2020 IEEE/ACM Workshop on Machine Learning in High Performance Computing Environments (MLHPC) and Workshop on Artificial Intelligence and Machine Learning for Scientific Applications (AI4S) | 978-1-6654-2291-8/20/$31.00 ©2020 IEEE | DOI: 10.1109/MLHPCAI4S51975.2020.00016

使用机器学习代理模型预测定常与非定常流动

Shanti Bhushan 机械工程系 密西西比州立大学 美国密西西比州斯塔克维尔
bhushan@me.msstate.edu

Greg W. Burgreen 先进车辆系统中心 密西西比州立大学 美国密西西比州斯塔克维尔
greg.burgreen@msstate.edu

Joshua L. Bowman 航空航天工程系 密西西比州立大学 美国密西西比州斯塔克维尔 jb1060@msstate.edu

Ian D. Dettwiller 工程研究与发展中心（ERDC） 美国密西西比州维克斯堡
ian.d.dettwiller@usace.army.mil

Wesley Brewer 国防部高性能计算现代化计划PET / GDIT 美国密西西比州维克斯堡
Wesley.Brewer@GDIT.com

摘要— 基于计算流体动力学（CFD）的设计工具的适用性取决于物理模型的准确性和复杂性，例如湍流模型（湍流建模仍是物理学中尚未解决的问题），以及决定旋翼航空器和风力/水轮机组仿真计算成本的旋翼模型。研究重点在于探究神经网络学习目标建模变量与流动参数之间相关性的能力，从而构建代理模型。针对湍流建模，研究开发了用于非定常边界层流动的机器学习湍流模型，并通过与DNS数据进行对比验证，同时与单方程非定常雷诺平均纳维–斯托克斯（URANS）预测结果进行比较。由于能够纳入湍流应力与应变率之间的非线性相关性，该机器学习模型的表现显著优于URANS模型。代理旋翼模型的开发基于以下假设：如果某模型能够模拟叶片解析模型产生的轴向和切向动量亏损，那么它应能产生在定性和定量上相似的尾流恢复。研究对该假设进行了初步验证，结果令人鼓舞。

关键词——机器学习、湍流建模、转子建模、非定常边界层流动。

I. 引言

计算流体力学（CFD）正被广泛用作工程设计工具，因为与实验相比，它成本低廉，而且能够模拟实验室中无法重现的流动条件。尽管高性能计算的进步正不断推动高保真计算（采用大规模网格以及先进数值方法和模型）在流动物理分析方面突破极限，但CFD工具在工程应用中的适用性仍受迭代周期缓慢的限制。我们需要能够在粗网格上运行的低保真模型，并能准确预测积分量（如力和力矩）以及大尺度流动特征（如流动分离和涡结构的发展）。对于涉及广泛长度和时间尺度、对建模人员而言仍是挑战的湍流，低保真模型的开发已陷入停滞；若不引入额外的复杂度（或计算成本）。机器学习（ML）正逐渐成为一种强大的工具，可为传统建模方法提供另一种途径，其中神经网络有助于识别输入与输出流动变量之间的相关性 [1]。

A. 背景：用于湍流建模的机器学习

大量直接数值模拟（DNS）/大涡模拟（LES）结果和实验数据集的出现，正推动机器学习作为一种促进湍流建模发展的工具而兴起 [2]。对于湍流建模而言，主要的未知问题在于湍流应力如何与平均应变率张量的不变量及其他局部流动参数相关联。机器学习方法利用解数据库生成所需湍流特征关于输入特征的响应面。文献综述表明，机器学习工具已被用于以下湍流建模任务：（1）直接场估计，即预测整个流场 [3,4]；（2）建模不确定性估计，即通过校准模型系数来使建模误差最小化 [5,6]；（3）湍流模型增强 [7-10]。湍流模型增强是文献中最常用的方法，已应用于非定常雷诺平均纳维–斯托克斯（URANS）模型，以调整湍流产生、调整湍流应力或引入非线性应力分量；以及（4）建立独立湍流模型，其中所需的湍流特征为湍流应力。在这一类别中，相关研究工作较为有限 [11]。

B. 背景：转子建模面临的挑战

旋翼广泛应用于许多工程领域，例如垂直起降飞行器（美国陆军开发的军用直升机系列 [12]）、风力机和水轮机等。预测旋翼尾流对于工程设计至关重要；例如，对于垂直起降飞行器，尾流会影响机动过程中的机身载荷，并可能对其稳定性产生不利影响；对于风力机或水轮机，尾流决定了尾流恢复长度，并最终影响阵列效率。采用完全解析叶片的 CFD 进行模拟，是预测旋翼尾流最准确的模型。然而，这类

978-1-6654-2291-8/20/$31.00 ©2020 IEEE
DOI 10.1109/MLHPCAI4S51975.2020.00016

授权许可仅限密西西比州立大学图书馆使用。于2023年5月5日 19:17:04协调世界时从 IEEE Xplore 下载。适用相关限制。

模拟的计算成本很高，限制了其在设计周期中的应用。此外，对于多种转子构型，其计算成本可能高得难以承受。为提高这些模拟的计算可行性，人们开发了多种低保真模型，例如致动盘、致动线或致动面模型。其中，致动线模型（ALM）是使用最广泛的模型，因为它能够对旋翼流动提供最佳的定性描述。在该模型中，叶片被建模为一条简单的线，该线上的每个点都会施加一个动量汇，其大小对应于根据叶片剖面在该位置的局部入流条件所预期的升力和阻力，同时该线以类似叶片的方式旋转 [13]。在通用模型中，动量汇通过预先确定的升力和阻力系数查找表，根据攻角进行规定。这些模型存在两个主要局限性：（i）无法考虑流动的三维性或上游流动的非定常性；（ii）无法考虑叶片产生的湍流，而湍流对于尾流发展和恢复至关重要。因此，需要一种高效的旋翼模型，既能模拟非定常动量汇，也能模拟叶片产生的湍流。本研究基于以下假设：如果一个水轮机模型能够仿真叶片解析模型产生的轴向和切向动量亏损及湍流，那么它应当能够产生定性和定量上相似的平均尾流恢复效果。本研究旨在建立旋翼轴向和切向动量亏损的回归映射，作为验证该假设的第一步。

C. 目标与方法

本研究旨在考察神经网络学习目标建模变量与流动参数之间相关性的能力，从而提供可用于 CFD 模拟的替代模型。本研究针对两类不同问题展开：湍流建模和转子建模。对于前者，利用机器学习推断湍流应力与平均应变率张量不变量之间的相关性。对于后者，利用机器学习推断转子叶片剖面在任意径向位置处的预期升力和阻力，并将其表示为局部入流条件的函数，以便在致动线建模框架中使用这些结果，进而开发一种能够考虑入流非定常性的中保真转子模型。

本研究基于作者此前的研究[1]，该研究聚焦于开发适用于稳态边界层流动的独立机器学习（ML）湍流模型。前期研究的主要成果总结如下。本研究将上述工作拓展至非定常流动。为此，我们针对振荡通道流获取了DNS数据集，相关内容概述于第三节A部分。在第三节B部分，利用该DNS数据集开发并验证机器学习湍流模型。在第三节C部分，探讨数据降维技术，以尽量减小训练数据集中某种湍流特征占主导地位所导致的模型偏斜性。在第三节D部分，通过先验和后验测试验证所开发的模型。在先验测试中，使用URANS模型进行模拟，并将机器学习模型作为后处理步骤调用。在后验测试中，机器学习模型与求解器耦合，用于湍流建模。第四节讨论了机器学习转子模型的开发进展。第五节给出一些初步结论，并列出未来工作。

II. 先前的湍流建模研究 H

前期研究 [1] 着重于开发并验证适用于稳态边界层流动的独立机器学习湍流模型，其中包括评估与神经网络训练相关的关键问题。为实现研究目标，开发了两种不同的模型：(1) 数据驱动模型和 (2) 物理信息机器学习（PIML）模型 [14,15]。这些模型用于求解边界层方程：

$$\nu \frac{\partial^2 U}{\partial y^2} + \frac{\partial \tau_{uv}}{\partial y} = u_\tau^2 \tag{1}$$

其中，ν 是运动分子黏度，u_τ 是摩擦速度，U是平均流速，y 是壁法向方向。上述方程中的未知量是剪切应力τ_{uv}。基于物理的湍流模型用已知的流动变量来表示应力。例如，在单方程 URANS 模型[16]中：

$$\tau_{uv} = \nu_T \frac{\partial U}{\partial y} \tag{2}$$

其中，湍流涡黏度ν_T 的计算方式如下：

$$\nu_T = \sqrt{0.3}\ell\sqrt{k} \tag{3}$$

上述公式引入了另一个未知量——湍动能k；l 是湍流长度尺度，以距壁面的距离（δ）表示，即：

$$\ell = \kappa\delta \tag{4}$$

其中，κ = 0.41 是冯·卡门常数。已知量k 通过求解额外的输运方程获得：

$$\frac{\partial k}{\partial t} = \underbrace{\nu_T \left(\frac{\partial U}{\partial y}\right)^2}_{\text{Production}} - \underbrace{\frac{0.1643k^{3/2}}{\ell}}_{\text{Dissipation}} + \underbrace{\frac{\partial}{\partial y}\left\{(\nu + \nu_T)\frac{\partial k}{\partial y}\right\}}_{\text{Diffusion}} \tag{5}$$

机器学习模型旨在确定湍流应力关于流动变量的回归映射，即：

$$\tau_{uv} = f\left(U, \delta, \nu, u_\tau, \frac{\partial U}{\partial y}\right) \tag{6}$$

在数据驱动模型中，剪切应力的回归映射经过训练，以最小化估计得到的代价函数，该代价函数为机器学习剪切应力与训练数据集之间的L_2范数误差。而对于物理信息机器学习 模型，代价函数同时包含控制方程中的误差以及L_2 范数误差。

T本研究重点评估以下内容： 题：

授权许可仅限：密西西比州立大学图书馆。于 2023年5月5日 19:17:04 协调世界时从 IEEE Xplore 下载。适用相关限制。

(a). 如何恰当地训练用于湍流应力的机器学习回归映射？具体而言，研究了输入特征和训练方法对机器学习回归映射准确性的影响。

(b). 机器学习湍流模型在后验应用过程中能否满足解的光滑性要求？它能否像基于物理的模型一样实现网格无关解？

(c). 机器学习湍流模型在不适定初始条件下如何收敛？

该机器学习湍流模型基于文献中已有的边界层流动DNS/LES数据库开发，其中包括：21个雷诺数范围从Re_τ=109 到5200 [17]的槽道流DNS算例；18个Re_θ = 670 到6500的零压梯度平板边界层DNS算例；以及14个Re_θ = 670到11000 [18]的零压梯度平板边界层大涡模拟算例。该数据库包含约20,000个数据点，其中3.4%位于近壁层，5.7%位于缓冲层，90.9%位于对数层或外层。

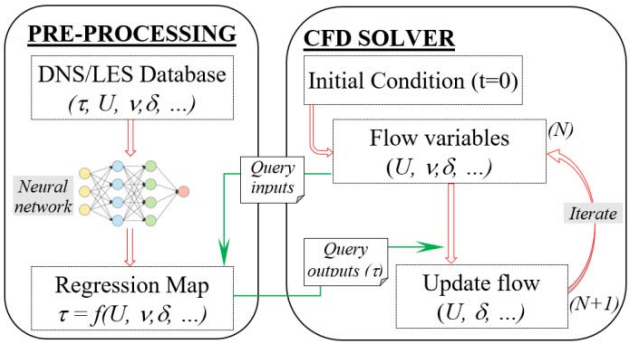

图 1. 展示机器学习湍流模型与 CFD 求解器耦合的示意图。

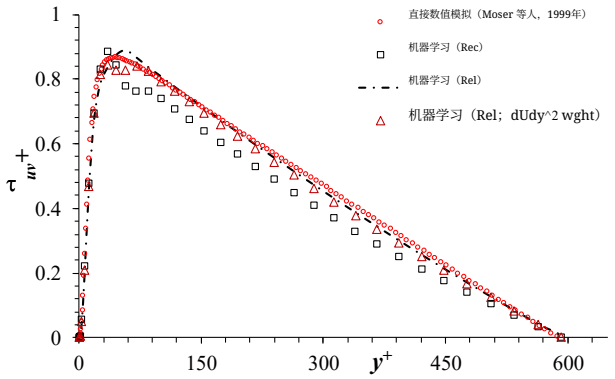

图 2. 使用数据驱动湍流模型获得的 Re_τ = 590 湍流剪切应力预测结果。其中，模型（*Rec*）使用全局雷诺数训练，模型（*Rel*）使用局部流动雷诺数训练，而对于（*Rel;dUdy^2 wght*），$\left(\frac{dU}{dy}\right)^2$在训练过程中用作权重。

该机器学习模型是通过预处理步骤获得的，使用了一个 8 层深度神经网络，每个隐藏层均包含 20 个神经元，并采用双曲正切激活函数。该模型使用 L-BFGS 拟牛顿全批量梯度优化方法进行优化，并迭代训练 2400 轮。

模型通过了先验和后验测试。在先验测试中，使用DNS结果作为查询输入，并将查询输出（剪切应力）与DNS 值进行比较。在后验测试中，将机器学习得到的湍流剪切应力用于求解边界层方程（式 2）。图 1 给出了机器学习湍流模型与 CFD 求解器耦合的示意图。

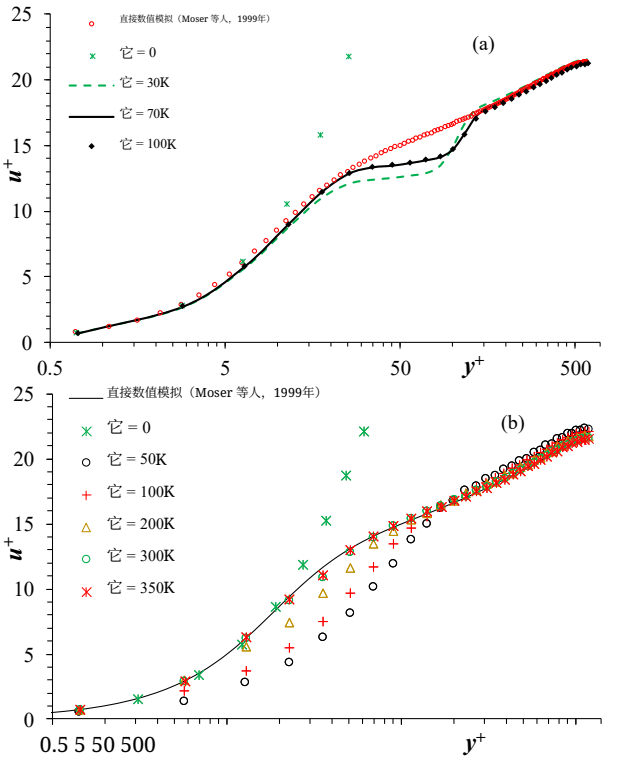

图 3. 使用以下模型获得的 Re_τ = 590 平均速度预测结果：(a) 数据驱动湍流模型和 (b) 物理信息机器学习湍流模型；模拟采用 $U = (1 - y^8)$ 不适定初始条件。

验证研究表明：

(a). 机器学习响应面的精度取决于输入参数的选择。我们采用特征工程，为神经网络训练找出最优输入特征。研究发现，将流动变量组合成问题相关参数可以提高模型精度。例如，如图 2 所示，使用基于局部流速和壁面距离的 *Re*（Re_l）训练的数据驱动模型，其剪切应力预测误差为 3%；相比之下，使用基于全局流动的 *Re* （Re_c）训练的模型误差为 12%。

(b). 响应面的精度取决于如何对数据库进行加权，以最大限度地减少数据集之间的重叠。这需要采用试错法来确定。

授权许可仅限：密西西比州立大学图书馆。于 2023年5月5日 19:17:04 协调世界时从 IEEE Xplore 下载。适用相关限制。

配合适当的加权函数。提高回归曲面精度的更好方法是按照 [3]，将物理约束纳入损失函数，即采用 物理信息机器学习 方法。

(c). 数据驱动模型在后验测试中出现了振荡，因为查询输出在数据库曲线之间跳变。通过对查询输入和查询输出进行局部平均，振荡有所减弱。物理信息机器学习模型没有表现出此类局限。由于模型的查询输出彼此独立，不受相邻数据点影响，因此得出结论：解的平滑性取决于模型的准确性。

(d). 当模拟从不适定初始条件开始时，即 $U=(1-y^8)$，其中 y = ±1 为无滑移壁面，如图 3 所示，数据驱动模型的预测在缓冲层和较低的对数层中收敛到不符合物理规律的结果。请注意，上述剖面中的流动特征不在训练数据库范围内，因此该查询本质上属于外推。令人惊讶的是，物理信息机器学习方法在外推模式下效果很好，结果逐渐收敛到正确的剖面。

III. 振荡通道流

振荡通道流是文献中用于验证大涡模拟模型预测能力的经典测试案例。在此测试案例中，施加了一个非定常压力脉冲（体力项），从而在流动中引入周期性非定常性。Scotti 和 Piomelli [19] 对脉冲槽道流进行了直接数值模拟和大涡模拟，以研究压力梯度对黏性底层调制、湍流应力及相干结构拓扑的影响。

A. 直接数值模拟

本研究中的直接数值模拟采用自主开发的并行伪谱求解器完成。该求解器沿均匀的流向和展向使用快速傅里叶变换（FFT），并沿壁面法向使用切比雪夫多项式，对不可压缩纳维–斯托克斯方程进行离散。求解器采用 OpenMP/MPI 混合方案实现并行化，可扩展至多达 16K 个处理器和 10 亿个网格点，并已在大涡模拟和直接数值模拟研究中得到广泛验证 [20,21]。

针对三种不同（高、中、低）的流向压力脉冲进行了直接数值模拟，设置与 [19] 中所用的一致。模拟采用的计算域尺寸为：沿流向、壁面法向和展向分别为 3π×2×π，网格由 192×129×192 个点组成。计算域尺寸与 [19]，中所用的一致，但网格更精细。模拟设置的详细信息见表 I。模拟在流向和展向采用周期性边界条件，并在$y=\pm1$处设置无滑移壁面。

中频工况下的壁面剪切应力和流向速度变化如图4所示。正压力梯度产生不利流动条件，使流动减速（并降低壁面剪切应力幅值）而负压力梯度产生有利流动条件，使流动加速（并增大壁面剪切应力）。峰值壁面剪切力（和速度）出现在 3/4th 个周期附近。先前的一项研究 [22] 验证了 DNS结果：针对 [19] 中给出的结果，预测平均流动的交流（交流）分量和直流（直流）分量。交流分量通过快速傅里叶变换，在每个壁面法向位置对每八分之一个周期的归一化平面平均速度剖面进行分解而获得。研究发现，DNS结果与现有基准结果吻合良好。

表 I. 直接数值模拟参数。无量纲量以黄色突出显示

流动参数	*High* 频率	*Med.* 频率	*Low* 频率
$Re_{\tau,0}$	350		
雷诺数$_{\alpha}$	7250		
U_c	1		
H	1		
ν	1.38×10^{-4}		
计算域尺寸	3π×2×π		
Grid	192×129×192		
$\partial P_0/\partial x$	$u_\tau^2=0.002331$		
ρ	1		
u_τ	0.048276		
α	200	50	8
$\alpha\, dP_0/dx$	0.4662	0.11655	0.01865
$\omega^+=\omega\nu/u_\tau^2$	0.04	0.01	0.0016
ω	0.67565	0.16891	0.02703
边界层厚度 $l_s=\sqrt{2\nu/\omega}$	0.2021	0.4042	1.0106
$l_s^+=\sqrt{2u_\tau^2/\nu\omega}=\sqrt{2/\omega^+}$	7.071	14.142	35.355
$Re_c=U_\infty\sqrt{2/\omega\nu}$	100	200	500
$Re_s/l_s^+=U_o/u_\tau$	$10\sqrt{2}$		
U_o/U_c	0.03296		
时间步长（Δt）	0.0002325	0.00093	0.000969
每周期时间步数（2π/ωΔt）	40000	40,000	240,000
压力脉冲	$\frac{dP}{dx}=\frac{dP_0}{dx}[1+\alpha\cos(\omega t)]$		

图4展示了中频工况下壁面剪切应力和流向速度的变化。正压力梯度会产生不利流动条件，使流动减速（并降低壁面剪切应力幅值）；负压力梯度则会产生有利流动条件，使流动加速（并增大壁面剪切力）。在约3/4th 个周期处观察到壁面剪切力（以及速度）的峰值。此前的一项研究 [22] 针对平均流动的交变（交流）分量和直流分量进行了预测，并将结果与Scotti和Piomelli的 [19] DNS及大涡模拟结果进行了比较，从而验证了DNS结果。通过对一个周期内八个等间隔时刻的归一化平面平均速度进行快速傅里叶变换分解，获得交流分量。直流分量则为整个周期内的平均速度。结果表明，DNS结果与基准结果吻合良好。

低频脉冲导致了再层流化和转捩行为，这对 URANS 预测而言是一个具有挑战性的工况。高频工况主要由压力梯度驱动，且湍流强度较小。中频工况在这两个极端之间取得了折中，因此在本研究中采用了该工况。为了训练机器学习湍流模型，三维直接数值模拟数据集被

授权许可使用仅限于：密西西比州立大学图书馆。于2023年5月5日19:17:04（协调世界时）从 IEEE Xplore 下载。使用受限。

处理以获得非定常一维数据集。由于沿流向采用周期性边界条件，预计模拟域会随时间移动 [23], , 如图 5 所示。此外，任一时间步的结果都代表了预期在该振荡相位下出现的湍流流场的多个实现（流向–展向平面中的每个网格点，或 192×192）。对这些实现进行平均，以获得沿壁面法向（y）方向的平均一维流动。利用每个 100th 时间步或每个压力振荡周期的 1/400th 的一维解，生成如图 6 所示的平均流动二维 y-时间图。收集三个压力振荡周期内的解，共得到 129×1201 （约 155,000）个数据点。

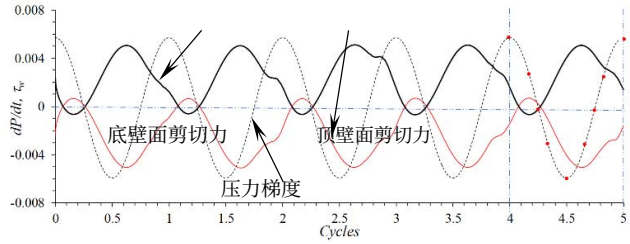

(a)

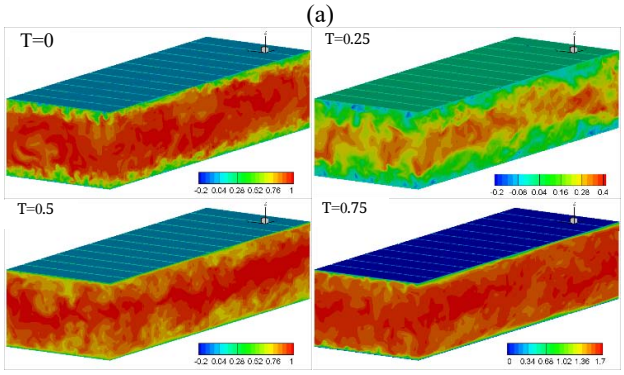

(b)

图4。（a）五个（5）个压力振荡周期内壁面剪切应力的变化，以及（b）中频工况下通过直接数值模拟得到的四分之一周期时刻的瞬时流向速度剖面。T=0 和0.5分别对应压力梯度振荡的峰值和谷值。

B. 机器学习湍流模型

针对平均流动预测建立了机器学习湍流模型。该工况下平均流动的控制方程为：

$$\frac{\partial U}{\partial t} = F(t) + \nu\frac{\partial^2 U}{\partial y^2} + \frac{\partial \tau_{uv}}{\partial y} \tag{7a}$$

$$F(t) = \frac{dP_0}{dx}[1 + \alpha\cos(\omega t)] \tag{7b}$$

与稳态情况类似，上述方程的闭合需要对剪切应力 τ_{uv}进行建模。此外，对于此情况，k的预测也被添加为一个未知湍流量，机器学习模型旨在获得具有两个输出（τ_{uv}、 k）的回归映射，其输入流动参数为以下局部量和平均流动量：

$$\underbrace{(\tau_{uv}, k)}_{Output} = f\underbrace{\left(Re_l = \frac{U\delta}{\nu}; F(t); y^+(t) = \frac{\delta u_\tau(t)}{\nu}; y_0^+ = \frac{\delta u_{\tau 0}}{\nu}; \frac{\partial U}{\partial y}\right)}_{Inputs} \tag{8a}$$

$$u_\tau(t) = \sqrt{\frac{|\tau_w(t)|}{\rho}} \tag{8b}$$

其中， u_τ 是局部摩擦速度， $u_{\tau 0}$ 是与$\frac{dP_0}{dx}$对应的基准壁面摩擦。

对于该工况，仅训练了数据驱动模型，因为训练过程中无法计算时间导数。该模型采用一个三层深度神经网络进行训练，每个隐藏层包含512个节点，并使用*ReLU*激活函数。最后一层为线性全连接层。模型使用*ADAM*优化器训练了200个训练轮次，批次大小为128，学习率为0.01。训练过程中，L_2 范数误差在前25个训练轮次内下降了一个数量级，此后误差下降停滞。

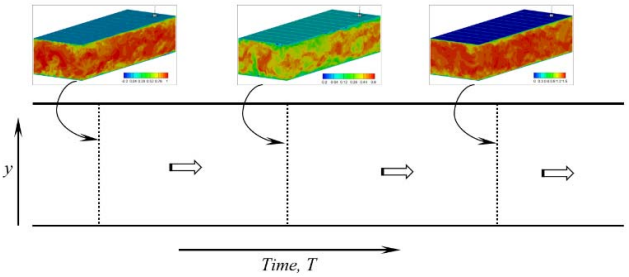

图 5. 示意图展示了如何对三维 DNS 数据进行后处理，以获得一维非定常平均流动。

C. 数据聚类与机器学习模型优化

脉动槽道流涉及范围广泛的湍流状态，不同于边界层情形，后者仅包含亚层、缓冲层和对数层。如图 6 所示，在此情形下，湍流在压力振荡周期末端最为显著，并且沿壁法向变化显著。因此，使用整个数据集训练机器学习模型可能会使模型偏向较为显著的特征。例如，对于边界层情形，由于 91% 的数据集位于对数层区域，模型在对数层中的表现远优于在缓冲层中的表现。 *Birch* 聚类算法 *sklearn* 被用于将 155,000 个数据点划分为不同的流动状态。算法使用 0.3 的无量纲阈值自动确定聚类，最终得到 412 个聚类；如图 7 所示，各聚类中数据点数量的（最小值、最大值、平均值、标准差）分别为（1、10700、376、937）。需要注意的是，聚类过程保留了数据的周期性。

通过从每个簇中随机抽取不同百分比的点（占数据集总

授权许可仅限密西西比州立大学图书馆使用。于2023年5月5日19:17:04（协调世界时）从 IEEE Xplore 下载。使用受限。

聚类）已使用。使用所有数据点训练模型时，获得了相似

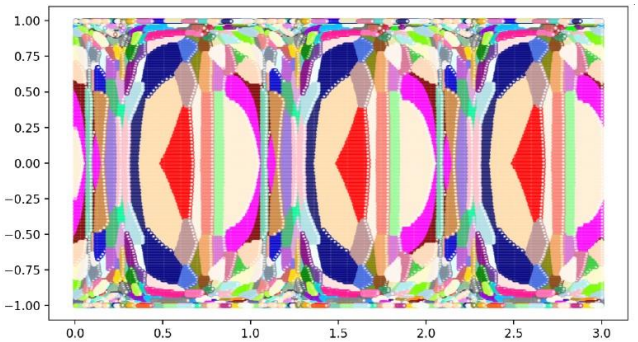

图7. 使用 *sklearn* 对剪切应力 DNS数据进行聚类。不同颜色的区域代表不同的湍流特征。

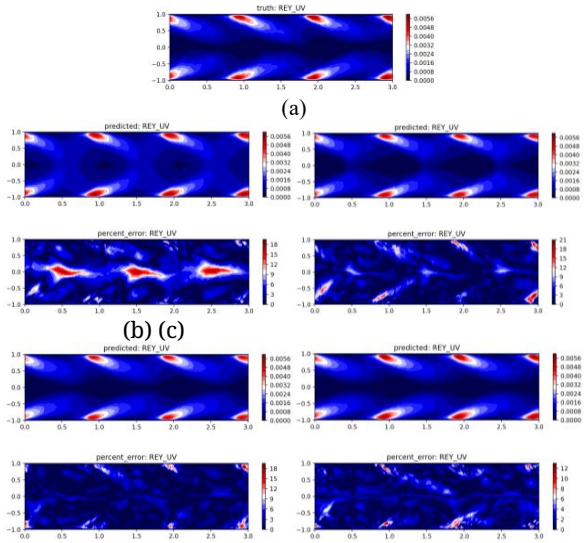

) 图8. (a) τ_{uv} (d)DNS预测的幅值。τ_{uv} 回归映射（上）以及机器学习模型的误差（下）；模型分别使用（b）0.25%、（c）1%、（d）10%和（e）100%的数据点进行训练。

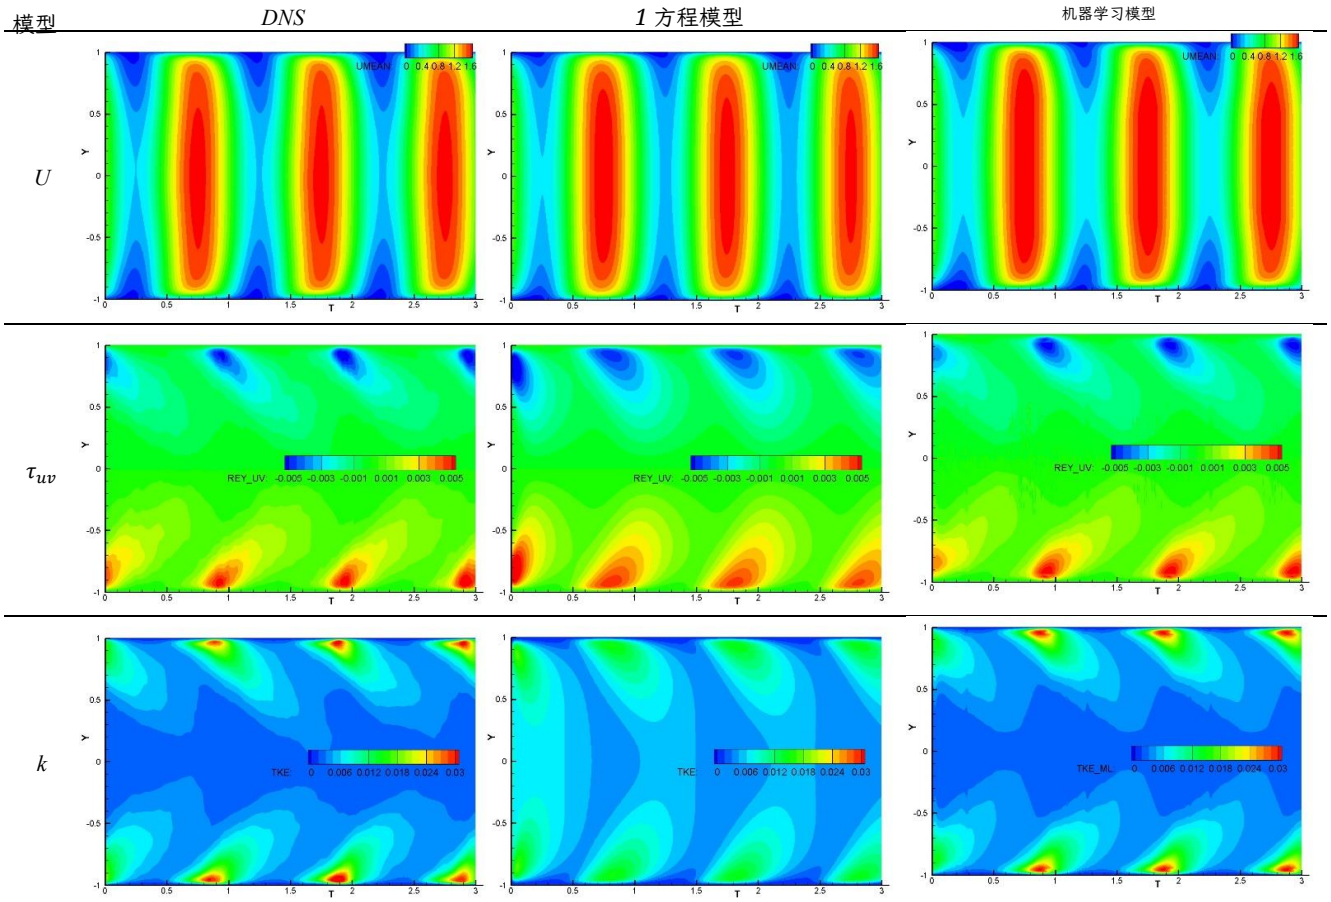

图 6. 将机器学习模型的预测结果（右列）与直接数值模拟（左列）和非定常雷诺平均纳维–斯托克斯（中列）的预测结果进行比较。非定常雷诺平均纳维–斯托克斯和机器学习模拟均从不适定初始条件开始。

授权许可使用仅限于：密西西比州立大学图书馆。于 2023年5月5日 19:17:04 协调世界时从 IEEE Xplore 下载。适用相关限制。

D. 先验与后验验证

针对该案例，使用壁法向方向上含有 65 个点的一维计算域进行了三组模拟。对于第 #1 组，机器学习模型以先验模式使用，即采用单方程 URANS 模型进行模拟，并使用局部流动预测查询回归映射。对于第 #2 组，机器学习模型以后验模式使用，模拟从T =0 时的完全收敛的 URANS 结果开始。对于第 #3 组，机器学习也以后验模式使用，但模拟从不适定初始条件开始，即 $U_{t=0}=(1-y^8)$。将机器学习模型的预测结果与 URANS 预测和 DNS数据进行了比较。第 #3 组模拟的结果如图 6 所示。

URANS模型对平均流动的预测相当准确，但预测的剪切应力明显扩散，峰值低估了 9%。湍动能的误差最大，其峰值低估了 60%。对于从不适定初始条件开始的模拟，模拟初期的解与直接数值模拟（DNS）存在较大差异，但随后逐渐恢复； 2nd 和 3rd 个周期的解与前一种情况的解非常相似。这是因为流动主要由压力梯度驱动，并会适应压力变化。

机器学习模型在先验测试中的预测结果显示，其剪切应力预测显著优于URANS模型。平均速度和剪切应力的预测误差约为 3–5%，湍动能峰值则高估了 15%。由于机器学习模型使用了URANS模型预测的速度和导数，因此前者预测性能的提升可归因于其学习湍流应力与应变率之间非线性相关性的能力。机器学习模型在后验模拟中也表现出色，平均速度、剪切应力和k与直接数值模拟（DNS）的差异均在 8% 以内。机器学习模型对不适定初始条件的适应速度也远快于URANS模型。

IV. 机器学习转子模型

目前的研究正将为直升机旋翼开发的机器学习致动线模型 [24] 扩展至单个水动能涡轮机转子的建模，并纳入黏性应力和叶尖诱导湍流的影响。研究已对机器学习致动线模型进行了可行性分析，其中利用叶片解析模拟得到的轴向和切向动量亏损来确定致动线模型的升力和阻力系数。

初步的机器学习致动线模型（称为数据驱动致动线模型）仅需 20% 的计算成本，就能给出与叶片解析模型非常相似的瞬时流动预测（如图 9 所示）。图 10 对比了中心平面 $y/D = 0$ 处的平均流向速度预测结果与实验数据 [25] 以及叶片解析模拟结果 [26] 。叶片解析模型与实验结果吻合较好，能够预测叶片尖端后方的峰值亏损，但对尾流向中心扩散的预测略有不足。数据驱动致动线模型对平均尾流亏损的预测非常准确，结果与叶片解析模型的预测非常相似。

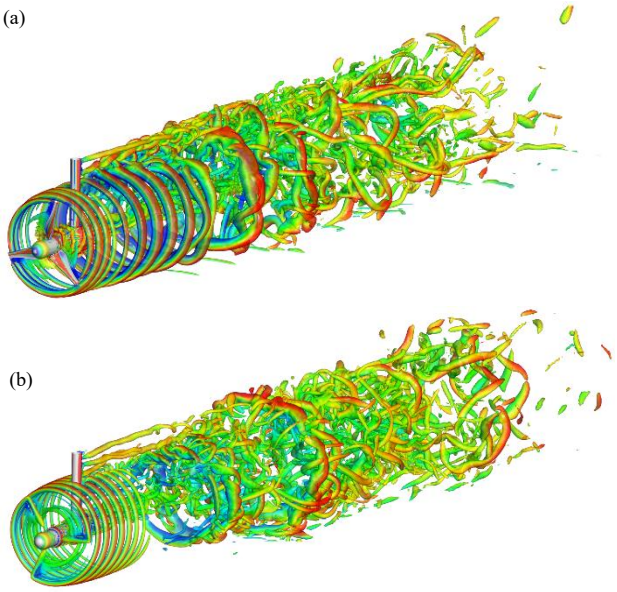

图 9. 使用以下方法获得的水动能涡轮机尾流预测结果：(a) 在包含 19M 个单元的网格上进行的叶片解析模型模拟；(b) 在包含 12M 个单元的网格上进行的数据驱动致动线模型模拟。

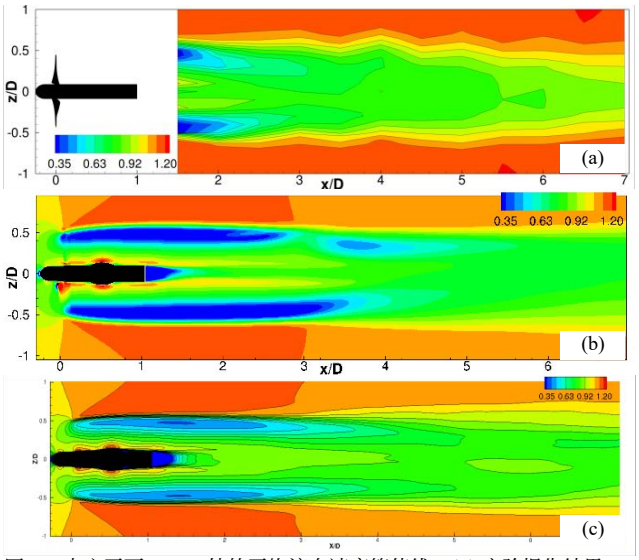

图 10. 中心平面y/D = 0处的平均流向速度等值线：(a) 实验报告结果 [25]；(b) 在包含 19M 个单元的网格上进行的叶片解析模拟 [26], ；(c) 在包含 12M 个单元的网格上进行的数据驱动致动线模型模拟。

V. 结论与未来工作

本研究探讨神经网络在两类不同问题中学习目标建模变量与流动参数之间相关性的能力：

授权许可使用仅限于：密西西比州立大学图书馆。于2023年5月5日19:17:04（协调世界时）从 IEEE Xplore 下载。适用相关限制。

湍流建模和转子建模。对于湍流建模，针对非定常边界层流动开发了独立的 数据驱动 机器学习模型，其性能显著优于非定常雷诺平均纳维–斯托克斯模型，与直接数值模拟的结果相比误差在 8% 以内。数据聚类被认为是提高机器学习模型精度和降低计算成本的有效工具。对于转子建模，数据驱动致动线模型在预测推力和功率、叶尖涡以及平均尾流方面展现出潜力。因此，将机器学习致动线模型作为可靠的转子模型是可行的。然而，迄今为止，机器学习一直应用于类似类型的数据集；这限制了该模型的适用性，也未能充分检验机器学习方法的稳健性。

目前针对机器学习湍流模型的工作重点是建立一个更大的数据库，涵盖稳态和非定常边界层流动，包括收敛-发散喷管内以及凸起上方的流动等分离边界层流动。利用此类数据库训练的模型将有助于开发适用于边界层流动的更通用湍流模型。鉴于湍流特性范围广泛，预计数据聚类将对训练此类模型非常有帮助。目前针对转子建模的工作重点是建立数据库，用于记录非定常来流条件下转子叶片型线所产生的预期升力和阻力，以训练非定常机器学习致动线模型。

致谢

密西西比州立大学所承担的工作由工程研究与发展中心根据合作协议编号 W912HZ-17-2-0014 资助。本文所载的观点和结论仅代表作者意见，不应被理解为必然代表工程研究与发展中心或美国政府明示或暗示的官方政策或认可。

本材料也基于美国国防部（DoD）高性能计算现代化计划（HPCMP）用户生产力提升、技术转让与培训（PET）合同 #47QFSA18K0111、任务单号 ID04180146 所支持的工作，或部分基于该工作。

参考文献

[1] S. Bhushan、G. W. Burgreen、D. Martinez 和 W. Brewer，“湍流建模与预测中的机器学习”，FEDSM2020-10940，ASME 2020 流体工程分部夏季会议论文集。2020年7月12日至16日，美国佛罗里达州奥兰多。[2] S. L. Brunton、B. R. Noack 和 P. Koumoutsakos，“流体力学中的机器学习”，《流体力学年度评论》，第52卷，第477–508页，2020年。[3] M. Milano 和 P. Koumoutsakos，“近壁湍流的神经网络建模”，《计算物理学杂志》，第182卷，第1–26页，2002年。[4] X. W. Jin、P. Cheng、W. L. Chen 和 H. Li，“基于圆柱体表面压力的融合卷积神经网络对不同雷诺数下圆柱体周围速度场的预测模型”，《流体物理学》，第30卷，第047105期，2018年。[5] W. N. Edeling、P. Cinnella、R. P. Dwight 和 H. Bijl，“k-ε 湍流模型参数变异性的贝叶斯估计”，《计算物理学杂志》，第258卷，第73–84页，2014年。[6] J. Ling 和 J. Templeton，“评估用于预测雷诺平均 Navier–Stokes 不确定性较高区域的机器学习算法”，《流体物理学》，第27卷，第085103期，2015年。[7] J. L. Wu、J. X. Wang、H. Xiao 和 J. Ling，“对数据驱动湍流建模预测置信度的先验评估”，《流动、湍流与燃烧》，第99卷，第25–46页，2017年。[8] K. Duraisamy、G. Iaccarino 和 H. Xiao，“数据时代的湍流建模”，《流体力学年度评论》，第51卷，第357–377页，2019年。[9] J. Ling、A. Kurzawski 和 J. Te mpleton，“采用嵌入不变性的深度神经网络进行雷诺平均湍流建模”，《流体力学杂志》，第807卷，第155–166页，2016年。[10] J. Weatheritt、J. 和 R. D. Sandberg，“使用新型进化算法开发代数应力模型”，《国际传热与流体流动杂志》，第68卷，第298–318页，2017年。[11] J-L. Wu、H. Xiao 和 E. Paterson，“用于增强湍流模型的物理信息机器学习方法：综合框架”，《物理评论：流体》，第3卷，074602，2018年，第 .期。[12] https://asc.army.mil/web/portfolio-item/aviation_gray-eagle-uas-2[13] J. Bowman、S. Bhushan、D. Thompson、D. O'Doherty、T. O'Doherty 和 A. Mason-Jones，“用于水流能涡轮机的基于物理的致动盘模型”，2018年流体动力学会议，AIAA 航空论坛（AIAA 2018-3227）。[14] Y. LeCun、Y. Bengio 和 G. Hinton，“深度学习”，《自然》，第521卷，第436–444页，2015年。[15] M. Raissi、P. Perdikaris 和 G. E. Karniadakis，“物理信息神经网络：用于求解涉及非线性偏微分方程的正向与反向问题的深度学习框架”，《计算物理学杂志》，第378卷，第686–707页，2019年。[16] Z. U. A Warsi，《流体动力学：理论与计算方法》，第二版，CRC出版社，1998年。[17] M. Lee 和 R. D. Moser，“高达 $Re_\tau = 5200$的湍流槽道流直接数值模拟”，JFM，744，第395–415页，2015年。[18] G. Borrell、J. A. Sillero、J. Jimenez，“用于在 BG/P 超级计算机上对高雷诺数湍流边界层进行直接数值模拟的代码”，《计算与流体》，第80卷，第37–32页，2013年。[19] A. Scotti 和 U. Piomelli，“脉动湍流槽道流的数值模拟”，《流体物理学》，第13卷，第5期，第1367–1384页，2001年。[20] S. Bhushan 和 D. K. Walters，“使用影响矩阵法开发并行伪谱求解器及其在边界层转捩中的应用”，《计算流体力学工程应用》，第8卷（1），第158–177页，2014年。[21] S. Bhushan 和 S. Muthu，“用于直接数值模拟的并行伪谱方法的性能与误差评估”，《计算流体动力学工程应用》，第13卷（1），第763–781页，2019年。[22] T. Jamal、S. Bhushan 和 D. K. Walters，《使用双指数动态时间滤波技术对非定常湍流进行数值模拟》，ASME 2020 流体工程分部夏季会议论文集 FEDSM2020，16，2020年，12July—奥兰多，佛罗里达州，美国。[23] S. Muthu 和 S. Bhushan，“平板边界层旁路转捩的时间直接数值模拟”，《湍流杂志》，第21卷（5–6），第311–354页，2020年。[24] D. Martinez、J. Sitaraman、W. Brewer、P. Rivera 和 D. Jude，“基于机器学习的旋翼叶片气动模型”，发表于2020年 VFS 变革性垂直飞行会议，美国加利福尼亚州圣何塞，2020年。[25] S. C. Tedds、I. Owen 和 R. J. Poole，“模型水平轴潮流涡轮机的近尾流特性”，《可再生能源》，第63卷，第222–235页，2014年。[26] S. Salunkhe、O. El Fajri、S. Bhushan、D. Thompson、D.、D. O’Doherty、T. O’Doherty 和 A. Mason-Jones，“潮流涡轮机尾流预测的验证及尾流恢复机制分析”，《海洋科学与工程杂志》，第7卷（10），第1–24页，2019年。

授权许可仅限密西西比州立大学图书馆使用。于2023年5月5日19:17:04协调世界时从 IEEE Xplore 下载。使用受限。