

基于深度神经网络的超声速隔离段湍流涡黏性系数辨识

杨茂桃^{1,2}, 梁爽^{1,2}, 易森荣², 田野^{1,2}, 郭明明^{1,2}, 乐嘉陵², 张华¹

(1. 西南科技大学 信息工程学院, 四川 绵阳 621000;

2. 中国空气动力研究与发展中心 空天技术研究所, 四川 绵阳 621000)

摘 要: 雷诺平均 Navier-Stokes(RANS)方程由于计算成本较低,当前仍然在工程设计领域广泛应用。为了进一步提升计算精度和减少时间,应用深度神经网络(deep neural networks, DNN)方法自适应辨识稳态湍流涡黏性系数。以隔离段的激波串前缘位置检测流场生成为例,使用 Wilcox-2006 $k-\omega$ 湍流模型进行模拟。在不同的背压情况下,产生稳定状态的湍流涡黏性流场作为模型学习的训练数据集。最后在不同背压条件下开展了测试。结果表明:提出的 DNN 方法能够快速预测湍流涡黏性系数的值,预测值与计算流体力学数值模拟计算的参数值相比,方均根误差较小,可决系数大于 99%,预测的流场结果与真实流场基本一致,进一步验证了深度学习技术在湍流模型参数辨识的可行性。

关 键 词: 湍流模型; 深度神经网络; 涡黏性系数; 参数辨识; 流场预测

中图分类号: V235.21

文献标志码: A

Identification of turbulence eddy viscosity coefficient in supersonic isolation section based on deep neural network

YANG Maotao^{1,2}, LIANG Shuang^{1,2}, YI Miaorong², TIAN Ye^{1,2}, GUO Mingming^{1,2},
LE Jialing², ZHANG Hua¹

(1. School of Information Engineering,

Southwest University of Science and Technology, Mianyang Sichuan 621000, China;

2. Institute of Aerospace Technology,

China Aerodynamic Research and Development Center, Mianyang Sichuan 621000, China)

Abstract: The Reynolds-averaged Navier-Stokes (RANS) equation is still widely used in engineering design due to its low computational cost. In order to further improve the calculation accuracy and reduce the time, a deep neural network (deep neural networks, DNN) method was applied to adaptively identify the steady-state turbulent eddy viscosity coefficient. Taking the detection flow field generated at the front edge of the shock train in the isolation section as an example, the Wilcox-2006 $k-\omega$ turbulence model was used for simulation. A steady-state turbulent eddy-viscous flow field was generated as a training dataset for model learning under different back pressure conditions. Finally, tests were carried out under different back pressure conditions. The results showed that the proposed DNN method can quickly predict the value of the turbulent eddy viscosity coefficient. The coefficient of determination was greater than 99%, and the predicted flow field results were basically consistent with the real flow field,

收稿日期: 2022-03-30

基金项目: 国家自然科学基金(12002362)

作者简介: 杨茂桃(1997—),男,硕士生,主要从事人工智能及超燃冲压发动机技术研究。

通信作者: 田野(1987—),男,副研究员,博士,主要从事超燃冲压发动机燃烧组织技术研究。E-mail: tianye@cardc.cn

引用格式: 杨茂桃,梁爽,易森荣,等. 基于深度神经网络的超声速隔离段湍流涡黏性系数辨识[J]. 航空动力学报, 2023, 38(2): 312-324. YANG Maotao, LIANG Shuang, YI Miaorong, et al. Identification of turbulence eddy viscosity coefficient in supersonic isolation section based on deep neural network[J]. Journal of Aerospace Power, 2023, 38(2): 312-324.

which further verified the feasibility of deep learning technology in turbulence model parameter identification.

Keywords: turbulence model; deep neural network; eddy viscosity coefficient; parameter identification; flow field prediction

冲压发动机隔离段位于燃烧室和进气道之间,为激波串的形成提供了空间^[1]。隔离段结构虽比较简单,但其内部复杂的湍流流动特性关系到超燃冲压发动机进气道的起动特性和燃烧室的燃烧特性^[2-3]。在高背压条件下,可能将激波串推出进气道,导致进气道不起动^[4-5]。因此,针对隔离段内部复杂的湍流流动,如何快速精准地计算和分析流场具有重要意义。目前,直接数值模拟^[6](direct numerical simulation, DNS)或大涡模拟^[7](large eddy simulation, LES)等高精度数值方法仍然难以用于解决实际工程问题,雷诺平均 Navier-Stokes (RANS)方程仍然是气动设计中最常用的数值模拟方法^[8]。然而在复杂湍流流动现象中,RANS 方程无法给出符合工程精度要求的结果^[9]。对于 RANS 方程的计算误差,研究者认为主要来自雷诺应力的建模误差,并提出了线性和非线性涡黏性模式或直接对雷诺应力进行建模的雷诺应力模式^[10],但未能找到能在不同类型复杂流动下精确计算,又能保持鲁棒性和节省成本的湍流计算模型。在求解 RANS 方程过程中,在不同的湍流模型下,求解的闭合系数不尽相同。Stefano 等^[11]对 RANS 仿真中常用的四种湍流模型的闭合系数进行了不确定性和灵敏度分析,并将其应用于超燃冲压发动机隔振器流动几何的仿真中^[12]。

随着机器学习技术和数据驱动方法的不断发展^[13-14],研究者通过使用高保真移植策略来构建代理模型,从而提高计算流体动力学(CFD)计算速度和精度。2012年,Yarlanki 等^[15]使用机器学习算法对湍流模型的模型常数进行优化,得到了最佳湍流模型常数,与使用标准模型常数结果相比,误差明显减少。2015年,Zhang 等^[16]研究了机器学习模型从高保真模拟和实验数据中提取的空间分布量的功能形式,该研究结果突出了机器学习作为数据驱动湍流建模工具的潜力。2018年,Kaandorp 等^[17]提出了张量基随机森林(TBRF)来预测雷诺应力各向异性张量。该方法准确预测了各种流动情况下的各向异性张量,大部分预测是可实现的,接近 DNS/LES 参考数据。2019年,Saakaar 等^[18]提出了一种基于卷积神经网络(CNN)的流

场预测近似模型。利用 CNN 来预测在不可见的流动条件下的速度场和压力场。该方法可以自动检测基本特征,以最少的人力监督有效地估计显示速度和压力场数量级的速度,使机翼形状的操作条件接近实时的流场。2019年,Zhu 等^[19]直接以 Spalart-Allmaras 方程模型计算的涡黏性为目标,建立人工神经网络。用网络代替原模型,提高了计算效率,降低了对网格密度的依赖性。2021年,Panda 等^[20]利用机器学习(ML)算法构建了 ML 模型,对经典 CFD 方法进行了替代,预测了旋转的轴对称体(ABR)上的流场。实验结果表明,训练后的 ML 模型可以快速预测流场,为实际工程设计提供了一个快速和准确的预测框架。2021年,Shuvayan 等^[21]针对进气道流场的预测问题,开展了本征正交分解(proper orthogonal decomposition, POD)降阶模型的多层感知机代理模型研究,成功减少了机器学习在流场预测过程中神经元个数及计算时间。2022年,Sun 等^[22]用深度学习的高雷诺数翼型绕流湍流模型代替 Spalart-Allmaras 湍流模型。在不同的来流条件(迎角、马赫数、雷诺数和翼型)下,该方法具有很强的通用性。将机器学习用于湍流模型,改进 CFD 精度或速度的相关工作还很多,特别是近几年,大量学者对此类工作做出了很大贡献^[23]。

此外,哈尔滨工业大学常军涛团队已经开展了大量超燃冲压发动机隔离段的研究工作,近年来也将深度学习应用到流体力学中,特别是超声速流及激波串等,已经取得了较好的进展。如 Li 等^[24]利用机器学习算法在流动建模、重构与预测以及主动流动控制在实验与仿真中的应用,验证了机器学习算法有利于解决传统流体力学方面的问题;Kong 等^[25-27]利用深度学习方法进行了超燃冲压发动机隔离段流场预测,验证了基于该方法的模型预测效果与计算流体力学结果吻合良好,并高精度地重构了流场。

综上,本文针对 Wilcox-2006 $k-\omega$ 湍流模型开展了基于深度神经网络(DNN)的超声速隔离段湍流涡黏性系数辨识的研究工作。通过机器学习

的方法,建立湍流涡黏性系数辨识的深度神经网络代理模型,代替求解湍流涡黏性系数的湍流模型,有望进一步提高 RANS 方法在 CFD 软件中的计算速度。本文的主要工作主要包括四部分:

1) 以隔离段激波串位置检测的流场生成为例,使用 Wilcox-2006 $k-\omega$ 湍流模型进行建模。在闭合模型下,产生稳定状态的湍流涡黏性文件。

2) 开展了基于 DNN 的湍流涡黏性系数代理模型研究,近似拟合了设计变量与目标函数之间的非线性关系。

3) 对 DNN 的湍流涡黏性系数代理模型计算结果和真实值进行了对比和分析,并对影响代理模型精度的因素进行了研究。

4) 对不同背压下的最终结果和真实值进行

了比较和分析,初步证明了 DNN 在 CFD 计算中代替湍流模型求解涡黏性系数的可行性。

1 数据集的建立 (CFD)

1.1 网格生成及计算域

本文采用中国空气动力研究与发展中心自主开发的大规模并行软件 AHL3D 开展数值模拟,该软件可以模拟二维或三维、定常或非定常、完全气体或化学非平衡流动等,软件可靠性得到了广泛验证。本文研究的结果通过数值求解 RANS 模拟方程可以获得。以哈尔滨工业大学地面直连式超燃冲压发动机隔离段为研究对象,实验装置如图 1 所示,图中 T1~T10 代表传感器,该实验台的详细介绍可参考文献 [28]。




图 1 地面直连式超燃冲压发动机实验台

Fig. 1 Ground direct connect scramjet test bench

考虑到三维数值模拟计算耗时较大,本文数值模拟采用二维模拟。为了保证数据获得的精度,在数值模拟过程必须进行网格无关性分析,本文生成了三种不同分辨率的网格 (3401×201 , 401×101 和 240×101),不同网格下 Wilcox-2006 $k-\omega$ 湍流模型模拟的壁面压力分布如图 2 所示,可以发现网格分辨率为 401×101 可以准确模拟壁面压力,因此为了平衡精度和速度,选取 401×101 的网格作为后续所有状态的研究。

如图 3 所示,使用二维结构化网格量约为 40 000 个单元,长为 340 mm,高为 30 mm,壁面第一层网格厚度为 0.001 mm,流向间隔为 1 mm。使用斜劈在隔离段产生背景波系,在斜坡位置进行加密。

来流条件参数设置如下:发动机入口马赫数为 2.72,气体分子量为 28.96,比热比为 1.4,静压为 50 604.77 Pa,静温为 123.0 K,停滞温度为 300 K,设置来流边界层厚度为 3.0 mm。计算采用定常




图 2 网格无关性分析

Fig. 2 Grid independence analysis



图 3 网格模型

Fig. 3 Grid model

Navier-Stokes 方程, 无黏对流项离散采用 MUSCL (monotone upstream-centred schemes for conservation laws) + AUSMPW+ (advective upwind splitting method by pressure-based weight functions) 方法, 湍流模型为 Wilcox-2006 k - ω 模型, 算取的激波串前缘位置的其中一个结果如图 4 所示。




图 4 激波串的位置纹影图

Fig. 4 Position schlieren diagram of shock train

1.2 Wilcox-2006 k - ω 模型

由 Wilcox 提出的原始的传输方程表达式如下:

$$\frac{\partial(\rho k)}{\partial t} + \frac{\partial(\rho u_j k)}{\partial x_j} = \tau_{i,j} \frac{\partial u_i}{\partial x_j} - \beta^* \rho \omega k + \frac{\partial}{\partial x_j} \left[\left(\mu + \sigma_k C_\mu \frac{\rho k}{\omega} \right) \frac{\partial k}{\partial x_j} \right] \quad (1)$$

$$\frac{\partial(\rho \omega)}{\partial t} + \frac{\partial(\rho u_j \omega)}{\partial x_j} = \frac{\gamma \omega}{k} \tau_{i,j} \frac{\partial u_i}{\partial x_j} - \beta \rho \omega^2 + \frac{\partial}{\partial x_j} \left[\left(\mu + \sigma_\omega C_\mu \frac{\rho k}{\omega} \right) \frac{\partial \omega}{\partial x_j} \right] + \frac{\rho \sigma_d}{\omega} \cdot \frac{\partial k}{\partial x_j} \cdot \frac{\partial \omega}{\partial x_j} \quad (2)$$

其中 t 表示时间, ρ 表示密度, k 表示湍流动能, u_i 、 u_j 分别表示 x_i 、 x_j 方向的速度, γ 表示比热比, $\tau_{i,j}$ 表示雷诺应力张量的分量, β^* 、 σ_k 表示湍流模型参数, ω 表示单位湍流动能耗散, μ 表示分子动力黏度, β 、 σ_ω 、 σ_d 表示特定耗散率方程中的闭合系数。

上述方程虽然并未直接出现应力限制系数 C_{lim} 和卡门常数 κ , 但是它们分别作为用于提高模型模拟剪切层流动、强分离流动问题精度的压力限制和对数律层校准。Wilcox 的公式中定义湍流黏度 μ_t 为

$$\mu_t = \frac{\rho k}{\omega} \quad (3)$$

对数值模拟软件 AHL3D 中两方程模型进行转换, 获得 k - ω 公式中使用的涡流黏度的标准形式, 为了确保两种计算一致和有效, 根据式(2)和式(3)

可以得出新的湍流动能耗散 ω_{Wilcox} 如下:

$$\omega_{Wilcox} = \frac{\omega}{C_\mu} \quad (4)$$

其中 C_μ 为经验常数。

将式(4)代入式(1)和式(2)中, 可以获得在 AHL3D 中使用的控制方程表达式如下, 更详细的推导可以参考文献 [12]:

$$\frac{\partial(\bar{\rho} \tilde{k})}{\partial t} + \frac{\partial(\bar{\rho} \tilde{u}_j \tilde{k})}{\partial x_j} = \bar{\tau}_{i,j} \frac{\partial \tilde{u}_i}{\partial x_j} - \left(\frac{\beta^*}{C_\mu} \right) \bar{\rho} \tilde{\omega} \tilde{k} + \frac{\partial}{\partial x_j} \left[\left(\mu + \sigma_k C_\mu \frac{\bar{\rho} \tilde{k}}{\tilde{\omega}} \right) \frac{\partial \tilde{k}}{\partial x_j} \right] \quad (5)$$

$$\frac{\partial(\bar{\rho} \tilde{\omega})}{\partial t} + \frac{\partial(\bar{\rho} \tilde{u}_j \tilde{\omega})}{\partial x_j} = \frac{\gamma \tilde{\omega}}{\tilde{k}} \bar{\tau}_{i,j} \frac{\partial \tilde{u}_i}{\partial x_j} - \left(\frac{\beta}{C_\mu} \right) \bar{\rho} \tilde{\omega}^2 + \frac{\partial}{\partial x_j} \left[\left(\mu + \sigma_\omega C_\mu \frac{\bar{\rho} \tilde{k}}{\tilde{\omega}} \right) \frac{\partial \tilde{\omega}}{\partial x_j} \right] + \frac{\bar{\rho} \sigma_d C_\mu}{\tilde{\omega}} \cdot \frac{\partial \tilde{k}}{\partial x_j} \cdot \frac{\partial \tilde{\omega}}{\partial x_j} \quad (6)$$

其中“-”表示平均量, “~”表示有效计算量。

1.3 获取数据及预处理

本文选取背压作为生成机器学习训练和测试数据的控制参数。分别对 0.22、0.23、0.24、0.25、0.26、0.27、0.28、0.29、0.30 MPa 和 0.31 MPa 共 10 个不同背压进行数值模拟获取数据, 以隔离段的激波串位置检测的流场生成为例, 在 AHL3D 软件中根据上述的边界条件, 使用 Wilcox-2006 k - ω 湍流模型产生稳定状态的涡黏性文件, 通过特征预处理或几何信息增强初始条件的信息。以初始条件和稳态湍流涡黏性的逐个点“输入-输出”的形式保存训练数据。在每个背压条件下获取了 14 输入 1 输出的数据, 共 405 010 个数据。具体的数学映射关系如下:

$$T_t, p_t, k_{turb}, w_{turb}, Ma, T, \rho, p, u(x), v(x), w(x), x(x), y(x), z(x) \rightarrow v_t(x) \quad (7)$$

本文选择 ρ 、 p 、 $u(x)$ 、 $v(x)$ 、 $x(x)$ 、 $y(x)$ 六个参数作为 $v_t(x)$ 的特征辨识参数, 即流场中某个点的密度、流场中某个点的压力、初始条件的垂直和水平方向的速度结果、流场中某个点的网格坐标作为 DNN 的输入参数。 $v_t(x)$ 为任意选择的某个湍流闭合模型中的涡黏性系数, 作为 DNN 的输出。具体的数学映射关系如式(8), 各参数的物理意义介绍如表 1 所示。

$$\rho, p, u(x), v(x), x(x), y(x) \rightarrow v_t(x) \quad (8)$$

为提升 DNN 训练的收敛速度, 训练数据集的输入和输出均被缩放为均值为 0、方差为 1 的数

据, 归一化处理如下式所示:

$$x^* = \frac{x_{\text{ori}} - \mu_{\text{mean}}}{\sigma_{\text{sd}}} \quad (9)$$

其中 x^* 表示归一化后的数据, x_{ori} 表示原始数据, μ_{mean} 表示输入或者输出数据的均值, σ_{sd} 表示输入或者输出数据的标准差。

表 1 参数的物理意义

Table 1 Physical meaning of parameters

参数	物理意义
T_t	总温
p_t	总压
ρ	点的密度
k_{turb}	湍流模型 k 的值
$x(x), y(x), z(x)$	流场中点的网格坐标
Ma	马赫数
t	温度
p	点的压力
$\nu_t(x)$	涡黏性系数
w_{turb}	湍流模型 w 的值
$u(x), v(x), w(x)$	流场中点的速度分量
C_{lim}	应力限制系数
κ	卡门常数

2 DNN 方法介绍

DNN 因其较强的非线性拟合能力而受到广泛关注。DNN 由三部分组成: 输入层、隐藏层和输出层。输入层和输出层中的神经元数量取决于输入和输出的大小, 隐藏层由多层神经元构成, 为了增加其非线性拟合能力, 隐藏层每层神经元后还接有激活函数。隐藏层层数、每层神经元的个数以及激活函数种类在很大程度上决定了神经网络的性能, 特别是对于隐藏层层数和每层神经元的个数影响最大。但到目前还没有一种普遍性的公式能用于确定网络中神经元的个数和层数, 主要还是依靠使用者的经验积累^[29]。

目前, DNN 的训练过程可分为三个步骤: 正向传播、损失函数计算和反向传播^[21]。在正向传播步骤中, 输入层接收到的输入值用以下方式传播到最终输出层:

$$Y^m = f^m(W^m Y^{m-1} + b^m) \quad (10)$$

其中 W^m 、 b^m 分别为第 m 层网络的网络权系数及其偏置, Y^m 为第 m 层网络的涡黏性系数输出值。

f^m 为第 m 层的激活函数, 它引入的目的是在产生的神经元中引入非线性。

在输出层, 使用正向传播获得的预测输出值 Y^{pred} 与实际输出值 Y^{actual} 之间的误差来衡量预测效果。误差值取决于损失函数(loss function), 一旦计算出损失函数, 它将被反向传播, 使用损失函数的梯度更新每个神经元的权重和偏差。在目前的工作中, 最有效的损失函数是方均根误差, 其定义如下:

$$L = \frac{1}{2} \sum_{i=1}^n (y_i^{\text{pred}} - y_i^{\text{actual}})^2 = \frac{1}{2} \sum_{i=1}^n (\delta_i)^2 \quad (11)$$

其中 n 为数据个数, y_i^{pred} 为第 i 个预测输出值, y_i^{actual} 为第 i 个实际输出值, $\delta_i = y_i^{\text{pred}} - y_i^{\text{actual}}$ 。反向传播过程中, 权重和偏差更新如下:

$$W_t^m = W_{t-1}^m - \eta \frac{\partial L}{\partial W_{t-1}^m} \quad (12)$$

$$b_t^m = b_{t-1}^m - \eta \frac{\partial L}{\partial b_{t-1}^m} \quad (13)$$

其中 W_t^m 为第 m 层 t 时刻的权重, b_t^m 为第 m 层 t 时刻的偏差, η 为 DNN 的学习率, 即搜索权重值的步长, $\partial L / \partial W$ 为梯度(gradient), “-”号表示权重的更新方向是朝损失函数减小的方向。

在这项工作中, 使用 Pytorch 框架创建 DNN 模型。搭建的网络输入层神经元个数为 6 个, 激活函数为 Tanh; 输出层神经元个数为 1 个, 不使用激活函数; 隐藏层个数为 6 个, 每层 40 个神经元, 使用 Tanh 激活函数, 由此搭建的网络如图 5 所示。采用 Adam 优化器进行训练, 学习率设置为 0.001, 在训练时使用自适应学习速率, 通过反向传播算法调整权重和偏差的值, 使代价函数最小化。




图 5 DNN 湍流涡黏性系数辨识网络

Fig. 5 DNN turbulent eddy viscosity coefficient identification network

3 结果与讨论

3.1 8个背压下406组预测样本的湍流涡黏性系数辨识实验与结果分析

在8个不同背压(0.23、0.24、0.25、0.26、0.27、0.28、0.30 MPa和0.31 MPa)下,共324 008个样本,根据8个背压随机选取406组数据用于训练完成后的预测数据,32 400组数据用于训练过程中的测试数据,剩余数据用于DNN训练。训练过程中的损失下降曲线如图6所示。




图6 DNN训练损失下降曲线

Fig. 6 DNN training loss decline curve

图6显示了DNN的收敛过程,迭代次数大约为300时,足以对输入-输出关系进行精确的参数化。训练样本的损失与测试样本的损失最低分别达到了 5.48682×10^{-4} 、 7.54169×10^{-4} ;图6的损失下降曲线表明,训练过程中DNN代理模型不断接近真实模型,最后建立的DNN代理模型可以保证在一定误差允许范围内对湍流涡黏性系数进行预测。

将预测数据集集中的406组数据放入训练好的DNN中进行预测。预测结果选用了方均根误差 E_{rms} 、可决系数 R^2 、真实结果与预测结果对比图、真实结果与预测结果之间的偏离程度图、预测偏差图等表述。

方均根误差 E_{rms} 为

$$E_{rms} = \sqrt{\frac{1}{406} \sum_{i=1}^{406} (y_i - y_i^{pred})^2} = 0.0009 \quad (14)$$


可决系数为

$$R^2 = 1 - \frac{\sum_{j=1}^{406} (y_j - y_j^{pred})^2}{\sum_{i=1}^{406} (y_i - \bar{y})^2} = 0.998 \quad (15)$$


其中 y_i 、 y_j 分别为第 i 、 j 个真实值, y_i^{pred} 、 y_j^{pred} 分别为第 i 、 j 个预测值, $\bar{y}$ 为平均值。

真实流场与预测流场结果对比图、偏离程度图以及预测偏差图如图7所示,其中横坐标点的顺序是按照真实湍流涡黏性系数升序排序确定,图7(b)中的直线是参考线。


对于预测的406组数据,方均根误差为0.0009,可决系数为0.998,湍流涡黏性系数预测值与真实值之间的变化趋势非常接近,预测值在回归曲线附近非常密集。表明这406组数据的预测精度较高。图7的真实结果与预测结果对比图、偏离程度图以及预测偏差图也表明了上述结论。基于此,可以初步得到结论:搭建的DNN能在满足一定精度的条件下对涡黏性系数进行预测。



(a) 真实值与预测值结果对比



(b) 真实值与预测值之间的偏离程度



(c) 预测值与真实值相对误差



图7 8个背压下406组预测样本预测结果分析

Fig. 7 Analysis of prediction results of 406 groups of prediction samples under 8 different pressures

3.2 一个背压为预测样本的湍流涡黏性系数辨识 实验与结果分析

本节在 3.1 节基础上, 利用 DNN 分别对 0.23 MPa 和 0.28 MPa 背压下的数据进行预测分析。选取了 8 个不同背压(0.23、0.24、0.25、0.26、0.27、0.28、0.30 MPa 和 0.31 MPa), 共 324 008 个样本。其他 7 个背压数据为训练样本集(其中, 90% 的数据作为 DNN 的训练样本, 10% 的数据作为训练过程中的测试样本)。

0.23 MPa 下的数据作为测试集, 实验结果的方均根误差为 0.001 5, 可决系数为 0.995 4, 测试结果如图 8 所示。预测的二维流场云图与真实 v_t 的二维流场云图如图 9 和图 10 所示。图 9 中 x 、 y 指的是所画构型对应的网格点坐标; 图 10 中 u 、 v 分别指的是它的横向、纵向速度。观察涡黏性系数所对应的流场速度分布特点, 检验不同的速度分布对涡黏性系数预测精度是否有显著的影响。后续相同参数表达的意义一致。



(d) 真实值与预测值分布统计密度(密度缩小了10倍)

图 8 一个背压为预测样本的预测结果分析(0.23 MPa)
Fig. 8 Analysis of prediction results with a back pressure of predicted sample (0.23 MPa)





图 9 流场预测结果分析(0.23 MPa)
Fig. 9 Analysis of prediction results of downstream flow field (0.23 MPa)







图10 速度场预测结果分析(0.23 MPa)


Fig. 10 Analysis of velocity field prediction results (0.23 MPa)

0.28 MPa 下的数据作为测试集, 实验结果的方根误差为 0.002 1, 可决系数为 0.993 8, 测试结果如图 11 所示, 预测的二维流场云图与真实 v_t 的二维流场云图如图 12 和图 13 所示。

对学习的统计评估如图 8(a) 和如图 11(a) 所示。在这些图中, 注意到 v_t 的预测值与真实值吻合较好, 特别是在峰值较小时。同时也注意到图 11(d) 的真实 v_t 的概率密度的最大值比图 8(d) 小得多, 从而表明数据的范围较窄。经过分析, 这可能是对 0.28 MPa 下训练数据集的 v_t 有更广泛的采样。同时, 预测模型和真实模型的概率分布图也显示出良好的一致性。注意到, DNN 准确地捕捉到了 v_t 量级。



(a) 真实值与预测值结果对比




(d) 真实值与预测值分布统计密度(密度缩小了10倍)

图11 一个背压为预测样本的预测结果分析(0.28 MPa)

Fig. 11 Analysis of prediction results with a back pressure of predicted sample (0.28 MPa)

进一步, 根据图 9 和图 12 的流场云图可以看出, DNN 预测的流场云图几乎与真实流场云图一致, 偏差主要集中在边界位置处。图 10 和图 13 的流场云图结果也能得出上述结论, 但 u 、 v 与偏差大小没有明显的关系。

(b) 横纵坐标分别为 x 、 y 的预测流场云图




图12 流场预测结果分析(0.28 MPa)

Fig. 12 Analysis of prediction results of downstream flow field (0.28 MPa)




图13 速度场预测结果分析(0.28 MPa)

Fig. 13 Analysis of velocity field prediction results (0.28 MPa)

3.3 增加训练样本对预测结果的影响

上述实验已经表明,对于单个背压下的流场, DNN 能很好的对其预测,且能够较为准确地再现流场变化趋势。进一步,增加样本数,共选取 10 个背压,其中选取 8 个不同背压(0.23、0.24、0.25、0.26、0.27、0.28、0.30 MPa 和 0.31 MPa)的数据进

行 DNN 训练(90% 的数据作为训练数据,10% 的数据用于训练过程中测试),分别对另外两个背压(0.22 MPa,在训练集外部;0.29 MPa,在训练集内部)下的数据进行预测。

0.22 MPa 下的数据作为测试集,实验结果的方均根误差为 0.001 4,可决系数为 0.995 6,预测结果如图 14 所示,预测的二维流场云图与真实 v_t 的二维流场云图如图 15 和图 16 所示。







图14 8个不同背压为训练集条件下预测结果分析(0.22 MPa)

Fig. 14 Analysis of prediction results under 8 different back pressure training sets (0.22 MPa)

0.29 MPa 下的数据作为测试集, 实验结果的方均根误差为 0.001 8, 可决系数为 0.995 7, 预测结果如图 17 所示, 预测的二维流场云图与真实 v_t 的二维流场云图如图 18 和图 19 所示。




图 15 8 个不同背压为训练集条件下流场预测结果分析 (0.22 MPa)

Fig. 15 Analysis of prediction results of downflow field under 8 different back pressure training sets (0.22 MPa)









图 16 8 个不同背压为训练集条件下速度场预测结果分析 (0.22 MPa)

Fig. 16 Analysis of velocity field prediction results under 8 different back pressures training sets (0.22 MPa)

观察在 0.22 MPa 和 0.29 MPa 下的结果, 可以得出与 3.2 节实验一样的结论。对比 3.2 节中的实验, 发现在增加样本数据集的情况下, 训练集背压外的数据在 3.3 节实验中精度有所提升, 同时, 训练集背压内的数据在 3.3 节实验中精度也有所提升, 突出了增加样本数据量给 DNN 的预测精度提升带来的优势。











(d) 真实值与预测值分布统计密度 (密度缩小了10倍)

图 17 8 个不同背压为训练集条件下预测结果分析
(0.29 MPa)

Fig. 17 Analysis of prediction results under 8 different back pressure training sets (0.29 MPa)

(a) 横纵坐标分别为 x 、 y 的真实流场云图(b) 横纵坐标分别为 x 、 y 的预测流场云图(c) 横纵坐标分别为 x 、 y 的真实流场与预测流场的
相对误差云图图 18 8 个不同背压为训练集条件下流场预测
结果分析(0.29 MPa)Fig. 18 Analysis of prediction results of downflow field under
8 different back pressure training sets (0.29 MPa)(a) 横纵坐标分别为 u 、 v 的真实流场云图(b) 横纵坐标分别为 u 、 v 的预测流场云图(c) 横纵坐标分别为 u 、 v 的真实流场与预测流场的
相对误差云图图 19 8 个不同背压为训练集条件下速度场预测
结果分析(0.29 MPa)Fig. 19 Analysis of velocity field prediction results under 8
different back pressures training sets (0.29 MPa)

通过 3.1 节实验的验证,可以初步得出:通过神经网络,选择 x 、 y 、 u 、 v 这几个特征参数能够辨识对应网格点下的湍流涡黏性系数。在 3.1 节实验的基础上,开展的 3.2 节实验验证了神经网络对某个背压下,整个流场点涡黏性系数的外插及内插能力,表明了搭建的神经网络能够很好地预测外插、内插的整个流场涡黏性系数。3.3 节实验,进一步增加了数据集,验证数据集的增加对整个流场点涡黏性系数预测精度的影响。

4 结 论

本文将 DNN 引入 RNAS 方程,通过建立代理模型代替湍流模型计算,使 RANS 方程封闭。以 Wilcox-2006 $k-\omega$ 湍流模型为对象开展了相关研究,经过仿真和实验,得到以下结论:

1) 初步证明了 DNN 对湍流涡黏性系数预测的可行性,对不同背压下的数据点进行了预测,预测值较好地分布在了回归曲线两侧,特别是在涡黏性系数较低的值上,但在涡黏性系数较高的值上观察到的偏差相对较大。

2) 真实流场云图与预测流场云图的分布统计密度图表明:在涡黏性系数值较小的地方样本

点较多,仅0.001以下的数据点就占了整个数据集的一半以上,这侧面反映了训练集的数据点在采样时更集中在涡黏性系数值较小的地方,进而影响了涡黏性系数较大处数据点的训练和预测。后续可针对涡黏性系数进行均匀采样,进而提高模型在涡黏性系数较高处的预测精度。

3) 搭建的DNN能很好的再现湍流流场,各背压下预测数据集的可决系数接近于1,表明湍流涡黏性系数预测值与真实值之间的变化趋势非常接近,预测值在回归曲线附近非常得密集。观察所得到的流场云图,可以看出,预测的云图与真实云图几乎一样。该网络能很好的预测其变化趋势。

本文的相关工作已经初步表明,该方法在求解RANS方程中的可行性,在下一步的工作当中,我们将该DNN嵌入CFD软件当中,用于代替湍流模型计算湍流涡黏性系数,使RANS方程封闭,从而加速CFD计算。

参考文献:

- [1] 陈植. 超燃冲压发动机隔离段流动机理及其控制的试验研究[D]. 合肥: 国防科学技术大学, 2015.
CHEN Zhi. Experimental study on flow mechanism and control of isolation section of scramjet engine[D]. Hefei: National University of Defense Technology, 2015. (in Chinese)
- [2] DOLLING D S. Fifty years of shock-wave/boundary-layer interaction research: what next?[J]. *AIAA Journal*, 2001, 39(8): 1517-1531.
- [3] 贺武生. 超燃冲压发动机研究综述[J]. *火箭推进*, 2005(1): 29-32.
HE Wusheng. A review of scramjet research[J]. *Journal of Rocket Propulsion*, 2005(1): 29-32. (in Chinese)
- [4] MATSUO K. Shock train and pseudo-shock phenomena in supersonic internal flows[J]. *Journal of Thermal Science*, 2003(3): 204-208.
- [5] 詹王杰, 严红. 隔离段内激波串受稳态和脉动背压影响的数值研究[J]. *推进技术*, 2021, 42(5): 980-990.
ZHAN Wangjie, YAN Hong. Numerical study on the influence of shock string on steady-state and pulsating back pressure in isolation section[J]. *Journal of Propulsion Technology*, 2021, 42(5): 980-990. (in Chinese)
- [6] 吴正园, 莫凡, 高振勋, 等. 湍流边界层与高温气体效应耦合的直接数值模拟[J]. *空气动力学学报*, 2020, 38(6): 1111-1119.
WU Zhengyuan, MO Fan, GAO Zhenxun, et al. Direct numerical simulation of coupling of turbulent boundary layer and hot gas effect[J]. *Acta Aerodynamica Sinica*, 2020, 38(6): 1111-1119. (in Chinese)
- [7] XIAO Heng, CINNELLA P. Quantification of model uncertainty in RANS simulations: a review[J]. *Progress in Aerospace Science*, 2019, 108: 1-31.
- [8] 尹宇辉, 李浩然, 张宇飞, 等. 机器学习辅助湍流建模在分离流预测中的应用[J]. *空气动力学学报*, 2021, 39(2): 23-32.
YIN Yuhui, LI Haoran, ZHANG Yufei, et al. Application of machine learning-assisted turbulence modeling in separated flow prediction[J]. *Acta Aerodynamica Sinica*, 2021, 39(2): 23-32. (in Chinese)
- [9] CRAFT T J, LAUNDER B E, SUGA K. Development and application of a cubic eddy-viscosity model of turbulence[J]. *International Journal of Heat and Fluid Flow*, 1996, 17(2): 108-115.
- [10] SPALART P R. Strategies for turbulence modelling and simulations[J]. *International Journal of Heat and Fluid Flow*, 2000, 21(3): 252-263.
- [11] STEFANO M, HOSDER S, BAURLE R A. Effect of turbulence model uncertainty on scramjet isolator flowfield analysis[J]. *Journal of Propulsion and Power*, 2019, 36(1): 1-14.
- [12] SCHAEFER J, HOSDER S, WEST T, et al. Uncertainty quantification of turbulence model closure coefficients for transonic wall-bounded flows[J]. *AIAA Journal*, 2017, 55(1): 195-213.
- [13] XIAO H, WU J L, WANG J X, et al. Quantifying and reducing model form uncertainties in Reynolds-averaged Navier-Stokes simulations: a data-driven, physics informed Bayesian approach[J]. *Journal of Computational Physics*, 2016, 324: 115-136.
- [14] MAULIK R, SAN O, RASHEED A, et al. Data-driven deconvolution for large eddy simulations of Kraichnan turbulence[J]. *Physics of Fluids*, 2018, 30(12): 125109.1-125109.15.
- [15] YARLANKI S, RAJENDRAN B, HAMANN H. Estimation of turbulence closure coefficients for data centers using machine learning algorithms[R]. San Diego, Canada: 13th Intersociety Conference on Thermal and Thermomechanical Phenomena in Electronic Systems, 2012.
- [16] ZHANG Zejia, DURAISAM K. Machine learning methods for data-driven turbulence modeling[R]. Dallas, US: 22nd AIAA Computational Fluid Dynamics Conference, 2015.
- [17] KAANDORP M. Machine learning for data-driven RANS turbulence modelling[D]. Delft, US: Delft University of Technology, 2018.
- [18] SAKAAR B, YASER A, SHAOWU P, et al. Prediction of aerodynamic flow fields using convolutional neural networks[J]. *Computational Mechanics*, 2019, 64(2): 525-545.
- [19] ZHU Linyang, ZHANG Weiwei, KOU Jiaqing, et al. Machine learning methods for turbulence modeling in subsonic flows around airfoils[J]. *Physics of Fluids*, 2019, 31(1): 015105.1-015105.14.
- [20] PANDA J P, WARRIOR H V. Data-driven prediction of complex flow field over an axisymmetric body of revolution using machine learning[J]. *Fluid Dynamics (preprint)*, 2021, arXiv: 2111.07937.
- [21] SHUVAYAN B, ANANTHAKRISHNAN B, HIDEAKI O. Fast estimation of internal flowfields in scramjet intakes via reduced-order modeling and machine learning[J]. *Physics of Fluids*, 2021, 33(10): 106110.1-106110.24.
- [22] SUN Xuxiang, CAO Wenbo, LIU Yilang, et al. High Reynolds number airfoil turbulence modeling method based on machine learning technique[J]. *Computers and Fluids*, 2022, 236: 105298.1-105298.30.
- [23] 何创新, 邓志文, 刘应征. 湍流数据同化技术及应用[J]. *航空学报*, 2021, 42(4): 167-184.
HE Chuangxin, DENG Zhiwen, LIU Yingzheng. Turbulent data assimilation technology and its application[J]. *Chinese Journal of Aeronautics*, 2021, 42(4): 167-184. (in Chinese)
- [24] LI Yunfei, CHANG Juntao, KONG Chen, et al. Recent progress of machine learning in flow modeling and active flow control[J]. Chi-

- nese Journal of Aeronautics, 2021, 35(4): 14-44.
- [25] KONG Chen, CHANG Juntao, LI Yunfei, et al. Flowfield reconstruction and shock train leading edge detection in scramjet isolators[J]. *AIAA Journal*, 2020, 58(9): 4068-4080.
- [26] KONG Chen, CHANG Juntao, LI Yunfei, et al. A deep learning approach for the velocity field prediction in a scramjet isolator[J]. *Physics of Fluids*, 2021, 33(2): 026103.1-026103.18.
- [27] KONG Chen, CHANG Juntao, WANG Ziao, et al. Prediction model of flow field in an isolator over various operating conditions[J]. *Aerospace Science and Technology*, 2021, 111: 106576.1-106576.14.
- [28] LI Nan, CHANG Juntao, XU Kejing, et al. Prediction dynamic model of shock train with complex background waves[J]. *Physics of Fluids*, 2017, 29: 116103.1-116103.16.
- [29] KUKREJA H, BHARATH N, SIDDESH C S, et al. An introduction to artificial neural network[J]. *International Journal of Advance Research and Innovative Ideas in Education*, 2016, 1: 27-30.

(编辑: 秦理曼)