问题。另外,当模型进行控制系统预测时,未来其他基本参数的变化不包括在模型结果预测中,而是直接预测目标参数的未来变化值。但模型在预测目标参数的同时分析并预测了其他参数的未来趋势。以此导致的不准确结果,因无法精确得知其他参数的未来变化,而




图 22 过渡态稳态箱型分布 (VBV, A 型发动机)

只能根据所学到的参数间的作用关系进行推论。因此,未来的研究可侧重于如何从其他重要参数中收集信息,而不是直接预测目标参数。为此可为模型提供更有用的信息,从而得出更准确的预测结果。由于机械原因也会带来不可避免的误差。因此,如何合理地解决这些问题将是进一步研究的重点。

#### 参考文献:

- [1] Lee J, Wang H. Complex system maintenance handbook[M]. London: Springer, 2008:49-78.
- [2] Xiong M, Wang H, Fu Q, et al. Digital twin - driven aero-engine intelligent predictive maintenance[J]. The International Journal of Advanced Manufacturing Technology, 2021, 114(11):3751-3761.
- [3] Greitzer E M. Review—axial compressor stall phenomena[J]. Journal of Fluids Engineering, 1980, 102(2):134.
- [4] 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)
- [5] 中国民用航空局安全办公室,中国民航科学技术研究院. 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>.  
Safety Office of the Civil Aviation Administration of China, Civil Aviation Science and Technology Research of China. Statistics report on China civil aviation safety information[EB/OL].[2022-03-06]. <http://news.carnoc.com/list/461/461183.html>.
- [6] Willems F, De Jager B. Modeling and control of compressor flow instabilities[J]. IEEE Control Systems Magazine, 1999, 19(5):8-18.
- [7] Voiponi A J. Gas turbine engine health management: past, present, and future trends[J]. Journal of Engineering for Gas Turbines and Power, 2014, 136(5):051201.
- [8] Jumper J, Evans R, Pritzel A, et al. Highly accurate protein structure prediction with AlphaFold[J]. Nature, 2021, 596(7873):583-589.
- [9] Davies A, Veličković P, Buesing L, et al. Advancing mathematics by guiding human intuition with AI[J]. Nature, 2021, 600(7887):70-74.
- [10] 张振兴,金帅,闫海骄. 高压压气机可调静子叶片  $a_2$  摆动故障诊断与分析[J]. 航空发动机, 2021, 47(S1):57-59.  
ZHANG Zhenxing, JIN Shuai, YAN Haijiao. Diagnosis and analysis of  $\alpha_2$  swing fault of adjustable stator vane in high-pressure compressor [J]. Aeroengine, 2021, 47(S1):57-59. (in Chinese)
- [11] Li B, Gu C W, Li X T, et al. Numerical optimization for stator vane settings of multi-stage compressors based on neural networks and genetic algorithms[J]. Aerospace Science and Technology, 2016, 52:81-94.
- [12] Wang L, Zhang L, Xu M, et al. Research on fault diagnosis method of civil aviation engine variable bleed valve system based on artificial immune algorithm[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2016, 30(7):1659021.
- [13] Data to Biz. Importance of datasets in machine learning and AI research[EB/OL]. (2022-05-13)[2022-06-03]. <https://www.datatobiz.com/blog/datasets-in-machine-learning/>.
- [14] 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.
- [15] CFM company. Training manual CFM56-7B engine systems[M]. Cincinnati: GE Customer Training Center, 2012:9-29.
- [16] CFM company. CFM56-7B advanced engine system[M]. Cincinnati: GE Customer Training Center, 2016:99-130.
- [17] Jalil N A, Hwang H J, Dawi N M. Machines learning trends, perspectives and prospects in education sector[C]//Proceedings of the 3rd International Conference on Education and Multimedia Technology. Nagoya: ACM Press, 2019: 201-205.
- [18] Mitchell T. Key ideas in machine learning[D]. Pittsburgh, US Carnegie Mellon University, 2017.
- [19] 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 Press, 2016: 770-778.
- [20] 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 Press, 2018:7132-7141.
- [21] Liu Z, Mao H, Wu C Y, et al. A convnet for the 2020s[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York:IEEE Press, 2022:11976-11986.
- [22] 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 Press, 2015:5353-5360.
- [23] Srivastava R K, Greff K, Schmidhuber J. Highway networks[EB/OL]. (2015-11-03)[2022-03-06]. <https://doi.org/10.48550/arXiv.1505.00387>.
- [24] Liu Z, Lin Y, Cao Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[EB/OL]. (2021-08-17)[2022-06-03]. <https://arxiv.org/abs/2103.14030>.
- [25] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: transformers for image recognition at scale[EB/OL]. (2021-06-03)[2022-03-06]. <http://arXiv.2010.11929>.
- [26] Loshchilov I, Hutter F. Decoupled weight decay regularization[EB/OL]. (2019-01-04)[2022-03-06]. <http://arxiv.org/abs/1711.05101>.

(编辑:贺红井)