

基于热力学的涡扇发动机神经网络建模方法

任立坤, 谢 静, 秦海勤, 谢镇波

(海军航空大学青岛校区 航空机械工程与指挥系, 山东 青岛 266041)

摘 要: 由于无法掌握不同发动机的真实部件特性, 传统热力学模型对在翼涡扇发动机的建模存在较大的建模误差; 同时, 热力学模型在特性图边界线附近迭代时, 容易迭代到特性图之外, 造成迭代过程的不收敛。针对上述问题, 本论文提出基于热力学过程的涡扇发动机神经网络建模方法, 在神经网络模型的训练过程中充分考虑对部件共同工作热力学约束的优化, 提高发动机建模的准确性。通过构建部件级网络结构、部件共同工作损失函数及融合训练过程, 将基于部件特性图的传统热力学模型迭代过程转化为部件级神经网络的多目标优化与训练过程, 提高了模型的收敛性及建模准确性。模型在 26 970 条发动机实际飞行数据上进行了训练及测试, 结果表明, 在相当宽松的准稳态数据下, 论文提出的建模方法最大误差可以达到 7% 左右, 比基于部件特性图的热力学模型低 5% 左右。

关 键 词: 涡扇发动机; 热力学模型; 神经网络模型; 飞行数据; 融合方法

中图分类号: V231.1

文献标志码: A

A thermodynamics-based neural network modeling approach for turbofan engines

REN Likun, XIE Jing, QIN Haiqin, XIE Zhenbo

(Aviation Mechanical Engineering and Command Department,
Qingdao Campus of Naval Aeronautical University, Qingdao Shandong 266041, China)

Abstract: Owing to the inaccuracies of the component characteristic maps, the traditional thermodynamic model for on-wing turbofans exhibited a significant modeling error. Moreover, when the model was iterated near the boundary points of the maps, it was prone to non-convergence, rendering it unreliable. To address these issues, a neural network modeling method for turbofans based on thermodynamic was put forward. This method improved modeling accuracy by fully considering the optimization of thermodynamic constraints during the training process of neural network models. By constructing a component-level network structure, implementing a components-cooperating loss function, and applying a fusion training process, the traditional iterative process of the thermodynamic model was transformed based on the component characteristic maps into a multi-objective optimization and training process of the component-level neural network. This approach improved the convergence and modeling accuracy of the model. The model was trained and tested using 26 970 actual engine flight data. The results demonstrated that the maximum error of the proposed modeling method was approximately 7%, even under loose quasi-steady-state data, which was about 5% lower than that of the thermodynamic model based on the characteristic maps.

收稿日期: 2022-09-26

基金项目: 山东省自然科学基金(ZR2021QE193)

作者简介: 任立坤(1987—), 男, 讲师, 博士, 主要从事航空发动机性能方面的研究。

通信作者: 秦海勤(1981—), 男, 副教授, 博士, 主要从事航空发动机性能方面的研究。E-mail: xiao_qin_1981@163.com

引用格式: 任立坤, 谢静, 秦海勤, 等. 基于热力学的涡扇发动机神经网络建模方法[J]. 航空动力学报, 2023, 38(7): 1571-1582. REN Likun, XIE Jing, QIN Haiqin, et al. A thermodynamics-based neural network modeling approach for turbofan engines[J]. Journal of Aerospace Power, 2023, 38(7): 1571-1582.

Keywords: turbofan engines; thermodynamic model; neural network model; flight data; fusion approach

航空发动机热力学模型^[1]被广泛用于发动机设计^[2]、开发^[3]及监控^[4]等领域。然而,在军用涡扇发动机领域,热力学模型的计算过程存在着严重的不收敛及不准确现象^[5],其主要原因在于:

一是气动热力学模型对非线性平衡方程组的迭代过程对迭代初值的选取非常敏感,不合理的初值选取容易导致迭代过程的发散;

二是受制于发动机制造过程的个体差异及装配公差等,对于来源于某一个或几个部件实验的特性图而言,不同批次甚至同一批次的部件仍然存在着偏差,特性图的不准确进而造成了建模的不准确;

三是对于军用涡扇发动机而言,由于其长时间工作于高转速附近的大状态^[6],热力学模型在高转速附近进行迭代时,容易迭代到部件特性图中没有的转速范围内,导致模型不收敛。

许多研究人员尝试从提高特性图精度和泛化能力方面解决热力学模型的不收敛问题^[7]。Kong 等人^[8]提出了一种多项式缩放方法来修正部件特性图。Kong 等人^[9]使用三次拟合来直接拟合空气质量流量和等熵效率。Li 等人^[10-11]中,使用二次曲线对比例因子进行回归。Tsoutsanis 等人^[12]采用椭圆曲线拟合调整部件特性图。Tsoutsanis 等人^[13]根据原始特性图的形状,用不同的函数对不同比例因子进行回归。Kim 等人^[14]采用比例因子对整体性能参数和局部性能参数进行调整。

通过曲线拟合提高特征图的精度和泛化能力可以在一定程度上改善模型的收敛性。然而,即使特性图足够平滑,当发动机工作在飞行包络线附近时,热力学模型很容易迭代到特性图之外,导致不收敛现象。

随着近年来神经网络的发展,有许多不同的领域都应用了先进的人工智能方法作为解决方法。基于神经网络的方法可以通过数据驱动的方式获得更加个性化的特性图,或者通过训练过程直接建立航空发动机相关参数映射的黑箱模型。Yu 等人^[15]使用制造商提供的数据训练了一个3层反向传播神经网络来预测压气机部件特性图;Ghorbanian 等人^[16]利用实验数据预测压气机性能;艾璐^[17]通过神经网络方法建立了低转速旋转部

件特性;王昊^[18]建立了发动机测量参数-健康因子神经网络,用于预测航空发动机剩余寿命;史国华^[19]提出了长短时记忆网络对航空发动机剩余寿命进行预测;李国军^[20]结合遗传算法与神经网络,建立了数据驱动的航空发动机控制系统;Chao 等人^[21]结合卷积神经网络(CNN)与 Kalman 滤波建立了航空发动机测量参数及健康因子的评估方法。

基于神经网络的方法通过前向计算提高了收敛性。然而,大多数神经网络将部件特性建模作为一个单纯的回归问题,忽略了部件共同工作过程中的热力学约束,导致模型的泛化能力较弱,容易对训练数据过拟合,当模型由训练集转移到实际飞行数据集时,会产生较大的建模误差。

为了解决传统热力学模型的不收敛问题和神经网络模型与发动机工作过程的不匹配问题,本文提出了一种基于热力学过程的、基于神经网络的涡扇发动机融合建模方法。热力学模型的迭代过程被转化为融合模型的前馈计算以提高收敛性。提出了描述部件共同工作过程的多目标损失函数,引导融合模型向涡扇发动机的真实热力学状态空间收敛。

论文首先简要介绍了传统热力学模型对航空发动机的建模过程;然后,提出了基于热力学过程的神经网络模型的构建方法,通过部件网络结构、热力学约束下的多目标联合优化及多数据源的融合训练过程,充分考虑对部件共同工作的热力学约束,提高发动机建模的准确性;最后,在飞行数据下对论文提出的模型进行了测试,与传统热力学模型及数据驱动的神经网络模型进行了比较。

1 航空发动机热力学模型

在热力学模型中,主要部件如低压压气机(LPC)、高压压气机(HPC)、燃烧室、高压涡轮(HPT)、低压涡轮(LPT)、外涵道、混合器和尾喷管都是通过其热力学过程来建模。这些部件的出口参数可以在给定的进口和运行参数下计算出来。

在发动机建模术语中,部件进口和出口的状态参数被称为截面参数。为了区分不同部件的截

面参数,引入了截面编号,如图1所示。例如,截面25代表高压压气机的入口,截面3是高压压气机的出口,也是燃烧室的入口。通常采用截面参数+截面编号来表示在某一截面下的截面参数,如 T_6 表示涡轮后(截面6)的燃气温度。




图1 热力学模型的截面编号

Fig. 1 Station numbers of thermodynamic model

在给定一些飞行参数,如环境压力、发动机进口温度和压力,以及一些运行参数,如转子速度后,截面参数可以通过求解以下平衡方程来计算。

首先是功率平衡,即高低压涡轮的输出功与高低压压气机的输入功相平衡

$$\begin{aligned} W_{lpt}\eta_{ml} &= W_{lpc} \\ W_{hpt}\eta_{mh} &= W_{hpc} \end{aligned} \quad (1)$$

其中 W_{lpt} 为低压涡轮的输出功, η_{ml} 为低压转子的机械效率, W_{lpc} 为低压压气机的输入功; W_{hpt} 为高压涡轮的输出功, η_{mh} 为高压转子的机械效率, W_{hpc} 为高压压气机的输入功。

然后是流量平衡,即高低压涡轮的空气流量与其特性图插值流量平衡

$$\begin{aligned} Q_{alpt} &= Q_{alptmap} \\ Q_{ahpt} &= Q_{ahptmap} \end{aligned} \quad (2)$$

其中 Q_{alpt} 为低压涡轮的燃气流量, $Q_{alptmap}$ 为从低压涡轮特性图中得到的插值流量; Q_{ahpt} 为高压涡轮的燃气流量, $Q_{ahptmap}$ 为从高压涡轮特性图中得到的插值流量。

最后是压力平衡,即喷管喉道静压平衡以及混合器内外涵静压平衡

$$\begin{aligned} p_{nz} &= p_{nzq} \\ p_{bypass} &= p_{core} \end{aligned} \quad (3)$$

其中 p_{nz} 为通过喷管入口截面参数计算得到的喷管喉道静压, p_{nzq} 为通过喷管出口截面参数计

算得到的喷管喉道静压; p_{bypass} 为混合器外涵入口静压, p_{core} 为混合器内涵入口静压。

将上述平衡方程联立,可以得到发动机共同工作的平衡方程组。热力学模型通常采用迭代法对上述平衡方程组进行求解:首先给定一组独立变量的初值,在初值点邻域内对上述非线性方程组线性化;然后沿着负梯度方向构造迭代公式不断对独立变量进行迭代,直到平衡方程组的残差满足规定的精度;从而得到满足平衡条件的独立变量,然后通过求解的独立变量计算发动机各截面的气动热力学参数。

2 基于热力学过程的神经网络模型

2.1 部件级神经网络模型结构

神经网络模型将发动机各部件建模为网络模块,模块输入为各部件工作参数及入口状态参数,输出为各部件出口状态参数。

利用各部件特性图对各网络单元进行预训练,使其能够提取到对应部件的热力学特性,下面以低压压气机为例,阐述网络单元的预训练过程。

首先,产生一系列符合发动机工作实际的低压压气机入口截面参数;然后,利用低压压气机特性图计算其对应的出口截面参数,得到“入口参数-出口参数”训练集;最后,利用上述训练集对网络单元进行训练,构建能够反映部件特性的低压压气机网络模块。

在上述过程中,部件特性图主要用于构建训练集中的“入口参数-出口参数”间的映射关系,将部件特性固化于训练数据中。然后通过网络的训练过程将部件特性从训练数据中转移到训练后的网络权重上。

将各网络模块按照发动机真实的热力学过程连接起来,建立发动机部件级的神经网络模型,如图2所示。

下面以图3所示的低压压气机模块为例,说明神经网络模块的构建过程。从气路连接关系来看,低压压气机是一个单输入、双输出的通道,因此,低压压气机模块的入口参数(如入口总温、总压等)只有一路,而出口参数为两路,分别接入到外涵道模块及高压压气机模块的入口参数。同时,为了确定低压压气机模块的出口参数,还应向模块输入低压压气机的工作参数,如转速、流量等;以及环境参数如环境静压。

在上述连接关系确定后,就可以将低压压气




图 2 部件级神经网络模型结构

Fig. 2 Structure of the component level neural network model




图 3 低压压气机的网络结构

Fig. 3 Structure of the low pressure compressor net

机实际的气路流动过程(图 3(a))转化为基于其热力学过程的神经网络模块(图 3(b)),从而完成对低压压气机工作过程的网络化过程。

所有的部件网络模块采用与图 4 相似的全连接网络结构。各部件网络模块的输入包含入口截面参数,即上一部件网络模块的出口截面参数(如部件入口总温、总压等)及部件的工作参数(如转速或燃油流量等);部件网络模块的输出为该部件的出口截面参数。部件网络模块的基本结构如图 4 所示,在中间层采用 ReLU 激活函数,在输出层采用 softmax 激活函数。图中括号内的 128/256 表示根据不同的部件复杂程度选取不同的神经元个数。由于低压压气机为一个单输入-多输出模块,其热力学计算过程较为复杂,因此其神经元个数选为 256 个;在其他部件模块中,选择 128 个神经元。

值得说明的是,在发动机的实际飞行过程中,其入口流量是无法测量的。单纯就低压压气机入




图 4 部件网络模块结构

Fig. 4 Component net module structure

口截面而言,其气动参数(如流量、马赫数)是无法计算的。然而,从整个发动机热力学过程来看,低压压气机入口流量可以通过发动机共同工作求解。由于低压压气机网络模块包含了发动机热力学过程的边界条件(入口总温、总压、环境压力、转速),理论上讲,其出口气动参数可以通过低压压气机网络模块回归。因此,低压压气机网络不但是一个部件网络,同时也是一个对发动机入口流量/马赫数的回归网络。从后续的实验可以看出,在缺乏入口马赫数输入的前提下,基于发动机热力学过程,通过低压压气机网络回归的出口马赫数偏差较大。

整体的神经网络结构如图5所示,其中虚线框中的参数为神经网络的输入参数。




图5 网络整体结构

Fig. 5 Overall structure of the network

由图4及图5可以看出,网络整体结构的规模较大,其训练过程容易产生过拟合及梯度爆炸、梯度弥散现象。针对该问题,本文给出了以下3点解决方案。

1) 通过文中第2.1节给出的部件预训练方法,对网络规模较小的单个部件网络模型进行训练,降低整体训练过程的优化难度。

2) 在文中第2.4.1节给出的仿真训练中,采

用式(9)对各部件网络输出的截面参数进行约束,相当于每个部件网络模块都有单独的损失函数,进而降低优化难度。

3) 针对网络参数量较大产生的过拟合问题,论文通过引入部件共同工作的热力学约束正则项(详见文中第2.2节),引导网络优化过程朝着发动机工作的热力学过程收敛。

2.2 多目标联合优化

传统热力学模型通过各截面流量、压力平衡及高低压转子功率平衡建立发动机各部件共同工作时的平衡方程组,通过迭代求解方式得到部件共同工作时应满足的工作参数。在转化为神经网络模型后,网络的前馈过程取代了传统热力学模型的迭代求解过程,然而在前馈过程中,部件共同工作的平衡方程组无法满足。

针对上述问题,论文提出基于部件共同工作的多目标联合优化方法,将平衡方程组转化为神经网络训练过程中的损失函数,通过训练过程引导神经网络模型向着流量平衡、压力平衡及功率平衡的方向收敛,完成对部件共同工作过程的建模。

对应部件共同工作所需满足的流量平衡、压力平衡及功率平衡,神经网络模型的热力学损失分为流量平衡损失、压力平衡损失及功率平衡损失。发动机稳定工作时,部件出入口流量应平衡,因此可以用出入口流量差构建流量平衡损失,衡量神经网络模型对流量平衡的逼近程度;同时,混合器入口内外涵的静压应平衡,因此可以用上述静压差构建压力平衡损失,衡量神经网络模型对压力平衡的逼近程度;此外,同一转子上的功率应平衡,因此可以用涡轮与压气机功率差构建功率平衡损失,衡量神经网络模型对功率平衡的逼近程度。

流量平衡损失用于衡量各截面的流量平衡程度。当发动机稳定工作时,由上一截面流入的空气流量应与该截面流出的空气流量相等。因此,两者的差异可以用来衡量神经网络模型偏离流量平衡的程度。流量平衡损失可以写为

$$l_1 = \frac{1}{M} \sum_{i \in S} \frac{[W_i - Q(T_i, p_i, Ma_i, A_i)]^2}{W_i^2} \quad (4)$$

其中 M 为发动机截面个数, W_i 为由上一截面流量推导出的第 i 个截面空气流量值, $Q(T_i, p_i, Ma_i, A_i)$ 为由第 i 个发动机截面参数通过流量公式得到的空气流量计算值。

$$Q(T_i, p_i, Ma_i, A_i) = K \frac{p_i A_i}{\sqrt{T_i}} q(Ma_i) \quad (5)$$

功率平衡损失是压气机需要的功率和涡轮提供的功率之间的差异。当发动机稳定运行时, 涡轮提供的功率等于同一转子轴上压气机的需求功率。因此, 两者功率之差可以用来衡量神经网络模型偏离功率平衡的程度。功率平衡损失可以写为

$$l_2 = \frac{|\eta_m \Delta H_t - \Delta H_c - P_{ext}|^2}{\Delta H_t^2} \quad (6)$$

其中 η_m 为涡轮转子的机械传动效率, ΔH_t 为涡轮部件的输出功, 可以由涡轮的出入口截面参数计算, ΔH_c 为压气机部件的需用功, P_{ext} 为功率提取量。

当发动机稳定工作时, 混合器内外涵入口的静压应保持平衡。因此, 两者的差异可以用来衡量神经网络模型偏离压力平衡的程度。压力平衡损失可以写为

$$l_3 = \frac{|p_{s-by}(T_i, p_i, Ma_i, A_i) - p_{s-in}(T_i, p_i, Ma_i, A_i)|^2}{p_{s-by}^2(T_i, p_i, Ma_i, A_i)} \quad (7)$$

其中 $p_{s-by}(T_i, p_i, Ma_i, A_i)$ 为混合器外涵入口静压, 可以通过外涵入口截面参数求解, $p_{s-in}(T_i, p_i, Ma_i, A_i)$ 为混合器内涵入口静压。

结合均方差损失, 将上述损失按照一定的权重累加起来, 形成最终多目标联合优化的损失函数

$$l = \lambda_0 l_m + \lambda_1 l_1 + \lambda_2 l_2 + \lambda_3 l_3 \quad (8)$$

其中 l_m 为相对均方差损失函数, 用于度量截面参数实际值 y_i 与神经网络模型估计值 $\hat{y}_i$ 间的相对差异

$$l_m = \sqrt{\frac{1}{N} \sum_{i=1}^N \frac{(y_i - \hat{y}_i)^2}{y_i^2}} \quad (9)$$

2.3 多目标联合优化的部件匹配分析

在热力学模型中, 通常采用优化算法对用于衡量各部件匹配性的平衡方程组进行迭代求解。在迭代过程中, 不断检查各平衡方程的相对差值, 若所有相对差值均小于预先设定的阈值(通常在 $10^{-5} \sim 10^{-3}$ 之间^[22]), 则优化过程收敛, 迭代终止; 否则, 在梯度方向上更新迭代变量继续迭代。由此可见, 热力学模型的平衡方程求解仍然是基于梯度优化的数值求解方法, 无法精确求得平衡方程组的解析解。

而在文中第 2.2 节建立的基于部件匹配性的多目标优化过程中, 以平衡方程残差作为最终的优化目标, 利用梯度优化算法, 不断引导神经网络模型(对应热力学模型的各部件模块)朝着残差缩小的方向收敛。其本质与热力学模型对平衡方程组的迭代求解是一致的, 都是通过迭代优化算法, 尽量减小部件间的不匹配程度。

通过后续的实验结果可知, 在合理设定多目标损失函数各权重值的前提下, 通过梯度优化算法训练完成的神经网络模型, 其在仿真数据集上的平衡方程相对误差最大值不超过 2×10^{-4} , 其在飞行数据测试集上的平衡方程相对误差最大不超过 5×10^{-3} , 与热力学模型迭代求解平衡方程的误差阈值设定值差别不大。

综上所述, 通过合理设定多目标损失函数中各损失的权重值及有效的梯度优化算法, 多目标联合优化方法能够引导神经网络模型各部件的匹配程度收敛到相应的热力学模型给定的误差阈值空间。

2.4 多数据源融合训练方法

受限于传感器数量, 在实际的飞行数据中, 发动机的截面参数较少, 难以有效地保证所有神经网络模型对发动机真实工作状态的收敛性。因此, 本文提出了多数据源融合训练方法: 首先, 利用仿真数据对网络模型进行预训练, 建立模型对发动机各截面参数的映射; 然后, 利用飞行数据对网络模型进行精细化训练, 在利用上文提出的多目标联合优化方法保证网络模型对发动机工作状态建模精度的同时, 利用飞行数据中少量的截面参数对网络权重进行微调, 提高网络模型对飞行数据的建模精度。具体的训练流程如图 6 所示。




图 6 多目标融合训练流程

Fig. 6 Multi-objective fusion training process

2.4.1 仿真数据预训练

仿真数据预训练采用以下过程。

首先,按照热力学模型的输入要求,在飞行包线内,按照某种事先给定的分布,如真实飞行数据所服从的分布,随机产生大量输入样本,每条输入样本通常包含高压转子转速(N_2)、低压压气机入口总温(T_2)、低压压气机入口总压(p_2)以及环境压力(p_{amb})。

$$T_{2i}, p_{2i}, p_{amb}, N_{2i} \sim P(x) \quad (10)$$

其中下标 i 为样本编号, $P(x)$ 为事先给定的分布。

然后,上述输入样本依次输入到热力学模型中,计算发动机状态参数及截面参数

$$N_{1i}, W_{fi}, S_i = m(T_{2i}, p_{2i}, p_{amb}, N_{2i}) \quad (11)$$

其中 N_{1i} 为第 i 条样本的低压转子转速, W_{fi} 为第 i 条样本的燃油流量, S_i 为第 i 条样本的各截面状态参数。

当所有样本计算完毕,网络模型所需要的输入输出参数都可以从上述样本参数中得到,进而可以建立用于训练网络模型的仿真数据集

$$\Omega_{mc} = \{(x_i, y_i), i = 1, 2, \dots, N\} \quad (12)$$

其中 x_i 为网络模型的输入向量,包含发动机入口参数(如入口总温、总压及环境压力),发动机状态参数(如高低压转子转速、燃油流量); y_i 为网络模型的输出向量,如各截面的总温、总压、气流马赫数等。

最后,利用仿真数据集 Ω_{mc} 及多目标损失函数式(8)对网络模型进行训练。

2.4.2 飞行数据训练

由于仿真数据集是由热力学模型产生的,因此由仿真数据集训练得到的网络模型精度最多只能达到热力学模型的建模精度。为了进一步提高网络模型精度,采用飞行数据对预训练的网络模型进行精细化训练。

首先,定义了发动机工作的准稳态条件:3 s内低压转子转速波动幅度不超过1%。该稳态条件没有考虑发动机飞行条件(如飞行高度、马赫数)等的变化,可以从飞行数据中提取较多的稳态工作点。另一方面,宽松的稳态条件也给模型对飞行数据的逼近精度提出了更大的挑战。

然后,利用上述准稳态条件从飞行数据中提取发动机稳态工作时参数,形成飞行数据集

$$\Omega_{fd} = \{(x_i, y_i), i = 1, 2, \dots, N\} \quad (13)$$

最后,多目标损失函数式(8)被用于在飞行数据集上训练网络模型。与仿真训练不同的是,由于飞行数据中只有少量的截面状态参数,网络模型中的其他截面参数无法用于训练网络。均方差损失函数被改写为

$$l_p = \frac{1}{N} \sum_{(x_i, y_i) \in \Omega_{fd}} \frac{\{S[N_{et}(x_i)] - y_i\}^2}{y_i^2} \quad (14)$$

其中 $S[N_{et}(x_i)]$ 用于从网络模型的输出中提取与飞行数据中记录的截面参数 y_i 对应的估计值。

通过飞行数据的精细化训练,部件特性通过网络节点间的权重朝着发动机的真实工作空间调整。

在文中第2.1~2.3节的3部分内容中,部件级神经网络模型结构保证了网络模型与气体的流动过程一致,同时利用网络的前馈计算过程代替热力学模型的迭代求解过程,避免了热力学模型迭代过程中的不收敛现象;多目标联合优化通过引入平衡方法损失函数确保了网络模型朝着部件共同工作空间收敛;多数据源联合优化则通过仿真数据预训练与飞行数据的精细化训练确保了网络模型对实际飞行数据的建模精度。

3 模型测试

本节利用某型军用涡扇发动机近一年共26 970条飞行数据对上述建立的神经网络模型的准确性进行验证。飞行数据中包含发动机入口总温(T_2)、入口总压(p_2)、环境压力(p_{amb})、低压转子转速(N_1)、高压转子转速(N_2)、燃油流量(W_f)以及涡轮后温度(T_6)。

3.1 仿真数据集预训练结果

15 360组热力学输入参数(T_2 、 p_2 、 p_{amb} 和 N_2)由式(12)在飞行包线内随机产生。然后每组数据输入到热力学模型中,计算得到发动机的工作参数及各截面的状态参数,进而形成15 360条仿真数据集 Ω_{mc} 。网络模型在该数据集上,采用多目标联合优化损失函数式(8)进行训练,训练代数为1 000代,步长为0.001,每100代步长衰减10%,训练批量大小为256,为了提高模型对部件匹配的约束,式(8)中各损失权重设置为 $\lambda_0 = 1$, $\lambda_1 = \lambda_2 = \lambda_3 = 5$ 。

建模精度以所有样本的最大相对误差衡量

$$m_e = \max_{i \in \omega} \frac{|\hat{y}_i - y_i|}{y_i} \quad (15)$$

其中 y_i 为样本 i 的某个截面参数, ω 为仿真数据集 Ω_{mc} 的下标集合。

涡轮后温度建模最大误差随训练代数的变化趋势如图 7 所示。可以看出,当训练代数达到 200 代左右时,网络模型趋于收敛,涡轮后温度的最大误差小于 0.5%。

式(8)中的各平衡损失最大值随训练代数的变化趋势如图 8、图 9 及图 10 所示。可以看出,




图 7 涡轮后温度最大训练误差趋势

Fig. 7 Trend of maximum training error for turbine exit temperature




图 8 流量平衡损失最大值随训练代数的变化趋势

Fig. 8 Trend of flow balance loss maximum with training epochs




图 9 功率平衡损失最大值随训练代数的变化趋势

Fig. 9 Trend of the maximum power balance loss with the training epochs




图 10 压力平衡损失最大值随训练代数的变化趋势

Fig. 10 Trend of maximum pressure balance loss with training epochs

随着训练的进行,各平衡损失逐渐趋于可接受的误差($< 2 \times 10^{-4}$)范围。

经过仿真数据集预训练后,各截面状态参数的最大误差如图 11 所示。

可以看出,低压压气机出口处马赫数的建模最大误差为 3.2%,远高于其他截面参数,这是因为网络模型的低压压气机模块的输入参数中没有马赫数参数。除此之外,其他截面状态参数的最大建模误差都低于 1.5%,验证了仿真数据集预训练的有效性。




图 11 仿真数据集预训练误差

Fig. 11 Errors after the simulation data pre-training

3.2 飞行数据集训练结果

如文中第 2.3.2 节所述,在仿真数据集训练后,网络模型进一步通过飞行数据训练。飞行数据集被分为训练集 Ω_{fd-tr} 与测试集 Ω_{fd-tt} 。其中,训练集用于对网络模型进行训练,测试集用于对训练后的网络模型建模精度进行测试。在近一年的某型军用涡扇发动机的飞行数据中提取了 26 970 条准稳态数据。准稳态数据的提取标准为:3 s 内低压转速波动小于 1%,与常规的试车台及飞行实验稳态性能录入标准(通常为油门杆稳定 30 s 后或 3 min

内转速波动小于 0.5%)相比,该稳态提取标准较为宽松。

在包线内及其左边界、上边界及右下边界近似等间距随机选取 6 970 条数据构成测试集:当在某些位置上无法提取到稳态数据时,选取离该位置最近的稳态点,当某些位置存在多于选取数量的稳态数据点时,在备选数据点中随机选取);剩余 20 000 条构成训练集。

训练参数如下:训练代数数为 1 000 代,步长为 0.000 1,每 100 代步长衰减 5%,训练批量大小为 256。

式(8)中的各平衡损失最大值随训练代数的变化趋势如图 12、图 13 及图 14 所示。可以看出,随着训练的进行,虽然各平衡损失误差值较仿真数据预训练结果放大,但各平衡损失仍然处于可接受的误差($<5 \times 10^{-3}$)范围。

为了验证飞行数据精细训练对网络模型建模精度的提升作用,对比了飞行数据精细训练前后网络模型对飞行测试集中涡轮后温度的建模误差分布,如图 15 所示。




图 12 飞行训练集上流量平衡损失最大值随训练代数的变化趋势

Fig. 12 Trend of flow balance loss maximum with training epochs in flight dataset




图 13 飞行训练集上功率平衡损失最大值随训练代数的变化趋势

Fig. 13 Trend of power balance loss maximum with training epochs in flight dataset




图 14 飞行训练集上压力平衡损失最大值随训练代数的变化趋势

Fig. 14 Trend of pressure balance loss maximum with training epochs in flight dataset




图 15 飞行数据训练前后网络模型对涡轮后温度的建模误差分布

Fig. 15 Modeling error distribution of network models for turbine exit temperature before and after flight data training

可以看出,仅通过仿真数据集训练的网络模型对涡轮后温度的建模误差呈均值为 6% 左右、方差较大的分布特征,最大建模误差高达 13.8%。而飞行数据训练后的网络模型,其建模误差集中于 4% 以内,最大建模误差为 7.1%。验证了飞行数据精细训练对降低网络模型建模误差的有效性。

3.3 与热力学模型的对比

经过飞行数据训练后的网络模型对飞行数据测试集的建模误差与热力学模型的建模误差对比如图 16 所示。其中,热力学模型在 67 条飞行数据中未得到计算结果(迭代过程未收敛,占比 0.96%),这些发散数据未计入误差统计;而神经网络模型对所有飞行数据都得到了估计结果。

由于用于训练网络模型的仿真数据集就是由热力学模型产生的,因此热力学模型的建模误差分布与飞行数据训练前的网络模型建模误差分布




图16 热力学模型与网络模型的误差分布对比

Fig. 16 Error distribution comparison of the thermodynamic model and the proposed model

类似,其最大误差达到12.3%。

这里的误差与实际工程应用对热力学模型误差的要求(1%左右)差距较大,其主要原因如下。

1) 工程上的稳态误差对稳态的要求很高,试车台上的稳态点选取原则一般为转速稳定2~3 min后进行稳态性能录入,飞行实验的稳态录入标准通常为2 min内转速波动不超过0.5%(如航标HB7507-2014);而本文中的稳态点是从实际飞行训练的飞参中提取的,如果在实飞数据中按照上述原则选取稳态点,则基本不存在稳态过程。因此,本文放松了稳态的条件,按照3 s内低压转速波动小于1%选取稳态点,这就造成较大的稳态误差。

2) 工程中的稳态误差大多是与试车台数据进行比对,没有考虑飞发匹配对发动机工作的影响,而本文中模型是与真实飞参进行比对,飞发匹配对模型误差的影响较大。

3) 工程中的稳态误差比对点通常为包线内的有限点,无法覆盖整个飞行包线,本文中的比对点为全包线内的比对。

4) 工程中的稳态误差通常为均值误差,而本文中这里论述的稳态误差为最大误差。若以平均误差论,热力学模型误差在4%左右,本文模型误差在1.5%左右。

3.4 模型误差对比

为了对比本文神经网络模型与基于特性图修正模型对航空发动机建模的准确性,选取目前特性图修正广泛采用的多项式拟合及二次曲线拟合进行对比:其中,Cubic^[10]采用三次函数对部件特性图进行修正,Elliptical^[12]椭圆曲线对部件特性进行拟合。上述两种方法均采用航空发动机热力

学建模软件PROOSIS(propulsion object-oriented simulation software)的特性图修正工具进行复现。

为了对比本文基于发动机部件共同工作的神经网络模型与单纯数据驱动神经网络模型的精度,选取基于卷积神经网络的建模方法^[21]进行对比。

误差以涡轮后温度(T_6)的相对建模误差衡量

$$e = \frac{|\hat{T}_6 - T_6|}{T_6} \quad (16)$$

对比结果如表1中所示,其中,“均值”表示模型对所有测试样本的建模误差均值,“方差”表示模型对所有测试样本的建模误差方差,“25%”表示对所有测试样本的建模误差按照从小到大的顺序进行排序,排序位于样本数量25%的建模误差大小,“最大”表示模型对所有测试样本的建模误差的最大值。

表1 不同建模方法误差对比

Table 1 Accuracy comparison of different methods

方法	均值	方差	建模误差/%			最大
			25	50	75	
Cubic ^[10]	0.036	0.021	0.013	0.032	0.051	0.11
Elliptical ^[12]	0.033	0.019	0.012	0.027	0.053	0.126
CNN ^{[21]*}	0.028	0.016	0.011	0.024	0.037	0.104
本文模型	0.014	0.011	0.005	0.012	0.019	0.071

注: *代码来源为 <https://gitlab.ethz.ch/armanue/Fusing-physics-based-and-deep-learning-models-for-prognostics>。

可以看出,本文提出的网络模型比其他模型的建模误差都小,以最大建模误差为例,本文模型的最大建模误差比传统热力学模型低5%左右,比三次拟合修正模型低4%左右,比椭圆拟合修正模型低5%左右,比单纯数据驱动的卷积神经网络低3%左右。

本文模型精度的提升一方面来源于神经网络模型在表达部件特性时更为灵活,不同于多项式拟合或二次曲线拟合,论文模型不局限于特性图的具体形状,通过调整神经元权重,可以对部件特性进行更加局部的调整;另一方面,不同于单纯数据驱动的神经网络模型,本文模型利用部件共同工作约束降低了神经网络对飞行数据的过拟合,使得训练过程能够朝着发动机真实的热力学过程收敛。

4 结 论

论文提出了一种新的基于热力学过程的涡扇

发动机神经网络建模方法: 通过将气路部件网络化, 将常规热力学模型的迭代求解平衡方程组过程转化为神经网络的前馈过程, 解决迭代过程不收敛现象; 通过引入流量、压力及功率损失函数构建多目标联合优化算法, 描述发动机气路部件的共同工作过程; 通过仿真数据和飞行数据的融合训练, 完成飞行包线内的网络优化过程。在真实飞行数据上对神经网络模型进行了验证, 实验表明, 神经网络模型在提高模型收敛性的同时, 也提高了建模精度, 以涡轮后总温最大相对误差衡量, 该神经网络模型的建模误差可以达到 7%, 比常规的热力学模型低 5%, 验证了本文模型的有效性。

论文的主要创新在于以下 3 个方面。

1) 提出了一种新的基于涡扇发动机部件的网络结构, 将热力学模型的迭代过程转化为神经网络的前馈过程, 同时降低模型对特性图的依赖程度, 进而提高模型的收敛性及计算效率。

2) 提出基于部件共同工作的多目标联合优化方法, 将部件共同工作的平衡方程组转化为神经网络训练过程中的损失函数, 通过训练过程引导神经网络模型向着流量平衡、压力平衡及功率平衡的方向收敛, 完成对部件共同工作过程的建模。

3) 建立了飞行包线内多数据源的融合训练方法, 综合利用仿真数据、台架数据、飞行数据对神经网络模型进行融合训练方法, 建立收敛性好、计算精度高的涡扇发动机神经网络模型。

参考文献:

- [1] SELLERS J F, CARL J D. DYNGEN-a program for calculating steady-state and transient performance of turbojet and turbofan engine[R]. NASA TN-D-7901, 1973.
- [2] 陈贞来, 苏三买, 李荣. 航空发动机涡轮特性转换方法[J]. 航空动力学报, 2020, 35(3): 651-657.
CHEN Zhenlai, SU Sanmai, LI Rong. Turbine characteristics conversion method of aeroengine[J]. Journal of Aerospace Power, 2020, 35(3): 651-657. (in Chinese)
- [3] LIU Xiaofeng, ZHANG Liming, LUO Chenshuang. Model reference adaptive control for aero-engine based on system equilibrium manifold expansion model[J]. International Journal of Control, 2023, 96(4): 884-899.
- [4] 鲁峰, 黄金泉. 航空发动机部件性能参数融合预测[J]. 航空学报, 2009, 30(10): 1795-1800.
LU Feng, HUANG Jinquan. Engine component performance prognostics based on decision fusion[J]. Acta Aeronautica et Astronautica Sinica, 2009, 30(10): 1795-1800. (in Chinese)
- [5] SANCHEZ L L, VEGA J M, MONTANES J L, et al. Gradient-like minimization methods for signal treatment and aeroengines diagnosis and control ROM methods and LSI future applicability[C]// AIAA Propulsion and Energy 2020 Forum. Virtual Event: AIAA, 2020: 3681-3688.
- [6] 甘晓华, 李伟. 现役航空发动机使用寿命确定和控制方法[J]. 航空工程进展, 2010, 1(2): 103-106.
GAN Xiaohua, LI Wei. A summary of military aero-engine life determination methods[J]. Advances in Aeronautical Science and Engineering, 2010, 1(2): 103-106. (in Chinese)
- [7] 王占学, 宋甫, 周莉, 等. 航空发动机数值缩放技术的研究进展[J]. 推进技术, 2018, 39(7): 1441-1454.
WANG Zhanxue, SONG Fu, ZHOU Li, et al. Research progress in numerical zooming technology of aero-engine[J]. Journal of Propulsion Technology, 2018, 39(7): 1441-1454. (in Chinese)
- [8] KONG C, KI J, KANG M. A new scaling method for component maps of gas turbine using system identification[J]. Journal of Engineering for Gas Turbines and Power, 2003, 125(4): 979-985.
- [9] KONG C, KI J. Study on component map identification from gas turbine performance deck data using hybrid method[J]. International Journal of Turbo and Jet Engines, 2007, 24(3/4): 171-182.
- [10] LI Y G, GHAFIR M F, WANG L, et al. Nonlinear multiple points gas turbine off-design performance adaptation using a genetic algorithm[J]. Journal of Engineering for Gas Turbines and Power, 2011, 133(7): 071701.1-071701.9.
- [11] LI Y G, ABDUL G F, WANG L, et al. Improved multiple point nonlinear genetic algorithm based performance adaptation using least square method[J]. Journal of Engineering for Gas Turbines and Power, 2012, 134(3): 031701.1-031701.10.
- [12] TSOUTSANIS E, MESKIN N, BENAMMAR M, et al. A component map tuning method for performance prediction and diagnostics of gas turbine compressors[J]. Applied Energy, 2014, 135: 572-585.
- [13] TSOUTSANIS E, MESKIN N, BENAMMAR M, et al. Transient gas turbine performance diagnostics through nonlinear adaptation of compressor and turbine maps[J]. Journal of Engineering for Gas Turbines and Power, 2015, 137(9): 091201.1-091201.12.
- [14] KIM S, KIM K, SON C. Adaptation method for overall and local performances of gas turbine engine model[J]. International Journal of Aeronautical and Space Sciences, 2018, 19(1): 250-261.
- [15] YU Y, CHEN L, SUN F, et al. Neural-network based analysis and prediction of a compressor's characteristic performance map[J]. Applied Energy, 2007, 84(1): 48-55.
- [16] GHORBANIAN K, GHOLAMREZAEI M. An artificial neural network approach to compressor performance prediction[J]. Applied Energy, 2009, 86(7/8): 1210-1221.
- [17] 艾璐. 某型涡扇发动机部件特性预测与多变量控制研究[D]. 辽宁大连: 大连理工大学, 2021.
AI Lu. Research on component characteristics prediction and multi-variable control for a turbofan engine[D]. Dalian Liaoning: Dalian University of Technology, 2021. (in Chinese)
- [18] 王昊. 航空发动机剩余使用寿命预测研究[D]. 辽宁大连: 大连理工大学, 2022.
WANG Hao. Research on remaining useful life prediction of aero-engine[D]. Dalian Liaoning: Dalian University of Technology, Dalian, 2022. (in Chinese)
- [19] 史国华. 数据驱动的航空发动机RUL预测模型研究[D].

- 辽宁 大连: 大连理工大学, 2021.
- SHI Guohua. Research on data-driven aero-engine RUL prediction model[D]. Dalian Liaoning: Dalian University of Technology, 2021. (in Chinese)
- [20] 李国军. 基于神经网络的涡轴航空发动机控制系统建模及优化研究[D]. 成都: 电子科技大学, 2019.
- LI Guojun. Research on control system of turboshaft engine based on component method modeling and neural network[D]. Chengdu: University of Electronic Science and Technology of China, 2019. (in Chinese)
- [21] CHAO M A, KULKARNI C, GOEBEL K, et al. Fusing physics-based and deep learning models for prognostics[J]. Reliability Engineering & System Safety, 2022, 217: 107961.1-107961.18.
- [22] 王元, 李秋红, 黄向华. 基于自校正Broyden拟牛顿法的航空发动机模型数值计算[J]. 航空动力学报, 2016, 31(1): 249-256.
- WANG Yuan, LI Qiuhong, HUANG Xianghua. Numerical calculation of aero-engine model based on self-tuning Broyden quasi-Newton method[J]. Journal of Aerospace Power, 2016, 31(1): 249-256. (in Chinese)

(编辑: 张 雪)