



基于不确定性预测的气动力建模与主动采样

张子军 李怀璐 赵彤 王旭 张伟伟

Aerodynamic modeling and active sampling based on uncertainty prediction

ZHANG Zijun, LI Huailu, ZHAO Tong, WANG Xu, ZHANG Weiwei

引用本文:

张子军,李怀璐,赵彤,等. 基于不确定性预测的气动力建模与主动采样[J]. 空气动力学学报, 2025, 43(1): 12–21. DOI: 10.7638/kqdlxxb-2024.0045

ZHANG Zijun, LI Huailu, ZHAO Tong, et al. Aerodynamic modeling and active sampling based on uncertainty prediction[J]. *Acta Aerodynamica Sinica*, 2025, 43(1): 12–21. DOI: 10.7638/kqdlxxb-2024.0045

在线阅读 View online: <https://doi.org/10.7638/kqdlxxb-2024.0045>

您可能感兴趣的其他文章

Articles you may be interested in

证据理论框架下主动学习代理模型驱动的CFD模拟不确定性量化方法

An active learning surrogate model-based uncertainty quantification method for CFD simulation under the framework of evidence theory
空气动力学学报. 2024, 42(9): 86–99 <https://doi.org/10.7638/kqdlxxb-2024.0125>

面向飞行试验认知不确定性的气动数据融合方法

Aerodynamic data fusion method under epistemic uncertainty in flight tests
空气动力学学报. 2024, 42(10): 69–83 <https://doi.org/10.7638/kqdlxxb-2024.0109>

来流变化导致飞行器气动力/热不确定度量化分析

Uncertainty quantification analysis of aerodynamic force and heat for air vehicle due to freestream variation
空气动力学学报. 2024, 42(9): 114–123 <https://doi.org/10.7638/kqdlxxb-2024.0051>

高效率采样的数据关联融合气力建模方法

Data association and fusion aerodynamic modeling method based on efficient sampling
空气动力学学报. 2022, 40(5): 39–49 <https://doi.org/10.7638/kqdlxxb-2021.0425>

基于物理信息神经网络的气动数据融合方法

Aerodynamic data fusion method based on physics-informed neural network
空气动力学学报. 2023, 41(8): 87–96 <https://doi.org/10.7638/kqdlxxb-2023.0060>

基于卷积神经网络的气动热预测方法

CNN-based method for predicting aerodynamic heating
空气动力学学报. 2024, 42(1): 13–25 <https://doi.org/10.7638/kqdlxxb-2023.0072>

地址: 四川省绵阳市二环路南段8号11信箱9分箱
电话: 0816-2463375
Email: kqdlxxb@163.com



关注微信公众号
获得更多资讯信息

文章编号: 0258-1825(2025)01-0012-10

基于不确定性预测的气动力建模与主动采样

张子军¹, 李怀璐^{1, 2}, 赵彤¹, 王旭², 张伟伟^{2,*}

(1. 沈阳飞机设计研究所, 沈阳 110035;

2. 西北工业大学 航空学院, 西安 710072)

摘要: 神经网络方法作为一种高效高精度建模方法, 在多个领域得到广泛应用, 但其自身的“黑箱”特性结合工程问题特有的小样本现象使得模型可靠性不足, 预测结果不确定性大, 严重制约了神经网络模型的使用。为提高神经网络模型的工程适用性, 以飞机纵向非定常气动特性为研究对象, 利用时间卷积神经网络实现了纵向大幅振荡风洞试验的时域非定常气动力建模, 并使用 MC-Dropout 技术对预测结果的不确定性进行评估。在此基础上结合不确定性分析结果, 开展了风洞试验样本主动采样。结果表明, 模型不确定性可作为预测精度的先验评价指标, 模型预测误差与不确定性具有强线性关系, 主动采样策略较随机采样策略可以最多降低 40% 的样本需求, 验证了该方法在提升黑箱模型可信度与降低建模样本需求量方面的有效性。

关键词: 大迎角; 风洞试验; 非定常气动力; 神经网络; 不确定性; 主动采样

中图分类号: V211.5 文献标识码: A doi: 10.7638/kqdlxxb-2024.0045

Aerodynamic modeling and active sampling based on uncertainty prediction

ZHANG Zijun¹, LI Huailu^{1, 2}, ZHAO Tong¹, WANG Xu², ZHANG Weiwei^{2,*}

(1. Shenyang Aircraft Design and Research Institute, Shenyang 110035, China;

2. School of Aeronautics, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: Neural network methods, as an efficient and accurate modeling approach, have been widely used in various fields. However, the "black-box" feature of neural networks, combined with the engineering problem of few-shot phenomenon, leads to insufficient model reliability and high uncertainty in the prediction results, severely limiting the use of neural network models. In order to enhance the engineering applicability of neural network models, this study focuses on the unsteady aerodynamic characteristic and utilizes time convolutional networks (TCN) to model the temporal unsteady aerodynamic forces in large-amplitude oscillatory wind tunnel tests. The MC-Dropout technique is employed to evaluate the uncertainty of prediction results. Based on the uncertainty analysis results, active sampling of wind tunnel test samples is conducted. The results indicate that model uncertainty can be used as a prior evaluation of the prediction accuracy. There is a strong linear relationship between the model prediction error and the uncertainty. The active sampling strategy can reduce the required samples by up to 40% compared to the random sampling strategy. This validates the effectiveness of the present method in improving the trustworthiness of black-box models and reducing the number of modeling samples required.

Keywords: high angle of attack; wind tunnel test; unsteady aerodynamic; neural network; uncertainty; active sampling

收稿日期: 2024-04-16; 修订日期: 2024-06-11; 录用日期: 2024-06-19; 网络出版时间: 2024-08-01

基金项目: 国家自然科学基金(U2441211)

作者简介: 张子军(1966—), 男, 博士, 研究员, 研究方向: 飞行力学, 大迎角气动力. E-mail: zuoeddie@foxmail.com

通信作者: 张伟伟*, 男, 博士, 教授, 研究方向: 流固耦合力学, 智能流体力学. E-mail: aeroelastic@nwpu.edu.cn

引用格式: 张子军, 李怀璐, 赵彤, 等. 基于不确定性预测的气动力建模与主动采样[J]. 空气动力学学报, 2025, 43(1): 12–21.

ZHANG Z J, LI H L, ZHAO T, et al. Aerodynamic modeling and active sampling based on uncertainty prediction[J]. Acta Aerodynamica Sinica, 2025, 43(1): 12–21(in Chinese). doi: 10.7638/kqdlxxb-2024.0045

0 引言

随着研制需求不断提升,飞机的飞行包线范围不断放宽,其飞行迎角范围逐渐从中小迎角向大迎角甚至失速迎角扩展,飞机不可避免地会进入大迎角极限飞行状态。极限飞行状态下,飞机往往面临着大迎角、大侧滑、大旋转速率等情况,作用在飞机表面的流场存在剧烈流动分离现象,气动力出现非对称、迟滞等现象^[1],飞机表面气动力的非定常现象变得尤为突出,严重影响飞行品质与飞行安全^[2]。传统气动力建模方法往往基于小扰动假设,采用动导数模型进行动态非定常气动力刻画,但该方法在具有强流动分离的大迎角下无法适用^[3]。

当下高性能计算、大数据、人工智能等技术快速发展,依托试验、仿真数据开展空气动力学研究,融入第四研究范式(数据驱动)的研究方法催生出了人工智能与空气动力学的结合——智能空气动力学。近年来,关于智能空气动力学的研究越来越多,针对一些传统方法难以解决的问题,数据驱动方法带来了新的曙光。数据驱动非定常气动力建模也受到广泛关注,成为国内外学者研究的重点^[4-6]。Bagherzadeh^[7]针对F-18飞行辨识气动力,利用经验模态分解与神经网络方法相结合,成功获得了六自由度下的大迎角非定常气动力模型。Li等^[8]采用长短期记忆网络(long short-term memory, LSTM, 一种时间循环神经网络)对翼型跨声速非定常气动力开展建模,并与结构运动学方程耦合进行了气动弹性分析,充分证明了神经网络模型的高效建模能力。

正是由于数据驱动方法“端到端”的建模思路弥补了对复杂现象机理认识不清的“技术鸿沟”,其巨大的潜力受到了飞行器设计工程师的关注。陈翔等^[9]利用LSTM模型对飞机纵向大幅振荡数据开展建模,并进行了风洞虚拟飞行试验,展望了其在多自由度耦合建模中的应用潜力。目前来看,尽管数据驱动非定常气动力建模的研究有很多,但基本都处于理论研究阶段,尚未发展出成熟的工程适用的非定常气动力建模方法^[2]。其主要困难主要来源于以下两个方面^[5]:一是领域数据的小样本现象,尽管数值仿真等手段能够产生海量数据,但是其往往只是稀疏状态下的数据,空气动力学建模面临着“大数据小样本”的情况,给神经网络建模带来了数据上的困难。二是神经网络模型的“黑箱”属性,可解释性不足、可靠性差限制了神经网络模型在工程实践中的有效应

用。针对小样本问题,现有大多数研究主要基于数据融合思路^[10]开展工作,相对于单一数据来源建模,数据融合建模在相同泛化性要求下能够有效减少所需样本量^[11]。但是,利用神经网络方法开展数据融合,其模型的“黑箱”属性并没有发生改变,模型的可信性依旧不足。

为了提升神经网络的可靠性与可信性,扩展应用场景,神经网络模型的不确定性研究受到广泛关注^[12]。利用神经网络模型的输出不确定度来评价模型预测或分类的准确性与可信性,已在图像识别、医学图像分类^[13]、剩余寿命预测^[14]等领域应用。实际上,气动模型的不确定性评估在气动弹性、优化设计^[15]和流固耦合系统^[16]设计中占据重要地位,因而开发了许多基于Kriging等方法的技术,用于气动代理模型的输出不确定性分析和主动采样^[17]。Peng等^[18]利用分层Kriging方法进行了小幅振荡下非定常气动力建模与不确定性评估,并展示了基于不确定性的主动采样技术在提升模型泛化能力上的高效表现。其结果表明,将模型不确定性分析引入建模过程可以显著提升黑箱模型建模效率,从而降低数据获取成本,改善训练样本质量。在实际工程应用中,大幅振荡风洞试验数据是定常气动性能评估和确认的主要数据来源,但是参数范围广、试验机构复杂、风洞试验点的获取成本高,造成大迎角非定常风洞试验数据覆盖不全面,难以对其进行有效利用。通过神经网络不确定性技术能够实现对非定常气动力预测不确定度的评估,进而指导风洞试验选点,解决非定常气动力神经网络模型训练样本少、模型置信度低的问题,推进其工程化应用。

本文基于飞行器纵向大幅振荡试验数据,采用时间卷积神经网络进行非定常气动力建模,结合MC-Dropout技术获取非定常气动力模型输出不确定性,评估气动力预测可信度,并基于预测不确定性开展风洞试验主动采样,减小建模样本需求量。相关工作可以为气动神经网络可信度评估、小样本神经网络训练样本采样提供一种可行的解决方案。

1 风洞试验数据

根据单自由度俯仰大幅振荡风洞试验数据进行纵向非定常气动力建模,试验过程中保证飞机舵面不变,飞机强迫运动下迎角变化规律如式(1)所示:

$$\alpha(t) = \alpha_0 - \alpha_m \cos(2\pi ft) \quad (1)$$

其中, α_0 为强迫振荡平衡迎角, α_m 为振幅, f 为振荡频

率。运动过程中的减缩频率计算如式(2)所示:

$$\omega = \frac{2\pi f c}{V} \quad (2)$$

其中: V 为试验风速; c 为飞机参考长度, 在纵向运动中一般为飞机的平均气动弦长。算例共使用 24 组试验数据, $\alpha_0=30^\circ, 40^\circ$, $\alpha_m=20^\circ, 40^\circ$, $\omega=0.02, 0.04, 0.06, 0.08, 0.10, 0.12$, 基本涵盖飞机使用包线的迎角和减缩频率范围。

2 气动力建模与不确定性评估

2.1 时间卷积神经网络

时间卷积神经网络 [19] (temporal convolutional network, TCN) 采用一维卷积方式来处理时间序列建模问题, 相对于 LSTM 等循环神经网络, 它可以避免循环神经网络在训练时出现的梯度爆炸/消失问题, 并容许模型在训练时进行并行计算, 能够有效处理时间序列建模中的时序预测问题。目前 TCN 已经成为时间序列建模的一类主流模型。

对于给定时间序列数据 $[x_0, x_1, \dots, x_T]$, 其对应的序列输出为 $[y_0, y_1, \dots, y_T]$, 时间序列建模要求实现如式(3)所示的函数映射:

$$[y_0, y_1, \dots, y_T] = f([x_0, x_1, \dots, x_T]) \quad (3)$$

时间卷积神经网络通过采用因果卷积方式, 确保网络仅利用当前时刻及其过去时刻的信息进行建模, 从而避免未来信息对当前预测的干扰。同时采用残差连接来加速深度神经网络的训练与收敛, 提升网络性能。其网络框架如图 1 所示。

2.2 MC-Dropout 方法

深度神经网络常常用于对任意非线性函数的拟合, 使其实现从可测量的输入 \mathbf{X} 向可测量的输出 \mathbf{Y} 的映射, 这种映射通常是一种点估计。这种点估计方法无法提供结果的置信区间或者不确定性, 因此降低了模型的可信任性, 制约了神经网络的应用范围。这一局限性推动学者致力于深度神经网络的不确定性研究, 通过量化不确定性, 为评估模型对新样本预测的可靠性提供理论依据。一般认为深度学习中存在偶然不确定性和认知不确定性。偶然不确定性通常被认为是在数据测量或标注中引入的不确定性, 是由数据自身不确定性带来的; 认知不确定性是模型自身预测存在的不确定性, 通常被认为是由训练数据不充分带来的, 反映模型对新输入数据分布的判断, 也被称为模型不确定性, 是所期望建模的不确定性。

为了捕捉模型的认知不确定性, 通常采用的模型

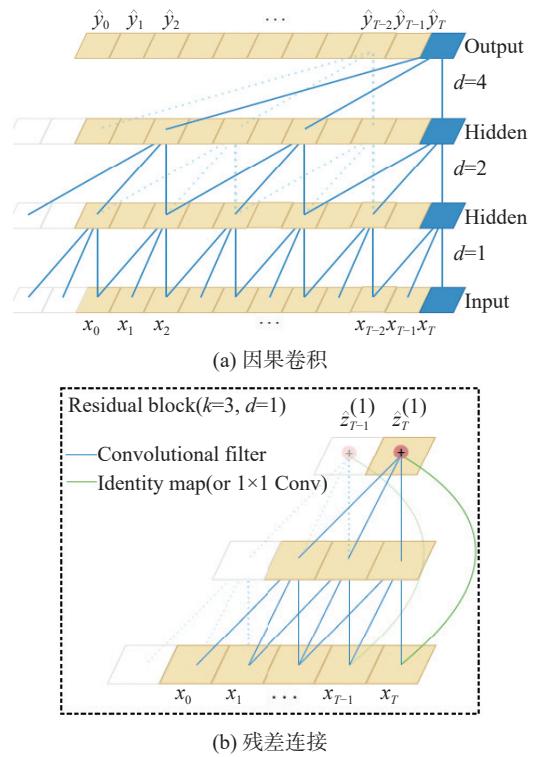


图 1 时间卷积神经网络示意图^[19]

Fig. 1 Schematic diagram of time convolutional networks (TCN)^[19]

架构为贝叶斯神经网络, 但该网络训练成本高, 结构固定。于是, 有学者将目光转向正则化的 Dropout 方法。Dropout 通过在前向传播过程中随机屏蔽(失活)部分神经元, 迫使网络在冗余路径中学习鲁棒特征, 从而有效抑制过拟合现象, 被广泛用于各类深度神经网络中。Gal 和 Ghahramani^[20] 通过数学推导, 对高斯过程与 Dropout 方法之间的理论联系进行分析, 证明应用了 Dropout 技术的神经网络等价于对神经网络训练参数进行变分推断。在训练和推理过程中, 以一定概率从所有参数中抽取部分参数进行训练或推理, 通过蒙特卡罗采样方法获取预测模型的近似不确定性, 形成了 Monte Carlo Dropout (MC-Dropout) 方法。该方法与 Dropout 的唯一区别在于, 其在神经网络推理时依旧保持神经网络的随机失活能力, 使得模型输出呈现随机性, 进而进行模型不确定性的近似估计。

与传统 Dropout 仅在训练阶段使用不同, MC-Dropout 技术在网络模型训练完成后保留其随机失活特性。具体而言, 对于训练所得模型 $f(x|\theta)$, 在网络正向推理时仍启用神经网络随机失活功能。此时, 由于神经网络神经元随机失活, 每次推理的预测结果均不同, 随机采样 N 次后, 得到 N 个预测结果。预测结果的均值 \hat{y} 可以视作模型的最终预测结果, 预测结果的方差 σ^2 作为模型预测的不确定度, 其表达式为:

$$\hat{y} = \frac{1}{N} \sum_{i=1}^N f_i(x|\theta)$$

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N [f_i(x|\theta) - \hat{y}]^2 \quad (4)$$

其中, θ 为神经网络待训练参数。

在本文中, 为保证模型训练收敛, 仅在神经网络模型的最后一层开启 Dropout, 并设置随机失活概率为 0.1。

2.3 非定常气动力模型

通常认为飞机所受的气动力和力矩可以表示为飞机状态变量的泛函:

$$C_i(t) = C_i[Ma(t), h(t), \delta(t), \alpha(\tau), \beta(\tau), p(\tau), q(\tau), r(\tau)], \quad -\infty \leq \tau \leq t \quad (5)$$

式中, C_i 表示气动力与气动力矩, 其状态量分别代表飞机的马赫数、高度、舵偏角、迎角、侧滑角以及三轴角速度的时间历程。该表达式反映了气动力的非定常与非线性情况, 但很难获得其具体表达式。 τ 表示从过去到当前时刻 t 的所有时间序列。

在实际应用中, 可以采用有限运动时刻的状态作

为气动力输入。以固定舵面的大幅俯仰振荡为例, 不考虑横向运动参数对气动力的影响, 则其表达式可简化为:

$$C_i(t) = f[\alpha(\tau), q(\tau)], \quad t - t_0 \leq \tau \leq t \quad (6)$$

其中, C_i 表示纵向气动力与力矩, 其仅与大幅振荡过程中的迎角、俯仰角速度有关, t_0 表示非定常气动力建模时考虑的历史运动时刻边界。将式(6)以 dt 时间离散后, 根据 t_0 可以获得其延迟阶数 n , 得到如式(7)所示的函数表达式:

$$C_i(t) = f[\mathbf{u}(t), \mathbf{u}(t-1), \dots, \mathbf{u}(t-n)] \quad (7)$$

其中, \mathbf{u} 为飞行参数向量, 其表达式为:

$$\mathbf{u}(t) = [\alpha(t), q(t)]^T \quad (8)$$

采用 TCN 对式(7)进行建模, 与传统的序列到序列建模不同, 该建模采用序列到单点方式, 即在输出时只选用 TCN 网络最后一层的最后一个卷积核的所有通道。在通过时间卷积网络完成时序信息提取后, 为增加模型非线性表达能力, 增加全连接层进行非线性变换。模型思路如图 2 所示。

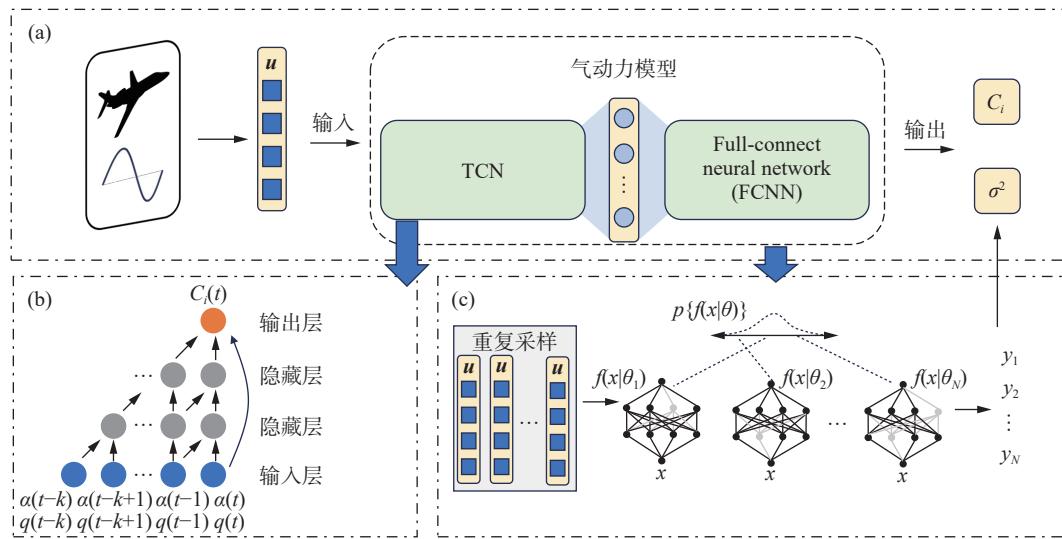


图 2 气动力建模与不确定性评估流程

Fig. 2 Flow chat of the aerodynamic force modeling and uncertainty evaluation

图 2(a)所示为基于时间卷积网络与全连接神经网络串联得到的气动力模型。针对大幅振荡数据提取时序输入, 其在每个 t 时刻的输入为向量, 将时间延迟阶数 k 作为超参数。经测试选取延迟阶数为四阶, 即利用 4 个历史时刻与当前时刻(共 5 个时刻)作为状态输入, 时间离散步长为 0.02 s, 构建多输入单输出模型, 分别对大幅振荡法向力 C_N 与俯仰力矩 C_m 进行建模, 如图 2(b) 所示。在全连接层设置

Dropout 层, 使其神经元随机失活, 从而调整网络结构, 如图 2(c) 所示。在模型推理预测阶段, 开启神经元随机失活, 针对同一输入向量进行 N 次蒙特卡罗采样并正向推理, 可以得到不同的输出结构, 通常将这 N 个结果的均值作为网络的最终输出, 将方差作为网络的不确定度量化指标。一般来说, 不同次的预测, 其输出的结果均值和方差都有所不同, 随着每次预测时的采样次数越来越多, 其结果越来越接近概率

期望。但为了节约计算成本,无法进行无限次采样,这里采样 100 次,利用输出结果的方差作为网络输出的不确定性值。而为了减小神经网络结果波动,同时保证气动力模型气动力预测结果唯一,神经网络的预测值采用未启用 Dropout 失活的神经网络的结果。

2.4 样本主动采样策略

大幅振荡等非定常动态试验因试验成本高,难度大,很难实现全参数空间内的满抽样,因此需要利用有限量的风洞试验数据来实现非定常气动力的准确建模。依据模型预测不确定度开展主动采样技术,可以在保证泛化性的情况下有效减少所需样本量,节约计算与试验成本^[18]。基于飞机使用包线划定的迎角范围与减缩频率范围,通过主动采样策略进行试验数据采样,具体采样流程如图 3 所示。

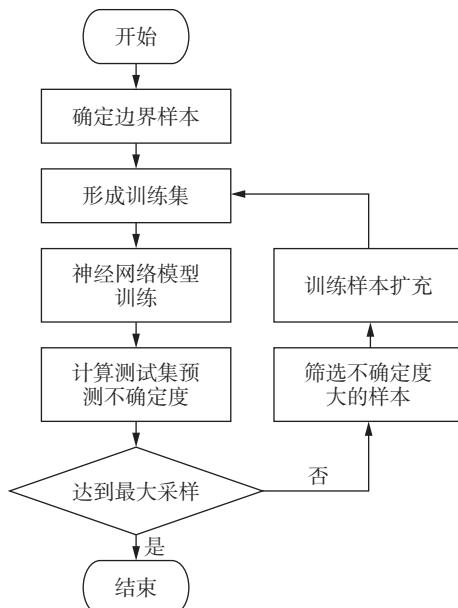


图 3 基于不确定性的主动采样流程

Fig. 3 Flow chart of uncertainty-based active sampling

详细步骤如下:

步骤一,根据关心的迎角与减缩频率范围确定边界样本,形成初始样本集 X_{init} ,初始样本集大小根据边界点选取,用于神经网络模型初始构建。

步骤二,基于确定的初始训练集,搭建非定常气动力神经网络模型,形成初始模型 f_{init} 。

步骤三,利用 MC-Dropout 技术对测试集进行推理并计算测试集预测不确定度,判断当前是否达到设置的最大采样数 M 。

步骤四,扩充训练样本,若样本量未达到最大采样数 M ,则将测试集样本不确定度进行排序,选取不确定度值大的前 m 个样本,将其与上一步得到的训练样本共同组成新的训练集,重新对神经网络模型进

行训练。直到训练集样本数达到预设的最大采样数后停止采样,固定训练模型。

由于模型采用多输入单输出形式分别构建法向力 C_N 与俯仰力矩 C_m ,因此在模型自适应采样时,分别根据法向力与俯仰力矩预测不确定性,进行主动采样,对比两种采样方式对样本选取的影响,观察采样的一致性。

3 非定常气动建模结果与试验对比

神经网络模型训练损失函数采用均方误差(mean squared error, MSE)损失,并利用 L2 损失进行模型正则化,表达式如式(9)所示:

$$L = \frac{1}{l} \sum_{i=1}^l (y_i - \hat{y}_i)^2 + \lambda \|\mathbf{w}\|^2 \quad (9)$$

其中: l 表示拟合样本点数; y_i 与 \hat{y}_i 分别表示试验值与预测值; \mathbf{w} 表示需要训练的网络模型参数; λ 为超参数,决定模型的 L2 正则化损失权重,本文取 1×10^{-5} 。神经网络采用 PyTorch 开源框架搭建,使用 AdamW 优化器进行网络权重寻优,学习率设置为 1×10^{-2} ,并采用指数学习率衰减律。根据所提供的试验数据选取 8 个边界样本,见表 1。

表 1 边界样本点
Table 1 Boundary sampling points

| | 平衡迎角 | 振幅 | 减缩频率 |
|-----------|------|--------|------------|
| train 1~4 | 30 | 20, 40 | 0.02, 0.12 |
| train 5~8 | 40 | 20, 40 | 0.02, 0.12 |

以边界样本点作为训练集,其余样本作为测试集,将训练集随机划分 10% 作为验证集,分别以法向力和俯仰力矩作为训练标签,进行模型训练。神经网络结构超参数设置如表 2 所示,其中,TCN 表示气动力神经网络模型的时间卷积模块,提供时序感知能力;FCNN 表示气动力神经网络模型的全连接模块,增强模型的非线性表达。气动力神经网络模型框架见图 2(a)。

表 2 神经网络超参数设置
Table 2 Hyperparameter settings in neural networks

| | TCN | FCNN | 激活函数 | 延迟阶数 |
|-----|---------------------|-------------|------|------|
| 超参数 | [2, 32, 32, 32, 32] | [32, 32, 1] | Tanh | 4 |

训练完毕后对测试集所有样本进行预测与不确定度评估,采用预测相对误差作为精度评价指标,公

式如式(10)所示:

$$e = \frac{\|y - \hat{y}\|_2}{\|y\|_2} \quad (10)$$

不确定度采用每个样本输出的所有值的标准差平均值 σ 进行评估, 以不确定度为横轴, 相对误差为纵轴, 绘制测试集所有样本散点图, 如图4所示。

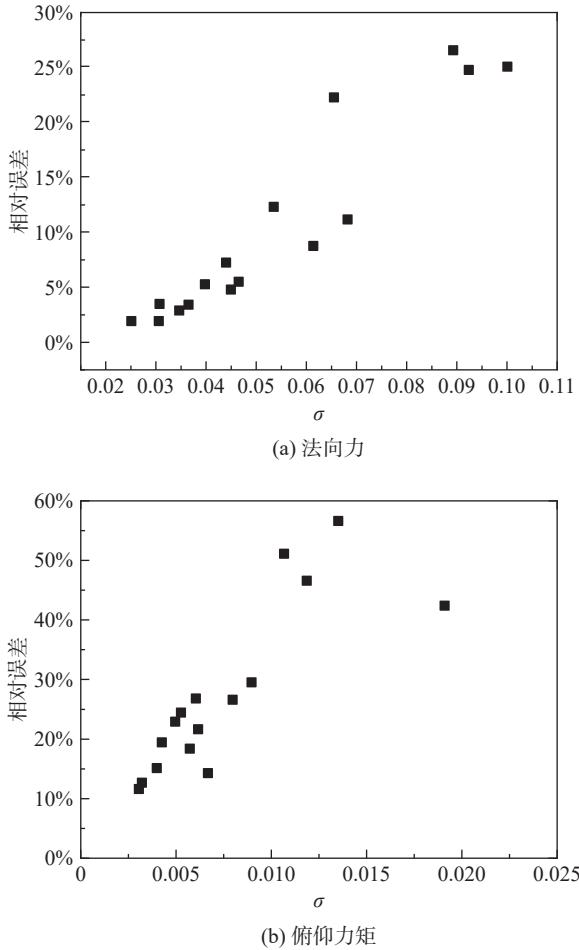


图4 预测相对误差与不确定度关系

Fig. 4 Relationship between predicted relative error and uncertainty

由图4可以观察到, 法向力预测结果的线性相关系数为0.94, 俯仰力矩预测结果的线性相关系数为0.83, 可以认为预测结果相对误差与不确定度间存在很强的线性正相关关系。这一结果表明, 在未知试验值真值的情况下, 可以将预测结果的方差或标准差作为不确定度评估, 从而先验地得到模型预测结果的可靠性与预测精度。同时, 基于模型不确定度进行主动采样, 能够将预测精度低、样本空间内呈现外插特性的样本点纳入网络的训练集中, 有效提高模型的泛化能力。绘制样本不确定性分布热图如图5所示。

由图5可知, 基于法向力与俯仰力矩预测不确定度绘制的热图具有较高的相似性, 证明两个模型对样

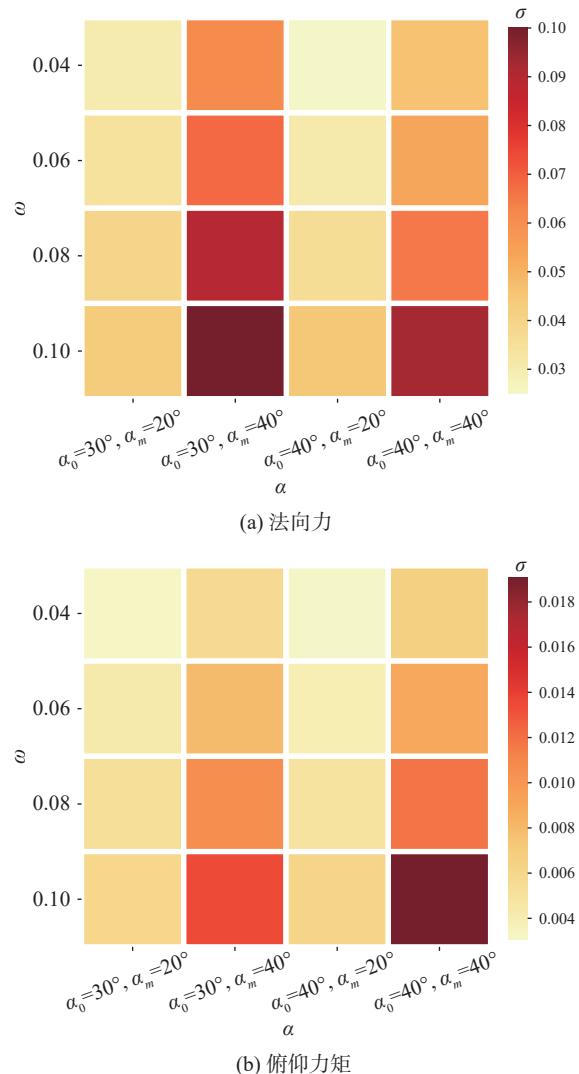


图5 模型预测不确定度分布热图

Fig. 5 Heatmap of uncertainty distributions from the model prediction

本的不确定性评估结果一致。减缩频率表征了飞机运动角速度的快慢, 常常作为飞机非定常程度的表征参数。在图5中, 从减缩频率上看, 随着减缩频率的增加, 模型预测不确定性增加, 模型预测的不确定性与非定常效应呈正相关, 符合强非定常气动力学建模的物理事实。从迎角上看, 大平衡迎角大振幅下的气动力预测不确定性高, 在大迎角区域往往飞机的非线性程度高, 在同一减缩频率下的迟滞环变化情况更复杂, 并不会呈现小迎角下的饱满迟滞环, 而是出现交叉等强非线性现象, 严重加大了建模难度。总的来说, 不确定性热图分析结果与物理机理相同证明了不确定性评估的合理性。

为了验证主动采样方法在减少训练样本上的有效性, 每次从测试集中抽取4个样本加入训练集进行训练。主动采样方法依据不确定性大小选取最大的

4个样本,随机采样方法则从测试集中随机选取4个样本,并保证随机性。随机采样方法重复15次,分别进行模型训练,而后对测试集中剩余的所有样本进行预测,并计算测试样本相对误差的平均值。

如图6所示,随着训练样本数的增加,测试集预测相对误差降低,模型的泛化能力逐步增强。对比主动采样方法与随机采样,随机采样下模型的泛化能力受训练样本选取影响较大,预测相对误差分布分散度大,模型可信度低;且随着样本的增加,模型泛化性提升变弱,尤其是当训练样本从16个变为20个时,预测损失均值降低不明显。而主动采样方法有效提高了模型的泛化性,预测相对误差显著降低,同时可以看到采用主动采样方法得到的模型,其预测损失均低于随机采样方法。通过15次随机采样,基本可以认为主动采样方法抽取的样本是在当前采样数限制下的最优采样策略。

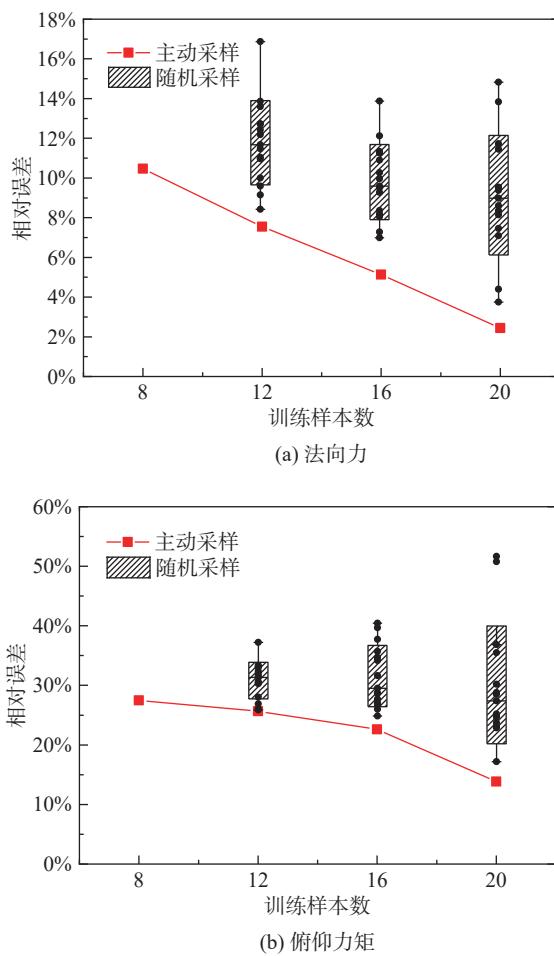


图 6 测试集泛化误差随训练样本数变化

Fig. 6 Variation of the generalization error with the number of training samples in test cases

为了对比TCN与LSTM之间的精度差异,本文对比了两者在每次主动采样后的神经网络测试集泛

化相对误差,结果如表3、表4所示。

以法向力和俯仰力矩为标签进行建模、不确定度评估、采样后,最终剩余的4个测试算例一致,并且为图5中不确定度最小的4个算例,这也充分佐证了模型不确定性分析的合理性。样本主动采样方法能够顺利确定出当前神经网络难以建模的数据样本,有效地指导了样本的采样。为了验证采样前后模型对特定样本精度的提升效果,对比了case1($\alpha_0=30^\circ$, $\alpha_m=20^\circ$, $\omega=0.04$)和case2($\alpha_0=40^\circ$, $\alpha_m=20^\circ$, $\omega=0.06$)两个算例的相对误差,结果见表5。

表3 LSTM 和 TCN 的法向力 C_N 预测相对误差对比

Table 3 Comparison of relative errors in the normal force C_N by LSTM and TCN

| | 训练样本数 | | | |
|------|--------|--------|-------|-------|
| | 8 | 12 | 16 | 20 |
| LSTM | 14.12% | 10.36% | 5.02% | 3.23% |
| TCN | 10.46% | 7.55% | 5.13% | 2.44% |

表4 LSTM 和 TCN 的俯仰力矩 C_m 预测相对误差对比

Table 4 Comparison of relative errors in the pitching moment C_m by LSTM and TCN

| | 训练样本数 | | | |
|------|--------|--------|--------|--------|
| | 8 | 12 | 16 | 20 |
| LSTM | 29.86% | 25.20% | 20.41% | 16.58% |
| TCN | 27.50% | 25.68% | 22.61% | 13.83% |

表5 测试样本预测相对误差

Table 5 Relative prediction errors of test samples

| | C_N | | C_m | |
|--------|-------|-------|--------|--------|
| | 采样前 | 采样后 | 采样前 | 采样后 |
| case 1 | 1.92% | 1.83% | 12.64% | 10.96% |
| case 2 | 3.49% | 2.50% | 15.12% | 10.09% |

从表5可以看到,随着训练样本的补充,神经网络对于新样本的预测相对误差变低,模型的泛化性得到了充分提升,相对误差最大可以降低33.27%。采样后的模型预测结果与风洞试验对比如图7所示。

从法向力看,模型预测结果和风洞试验结果吻合度高,在时域绘制出模型的置信区间(confidence interval, CI),即 $[\hat{y} - 1.96\sigma, \hat{y} + 1.96\sigma]$,可以看到大多数的试验点都落在了该区间之内。从俯仰力矩看,力矩迟滞环大小与形状基本与风洞试验状态相同,由于力矩非线性强的特点使得模型预测结果较法向力偏大,且有部分点落在区间之外,不确定区间并不能完全包含所有试验点,这进一步说明了非定常气动力的强不确定性。

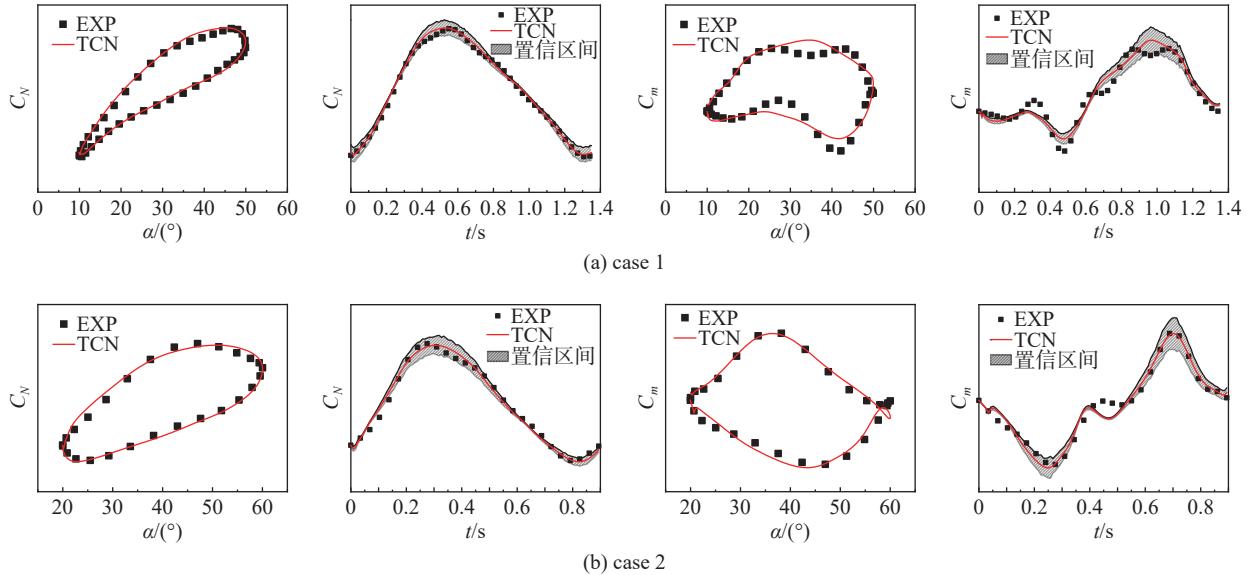


图 7 不同测试算例的神经网络模型预测结果与风洞试验结果对比

Fig. 7 Comparison of neural network model predictions with wind tunnel test results across different test cases

为了对比模型在不同平衡迎角下的外插性能, 对平衡迎角 45° 下的大幅振荡结果进行预测。由于在该平衡迎角下试验时, 飞机模型升降舵下偏 15° , 因此需要考虑舵效增量的影响, 利用静态测力得到的舵效增量与神经网络输出结果进行叠加来得到气动力。考虑到法向力系数受升降舵偏转影响小, 升降舵变化带来的非定常气动力改变可以用静态舵效增量来修正, 因此这里只对法向力系数外插进行分析。对 $\alpha_0=45^\circ$, $\alpha_m=20^\circ, 40^\circ$, $\omega=0.02, 0.04, 0.06, 0.08, 0.10, 0.12$, 共 12 组样本进行法向力预测, 预测不确定度与相对误差散点图如图 8 所示。

从图 8 中可以看到, 预测不确定度与相对误差依旧呈现强线性关系, 证明样本主动采样方法在外插算例下同样适用。新样本预测误差随训练集样本增加的变化如图 9 所示, 结果表明, 随着样本量的增加,

模型外插泛化能力逐步提高, 采用主动采样技术可以稳定地降低模型的预测误差, 有效减少对建模样本数的需求量。以泛化误差 8.5% 为指标, 主动采样方法相较随机采样方法, 其样本量可以从 20 个降低到 12 个, 达到 40% 的样本缩减能力。

图 10 展示了 $\alpha_m=40^\circ$, $\omega=0.08$ 外插样本下的模型预测情况, 可以看到尽管模型平衡迎角发生变化, 迎角范围外插 5° , 模型预测精度依旧较高, 且置信区间包含了大多数试验点。

为了验证模型的强外插能力, 将所得到的模型应用于飞机缩比模型试飞数据中, 针对类眼镜蛇机动过程开展法向力预测, 首先对模飞数据开展参数辨识工作, 得到飞行过程中的法向力系数。飞行过程中的迎角与侧滑变化如图 11(a)所示, 可以看到: 在 5.5 s 之前, 飞机基本处于对称拉起阶段, 飞机处于小侧滑状

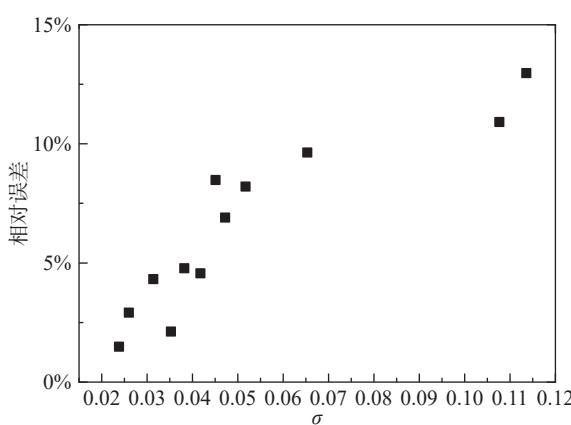


图 8 外插算例相对误差与不确定度关系

Fig. 8 Relationship between relative error and uncertainty in extrapolation cases

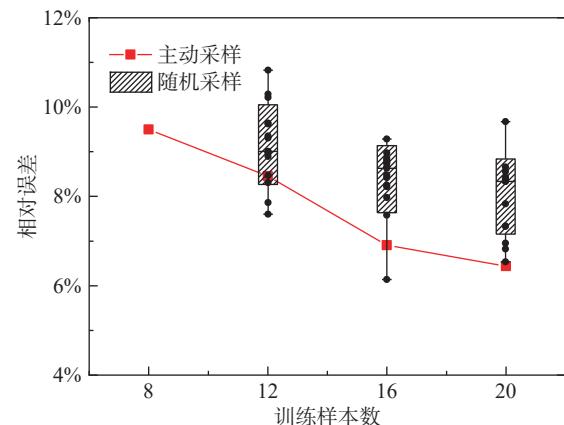


图 9 外插算例泛化误差随训练样本数变化

Fig. 9 Variation of the generalization error with the number of training samples in extrapolation cases

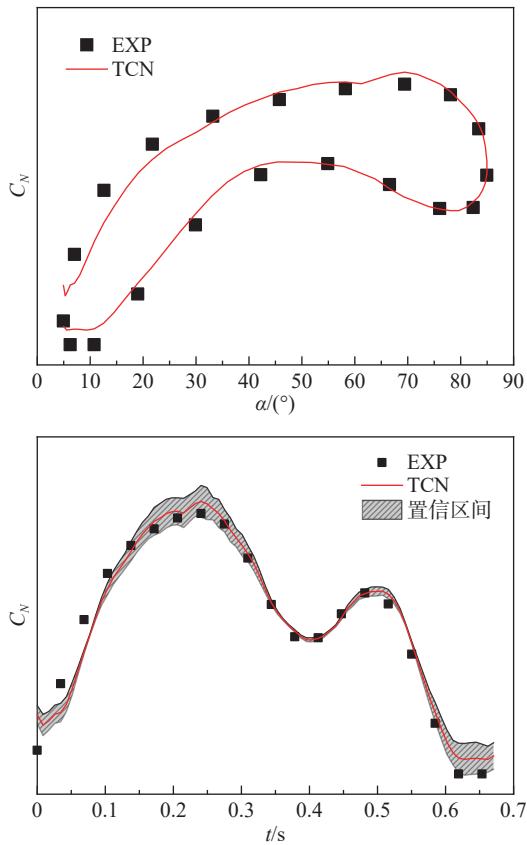


图 10 外插算例法向力预测结果 ($\alpha_m = 40^\circ$ 、 $\omega = 0.08$)

Fig. 10 Predicted normal force in extrapolation cases
with $\alpha_m = 40^\circ$ and $\omega = 0.08$

态;在 5.5 s 之后,由于出现航向偏离,产生了较大的侧滑,飞机整体经历了类眼镜蛇的先抬头后低头的过程。神经网络训练时,仅使用侧滑为零时的大幅振荡数据进行建模,因此在缩比模飞气动预测时也未考虑侧滑影响。在该机动过程中飞机为受控状态,舵面变化对气动力有影响,由于在神经网络建模时未考虑舵面效应,这里通过采用舵效增量的方式将控制面带来的气动力与神经网络模型输出的气动力叠加,如式(11)所示:

$$\begin{aligned} C_i &= f(\mathbf{u}(t), \mathbf{u}(t-1), \dots, \mathbf{u}(t-n)) + \\ &\Delta C_i(\alpha(t), \delta(t)) \mathbf{u}(t) \\ &= [\alpha(t), q(t)]^T \end{aligned} \quad (11)$$

式中 $\Delta C_i(\alpha(t), \delta(t))$ 表示由舵面偏转带来的气动力增量。

为展示非定常气动力模型优势,本文与基于大迎角风洞测力数据搭建的风洞数据集模型进行对比,结果如图 11 所示。该数据集模型将大迎角静态测力数据、旋转天平数据与强迫振荡试验数据进行组合,是目前飞行器大迎角气动数据集构建的主要手段^[2, 21]。

从图 11 可以看到,在小侧滑角(β)、较小迎角时,

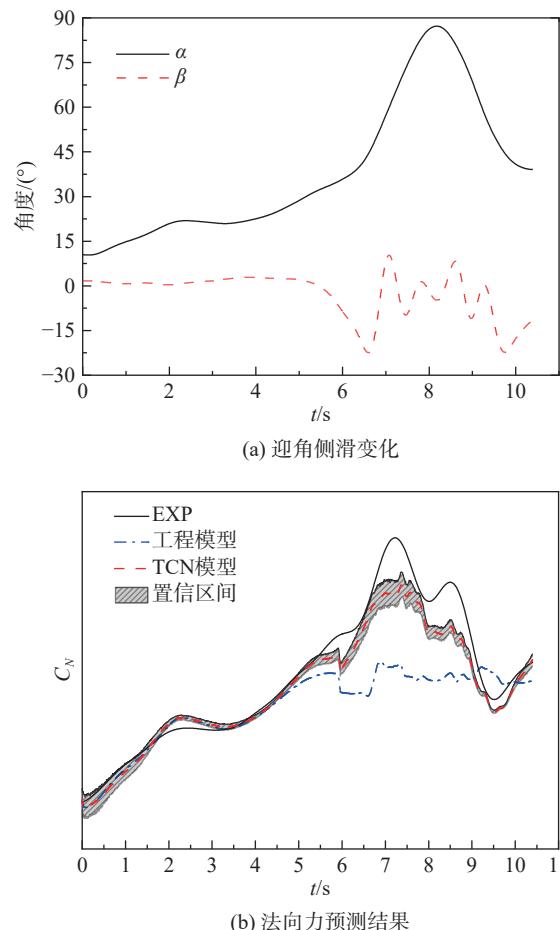


图 11 缩比模型试飞的迎角侧滑变化与对应的法向力预测结果

Fig. 11 Angles of attach and sideslip variations of the scaled model flight and the corresponding prediction result of the normal force

数据集模型输出结果与神经网络模型输出结果基本重合,证明经大幅振荡试验所构建的非定常气动力模型在小旋转速率下能够实现对准定常气动力的高精度预测。随着迎角增加,在还未诱导出大侧滑之前,对于数据集模型输出结果而言,较辨识结果开始产生偏差,但神经网络模型依旧逼近辨识结果。当侧滑产生后,两个模型的预测精度都显著下降,但数据集模型数值与变化趋势都与辨识结果有较大出入。神经网络模型预测结果数值与辨识气动力更为接近,气动力趋势基本相同,因此其偏差更多是由于没有考虑大迎角大侧滑测量时带来的误差,这展示了神经网络模型对强非定常气动力的高精度建模能力与强泛化性。图 11(b)中还绘制出了神经网络模型输出置信区间,可以看到,在大侧滑区域,辨识值基本都落在区间之外。这主要是由于建模输入未考虑侧滑角,模型构建输入信息不全导致模型不确定性刻画失真,因此神经网络输出不确定性的评估并不能仅从数据角度出发来刻画,还应该从物理信息、不确定性传递等多方面综合评估。

4 结 论

针对非定常气动力建模问题, 基于大幅振荡风洞试验数据, 结合时间卷积神经网络与不确定性评估方法, 就非定常气动力建模与动态风洞试验主动采样问题进行了研究, 主要结论如下:

1) 时间卷积神经网络作为一种考虑时序输入的神经网络模型, 具有与传统LSTM等时序建模模型相同的效果, 能够实现对非定常气动力的高精度建模, 并具备较强的泛化能力。

2) MC-Dropout技术从神经网络预测不确定性角度出发, 其模型输出不确定度与模型预测误差高度正相关, 可以依靠不确定度对模型结果进行判断, 一定程度上提高了神经网络“黑箱”模型的可信度。

3) 基于不确定性评估进行主动采样能够指导模型在小样本空间下的样本选取, 有效降低建模所需样本量, 在相同精度指标下较随机采样策略最多可以降低40%的样本量。

尽管本文提供了一种基于数据驱动的不确定性评估思路, 但不确定性的影响因素众多, 未来的工作需要进一步考虑试验测量不确定性、气动自身不确定性等不同来源, 开展不确定性下的模型验证与确认工作, 使其结果能够更好地指导工程设计。

参 考 文 献:

- [1] 张子军, 赵彤, 孙烨, 等. 飞机大迎角飞行问题研究综述[J]. 航空工程进展, 2022, 13(3): 74–85.
ZHANG Z J, ZHAO T, SUN Y, et al. Review of the study on high-angle-of-attack flight problems of aircraft[J]. Advances in Aeronautical Science and Engineering, 2022, 13(3): 74–85(in Chinese).
- [2] 王海峰, 展京霞, 陈科, 等. 战斗机大迎角气动特性研究技术的发展与应用[J]. 空气动力学学报, 2022, 40(1): 1–25.
WANG H F, ZHAN J X, CHEN K, et al. Development and application of aerodynamic research technologies for fighters at high angle of attack[J]. Acta Aerodynamica Sinica, 2022, 40(1): 1–25(in Chinese).
doi: 10.7638/kqdlxxb-2021.0306
- [3] 汪清, 钱伟祺, 丁娣. 飞机大迎角非定常气动力建模研究进展[J]. 航空学报, 2016, 37(8): 2331–2347.
WANG Q, QIAN W Q, DING D. A review of unsteady aerodynamic modeling of aircrafts at high angles of attack[J]. Acta Aeronautica et Astronautica Sinica, 2016, 37(8): 2331–2347(in Chinese).
doi: 10.7527/S1000-6893.2016.0072
- [4] KOU J Q, ZHANG W W. Data-driven modeling for unsteady aerodynamics and aeroelasticity[J]. Progress in Aerospace Sciences, 2021, 125: 100725.
doi: 10.1016/j.paerosci.2021.100725
- [5] 唐志共, 朱林阳, 向星皓, 等. 智能空气动力学若干研究进展及展望[J]. 空气动力学学报, 2023, 41(7): 1–35.
TANG Z G, ZHU L Y, XIANG X H, et al. Some research progress and prospect of intelligent aerodynamics[J]. Acta Aerodynamica Sinica, 2023, 41(7): 1–35(in Chinese).
doi: 10.7638/kqdlxxb-2023.0128
- [6] 张伟伟, 寇家庆, 刘溢浪. 智能赋能流体力学展望[J]. 航空学报, 2021, 42(4): 524689.
ZHANG W W, KOU J Q, LIU Y L. Prospect of artificial intelligence empowered fluid mechanics[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(4): 524689(in Chinese).
doi: 10.7527/S1000-6893.2020.24689
- [7] BAGHERZADEH S A. Nonlinear aircraft system identification using artificial neural networks enhanced by empirical mode decomposition[J]. Aerospace Science and Technology, 2018, 75: 155–171.
doi: 10.1016/j.ast.2018.01.004
- [8] LI K, KOU J Q, ZHANG W W. Deep neural network for unsteady aerodynamic and aeroelastic modeling across multiple Mach numbers[J]. Nonlinear Dynamics, 2019, 96(3): 2157–2177.
doi: 10.1007/s11071-019-04915-9
- [9] 陈翔, 展京霞, 陈科, 等. 非定常气动力建模研究与虚拟飞行试验验证[J]. 实验流体力学, 2022, 36(3): 65–72.
CHEN X, ZHAN J X, CHEN K, et al. Unsteady aerodynamic modeling research and virtual flight test verification[J]. Journal of Experiments in Fluid Mechanics, 2022, 36(3): 65–72(in Chinese).
doi: 10.11729/syldlx20210143
- [10] 何开锋, 钱伟祺, 汪清, 等. 数据融合技术在空气动力学研究中的应用[J]. 空气动力学学报, 2014, 32(6): 777–782.
HE K F, QIAN W Q, WANG Q, et al. Application of data fusion technique in aerodynamics studies[J]. Acta Aerodynamica Sinica, 2014, 32(6): 777–782(in Chinese).
doi: 10.7638/kqdlxxb-2014.0072
- [11] WANG X, KOU J Q, ZHANG W W, et al. Incorporating physical models for dynamic stall prediction based on machine learning[J]. AIAA Journal, 2022, 60(7): 4428–4439.
doi: 10.2514/1.J061210
- [12] GAWLIKOWSKI J, TASSI C R N, ALI M, et al. A survey of uncertainty in deep neural networks[J]. Artificial Intelligence Review, 2023, 56(1): 1513–1589.
doi: 10.1007/s10462-023-10562-9
- [13] RAGHU M, BLUMER K, SAYRES R, et al. Direct uncertainty prediction for medical second opinions[C]// 36th International Conference on Machine Learning, PMLR 97: 5281–5290, 2019.
- [14] 季文强. 基于深度学习和不确定性量化的数据驱动剩余寿命预测方法研究[D]. 合肥: 中国科学技术大学, 2020.
JI W Q. Research on data-driven remaining useful life prediction method based on deep learning and uncertainty quantification[D]. Hefei: University of Science and Technology of China, 2020.
- [15] 韩忠华. Kriging模型及代理优化算法研究进展[J]. 航空学报, 2016, 37(11): 3197–3225.
HAN Z H. Kriging surrogate model and its application to design optimization: A review of recent progress[J]. Acta Aeronautica et Astronautica Sinica, 2016, 37(11): 3197–3225(in Chinese).
doi: 10.7527/S1000-6893.2016.0083
- [16] DAI Y T, YANG C. Methods and advances in the study of aeroelasticity with uncertainties[J]. Chinese Journal of Aeronautics, 2014, 27(3): 461–474.
doi: 10.1016/j.cja.2014.04.016
- [17] SHIMOYAMA K, KAWAI S. A kriging-based dynamic adaptive sampling method for uncertainty quantification[J]. Transactions of the Japan Society for Aeronautical and Space Sciences, 2019, 62(3): 137–150.
doi: 10.2322/tjsass.62.137
- [18] PENG X H, KOU J Q, ZHANG W W. Multi-fidelity nonlinear unsteady aerodynamic modeling and uncertainty estimation based on Hierarchical Kriging[J]. Applied Mathematical Modelling, 2023, 122: 1–21.
doi: 10.1016/j.apm.2023.05.031
- [19] BAI S J, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling: arXiv 1803.01271 [EB/OL]. 2018.
doi: 10.48550/arXiv.1803.01271
- [20] GAL Y, GHAHRAMANI Z. Dropout as a Bayesian approximation: Representing model uncertainty in deep learning[J]. 33rd International Conference on Machine Learning, 2016.
- [21] 涂良辉, 江积祥, 袁建平. 某型高级教练机尾旋特性预测研究[J]. 飞行力学, 2011, 29(5): 1–4.
TU L H, JIANG J X, YUAN J P. Prediction of spin characteristic for a certain advanced trainer[J]. Flight Dynamics, 2011, 29(5): 1–4(in Chinese).