

文章编号: 1000-8055(2024)10-20220759-15

doi: 10.13224/j.cnki.jasp.20220759

基于神经网络的 SST 湍流代理模型研究及应用

梁爽^{1,3}, 郭明明^{2,3}, 易森荣³, 田野³, 宋文艳¹, 杨茂桃^{2,3},
张依³, 乐嘉陵^{1,3}

- (1. 西北工业大学 动力与能源学院, 西安 710072;
2. 西南科技大学 信息工程学院, 四川 绵阳 621000;
3. 中国空气动力研究与发展中心, 四川 绵阳 621000)

摘 要: 针对传统湍流模型参数众多且获取复杂流动数据慢的问题, 研究多种神经网络算法用于求解超声速流动中雷诺平均(Navier-Stokes)求解器的湍流代理模型。以超声速流动条件下的凹槽为例, 应用拉丁超立方抽样方法, 获取标准 SST 湍流模型的 9 个参数样本空间; 采用自主研发的高超声速内外流耦合数值模拟软件 AHL3D, 在来流马赫数为 2.92 下开展数值模拟, 获得壁面压力数据, 构建数据集; 搭建了深度神经网络(deep neural networks, DNN)、残差神经网络(residual neural network, ResNet)、长短时记忆网络(long short-term memory, LSTM)等多种模型对数据集进行训练, 从而形成 SST 湍流代理模型。实验结果表明: 在给定 SST 湍流模型系数下, 3 种神经网络代理模型均能高精度地预测壁面压力, 可决系数达到了 0.99 以上, 与数值模拟求解器结果基本一致, 可用于快速获取不同湍流模型参数下的壁面压力。

关键词: 凹槽; SST 湍流模型; 神经网络; 湍流代理模型; 壁面压力
中图分类号: V211.3 **文献标志码:** A

Research and application of SST turbulence surrogate model based on neural network

LIANG Shuang^{1,3}, GUO Mingming^{2,3}, YI Miaorong³, TIAN Ye³, SONG Wenyan¹,
YANG Maotao^{2,3}, ZHANG Yi³, LE Jialing^{1,3}

- (1. School of Power and Energy, Northwestern Polytechnical University, Xi'an 710072, China;
2. School of Information Engineering,
Southwest University of Science and Technology, Mianyang Sichuan 621000, China;
3. China Aerodynamic Research and Development Center, Mianyang Sichuan 621000, China)

Abstract: In view of the problem that traditional turbulence model has many parameters and is slow to obtain complex flow data, various kinds of neural network algorithms were studied to construct the turbulence surrogate model of the Navier-Stokes solver in supersonic flow. The cavity under supersonic flow conditions was taken as the research object, and the Latin hypercube sampling method was used to obtain the sample space of nine parameters of the standard SST turbulence model. The independently developed hypersonic internal and external flow coupling numerical simulation software AHL3D was used to carry out numerical simulation at the incoming flow Mach number of 2.92 Ma to obtain the wall pressure data, and then the dataset was constructed. Various kinds of models such as deep neural networks

收稿日期: 2022-10-01

基金项目: 国家自然科学基金(12002362)

作者简介: 梁爽(1999—), 男, 硕士生, 主要从事人工智能及超燃冲压发动机技术的研究。E-mail: liang199966@163.com

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

引用格式: 梁爽, 郭明明, 易森荣, 等. 基于神经网络的 SST 湍流代理模型研究及应用[J]. 航空动力学报, 2024, 39(10): 20220759. LIANG Shuang, GUO Mingming, YI Miaorong, et al. Research and application of SST turbulence surrogate model based on neural network[J]. Journal of Aerospace Power, 2024, 39(10): 20220759.

(DNN), residual neural network (ResNet), and long short-term memory (LSTM), which were trained by the training dataset, were used to build the SST turbulence surrogate model. The experimental results showed that: under certain SST turbulence model parameters, these three neural network surrogate models can predict the wall pressure with high accuracy, and the coefficient of determination was above 0.99, which was basically consistent with the results of the numerical simulation solver, and can be used to quickly obtain the wall pressure under different turbulence model parameters.

Keywords: cavity; SST turbulence surrogate model; neural networks; turbulence surrogate model; wall pressure

流场内部的静压并不容易测量,因为任何侵入式的测量都会对流动有干扰,引起流体压力的变化,破坏流场本身结构,而非接触式的光学类测量则得不到压力信息。由于流体在壁面附近处的压力较容易获取,且它包含了燃烧、流动过程的许多重要信息,因此壁面压力数据的获取在地面风洞试验、飞行试验和数值模拟中十分重要。众多学者利用壁面压力开展了相关工作,王西耀等^[1]针对直连式超燃冲压发动机,原创性地提出了基于壁面压力测量结果的试验参数分析方法,不仅丰富了试验参数类别,还提高了参数分析速度。唐兰等^[2]在非对称喷管的设计上,通过指定壁面压力分布规律来反设计其膨胀面型线。浮强等^[3]的实验表明:通过燃烧室实时壁面压力反馈来调节供油控制燃烧室工作状态是可能的。Li等^[4]通过非嵌入式多项式混沌展开(Non-Intrusive Polynomial Chaos, NIPC)构建壁面压力代理模型,利用贝叶斯方法校正了 Spalart-Allmaras (SA) 湍流模型参数。此外,在数值模拟工作中,研究者还经常将计算得到的壁面压力结果与实验测量结果进行对比,从而检验计算正确性。综上,壁面压力数据被广泛地应用于工程的各个方面。因此,如何在实验和数值模拟中低成本、高精度、快速地获取壁面压力数据变得十分有意义。

目前,随着机器学习技术和数据驱动方法的不断发展^[5-6],研究者利用机器学习算法开展了大量的研究工作,在构型优化,提升计算流体动力学(CFD)计算速度、精度等方面取得了许多进展。Zhang等^[7]研究了机器学习模型从高保真模拟和实验数据中提取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。Zhang等^[8]将高维模型表示(HDML)技术与高斯过程机器学习(GPML)方法相结合,构造代理模型,然后将所构造的代理应用于贝叶斯推理过程,得到模型参数的后验分布,从而用于

参数校正,最后得到了一个较优的结果。Zhu等^[9]以SA模型计算的涡黏度为目标,开展了神经网络数据驱动湍流模型工作,该模型可以应用于各种翼型和流动状态,预测的涡黏度、升阻系数和表面摩擦分布与原始SA模型的结果吻合较好。Di Stefano等^[10]开展了多种湍流模型在超燃冲压发动机隔离段流场激波串前缘位置检测的不确定度量化的研究,获得了不同湍流模型参数对输出的影响程度。Panda等^[11]利用人工神经网络算法构建了机器学习模型,对经典CFD方法进行了替代。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。Brahmachary等^[12]针对进气道流场的预测问题,开展了特征正交分解(proper orthogonal decomposition, POD)降阶模型的多层感知机代理模型研究,成功减少了流场预测过程中的计算时间。Maulik等^[13]利用深度神经网络构建了湍流涡黏度代理模型,加速了计算。

综上,国内外学者利用神经网络对湍流模型开展了大量研究工作,取得了较好的结果。因此,考虑到现有实验方法和数值模拟计算获取复杂流动数据成本高昂以及慢的问题,研究多种神经网络方法用于求解超声速流动中雷诺平均求解器的湍流代理模型。因此,本文以超声速流动条件下的凹槽(简称超声速凹槽)为例,利用标准SST湍流模型开展了基于神经网络的壁面压力预测研究。通过深度神经网络(deep neural networks, DNN)、残差神经网络(residual neural network, ResNet)、长短时记忆网络(long short-term memory, LSTM)等方法,建立了SST湍流模型输入参数与壁面压力的高维、非线性映射关系,分析了不同神经网络方法对超声速凹槽壁面压力的预测精度,验证了应用神经网络方法构建湍流代理模型的可行性。本文的工作主要包括以下几个部分:①针对超声速凹槽,本文通过拉丁超立方抽样获取了不同

SST 湍流模型参数下的样本空间, 应该课题组自主设计的高精度数值模拟软件 AHL3D, 生成了不同湍流模型参数下所对应的壁面压力曲线数据, 并进行了灵敏度分析; ②构建了包括 DNN、ResNet、LSTM 等多种神经网络模型, 利用数据进行训练, 学习了超声速凹槽壁面压力与湍流模型参数之间的关系, 得到了 SST 湍流代理模型。最终获得的壁面压力曲线与 SST 湍流模型结果之间的误差较小, 初步验证了神经网络在保证一定预测精度的前提下, 代替湍流模型计算壁面压力的可行性; ③讨论了在多种特征辨识参数的情况下, DNN、ResNet、LSTM 等神经网络对壁面压力的预测能力。

1 数据集建立及分析

1.1 计算模型及边界条件

选择如图 1 所示的二维凹槽开展相关工作 (其中 Ma_∞ 为来流马赫数, T_∞ 为来流静温, p_∞ 为来流静压), 它来自于文献 [14], 里面提供了大量的实验数据。如图 1 所示, 来流入口处是长为 22.9 cm 的平板, 平板后紧跟着一个高为 2.54 cm 的台阶和长为 6.19 cm 的平板, 然后接着一个长约 16 cm、与水平方向倾斜 20° 的平面坡道。根据分析, 湍流边界层最初会在这个 22.9 cm 长的平板上形成, 然后在后向台阶上分离。产生的自由剪切层跨越这个 2.54 cm 高的台阶, 最后重新附着平面坡道上。




图 1 超声速凹槽构型

Fig. 1 Supersonic cavity configuration

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数值模拟软件 AHL3D 进行超声速凹槽数值模拟计算, 它可进行二维、三维, 及其他等多种条件下的模拟计算, 并且该软件的计算可靠性已经得到了多方面的验证。对于该计算模型, 计算域的入口边界按照超声速来流条件给定所有进口参数, 并且没有添加任何扰动条件。其中来流马赫数为 $Ma_\infty = 2.92$ 、来流静压为 $p_\infty = 21.1669 \text{ kPa}$ 、来流静温为 $T_\infty = 95.37 \text{ K}$, 采用无滑移绝热壁面。在定常、完全气体条件下, 利用雷

诺平均纳维-斯托克斯方程 (Reynolds averaged Navier-Stokes, RANS)、标准 SST 湍流模型开展二维湍流 N-S 方程求解。

1.2 网格生成及计算域

为了说明超声速凹槽数值计算精度与网格数量无关, 首先需对该构型进行网格无关性分析。网格的独立性通过上述边界条件和计算方法进行验证, 因此本文共构建了 11 694、29 888、50 388 这 3 种网格。在这 3 种网格数下, 标准 SST 湍流模型计算得到的超声速凹槽壁面压力曲线如图 2 所示。可以发现, 3 种网格得到的结果整体趋势一致, 说明当网格数达到 11 694 时, 已经满足计算精度要求, 无需对网格进行进一步细化。因此, 为了避免不必要的计算, 降低计算成本, 平衡计算的精度和速度。本文选择总数为 29 888 的网格进行后续计算。

因此, 最终确定的网格模型如图 3 所示, 为了保证壁面的精度, 还进行了局部加密, 整体网格量为 29 888。利用该网格模型, AHL3D 在上述来流条件下, 使用标准 SST 湍流模型 (模型系数采用标称值 Normal) 计算得到的马赫数分布云图如




图 2 网格无关性分析

Fig. 2 Mesh Independence Analysis




图 3 网格模型

Fig. 3 Grid model

图 4 所示。最后,为了进一步验证该软件计算结果的正确性,本文将计算结果的壁面压力,摩阻系数,以及 $x = -2.54$ 、 $x = 3.81$ 、 $x = 6.35$ cm 和 $x = 8.89$ cm 处的速度剖面与该工况下的实验结果进行了对比,如图 5~图 7 所示(其中 C_f 为摩阻系数, U/U_∞ 为当前位置速度与来流速度的比值)。经过反复检验以及对比,该结果与文献 [15-16] 等文献取得的结果几乎一致,表明了 AHL3D 计算结果的正确性。




图 4 马赫数分布云图




图 5 壁面压力计算结果与实验结果对比
Fig. 5 Comparison between the calculated results and the experimental results for wall pressure





图 6 摩阻系数计算结果与实验结果对比
Fig. 6 Comparison between the calculated results and the experimental results for frictional coefficient


1.3 标准 SST 湍流模型

剪应力输运 (Shear Stress Transport, SST) 模型


是由 Menter 于 1994 年提出的^[17], 其基本思路是通过变形, 将 $k-\varepsilon$ 湍流模型与 Wilcox 两方程 $k-\omega$ 湍流模型通过混合函数结合起来。在近壁面使用 $k-\omega$ 模型, 在远离壁面充分发展的流场中采用 $k-\varepsilon$ 湍流模型, 充分结合了 $k-\omega$ 模型对分离流模拟精度高和鲁棒性以及 $k-\varepsilon$ 模型对湍流初始参数敏感



(a) $x = -2.54$ cm



(b) $x = 3.81$ cm



(c) $x = 6.35$ cm




图 7 流场速度剖面计算结果与实验结果的对比

Fig. 7 Comparison between the calculated results and the experimental results for velocity profile of flow field

度低的优势。因此, SST 成了当前应用最广的湍流模型之一^[18]。

原始通用的标准 SST 湍流模型方程如下:

$$\frac{D\rho k}{Dt} = \tau_{ij} \frac{\partial u_i}{\partial x_j} - \beta^* \rho \omega k + \frac{\partial}{\partial x_j} \left[(\mu + \sigma_k \mu_t) \frac{\partial k}{\partial x_j} \right] \quad (1)$$

$$\begin{aligned} \frac{D\rho \omega}{Dt} = & \frac{\partial}{\partial x_j} \left[(\mu + \sigma_\omega \mu_t) \frac{\partial \omega}{\partial x_j} \right] + \frac{\gamma}{\mu_t} \tau_{ij} \frac{\partial u_i}{\partial x_j} - \beta \rho \omega^2 + \\ & 2\rho (1 - F_1) \sigma_{\omega 2} \frac{1}{\omega} \cdot \frac{\partial k}{\partial x_j} \cdot \frac{\partial \omega}{\partial x_j} \end{aligned} \quad (2)$$

式中, $i = 1, 2, 3$ 且 $j = 1, 2, 3$ 。其中

$$\gamma = \frac{\beta}{\beta^*} - \sigma_w \frac{\kappa^2}{\sqrt{\beta^*}} \quad (3)$$

$$F_1 = \tanh(g_1^4) \quad (4)$$

$$g_1 = \min \left[\max \left(\frac{\sqrt{k}}{\beta^* \omega d}, \frac{500\nu}{d^2 \omega} \right), \frac{4\rho \sigma_{w2} k}{C_{kw} d^2} \right] \quad (5)$$

$$C_{kw} = \max \left(2\rho \sigma_{\omega 2} \frac{1}{\omega} \cdot \frac{\partial k}{\partial x_j} \cdot \frac{\partial \omega}{\partial x_j}, 10^{-20} \right) \quad (6)$$

SST 模型湍流黏度表达式如下:

$$\mu_t = \frac{a_1 \rho k}{\max(a_1 \omega, SF_2)} \quad (7)$$

$$F_2 = \tanh(g_2^2) \quad (8)$$

$$g_2 = \max \left(\frac{2\sqrt{k}}{\beta^* \omega d}, \frac{500\mu}{\omega d^2} \right) \quad (9)$$

式中 k 为湍流动能; ω 为湍流特殊耗散; t 为时间; ρ 为密度; u_i 为湍流速度; x_j 为坐标分量; μ 为层流黏度; μ_t 为湍流黏度; d 为到壁面的距离; τ_{ij} 为雷诺应力张量的分量; S 为涡度张量; F_1 为混合函数, 在紧靠壁面处为 $F_1 = 1$, 此时激活原始的 $k-\omega$ 模型; 在远离壁面时 $F_1 = 0$, 此时激活 $k-\varepsilon$ 模型。 σ_k 、 σ_ω 、 β 、 β^* 、 κ 、 a_1 为模型常数, 其中 β^* 、 κ 、 a_1 固定不变, 取值分别为 0.09、0.41、0.31。 σ_k 、 σ_ω 、 β 随着 F_1 变化 ($k-\varepsilon$ 中为 $\sigma_{k1} = 0.85$ 、 $\sigma_{\omega 1} = 0.5$ 、 $\beta_1 = 0.075$, $k-\omega$ 中为 $\sigma_{k2} = 1.0$ 、 $\sigma_{\omega 2} = 0.856$ 、 $\beta_2 = 0.0828$)。若用 ϕ_1 表示 $k-\omega$ 模型中的常数, 用 ϕ_2 表示 $k-\varepsilon$ 模型中的常数, 则 SST 模型中的常数 $\phi(\sigma_k, \sigma_\omega, \beta)$ 为:

$$\phi = F_1 \phi_1 + (1 - F_1) \phi_2 \quad (10)$$

大量工程实际应用已经表明: 标准 SST 湍流模型在处理存在逆压梯度和边界层分离的流动问题方面表现良好。但标准 SST 湍流模型是在不可压缩条件下发展起来的, 建模后的雷诺应力具有各向同性的性质, 对具有方向性的力不敏感, 一些其他行为的影响被忽略^[19]。随着计算能力的提升, 应用范围的拓展, 标准 SST 湍流模型在一些问题上显现出预测能力不足的问题。如在文中第 1.2 节中, 标准 SST 湍流模型的计算结果就与实验结果有一定差别。目前, 在旋转/曲率效应、可压缩性效应、激波不稳定性效应、雷诺应力各向异性效应、应力-应变偏差效应和层流-湍流转换效应等几个方面, 一些修正的 SST 湍流模型被提出。如在考虑可压缩性效应方面, 湍动能方程中应当增加结构可压缩性和膨胀可压缩性修正的源项^[20]。因此, 基于数据驱动的 SST 湍流模型修正也是本文后续将要开展的工作。

1.4 数据获取及预处理

根据文中第 1.3 节叙述, 标准 SST 湍流模型拥有 9 个模型系数, 每个系数都有一个由工程经验确定的标称值(normal)。在实际应用过程中, 针对不同的流动问题, 标称值可能不是其最优参数。模型系数的值选择不同, 最终 SST 湍流模型计算得到的结果也不同。因此, 本文选择湍流模型系数 (σ_{k1} 、 σ_{k2} 、 $\sigma_{\omega 1}$ 、 $\sigma_{\omega 2}$ 、 β^*/β_1 、 β^*/β_2 、 β^* 、 κ 、 a_1 , 变化区间如表 1 所示) 作为神经网络训练和测试数据的控制参数。在表 1 的区间范围内, 本文选择拉丁超立方抽样(Latin hypercube sampling,

表 1 SST 湍流模型系数及区间

Table 1 SST turbulence model parameters and intervals

系数	标称值	最小值	最大值
σ_{k1}	0.85	0.7	1.0
σ_{k2}	1.0	0.8	1.2
σ_{w1}	0.5	0.3	0.7
σ_{w2}	0.856	0.7	1.0
β^*/β_1	1.20	1.19	1.31
β^*/β_2	1.087 0	1.05	1.45
β^*	0.09	0.077 6	0.101 6
κ	0.41	0.38	0.42
a_1	0.31	0.31	0.40

LHS), 对 SST 湍流模型的 9 个系数进行随机抽样组合(如图 8), 形成 110 组模型参数样本空间。

进一步, 以超声速凹槽的壁面压力生成为例, 在 AHL3D 软件中使用标准 SST 湍流模型求解流场, 根据上述的来流、边界条件, 改变不同的模型参数, 产生稳定状态的壁面压力文件, 按照湍流模型参数、位置点和位置点对应的稳态壁面压力数据的格式, 逐点保存数据。最终得到了如图 9




图 8 拉丁超立方抽样结果

Fig. 8 Latin hypercube sampling results




图 9 110 组壁面压力曲线

Fig. 9 110 groups of wall pressure curves

所示的 110 组不同 SST 湍流模型参数下的凹槽壁面压力曲线。

进一步, 为提升神经网络训练的收敛速度, 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:

$$x_d^* = \frac{x_d - \mu_d}{\sigma_d} \quad (11)$$

其中 μ_d 为输入或者输出数据的均值; σ_d 为输入或者输出数据的标准差。

1.5 灵敏度分析

为了确定标准 SST 湍流模型各参数对计算的壁面压力的影响程度, 本文用非嵌入式多项式混沌展开(non-intrusive polynomial chaos, NIPC)方法随机展开和传播这些参数的不确定性, 并利用 Sobol 指数分析所有参数对壁面压力的影响。

首先, 利用文中第 1.4 节中构建的数据集, 构建湍流模型参数与壁面压力的关系。

$$y(x, \xi) \approx \sum_{i=0}^P \alpha_i(x) \Psi_i(\xi) \quad (12)$$

其中 y 为壁面压力序列; x 为湍流模型参数构成的矩阵; α 是待求解的系数矩阵, $(P+1)$ 表示多项式展开的项数, 计算表达式为 $P = C_{n+p}^p$, p 为多项式阶数(采用 2 阶展开); ξ 为 n 维随机变量(n 为不确定变量的数量, 即湍流模型参数的个数); $\Psi_i(\xi)$ 为 NIPC 的基函数矩阵。

式(12)多项式的系数矩阵 α 可应用最小二乘法对参数进行估计, 从而得到估计的系数矩阵 $\hat{\alpha}$:

$$\hat{\alpha} = (H^T H)^{-1} H^T Y_p \quad (13)$$

式中 Y_p 为目标值(壁面压力)矩阵, H 为多项式样本矩阵, 表达式如式(14)所示:

$$H = \begin{pmatrix} \Psi_0(\xi^0) & \Psi_1(\xi^0) & \cdots & \Psi_p(\xi^0) \\ \Psi_0(\xi^1) & \Psi_1(\xi^1) & \cdots & \Psi_p(\xi^1) \\ \vdots & \vdots & \ddots & \vdots \\ \Psi_0(\xi^{(N_s-1)}) & \Psi_1(\xi^{(N_s-1)}) & \cdots & \Psi_p(\xi^{(N_s-1)}) \end{pmatrix} \quad (14)$$

式中 N_s 为随机变量 ξ 总的采样点的个数。

利用式(15)求得标准 SST 湍流模型参数的 Sobol 指数^[21]。

$$S_{i_1, \dots, i_s} \approx \frac{D_{i_1, \dots, i_s}}{D} \quad (15)$$

Sobol 指数表示为每个随机变量的方差 $D_{i_1, \dots, i_s}$ 与总方差 D 的比值, 式(15)的详细介绍可参考文献

献 [21]。

为了评估标准 SST 湍流模型系数在不同位置处对壁面压力的影响程度, 本文得到了图 10 所示的不同位置点的 Sobol 指数。




图 10 不同位置点的 Sobol

Fig. 10 Sobol for different locations

在图 10 中, $x < 6$ cm 区域(台阶后的平板位置), 方差主要由 β^* 、 β_1 、 β_2 三个系数决定。在 $x > 6$ cm 区域(斜坡), 相比 $x < 6$ cm 区域, 模型系数对壁面压力的影响发生了明显的改变, 方差主要由 β^* 、 β_1 决定。

进一步, 本文还获得了模型系数对整体壁面压力的影响大小(图 11)。




图 11 模型系数的对壁面压力的影响大小

Fig. 11 Influence of turbulence model parameters on wall pressure

由图 11 可以看出, SST 湍流模型的 3 个参数 β^* 、 β_1 、 β_2 对壁面压力的方差贡献超过 80%, 这 3 个参数对壁面压力的计算结果有着重要影响。同时, 考虑到 SST 湍流模型的其他 6 个参数对壁面压力的方差贡献接近 20%, 且量级相同, 这 6 个参数的整体影响程度不可忽略。因此, 在神经网络

特征辨识壁面压力时, 为了保证较高的预测精度, SST 湍流模型的 9 个系数都应被考虑。

2 神经网络方法介绍

目前, 神经网络方法已在各个领域得到了广泛的应用。下面, 本文以基本的深度神经网络为例, 逐步开展神经网络方法的介绍。

基本的深度神经网络(DNN)相较于普通的人工神经网络具有更深的网络结构, DNN 的基本结构如图 12 所示, 它由 3 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, 隐藏层神经元数量由使用者根据经验自行定义, 为了增加其非线性拟合能力, 隐藏层神经元后还接有激活函数[22]。




图 12 DNN 基本结构

Fig. 12 Basic structure of DNN

输入层接收到的输入值按以下方式传播到输出层:

$$\mathbf{Y}^k = f^k(\mathbf{W}^k \mathbf{Y}^{k-1} + \mathbf{b}^k) \quad (16)$$

其中 $\mathbf{Y}^k$ 为第 k 层的输出; $\mathbf{W}^k$ 、 $\mathbf{b}^k$ 分别为第 k 层网络的权重系数及其偏置; $f^k(\cdot)$ 为第 k 层的激活函数。

残差神经网络(ResNet)在 DNN 的基础上, 在隐藏层之间使用跳跃连接, 形成了残差块, 因此 ResNet 可以轻松使用反向传播, 更容易避免梯度消失, 使得设计非常深的网络成为可能, 它在图像识别任务方面取得了非常好的结果, 残差块的基本结构如图 13[23]。

长短期记忆网络(LSTM)是在普通循环神经网络(recurrent neural Network, RNN)的基础上发展起来的, 解决了 RNN(RNN 也是在 DNN 的基础上进行了改进, 使神经元的输出可以在下一个时间段直接作用到自身)梯度消失的问题[24]。它的基本结构如图 14。

它的详细介绍、状态更新过程以及图 14 中




图 13 残差块基本结构

Fig. 13 Residual block basic structure




图 14 LSTM 基本结构

Fig. 14 LSTM basic structure

相关变量(c_{t-1} 、 c_t 、 f_t 、 h_t 、 x_t 、 o_t 、 l_t 、 i_t 、 $\sigma(\cdot)$ 和 $\tanh(\cdot)$)的说明详见文献[24],在此不再详细展开。

神经网络的训练过程可分为 3 个步骤:正向传播,损失函数计算和反向传播。在输出层,使用正向传播获得的预测输出值 Y^{pred} 与实际值 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。在目前的工作中,最常用的损失函数是方均根误差,其定义如下:

$$L = \frac{1}{2} \sum_{i=1}^{n_k} (y_i^{\text{pred}} - y_i^{\text{actual}})^2 = \frac{1}{2} \sum_{i=1}^{n_k} (\delta_i)^2 \quad (17)$$

其中 $\delta_i = y_i^{\text{pred}} - y_i^{\text{actual}}$, n_k 是输出的个数。反向传播过程中,利用梯度下降算法进行参数更新[25]。

3 结果及分析

针对文中第 1.4 节所获取的 110 组不同 SST 湍流模型参数下的凹槽壁面压力曲线,选择了其中 100 组数据作为训练数据,10 组作为测试数据。选择不同的输入参数、神经网络来对特定标准 SST 湍流模型参数下的超声速凹槽壁面压力曲线进行预测,探究在不同输入参数的情况下,各种神经网络对壁面压力曲线的预测能力。

经过分析,采用了 M1、M2、M3 这 3 种壁面

压力数学映射关系,具体形式如式(18)~式(20)所示。

M1: 基于湍流模型参数的壁面压力预测

$$\sigma_{k1}, \sigma_{k2}, \sigma_{w1}, \sigma_{w2}, \beta^*/\beta_1, \beta^*/\beta_2, \beta^*, \kappa, a_1 \rightarrow 231 \text{ 个压力点} \quad (18)$$

M2: 基于湍流模型参数与压力位置的壁面压力预测


$$\sigma_{k1}, \sigma_{k2}, \sigma_{w1}, \sigma_{w2}, \beta^*/\beta_1, \beta^*/\beta_2, \beta^*, \kappa, a_1, \text{位置} \rightarrow 231 \text{ 个压力点} \quad (19)$$

M3: 基于湍流模型参数、压力位置和压力序列的壁面压力预测


$$\sigma_{k1}, \sigma_{k2}, \sigma_{w1}, \sigma_{w2}, \beta^*/\beta_1, \beta^*/\beta_2, \beta^*, \kappa, a_1, \text{位置、前一位置压力} \rightarrow 230 \text{ 个压力点} \quad (20)$$

在 Pytorch 环境下分别搭建了层数为 8 层的神经网络。输入层神经元个数为 N (M1: $N=9$; M2: $N=10$; M3: $N=11$)、输出层神经元个数为 O (M1: $O=231$; M2、M3: $O=1$),隐藏层神经元个数为 40。ANN、ResNet 采用的激活函数为 Relu。

M1 数学映射关系构成的数据不是序列的形式,故针对 M1,只采用了 ANN, ResNet 两种网络。训练过程中的两种网络的损失下降曲线如图 15 所示。



(a) DNN



(b) ResNet

图 15 在 M1 下的损失函数下降曲线

Fig. 15 Loss function descent curve under M1

针对超声速凹槽壁面压力曲线的预测, 在 M1 映射函数的情况下, 两种神经网络的损失函数最终均逐渐收敛到一个较为稳定的值。

本文采用方均根误差(RMSE, 量符号记为 E_{RMSE})、可决系数(用 R^2 表示)两个指标分别评判神经网络对壁面压力曲线的预测误差以及拟合程度, 具体形式如式(21)~式(22)。

$$E_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y_i^{\text{pred}})^2} \quad (21)$$

$$R^2 = 1 - \frac{\sum_{j=1}^N (y_j - y_j^{\text{pred}})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (22)$$

进一步, 将训练好的神经网络用未参与训练的 10 组参数(如图 16 所示)进行测试。DNN、

ResNet 的方均根误差分别为 658.612 5、699.142 5; 可决系数分别为 0.998 7、0.998 6。因此, 在 M1 映射函数下, DNN、ResNet 对壁面压力曲线的预测能力大致相同。最终结果如图 17~图 18 所示。

由图 17~图 18 可以看出, 当采用 M1 函数映射关系时, DNN、ResNet 能以较高的精度预测超




图 16 未参与训练的 10 组壁面压力曲线

Fig. 16 10 wall pressure curves without training





图 17 在 M1 下的基于 DNN 的壁面压力曲线预测结果

Fig. 17 Prediction results of wall pressure curve based on DNN under M1






图 18 在 M1 下的基于 ResNet 的壁面压力曲线预测结果

Fig. 18 Prediction results of wall pressure curve based on ResNet under M1

声速凹槽壁面压力。整体上看,两种神经网络对来流平板、斜坡位置处的壁面压力预测较好,主要的误差出现在后台阶到斜坡之间的平板处。表明在这段位置,输入特征参数与壁面压力之间存在更为复杂的非线性关系。

进一步,考虑 M2 映射函数。M2 在 M1 的基础上加入了壁面压力位置,采用了 DNN、ResNet、LSTM 这 3 种神经网络。训练过程中,3 种网络的损失下降曲线如图 19 所示。

3 种神经网络最终都能收敛到一个较为稳定的值,将训练好的神经网络用未参与训练的 10 组参数进行测试。DNN、ResNet、LSTM 的方均根误差分别为: 820.732 5、891.66、435.697 5; 可决系数分别为: 0.998 0、0.997 6、0.999 4。对比上述对

M1 映射函数的结果,在 M2 映射函数下, DNN、ResNet 对壁面压力曲线的预测能力有所下降,但两种网络预测精度仍大致相同。LSTM 对壁面压力的预测精度有较少的提高。预测结果如图 20~图 22 所示。

由图 20~图 22 可知,在 M2 映射函数下, DNN、ResNet 较大的误差仍出现在后台阶到斜坡之间的平板处,而 LSTM 在这段位置的精度得到了提升。

进一步,本文在 M2 映射函数的基础上加入了上一位置的真实压力值,由此构成了映射函数 M3。在 M3 映射函数下,同样采用了 DNN、ResNet、LSTM 这 3 种神经网络。训练过程中,3 种网络的损失下降曲线如图 23 所示。




图 19 在 M2 下的损失函数下降曲线

Fig. 19 Loss function descent curve under M2




图 20 在 M2 下的基于 DNN 的壁面压力曲线预测结果

Fig. 20 Prediction results of wall pressure curve based on DNN under M2





图 21 在 M2 下的基于 ResNet 的壁面压力曲线预测结果

Fig. 21 Prediction results of wall pressure curve based on ResNet under M2






图 22 在 M2 下的基于 LSTM 的壁面压力曲线预测结果

Fig. 22 Prediction results of wall pressure curve based on LSTM under M2





图 23 在 M3 下的损失函数下降曲线

Fig. 23 Loss function descent curve under M3

3 种神经网络最终都能收敛到一个较为稳定的值, 训练结束后, DNN、ResNet、LSTM 对 10 条壁面压力曲线预测结果的方均根误差分别为: 141.855、263.445、385.035; 可决系数分别为: 0.999 9、0.999 8、0.999 6。相比 M2, 在 M3 映射函数下, DNN、ResNet 对壁面压力的预测精度明显

提高, LSTM 几乎没有提升。最终结果如图 24~图 26 所示。

综上, 在 M1~M3 映射函数情况下, 3 种神经网络均可较高精度地预测超声速凹槽的壁面压力。当精度相对较低时, 神经网络的误差主要出现在后台阶到斜坡之间的平板处。在任意映射函数下,






图 24 在 M3 下的基于 DNN 的壁面压力曲线预测结果

Fig. 24 Prediction results of wall pressure curve based on DNN under M3






图 25 在 M3 下的基于 ResNet 的壁面压力曲线预测结果

Fig. 25 Prediction results of wall pressure curve based on ResNet under M3

DNN 与 ResNet 的性能大致相同; 在 M2 映射函数下, LSTM 的预测精度稍微优于 DNN、ResNet 的预测精度; 而在 M3 映射函数下, DNN、ResNet 的精度得到了明显提升, 稍微优于 LSTM。这表明: 当对壁面压力选择不同的特征辨识参数时, 在网

络结构、训练方法不变的情况下, 不同的神经网络可能表现出不同的预测性能。此外, 神经网络对壁面压力的预测时间仅为 ms 量级, 因此, 在经过一定时间的数据训练后, 神经网络可快速获得不同湍流模型参数下的壁面压力。






图 26 在 M3 下的基于 LSTM 的壁面压力曲线预测结果

Fig. 26 Prediction results of wall pressure curve based on LSTM under M3

4 结 论

本文将神经网络引入到壁面压力这类序列数据的预测当中。以超声速流动条件下的凹槽为对象,利用标准 SST 湍流模型开展了相关研究,经过仿真和实验,得到以下结论:

1) 在 M1、M2、M3 这 3 种映射函数下,DNN、ResNet、LSTM 均能高精度地预测不同输入参数下的壁面压力曲线。

2) LSTM 一般用于序列数据的预测方面,能够提取前后压力值之间的内在关系,因此,在 M2 映射函数下,LSTM 对壁面压力的预测精度有了一定提升。

3) 在 M3 映射函数下,相比 M2,LSTM 的预测精度大致不变;相比 M1、M2,DNN、ResNet 的精度得到了明显的提高。

4) 神经网络对壁面压力的预测时间仅为 ms 量级,在经过一定时间的数据训练后,神经网络可快速获得不同湍流模型参数下的壁面压力。

综上,在 M1~M3 映射函数下,3 种神经网络均可高精度地预测超声速凹槽的壁面压力,可决系数达到了 0.99 以上;当对壁面压力选择不同的特征辨识参数时,在网络结构、训练方法不变的情况下,不同的神经网络可能表现出不同的性能;本文的相关工作已经初步表明了神经网络在预测壁面压力等序列数据的可行性。此外,本文的研究能进一步推广到他算例,在不同来流条件下,开展其他序列数据的预测工作,结合实际实验结果(如壁面摩擦,壁面压力等),选取最优湍流模型系数,修正该算例下的湍流模型参数,一定程度减小数值模拟结果与实际实验结果之间的差异。

参考文献:

[1] 王西耀,赵慧勇,谭宇.基于壁面压力的试验参数分析方法

[J]. 推进技术, 2021, 42(10): 2367-2376.

WANG Xiyao, ZHAO Huiyong, TAN Yu. Parameter extracting method based on wall pressure[J]. Journal of Propulsion Technology, 2021, 42(10): 2367-2376. (in Chinese)

[2] 唐兰,徐惊雷,莫建伟,等.基于壁面压力分布的非对称喷管反设计[J].航空动力学报,2017,32(6):1515-1522.

TANG Lan, XU Jinglei, MO Jianwei, et al. Reverse design of asymmetric nozzle based on given wall pressure distribution[J]. Journal of Aerospace Power, 2017, 32(6): 1515-1522. (in Chinese)

[3] 浮强,宋文艳,王艳华,等.超声速燃烧室壁面压力特征实验研究[J].推进技术,2018,39(7):1633-1642.

FU Qiang, SONG Wenyan, WANG Yanhua, et al. Experimental investigation on wall pressure characteristic in hypersonic combustor[J]. Journal of Propulsion Technology, 2018, 39(7): 1633-1642. (in Chinese)

[4] LI Jinping, MING Ma, CHAO Yan. Bayesian uncertainty analysis of SA turbulence model for backward-facing step simulations[J]. Journal of Physics: Conference Series, 2021, 1786(1): 012048.

[5] XIAO Heng, WU Jinlong, WANG Jianxun, 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.

[6] 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.

[7] ZHANG Zejia, DURASAMY K. Machine learning methods for data-driven turbulence modeling[C]//Proceedings of the 22nd AIAA Computational Fluid Dynamics Conference. Reston, US: AIAA, 2015:2460-2478.

[8] ZHANG Jincheng, FU Song. An efficient approach for quantifying parameter uncertainty in the SST turbulence model[J]. Computers & Fluids, 2019, 181: 173-187.

[9] 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.

[10] DI STEFANO M A, HOSDER S, BAURLE R A. Effect of turbulence model uncertainty on scramjet isolator flowfield analysis[J]. Journal of Propulsion and Power, 2020, 36(1): 109-122.

[11] PANDA J P, WARRIOR H V. Data-driven prediction of complex flow field over an axisymmetric body of revolution using machine learning[J]. Journal of Offshore Mechanics and Arctic Engineering, 2022, 144(6): 060903.

[12] BRAHMACHARY S, BHAGYARAJAN A, OGAWA H. Fast estimation of internal flowfields in scramjet intakes via reduced-order modeling and machine learning[J]. Physics of Fluids, 2021,

- 33(10): 106110.
- [13] MAULIK R, SHARMA H, PATEL S, et al. A turbulent eddy-viscosity surrogate modeling framework for Reynolds-averaged Navier-Stokes simulations[J]. *Computers and Fluids*, 2021, 227: 104777.
- [14] HORSTMAN C, SETTLES G, WILLIAMS D R, et al. A reattaching free shear layer in compressible turbulent flow: a comparison of numerical and experimental results: AIAA 81-0333 [R]. Reston, US: AIAA, 1981.
- [15] LUO Dahai, YAN Chao, WANG Xiaoyong. Computational study of supersonic turbulent-separated flows using partially averaged Navier-stokes method[J]. *Acta Astronautica*, 2015, 107: 234-246.
- [16] TIAN Yuyan, GAO Zhenxun, JIANG Chongwen, et al. A correction for Reynolds-averaged-Navier-Stokes turbulence model under the effect of shock waves in hypersonic flows[J]. *International Journal for Numerical Methods in Fluids*, 2023, 95(2): 313-333.
- [17] 夏陈超, 陈伟芳, 郭中州, 等. 隐式紧耦合 SST 和 TNT 湍流模型的高速流动数值模拟[J]. *航空动力学报*, 2015, 30(4): 936-943.
- XIA Chenchao, CHEN Weifang, GUO Zhongzhou, et al. Numerical simulation of implicit fully coupled SST and TNT turbulence models for high speed flows[J]. *Journal of Aerospace Power*, 2015, 30(4): 936-943. (in Chinese)
- [18] 张程, 夏智勋, 马超, 等. 基于 $k-\omega$ SST 模型的同心筒发射装置流场数值模拟[J]. *航空动力学报*, 2019, 34(11): 2331-2338.
- ZHANG Cheng, XIA Zhixun, MA Chao, et al. Numerical simulation of flow field of concentric canister launcher based on $k-\omega$ SST turbulence model[J]. *Journal of Aerospace Power*, 2019, 34(11): 2331-2338. (in Chinese)
- [19] 曾宇, 汪洪波, 孙明波, 等. SST 湍流模型改进研究综述[J]. *航空学报*, 2023, 44(9): 027411.
- ZENG Yu, WANG Hongbo, SUN Mingbo, et al. SST turbulence model improvements: review[J]. *Acta Aeronautica et Astronautica Sinica*, 2023, 44(9): 027411. (in Chinese)
- [20] 韩省思, 叶桃红, 朱旻明, 等. $k-\varepsilon$ 湍流模型可压缩性修正在超音速混合层中的应用研究[J]. *工程热物理学报*, 2007, 28(6): 1053-1055.
- HAN Xingsi, YE Taohong, ZHU Minming, et al. An investigation of compressibility modification for $k-\varepsilon$ turbulence model and application in supersonic mixing layers[J]. *Journal of Engineering Thermophysics*, 2007, 28(6): 1053-1055. (in Chinese)
- [21] LI Yao, LI Jinping, ZENG Fanzhi, et al. Bayesian uncertainty quantification analysis of the SST model for transonic flow around airfoils simulation[J]. *Aerospace Science and Technology*, 2023, 137: 108273.
- [22] PAWAR S, RAHMAN S M, VADDIREDDY H, et al. A deep learning enabler for nonintrusive reduced order modeling of fluid flows[J]. *Physics of Fluids*, 2019, 31(8): 085101.
- [23] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, US: IEEE, 2016: 770-778.
- [24] 查雄, 彭华, 秦鑫, 等. 基于循环神经网络的卫星幅相信号调制识别与解调算法[J]. *电子学报*, 2019, 47(11): 2443-2448.
- ZHA Xiong, PENG Hua, QIN Xin, et al. Satellite amplitude-phase signals modulation identification and demodulation algorithm based on the cyclic neural network[J]. *Acta Electronica Sinica*, 2019, 47(11): 2443-2448. (in Chinese)
- [25] HAN Renkun, WANG Yixing, QIAN Weiqi, et al. Deep neural network based reduced-order model for fluid-structure interaction system[J]. *Physics of Fluids*, 2022, 34(7): 073610.

(编辑: 王碧琚)