

DOI:10.11918/202410071

面向战斗机尾旋仿真的增量叠加神经网络模型

赵彤^{1,3}, 李怀璐^{2,3}, 王旭², 张伟伟²

(1. 南京航空航天大学 航空学院, 南京 210016; 2. 西北工业大学 航空学院, 西安 710072;
3. 中国航空工业集团公司 沈阳飞机设计研究所, 沈阳 110035)

摘要: 为提升战斗机尾旋过程中的气动力预测能力, 改善稳定尾旋运动的仿真精度, 结合深度神经网络强大的函数拟合能力, 提出了一种新型神经网络模型, 实现对尾旋非定常气动力的准确建模, 并通过尾旋耦合仿真开展高精度的尾旋姿态预测。以战斗机失速尾旋下的气动特性为研究对象, 首先, 利用神经网络模型对立式风洞试验中的非定常气动力矩进行高精度建模。其次, 基于神经网络模型特点与传统气动数据库构造方式, 提出了增量叠加神经网络模型, 将气动数据库的舵效增量引入神经网络, 实现了变舵面下的尾旋非定常气动力矩的高精度建模。最后, 将得到模型与尾旋运动学方程耦合, 开展稳定尾旋仿真与尾旋特征预测。研究结果表明, 所提出的模型能够很好地刻画不同舵面组合下尾旋气动力变化, 与传统气动数据库相比气动力矩预测误差降低 77%, 利用该模型能够实现对飞机稳定尾旋特性的高精度预测, 其中稳定尾旋周期预测相对误差降低 34%, 验证了机器学习方法在飞机复杂动力学仿真中的工程有效性。

关键词: 立式风洞; 尾旋仿真; 神经网络; 飞行动力学; 非定常气动力

中图分类号: V211 **文献标志码:** A **文章编号:** 0367-6234(2025)04-0010-11

Incremental superposition neural network model for fighter jet spin simulation

ZHAO Tong^{1,3}, LI Huailu^{2,3}, WANG Xu², ZHANG Weiwei²

(1. College of Aerospace Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;
2. School of Aeronautics, Northwestern Polytechnical University, Xi'an 710072, China; 3. Shenyang Aircraft
Design and Research Institute, Aviation Industry Corporation of China, Ltd., Shenyang 110035, China)

Abstract: To improve the aerodynamic prediction capability during fighter jet spin maneuvers and enhance the simulation accuracy of stable spin motion, a novel neural network model is proposed, leveraging the powerful function approximation capabilities of deep neural networks. This model enables accurate modeling of the unsteady aerodynamic forces during spin maneuvers and achieves high-precision spin attitude prediction through spin-coupled simulation. Focusing on the aerodynamic characteristics of fighter jets in post-stall spin, this study first utilizes the neural network model to achieve high-precision modeling of the unsteady aerodynamic moments observed in vertical wind tunnel tests. Secondly, based on the features of the neural network model and traditional aerodynamic database construction methods, an incremental superposition neural network model is proposed. This model incorporates control surface deflection increments from aerodynamic databases into the neural network, enabling high-precision modeling of unsteady aerodynamic moments under varying control surface configurations. Finally, the resulting model is then coupled with the spin motion equations to conduct stable spin simulations and spin characteristic predictions. The research results indicate that the proposed model effectively captures variations in spin aerodynamics under different control surface combinations. Compared to traditional aerodynamic databases, the aerodynamic moment prediction error is reduced by 77%. Using this model enables high-precision prediction of stable spin characteristics, with the relative error in stable spin period prediction reduced by 34%, demonstrating the engineering effectiveness of machine learning methods in simulating complex aircraft dynamics.

Keywords: vertical wind tunnel; spin simulation; neural network; flight dynamics; unsteady aerodynamics

尾旋是飞机飞行中最复杂和最危险的飞行状态之一, 世界航空史上战机大迎角失事约 90% 都是因为进入尾旋造成的^[1], 直接威胁到飞行员的生命安

全。飞机的尾旋呈现多样性, 飞机在尾旋时的姿态特点、操纵性与正常飞行状态完全不同, 针对飞机尾旋的相关研究是非常必要的^[2]。尾旋特性分析首

收稿日期: 2024-10-30; 录用日期: 2024-12-19; 网络首发日期: 2025-03-03

网络首发地址: <https://link.cnki.net/urlid/23.1235.T.20250228.1753.002>

基金项目: 国家自然科学基金(U2441211)

作者简介: 赵彤(1984—), 男, 硕士, 高级工程师; 张伟伟(1979—), 男, 教授, 博士生导师

通信作者: 张伟伟, aeroelastic@nwpu.edu.cn

先要关注尾旋过程中作用于飞机上的气动力,飞机在尾旋过程中一直处于复杂的旋转流场中,气动力具有强耦合非线性特性,因此飞机大迎角及旋转流场下的气动力矩特性的高精度预测是首先需要被考虑的^[3]。尾旋气动力既涉及大迎角分离^[4]、又涉及旋转流场,与常规基于小扰动假设构建的小迎角线性模型有极大不同。

为了表征这种复杂流动下的气动力,工程实践中最常用的是被称为混合模型(blending method)^[5-6]的气动力模型构建方法,因此该方法将大迎角、尾旋过程中的强非线性非定常气动力分解为静态气动力与动态气动力的形式^[7]。静态气动力多为采用基本量叠加舵效增量的方式,可以通过静态大迎角测量获取;动态气动力分为两部分,一部分为飞机绕体轴系的振荡气动力,另一部分为飞机绕速度矢量旋转带来的附加气动力,分别由大迎角动导数与旋转天平试验提供。动态气动力的分解具有很多方式^[8],不同的分解方式对尾旋气动力的预测不同,甚至会影响到尾旋过程的进入与改出特性^[9]。尽管该分解方法在国内外较多飞机大迎角、尾旋气动力数据库构建上得到应用^[10-11],但是其动导数试验对非定常气动力的描述完全基于小扰动假设,对尾旋过程中的扰动量大的强非定常效应表述精度不足,无法从小幅强迫振荡试验中获取高精度非定常数据,严重制约了尾旋气动力的预测精度。

大幅振荡、立式风洞、飞行试验等动态试验可以以特殊的手段复现飞机飞行过程中的强非定常效应,目前有许多采用大幅振荡数据开展非定常气动力建模的方法^[12-13]。尾旋过程中的旋转流场与大幅振荡时的流场形态差异巨大,物理机理不同,非定常气动力效应不一致,无法作为气动力建模数据。立式风洞作为研究飞机尾旋运动的一种特殊风洞,在试验中能根据所获得的运动参数直接评判飞机的尾旋特性,并得到尾旋的改出效果,但是该试验无法直接获得定量的气动力,需要通过飞行动力学方程辨识作用于飞机上的全局力与力矩^[14]。飞行试验也需要气动参数辨识获取飞行过程中的气动力,通过尾旋动态试验,获取尾旋过程中的气动力,直接开展气动力建模是目前大家所广泛关注的方向^[15-16]。

随着人工智能技术的快速发展,依托数据驱动方法开展空气动力学研究的工作受到广泛关注^[17-18]。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”,在面对一些传统

方法难以解决的问题时体现了显著的优势,受到了大量科学家与飞行器设计师的广泛关注与研究^[19-20]。Bagherzadeh^[21]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结合,成功获得了六自由度下的大迎角非定常气动力模型。陈翔等^[22]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中的应用潜力。Lyu 等^[23]利用极限学习机进行非定常气动力建模,并基于得到的气动力模型开展眼睛蛇机动过程的飞行控制律设计,证明了人工智能方法在飞行控制与仿真中的潜力。神经网络方法的发展,使得气动力模型建模精度越来越高,泛化性越来越好,利用神经网络开展高精度尾旋气动力建模,进一步实现对飞机尾旋过程的仿真是开展飞机尾旋特性研究的一大重要手段。

综上所述,现有大迎角气动数据库无法对尾旋过程中的气动力进行准确预测,神经网络模型因其良好的函数拟合能力,被广泛应用于非定常气动力建模领域。为准确预测稳定尾旋气动力变化,实现尾旋的高精度仿真预测,本文提出了增量叠加神经网络模型,将黑箱神经网络模型与气动数据库组合,以为飞机尾旋进入与改出研究提供指导,为实现高精度稳定尾旋仿真提供可行的技术路线。

1 飞机尾旋试验与仿真

1.1 立式风洞尾旋试验

飞机模型的尾旋与改出试验主要在立式风洞这一特种风洞上开展,其主要目的是从宏观上判定飞机在失速后发生尾旋的可能性、飞机在螺旋运动中尾旋的模态以及飞机自身是否具备尾旋改出能力^[24]。在试验前预偏飞机模型的舵面,迫使飞机能够进入尾旋,开启风洞后,由投手按照预设角度将飞机模型投入试验段,待飞机模型稳定旋转后进行测量,在稳定旋转 5 圈后,尝试采用无线电操控飞机舵面进行飞机尾旋改出测试。

立式风洞采用吊挂支撑模型法进行尾旋研究,飞机模型被两根绳索牵引悬挂在风洞试验段,因此需要采用立体视觉测量与陀螺仪传感器测量飞机模型在尾旋过程中的姿态变化与角速度变化。由于立式风洞的风向始终保持竖直,可以通过几何位置关系得到气流坐标系与机体坐标系的夹角,即迎角与侧滑角^[25]分别为

$$\begin{cases} \alpha = \arctan(\tan(\theta + 90^\circ)\cos(\phi)) \\ \beta = \arctan(\sin(\theta + 90^\circ)\sin(\phi)) \end{cases} \quad (1)$$

式中: θ 为试验测量俯仰角, ϕ 为试验测量滚转角。立式风洞试验无法直接测量飞机模型表面的全局气动力, 并且在试验过程中飞机受绳索牵引, 线自由度受限, 在此情况下只能通过运动动力学平衡关系对作用在飞机三轴的气动力矩进行求解:

$$\begin{cases} C_l = [I_x \dot{p} + (I_z - I_y)qr - I_{xz}(pq + \dot{r})]/(q_\infty S b) \\ C_m = [I_y \dot{q} + (I_x - I_z)pr - I_{xz}(p^2 - r^2)]/(q_\infty S c) \\ C_n = [I_z \dot{r} + (I_y - I_x)pq - I_{xz}(qr - \dot{p})]/(q_\infty S b) \end{cases} \quad (2)$$

通过式(2), 可以得到飞机稳定尾旋过程中的飞行状态参数与气动力矩, 进而通过物理关系确定神经网络的输入与输出, 开展尾旋动态气动力建模。

1.2 尾旋动力学仿真

飞机在稳定尾旋过程中, 所受的重力和阻力基本平衡, 升力提供向心力以维持绕铅垂轴的稳定旋转, 因此飞机的尾旋运动用绕固定轴的三自由度旋转动力学模型来模拟^[26]。在飞行仿真过程中, 认为模型所受合外力为零, 在此时风洞来流速度保持不变, 可以认为飞机模型保持定速飞行, 其动力学方程如下^[27]:

$$\begin{cases} m(\dot{u} + qw - rv) = 0 \\ m(\dot{v} + ru - pw) = 0 \\ m(\dot{w} + pv - qu) = 0 \\ I_x \dot{p} + (I_z - I_y)qr - I_{xz}(pq + \dot{r}) = L \\ I_y \dot{q} + (I_x - I_z)rp + I_{xz}(p^2 - r^2) = M \\ I_z \dot{r} + (I_y - I_x)pq + I_{xz}(qr - \dot{p}) = N \end{cases} \quad (3)$$

在给定初始条件后, 通过气动力模型实时求解方程右端三轴力矩系数, 采用龙格库达等数值积分方法即可实现飞机的尾旋三自由度仿真。

2 气动力神经网络建模

2.1 深度神经网络

深度神经网络(deep neural network, DNN)作为一种重要的机器学习方法, 模仿人脑神经网络的结构和工作原理, 与浅层神经网络相比, DNN 通过更深的网络结构能够实现对复杂函数的高精度拟合。深度神经网络的每个神经元层接受上一层的输出作为输入, 通过一系列非线性变换和权重调节来计算输出。DNN 采用反向传播算法进行训练, 通过计算预测输出和真实输出之间的误差, 使用梯度下降法更新神经网络中的权重, 直到网络预测结果达到预定的误差水平。

DNN 模型能够实现对于任意维度输入输出数据的拟合, 通常针对多输入单输出问题进行拟合。对于多维输入向量 $\mathbf{x}$, 其对应的标量为 y , 神经网络拟合要求实现以下函数映射:

$$y = f(\mathbf{x}) \quad (4)$$

设深度神经网络有 L 层, 其中第 l 层有 n_l 个神经元, 定义 $\mathbf{a}^l$ 为第 l 层的激活值, $\mathbf{W}^l$ 为第 l 层的权重矩阵, $\mathbf{b}^l$ 为第 l 层的偏置向量, 非线性激活函数为 g 。

深度神经网络的前向传播过程可以表示为, 当输入向量 $\mathbf{x}$ 进入神经网络第 1 层后, 记

$$\mathbf{a}^0 = \mathbf{x} \quad (5)$$

对于后续的第 1 层到第 l 层, 则有

$$\mathbf{a}^l = g(\mathbf{W}^l \mathbf{a}^{l-1} + \mathbf{b}^l) \quad (6)$$

前向传播完成后, 对于最终输出层, 得到神经网络预测值如下:

$$\hat{y} = \mathbf{a}^L \quad (7)$$

在训练过程中, 通常使用损失函数来对网络预测值 $\hat{y}$ 与真值 y 之间的差异进行评估, 对于回归问题, 常用的损失函数为均方误差(mean squared error, MSE), 表达式如下:

$$S_{ME} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (8)$$

式中, S_{ME} 为均方误差。

DNN 由于其能对任意连续函数以任意精度逼近, 因此常被用在函数拟合问题中。深度神经网络的拟合能力能够实现尾旋过程中的运动参数与对应时刻气动力系数之间的映射关系, 下文将详细介绍尾旋气动力建模过程中的神经网络输入输出设置。

2.2 时间卷积神经网络

时间卷积神经网络^[28](temporal convolutional network, TCN)的主要目的是建模时间序列数据中的依赖关系, 相对于循环神经网络, 能够有效避免循环神经网络在训练时出现的梯度爆炸\消失问题。TCN 采用一维卷积方式来处理时间序列数据, 卷积核在时间维度上滑动, 逐步提取特征。对于给定的离散时间序列数据 $[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_t]$, 其对应的序列输出为 $[y_1, y_2, \dots, y_t]$, 序列建模要求实现以下函数映射关系:

$$(y_1, y_2, \dots, y_t) = f(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_t) \quad (9)$$

在动态气动力建模领域, 动态气动力被认为不仅与当前时刻的飞行状态有关, 也受过往时刻的飞行状态影响, 在此物理前提下, 动态气动力模型的输入需要考虑历史运动时刻, 即气动力系数表达式表

示如下:

$$C_i(t) = f(\mathbf{x}(\tau)), -\infty \leq \tau \leq t \quad (10)$$

式中: C_i 为需要建模的气动力和气动力矩, $\mathbf{x}$ 为状态量所组成的输入向量, 根据物理关系, 不同的气动系数所对应的输入向量不同, 下文将展开进行讨论, 这里统一采用输入向量 $\mathbf{x}$ 表示; τ 为从过去到当前时刻 t 的所有时间序列。

在实际应用中, 采用有限运动时刻的状态作为输入, 表达式可变为

$$C_i(t) = f(\mathbf{x}(\tau)), t - t_0 \leq \tau \leq t \quad (11)$$

式中: t_0 为动态气动力建模时所考虑的历史运动时刻边界, 将时序数据以 dt 时间离散, 并根据 t_0 确定延迟阶数 k , 得到离散时间下的气动力模型表达式如下:

$$C_i(t) = f(\mathbf{x}(t), \mathbf{x}(t-1), \dots, \mathbf{x}(t-k)) \quad (12)$$

对比式(6)与式(9), 可以看到与传统序列到序列建模不用, 气动力模型采用序列到单点, 在输出时只需输出 TCN 网络最后一层的最后一个卷积核信息即可。TCN 网络通过时间卷积层对时间序列信息进行感知, 因此被广泛应用于与时序输入相关的回归和分类问题中。由于非定常气动力显著的时间序列依赖特性, 因此通过利用时间卷积神经网络对输入序列信息进行提取, 能够实现对非定常动态气动力的精确建模, 便于后续开展尾旋动力学仿真工作。

2.3 尾旋气动力模型构建

目前国内外大迎角、尾旋气动数据库构建是将飞机大迎角静态测力试验、旋转天平试验、小幅振荡试验这3类试验数据进行组合, 以三轴力矩为例, 其气动力表达式如下:

$$\begin{cases} C_l = C_{l,static}(\alpha, \beta, \delta) + \Delta C_{l,rot}(\alpha, \beta, \omega) + \\ \quad (C_{lp}\bar{p}_{osc} + C_{lr}\bar{r}_{osc}) \\ C_m = C_{m,static}(\alpha, \beta, \delta) + \Delta C_{m,rot}(\alpha, \beta, \omega) + \\ \quad C_{mq}\bar{q}_{osc} \\ C_n = C_{n,static}(\alpha, \beta, \delta) + \Delta C_{n,rot}(\alpha, \beta, \omega) + \\ \quad (C_{np}\bar{p}_{osc} + C_{nr}\bar{r}_{osc}) \end{cases} \quad (13)$$

其中

$$\begin{cases} \bar{p}_{osc} = p_{osc} b/2V \\ \bar{q}_{osc} = q_{osc} c/2V \\ \bar{r}_{osc} = r_{osc} b/2V \end{cases}$$

式(13)中右端3项分别表示静态气动力、绕风轴旋转气动增量以及绕体轴振荡气动增量, 可以看到上式将动态气动力增量拆解为两部分, 分别用绕

风轴的旋转角速度 ω 以及绕体轴的振荡角速度 $p_{osc}, q_{osc}, r_{osc}$ 来作为特征参数表示, 角速率求解表达式如下:

$$\begin{cases} \omega = (p \cos \alpha + r \sin \alpha) \cos \beta + q \sin \beta \\ p_{osc} = p - \omega \cos \alpha \cos \beta \\ q_{osc} = q - \omega \sin \beta \\ r_{osc} = r - \omega \sin \alpha \cos \beta \end{cases} \quad (14)$$

式中 p, q, r 分别为试验测量的飞机滚转角速率、俯仰角速率与偏航角速率。该分解形成完备的气动数学表达式, 结合风洞试验形成的矩阵气动数据库, 通过数据库插值, 获得各类气动力或者气动导数值, 进而利用式(13)进行增量叠加来表达飞机的整体气动力。

在工程实践中, 对于全机静态测量还会进行二次拆解, 拆解为无舵偏的静态基础量与舵面偏转带来的气动增量两项, 即

$$C_{i,static}(\alpha, \beta, \delta) = C_{i0}(\alpha, \beta) + \Delta C_{i,\delta}(\alpha, \beta, \delta), \quad i = (l, m, n) \quad (15)$$

常规布局飞机具有3个气动舵面, 故式(15)的右端第2项还可继续拆解, 采用不同舵面单独偏转的增量的叠加来表示, 这里不再赘述, 统一采用 $\Delta C_{i,\delta}(\alpha, \beta, \delta)$ 表示。

式(13)中的气动力表达式具有明确的物理含义, 在神经网络建模时可以直接将其输入作为神经网络输入开展训练。但是, 神经网络建模的数据需求量随着输入维度的增加而呈指数级增长, 在神经网络训练时应尽可能选择较少的输入维度。稳定尾旋过程中飞机舵偏保持不变, 因此在舵面维度上, 尾旋试验样本分布稀疏, 仅有少量组合舵面, 若在神经网络建模时将不同舵面作为输入, 则容易导致模型出现过拟合现象。为了既考虑舵面偏转对气动力带来的影响, 又不增加神经网络的维度, 借鉴式(13)的线性增量叠加思路, 可以采用神经网络叠加舵效增量的形式进行建模, 即

$$\begin{cases} C_l = C_{l,NN}(\alpha, \beta, \omega, \bar{p}_{osc}, \bar{r}_{osc}) + \Delta C_{l,\delta}(\alpha, \beta, \delta) \\ C_m = C_{m,NN}(\alpha, \beta, \omega, \bar{q}_{osc}) + \Delta C_{m,\delta}(\alpha, \beta, \delta) \\ C_n = C_{n,NN}(\alpha, \beta, \omega, \bar{p}_{osc}, \bar{r}_{osc}) + \Delta C_{n,\delta}(\alpha, \beta, \delta) \end{cases} \quad (16)$$

式中: $C_{i,NN}$ 为利用神经网络进行无舵偏影响下的非定常气动力映射, $\Delta C_{i,\delta}(\alpha, \beta, \delta)$ 为舵面对气动力矩影响, 本文利用气动数据库中通过静态测力得到的气动力舵偏增量来构建插值表, 在对插值表进行查

询来得到对应状态下的舵面增量。对于神经网络气动力模型, DNN 模型与 TCN 模型的输入形式也有所不同, 根据上文所述, 对于 t 时刻的神经网络输出, 有

$$\begin{cases} C_{i, \text{NN}}(t) = f_{\text{DNN}}(\mathbf{x}(t)) \\ C_{i, \text{NN}}(t) = f_{\text{TCN}}(\mathbf{x}(t), \mathbf{x}(t-1), \dots, \mathbf{x}(t-k)) \end{cases} \quad (17)$$

式中 $\mathbf{x}$ 为神经网络输入向量, 对于不同气动力矩分量, 输入向量有所不同:

$$\begin{cases} \mathbf{x} = [\alpha, \beta, \omega, \bar{p}_{\text{osc}}, \bar{r}_{\text{osc}}], & i = (l, n) \\ \mathbf{x} = [\alpha, \beta, \omega, \bar{q}_{\text{osc}}], & i = m \end{cases} \quad (18)$$

至此, 得到了基于神经网络模型与传统气动数据库组合的气动力模型, 后续将开展气动力建模与尾旋仿真, 整体流程图见图 1。




图 1 尾旋建模仿真流程

Fig. 1 Flowchart of spin modeling and simulation

3 气动力建模与仿真结果

3.1 算例选取

本文基于立式风洞数据开展气动力建模与尾旋仿真验证, 立式风洞数据能够精确复现飞机在稳定尾旋阶段的姿态变化情况。同时相比飞机缩比模飞试验, 立式风洞测量数据噪声小、可靠度高、一致性好, 因此作为本文的主要数据来源。

选取同一组合舵面偏转下的 16 个车次数据, 进入尾旋时飞机左副翼下偏 15° 、右副翼上偏 25° , 平尾偏转 0° , 方向舵归中, 截取试验中的稳定尾旋段进行研究。如图 2 所示展示了同一舵面偏转组合下的不同车次飞机状态量变化情况, 由于在向风洞投入飞机模型时, 飞机初始姿态无法保持相同, 因此尽管在舵面偏转相同的情况下, 初始状态的不同会依然会导致稳定尾旋的模式特征不同, 飞机的姿态变化有所差异, 进而导致飞行状态参数采样空间发生变化, 因此可以将每个不同的车次视作独立样本。

风洞试验所采集到的飞行状态量包括迎角、侧滑角、滚转角速度、俯仰角速度、偏航角速度、滚转角、俯仰角和偏航角。通过滤波平滑算法^[29]对数据进行平滑处理, 并利用数值微分得到角速度, 通过式 (2) 求解尾旋过程中的三轴气动力矩, 最终得到气动力建模所需的输入输出值。




图 2 不同架次飞行状态参数随时间变化

Fig. 2 Variation of flight state parameters over time for different flights

3.2 尾旋气动力建模

针对已有的 16 个车次, 选取 13 个车次为训练集, 1 个车次为验证集, 剩余 2 个车次作为测试集。神经网络构建的输入输出已在式 (17)、(18) 中说明。针对 TCN 网络, 设置输入延迟阶数为 2, 神经网络训练学习率设置为 0.01, 采用指数学习率衰减策略, 神经网络训练的 L2 范数权重设置为 0.01, 采用 AdamW 优化器, 在 PyTorch 开源框架下搭建神经网络。

为测试神经网络对气动力预测的强泛化能力,

这里采用平均绝对误差(mean absolute error, MAE)作为评价指标,采用上文的数据集划分,随机划分10次,计算测试集的MAE,将10次的MAE均值与标准差进行统计,见表1,表中第1列展示了气动数据库预测的所有样本的气动力预测MAE均值。从误差可以看出神经网络模型较传统数据库其气动力的预测精度均有所提升,相较于气动数据库,DNN模型的三轴气动力矩平均预测误差降低了33%,TCN模型平均预测误差降低了77%,极大改善了气动力的预测精度。

表1 气动力矩系数预测MAE统计

Tab. 1 Aerodynamic moment coefficient prediction MAE statistics

气动力矩	气动数据库	DNN模型	TCN模型
C_l	0.006 41	0.006 03 ± 0.000 88	0.001 28 ± 0.000 66
C_m	0.033 48	0.018 51 ± 0.003 58	0.009 83 ± 0.003 58
C_n	0.015 18	0.007 84 ± 0.002 97	0.002 97 ± 0.001 84

选择其中一次试验结果,绘制测试集车次的气动力预测结果见图3。从图3中可以看出传统气动

数据库预测气动力与风洞试验结果有较大偏差,针对滚转力矩与俯仰力矩,气动数据库能反映试验值的大致趋势与均值,而偏航力矩则和试验值差异较大,因此通过传统气动数据库很难精确刻画尾旋过程中的气动力矩,这也是导致尾旋仿真精度低,动力学分析可靠性差的主要原因。两个神经网络模型的预测精度较传统气动数据库均有较大提升,尤其在偏航力矩系数上,基本能够反映试验值的变化趋势。对比两个神经网络,尽管二者都对气动力变化趋势有很好的刻画精度,但是TCN模型的精度更高,尤其是在高频变化部分,TCN模型预测值与试验值基本重合。这主要是由于TCN模型考虑了非定常气动力的时间依赖性,模型输入中包含了运动参数的时间延迟阶数,增强了对非定常气动力的刻画能力。DNN模型借助强非线性拟合能力,尽管没有对非定常气动力的时间延迟效应进行建模,但相较于近似线性构造的气动数据库而言,依旧能对复杂气动力进行更好的逼近。




图3 气动力矩系数预测结果

Fig. 3 Aerodynamic moment coefficient prediction results


3.3 稳定尾旋仿真

在完成气动力建模后,利用式(3)对测试集中的车次开展尾旋仿真预测,两个相同舵面组合的车次预测结果见图4。图4给出了尾旋动力学仿真的结果,可以发现利用传统气动数据库开展仿真,其尾旋轨迹在仿真初期与试验值接近,随着仿真时间的增加,误差变得越来越大。对比神经网络模型,可以观察到带时间延迟的TCN模型的仿真精度最差,随着时间推进动力学模型的误差变得越来越大,这一现象主要是由于TCN模型输入涉及多个时间步,模型鲁棒性不足。由于气动力模型带有预测误差,在耦合仿真过程中,气动力误差使得飞行动力学解算后的飞行状态具有一定偏差,导致下一时间步的气动力模型输入与试验值不同,进而使得下一时间步


解算出的飞行状态量偏差变大,最终仿真偏差积累放大,这一现象在先前研究中也观察到^[30]。TCN模型的多时间步输入,导致模型的扰动来源增加,轻微的输入扰动使得TCN模型的输出发生较大的偏差,误差累计速度快,容易出现仿真发散,而DNN模型只涉及当前时刻输入,模型扰动来源少,因而上述耦合仿真过程中的误差累计较慢,如图4(a)所示的偏航角变化,可以看到TCN模型和DNN模型在初期仿真精度一致,且两个模型仿真偏差都在逐渐增大,但TCN模型误差增长更快,每圈旋转的误差都在增大,因此利用DNN模型开展尾旋仿真,其姿态预测值与真实值吻合,基本实现了高精度稳定尾旋预测。在对尾旋过程分析时,通常关注尾旋过程中的迎侧角均值与振荡幅值,以及尾旋的旋转周期,见

表 2。可以看到通过利用 DNN 模型网络构建的气动力模型,在进行尾旋动力学仿真时起特征参数与试验结果的偏差最小,而 TCN 模型网络尽管能实现

气动力的高精度预测,但动力学仿真精度低,尾旋特征参数与试验值相差大。



(a) 车次A



(b) 车次B

图 4 相同舵面组合下稳定尾旋预测结果

Fig. 4 Stable tailspin prediction results for identical control surface combination

表 2 相同舵面组合下稳定尾旋特征参数

Tab. 2 Characteristic parameters of stable tailspin for identical control surface combination

车次	稳定尾旋参数	t/s	$\alpha/(^{\circ})$		$\beta/(^{\circ})$		车次	稳定尾旋参数	t/s	$\alpha/(^{\circ})$		$\beta/(^{\circ})$	
			振幅	均值	振幅	均值				振幅	均值	振幅	均值
车次 A	风洞试验	1.59	32.93	70.41	26.15	0.49	车次 B	风洞试验	1.20	18.73	75.26	25.46	-2.01
	数据库仿真	1.28	42.69	73.79	25.35	-1.07		数据库仿真	1.25	24.11	74.77	20.57	-2.60
	DNN 仿真	1.35	29.12	74.30	23.02	-0.90		DNN 仿真	1.24	16.81	74.87	17.15	-0.90
	TCN 仿真	1.29	43.04	74.24	47.35	-3.87		TCN 仿真	1.40	63.55	74.16	45.48	-3.87

为了验证所提出的方法的泛化性,将得到的气动力模型应用于新舵偏组合下的稳定尾旋仿真预测中。选取 3 个新舵面组合下的试验车次,见表 3。

表 3 立式风洞舵面组合


Tab. 3 Vertical wind tunnel control surface combinations

车次	副翼/ $(^{\circ})$		平尾/ $(^{\circ})$		方向舵/ $(^{\circ})$
	左	右	左	右	
训练集	-15	25	0	0	0
车次 C	-5	15	0	0	0
车次 D	-15	25	-5	5	0
车次 E	-15	25	0	0	25


由表 3 可以看出,车次 C、D、E 的进入舵面偏转与训练集有所不同,为了突出该建模方式对任意舵面

改变都适用,通过控制变量思路,选择的组合涉及 3 个不同的舵面偏转。上文展示了在同样的舵面组合下,新车次的动力学仿真结果,可以看到基于 TCN 模型的动力学仿真难以实现对风洞试验的精确预测,因此在变舵面组合仿真预测中不再对比 TCN 模型的仿真结果。

如图 5 所示,可以看到针对不同的舵面组合,基于 DNN 模型开展的尾旋仿真预测相对于传统仿真结果,能够更加精确地反映运动参数随时间的变化。如图 5(a)所示,基于 DNN 模型的仿真结果随时间增加,其精度变差,出现前文所述的误差累积现象,但由于 DNN 模型输入只与当前时刻有关,且其鲁棒性好,在有限时间内仍能够较为精确的预测尾旋参数变化趋势。




— 气动数据库 - - - DNN模型 ■ 试验值



(b) 车次D

— 气动数据库 - - - DNN模型 ■ 试验值



(c) 车次E

图 5 不同舵面组合下稳定尾旋预测结果

Fig. 5 Stable tailspin prediction results for different control surface combinations

接下来对不同车次特征参数进行对比,结果如表4所示,可以看到车次C与车次E中,神经网络方法仿真得到的特征参数与试验值更加接近,车次D中传统数据库仿真与神经网络仿真精度相当。稳定尾旋的周期预测平均误差从9.8%降低到6.5%,误差量降低了34%。总的来说,通过DNN模型搭建气动力模型,对尾旋过程气动力修正后,气动力预测精度比传统大迎角气动数据库模型更高,能够更加精确地实现飞机稳定尾旋姿态仿真与特征参数预测。

表4 不同舵面组合下稳定尾旋特征参数
Tab.4 Characteristic parameters of stable tailspin for different control surface combinations

车次	稳定尾旋参数	t/s	$\alpha/(^{\circ})$		$\beta/(^{\circ})$	
			振幅	均值	振幅	均值
车次C	风洞试验	1.59	32.93	70.41	26.15	0.49
	数据库仿真	1.28	42.69	73.79	25.35	-1.07
	DNN 仿真	1.62	49.88	69.45	29.71	-0.14
车次D	风洞试验	0.85	25.44	79.71	43.05	-1.12
	数据库仿真	0.86	29.51	81.00	34.07	-1.22
	DNN 仿真	0.70	27.40	80.62	41.82	-0.91
车次E	风洞试验	1.34	29.23	73.74	35.45	-1.75
	数据库仿真	1.22	33.71	75.25	25.58	-2.76
	DNN 仿真	1.34	39.11	73.49	34.00	-2.14

4 结 论

本文基于立式风洞试验数据,利用深度学习方法,提出一种组合神经网络与传统气动数据库的增量叠加神经网络模型,形成了不同舵面组合下的气动-动力学耦合尾旋仿真框架,就稳定尾旋过程中的尾旋气动力的高精度建模与尾旋姿态预测问题开展了研究,主要结论如下:

- 1)利用深度神经网络模型能够实现对尾旋过程中的非定常气动力的高精度建模,并具备较强的泛化能力,与传统气动数据库相比气动力矩预测误差降低77%。
- 2)在神经网络建模时,多时刻输入会提升非定常气动力建模精度,但会极大降低气动力模型的鲁棒性,导致动力学耦合仿真时的误差积累加快。
- 3)所提出的将神经网络模型与传统气动数据库组合的增量叠加神经网络模型,实现了气动力模型从单一组合舵面向不同组合舵面的气动力泛化,有效降低了神经网络的输入维度与样本需求量。
- 4)尽管本文通过立式风洞工程试验数据开展了相关研究,但尾旋进入阶段气动力复杂性更高,立

式风洞无法体现尾旋进入过程,未来工作需要基于高置信的大气缩比模飞数据,考虑尾旋进入与改出过程中的气动力变化与飞机响应特性,使其能更好地为战斗机尾旋预测与改出飞行训练提供工程指导。

参考文献

[1]涂良辉,周瑛,陈雅丽,等. 大迎角动力学特性分析与建模研究[J]. 航空科学技术, 2012, 23(5): 29
TU Lianghui, ZHOU Ying, CHEN Yali, et al. Dynamic characteristic analysis and modeling at high angle of attack[J]. Aeronautical Science & Technology, 2012, 23(5): 29. DOI: 10.3969/j. issn. 1007-5453. 2012. 05. 011

[2]颜巍,黄灵恩. 大型民用飞机偏离特性与尾旋敏感性分析[J]. 民用飞机设计与研究, 2016(2): 32
YAN Wei, HUANG Lingen. Departure characteristics and spin sensitivity analysis for a large civil aircraft[J]. Civil Aircraft Design & Research, 2016(2): 32. DOI:10.19416/j.cnki.1674-9804.2016.02.009

[3]MALIK B, MASUD J, AKHTAR S. Objective comparison of numerical spin study with aircraft model free-flight spin tests[J]. Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, 2023, 237(2): 419. DOI: 10.1177/09544100221103011

[4]MALIK B, AKHTAR S, MASUD J. Aircraft spin characteristics with high-alpha yawing moment asymmetry [J]. Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, 2018, 232 (15): 2793. DOI: 10.1177/0954410017718215

[5]MURCH A M. Aerodynamic modeling of post-stall and spin dynamics of large transport airplanes [D]. Atlanta: Georgia Institute of Technology, 2007

[6]沈霖. 大攻角非定常气动力建模及尾旋仿真研究[D]. 南京:南京航空航天大学, 2013
SHEN Lin. Research on unsteady aerodynamic models at high angle of attack and spin simulation of aircraft [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2013

[7]MALIK B, MASUD J, AKHTAR S. A review and historical development of analytical techniques to predict aircraft spin and recovery characteristics [J]. Aircraft Engineering and Aerospace Technology, 2020, 92(8): 1195. DOI: 10.1108/aeat-08-2019-0174

[8]KALVISTE J. Use of rotary balance and forced oscillation test data in six degrees of freedom simulation [C]//Proceedings of the 9th Atmospheric Flight Mechanics Conference. Reston: AIAA, 1982: 1364. DOI: 10.2514/6.1982-1364

[9]MURCH A, FOSTER J. Recent NASA research on aerodynamic modeling of post-stall and spin dynamics of large transport airplanes [C]//Proceedings of the 45th AIAA Aerospace Sciences Meeting and Exhibit. Reston: AIAA, 2007: 463. DOI: 10.2514/6.2007-463

[10]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
WANG Haifeng, ZHAN Jingxia, CHEN Ke, et al. Development and application of aerodynamic research technologies for fighters at high angle of attack[J]. Acta Aerodynamica Sinica, 2022, 40(1): 1. DOI:10.7638/kqdlxxb-2021.0306

[11]HULTBERG R. Low speed rotary aerodynamics of F-18 configuration for 0 deg to 90 deg angle of attack: Test results and analysis[R]. Hampton: National Aeronautics and Space Administration, 1984

[12]岑飞,刘志涛,蒋永,等. 民机极限飞行状态非定常气动力建模[J]. 航空学报, 2022, 43(8): 125582
CEN Fei, LIU Zhitao, JIANG Yong, et al. Unsteady aerodynamics

- modeling of civil transport configuration under extreme flight conditions[J]. *Acta Aeronautica et Astronautica Sinica*, 2022, 43(8): 125582. DOI: 10.7527/S1000-6893.2021.25582
- [13] WANG Xu, KOU Jiaqing, ZHANG Weiwei, et al. Incorporating physical models for dynamic stall prediction based on machine learning[J]. *AIAA Journal*, 2022, 60(7): 4428. DOI: 10.2514/1.J061210
- [14] 颜巍, 黄灵恩, 黎先平. 大型民用飞机尾旋运动的系统辨识研究[J]. *民用飞机设计与研究*, 2017(4): 58
YAN Wei, HUANG Lingen, LI Xianping. Systems identification research of a large spin motion for civil aircraft[J]. *Civil Aircraft Design & Research*, 2017(4): 58. DOI: 10.19416/j.cnki.1674-9804.2017.04.011
- [15] MOKHTARI M A, SABZEHPARVAR M. Identification of spin maneuver aerodynamic nonlinear model by applying ensemble empirical mode decomposition and extended multipoint modeling[J]. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, 2019, 233(5): 1865. DOI: 10.1177/0954410018764937
- [16] GRESHAM J L, SIMMONS B M, HOPWOOD J W, et al. Spin aerodynamic modeling for a fixed-wing aircraft using flight data [C]//AIAA SCITECH 2022 Forum. Reston: AIAA, 2022: AIAA2022-1160. DOI: 10.2514/6.2022-1160
- [17] KOU Jiaqing, ZHANG Weiwei. Data-driven modeling for unsteady aerodynamics and aeroelasticity[J]. *Progress in Aerospace Sciences*, 2021, 125: 100725. DOI: 10.1016/j.paerosci.2021.100725
- [18] MI Baigang, CHENG Shixin, ZHAN Hao, et al. Development on unsteady aerodynamic modeling technology at high angles of attack[J]. *Archives of Computational Methods in Engineering*, 2024, 31(8): 4305. DOI: 10.1007/s11831-024-10180-w
- [19] WANG Xu, KOU Jiaqing, ZHANG Weiwei. Unsteady aerodynamic prediction for iced airfoil based on multi-task learning[J]. *Physics of Fluids*, 2022, 34(8): 087117. DOI: 10.1063/5.0101991
- [20] LI Kai, KOU Jiaqing, ZHANG Weiwei. Deep learning for multifidelity aerodynamic distribution modeling from experimental and simulation data[J]. *AIAA Journal*, 2022, 60(7): 4413. DOI: 10.2514/1.J061330
- [21] BAGHERZADEH S A. Nonlinear aircraft system identification using artificial neural networks enhanced by empirical mode decomposition[J]. *Aerospace Science and Technology*, 2018, 75: 155. DOI: 10.1016/j.ast.2018.01.004
- [22] 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
CHEN Xiang, ZHAN Jingxia, CHEN Ke, et al. Unsteady aerodynamic modeling research and virtual flight test verification [J]. *Journal of Experiments in Fluid Mechanics*, 2022, 36(3): 65. DOI:10.11729/syltlx20210143
- [23] LYU Yongxi, CAO Yuyan, ZHANG Weiguo, et al. Dynamic surface control design of post-stall maneuver under unsteady aerodynamics[J]. *Aerospace Science and Technology*, 2018, 80: 269. DOI: 10.1016/j.ast.2018.06.037
- [24] 颜巍. 立式风洞与立式风洞试验[J]. *民用飞机设计与研究*, 2016(3): 52
YAN Wei. Vertical wind tunnel and vertical wind tunnel experiments[J]. *Civil Aircraft Design & Research*, 2016(3): 52. DOI: 10.19416/j.cnki.1674-9804.2016.03.012
- [25] FREMAUX C M. Spin-tunnel investigation of a 1/28-scale model of the NASA F-18 high alpha research vehicle (HARV) with and without vertical tails: NASA Contractor Report 201687 [R]. Hampton: National Aeronautics and Space Administration Langley Research Center, 1997
- [26] 郭林亮, 祝明红, 傅澹, 等. 水平风洞中开展飞机尾旋特性研究的理论分析[J]. *航空学报*, 2018, 39(6): 122030
GUO Linliang, ZHU Minghong, FU Hao, et al. Theoretical analysis of research on aircraft spin characteristic in horizontal wind tunnel[J]. *Acta Aeronautica et Astronautica Sinica*, 2018, 39(6): 122030. DOI:10.7527/S1000-6893.2018.22030
- [27] 郭林亮, 祝明红, 孔鹏, 等. 风洞虚拟飞行模型机与原型机动力学特性分析[J]. *航空学报*, 2016, 37(8): 2583
GUO Linliang, ZHU Minghong, KONG Peng, et al. Analysis of dynamic characteristics between prototype aircraft and scaled-model of virtual flight test in wind tunnel [J]. *Acta Aeronautica et Astronautica Sinica*, 2016, 37(8): 2583. DOI: 10.7527/S1000-6893.2015.0296
- [28] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [J]. *arXiv preprint arXiv: 180301271*, 2018
- [29] MORELLI E A. Estimating noise characteristics from flight test data using optimal Fourier smoothing[J]. *Journal of Aircraft*, 1995, 32(4): 689. DOI: 10.2514/3.46778
- [30] 李怀璐, 王旭, 王霄, 等. 大迎角机动飞行的气动力建模与飞行仿真[J]. *航空学报*, 2023, 44(19): 78
LI Huailu, WANG Xu, WANG Xiao, et al. Aerodynamic modeling and flight simulation of maneuver flight at high angle of attack[J]. *Acta Aeronautica et Astronautica Sinica*, 2023, 44(19): 78. DOI: 10.7527/S1000-6893.2022.28410

(编辑 张 红)