

基于神经网络的卧螺离心机螺旋流场流速建模

赵曰炜, 丛佩超*, 周 栋, 李文彬

广西科技大学机械与汽车工程学院, 广西 柳州

收稿日期: 2024年1月17日; 录用日期: 2024年3月12日; 发布日期: 2024年3月19日

摘 要

提出了一种基于深度学习方法的卧螺离心机螺旋流场流速预测模型。对于流体力学问题的数值模拟主要依赖于求解离散化的控制方程, 深度学习由于其处理强非线性和高维性的能力, 在解决流体问题方面显示出了新的前景。然而, 现成的神经网络架构大多用于简单流场, 对于稍复杂些的流场未得到充分应用。首先, 使用一个结构化的深度神经网络, 将流场控制的偏微分方程(即Navier-Stokes方程)纳入DNN的损失来驱动训练; 然后, 根据螺旋流场特征参数施加边界条件建立流速预测模型; 最后, 利用所构建的模型预测卧螺离心机螺旋流场流速分布并与数值模拟结果做对比实验。结果表明: 通过对流场不同压力、角速度下的流速进行预测, 构建的模型与数值模拟结果具有很好的一致性。

关键词

深度神经网络, 螺旋流场, 流体力学, 流动控制

Neural Network-Based Modeling of Flow Velocity in the Spiral Flow Field of a Decanter Centrifuge

Yuewei Zhao, Peichao Cong*, Dong Zhou, Wenbing Li

College of Mechanical and Automotive Engineering, Guangxi University of Science and Technology, Liuzhou Guangxi

Received: Jan. 17th, 2024; accepted: Mar. 12th, 2024; published: Mar. 19th, 2024

Abstract

A flow rate prediction model for the spiral flow field of a decanter centrifuge based on a deep learning approach is proposed. Numerical simulation of fluid dynamics problems mainly relies on

*通讯作者。

文章引用: 赵曰炜, 丛佩超, 周栋, 李文彬. 基于神经网络的卧螺离心机螺旋流场流速建模[J]. 建模与仿真, 2024, 13(2): 1304-1310. DOI: 10.12677/mos.2024.132122

solving discretized governing equations, and deep learning shows new promise in solving fluid problems due to its ability to handle strong nonlinearities and high dimensionality. However, off-the-shelf neural network architectures are mostly used for simple flow fields and are underutilized for slightly more complex flow fields. First, a structured deep neural network with partial differential equations for flow field control (Navier-Stokes equations) is used to drive the training by incorporating the losses of the DNN; then, a flow velocity prediction model is built by imposing boundary conditions based on the characteristic parameters of the spiral flow field; finally, the constructed model is used to predict the flow velocity distribution in the spiral flow field of a decanter centrifuge and experiments are conducted to compare the results with those of numerical simulations. The results show that the constructed model is in good agreement with the numerical simulation results by predicting the flow velocity under different pressures and angular velocities of the flow field.

Keywords

Deep Neural Network, Spiral Flow Field, Fluid Mechanics, Flow Control

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

流体系统通常由 Navier-Stokes 方程控制，这是一个高度非线性的偏微分方程系统。流体动力学问题的数值模拟主要依赖于使用离散形式的有限差分、有限体积或有限元方法，这被称为计算流体动力学(CFD)方法[1]。然而，计算流体动力学模拟往往在计算上很麻烦，特别是对于具有湍流和复杂几何形状的流动。

深度学习，特别是深度神经网络(DNN)已经成为一种常用的替代建模方法，并在处理高维非线性问题方面显示出了巨大的潜力[2]。武煜坤等人采用人工神经网络(Artificial Neural Network, ANN)与计算流体力学(Computational Fluid Dynamics, CFD)相结合的方法，构建了 ANN-CFD 湍流状态预测模型[3]。王龙滢等人提出了一种物理信息深度学习对动态尾流流场进行预测，该方法通过结合少量稀疏的激光雷达测量和流体动力学方程来实现动态尾流的时空重构[4]。韩仁坤等人提出了一种基于神经网络的流场预测模型，来学习并预测运动边界附近的非定常流场演化过程[5]。Nabian 和 Meidani [6]以及 Karumuri 等人[7]应用偏微分方程约束全连接神经网络(FCNN)在稳态热方程中的不确定性传播，他们的结果显示了使用物理驱动的 DNN 进行流动建模的潜力。

卧螺离心机是一种高效的离心分离设备，在污泥脱水、粒度分级、液相澄清等方面应用较成熟。过去对于卧螺离心机流场的研究主要是基于计算流体力学方法[8]。本文的目的是开发一个物理驱动的深度神经网络螺旋流场流速预测模型。首先构建一个结构化的神经网络模型来近似自然流动计算域 Navier-Stokes 方程的解，神经网络训练通过最小化控制偏微分方程的残差(即守恒定律)来驱动，初始以及边界条件根据流场参数进行限制，结合 DNN 的原始输出数据以及螺旋流场参数进行流速求解，最后将模型应用于卧螺离心机流场流速预测，证明了该方法的有效性。

2. 模型方法

2.1. 概述

大多数流动问题，可以用不可压缩的 Navier-Stokes 方程进行求解：

$$\rho \frac{DV}{Dt} = \rho f - \nabla p + \mu \nabla^2 V \tag{1}$$

当给定初始和边界条件时，速度和压力的解可以被确定。当给定参数集合后，可以通过使用有限差分、有限体积、有限元方法离散化方程组数值求解流场，但这个过程涉及网格生成和迭代求解大型线性或非线形系统，通常需要耗费大量时间。本文构建了一个基于深度神经网络(DNN)的螺旋流场流速预测模型，模型经过训练之后，基于给定的输入，模型能够快速对流速进行预测。图 1 展示了所提出的框架的示意图。全连接神经网络(FCNN)的输入层由坐标 x 和变量参数 α (包括流体粘度、密度等参数)组成，FCNN 的原始输出与包含初始条件、边界条件的特解被用来构建螺旋流场流速。FCNN 通过最小化 Navier-Stokes 方程的残差进行训练，从而保证 DNN 预测结果符合流体流动的守恒定律并满足指定的初始边界条件。

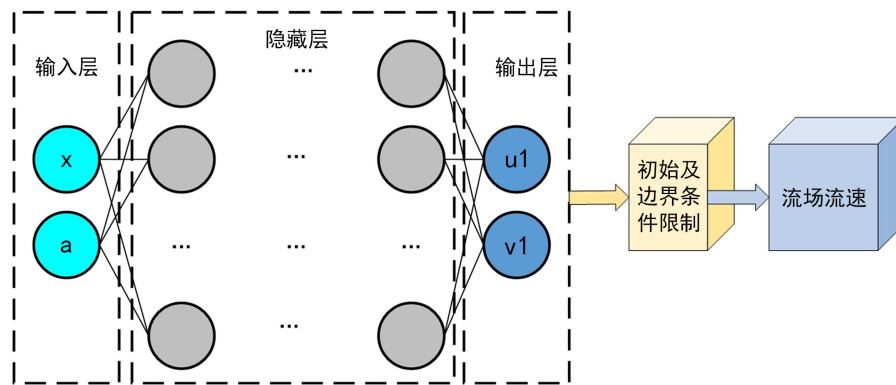


Figure 1. Schematic diagram of flow rate modeling for helical flow field
图 1. 螺旋流场流速建模示意图

2.2. 深度神经网络

神经网络是一种常用的机器学习算法，用于分类和回归任务。不同类型的神经网络具有不同的神经元连接形式和结构，如全连接神经网络(FCNN)、卷积神经网络(CNN)和递归神经网络(RNN)。在本研究中，使用前馈 FCNN，其中相邻层的神经元完全连接，各层的输出被前馈作为下一层的输入。FCNN 定义了从输入层到输出层的映射。输入层和输出层之间的层被称为隐藏层，具有多个隐藏层的神经网络被称为深度神经网络。在数学上，两个相邻的层被连接为：

$$z_l = \sigma_l (W_l z_{l-1} + b_l) \tag{2}$$

其中 W_l 和 b_l 为权值矩阵和偏置向量；下标 l 表示层的索引； σ_l 是一个激活函数，可以选择许多选项，比如 sigmoids, rectified linear units (ReLU)和 tanh 函数。训练后，可以确定每层的权重、偏置和激活函数。与 CFD 模拟相比，训练好的模型能够大大降低计算成本。

2.3. 施加边界条件

对于螺旋流场的边界条件本研究采用特定解与损失函数方程结合的方式处理。具体地：

$$\hat{u}^y(x, \alpha; W, b) = u'(x, \omega, \alpha) + F(x, \omega, \alpha) u^y(x, \alpha; W, b) \tag{3}$$

其中 $u'(x, \omega, \alpha)$ 是一个特定的解，满足初始边界条件； $F(x, \omega, \alpha)$ 是一个基于螺旋流场特性与流体参数的连续函数，定义了一个与坐标、流场参数、角速度相关的方程； u^y 为 FCNN 模型的原始输出。对于卧螺离心机流场，函数 $F(x, \omega, \alpha)$ 和特定解可以用解析形式表示。特定解 u' 参考旋转流体中的速度计算公式：

$$v = \omega r \quad (4)$$

其中 v 表示速度, 单位为 m/s; ω 表示角速度, 单位为 rad/s; r 表示旋转半径, 单位为 m。

本文以 LW450 型卧螺离心机柱段转鼓处的流动为研究对象, 将其简化为二维流动模型(如图 2)进行研究。设置流体参数为: 粘度 0.001, 密度 1; 结合卧螺离心机参数(表 1)可以构建基于 DNN 的卧螺离心机内部螺旋流场流速预测模型。根据卧螺离心机内部流场实际工况(入口流速小于或等于平均旋转线速度, 即 $u^p \leq \overline{\omega R}$), 构建流速分量 \hat{u} 、 \hat{v} 为:

$$\hat{u} = \omega|y| + \frac{1}{\omega} \left(\frac{d^2}{4} - (y + 0.172)^2 \right) u^p \quad (5)$$

$$\hat{v} = \left(\frac{d^2}{4} - (y + 0.172)^2 \right) v^p \quad (6)$$

式中, y 为纵坐标, $d = 0.106$ m 为螺旋内壁与外壁的距离, 原始 DNN 输出分量用 u^p 、 v^p 表示。

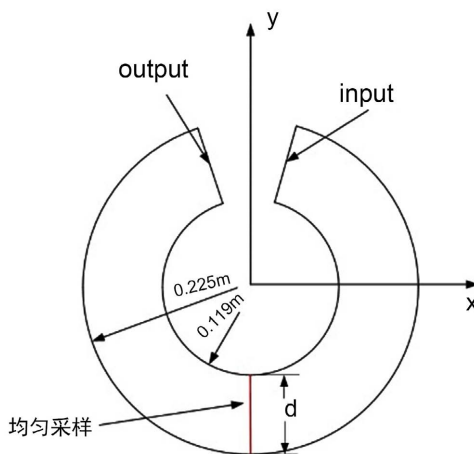


Figure 2. Two-dimensional schematic diagram of the flow field in the column section of decanter centrifuge

图 2. 卧螺离心机柱段流场二维示意图

Table 1. Structural parameters of LW-450 decanter centrifuge

表 1. LW-450 卧螺离心机的结构参数

结构参数	数值	结构参数	数值
柱段长度(mm)	1024	叶片厚度(mm)	8
锥段长度(mm)	663	叶片顶隙(mm)	2
叶片倾角(°)	0	转鼓内径(mm)	450
半锥角(°)	8	进料直径(mm)	60
柱段螺旋输送机导程(mm)	160	柱段螺旋输送机导程(mm)	128

2.4. 神经网络参数与训练

在本研究中, 我们只考虑了稳态解来进行。使用了一种复合 FCNN 结构, 由两个子 DNN 组成, 3 层结构相同, 每层 20 个神经元。除最后一层使用线性激活函数外, 每一层都采用了具有固定超参数的 Swish 激活函数。这两个子 DNN 使用相同的输入层, 并分别预测两个标量状态变量, 即速度分量 u 、 v 。所有两个子 DNN 都用统一的物理损失函数同时训练, 本文使用了 Adam 优化器, 学习率基于矩的估计自

适应地改变。DNN 架构的参数选择,包括层数、每层神经元数、激活功能和初始化方案等对学习性能很重要,本文通过测试采用了最优参数架构,并且本文中所有案例的结构和超参数都保持不变。在本文中,为了确保学习质量,残差在大量的样本点上进行了评估。对于所有的测试案例,训练大约进行了 10^5 次迭代,使用 NVIDIA GeForce GTX 1650Ti 图形处理器(GPU)进行计算,耗时约为 1.5 小时。

3. 结果与讨论

卧螺离心机内部流场通常是由叶片的压力驱动,因此入口为压力入口,这里只研究流场完全发展的状态。为了测试构建模型的预测性能,使用 Fluent 软件进行了相应的 CFD 模拟,然后将模型的预测结果与 CFD 计算结果进行对比实验。如图 3 为 CFD 模拟得到的压力为 0.3 pa,角速度为 3 rad/s、5 rad/s、10 rad/s 速度分布图像。

从图 3 中可以看出,径向流场流速受压力及角速度影响;当压力不变时,随角速度增大,流速最大值向外壁面处移动。这是由于当角速度逐渐增大时,流速受压力的影响变小,此时流速由角速度主导,当达到某一角速度后外壁面处流速最大。

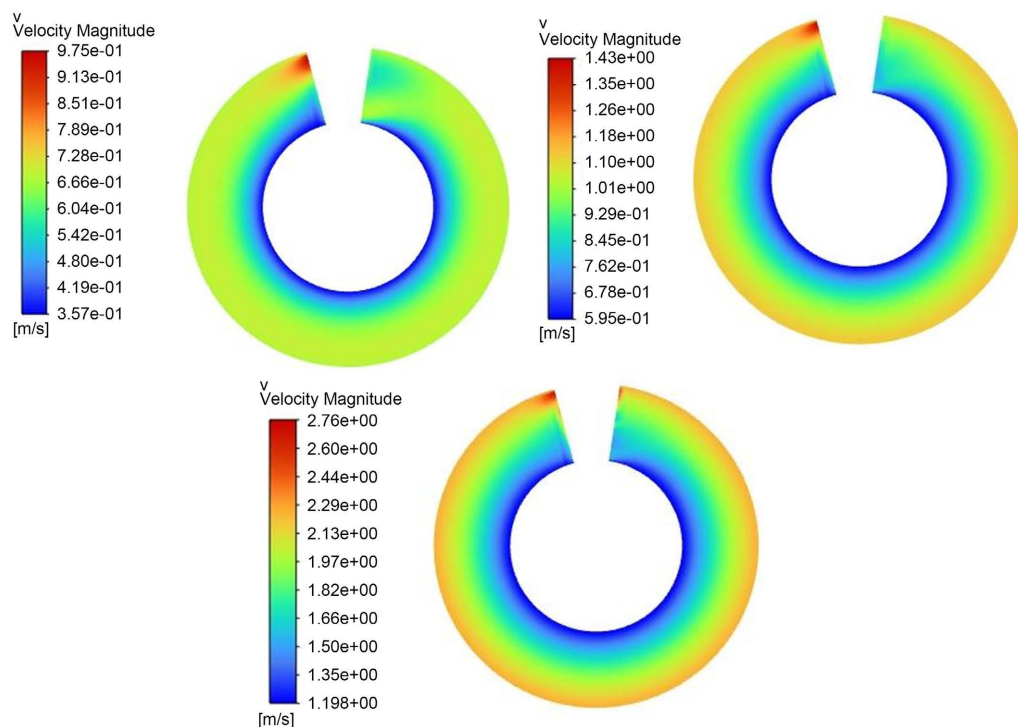
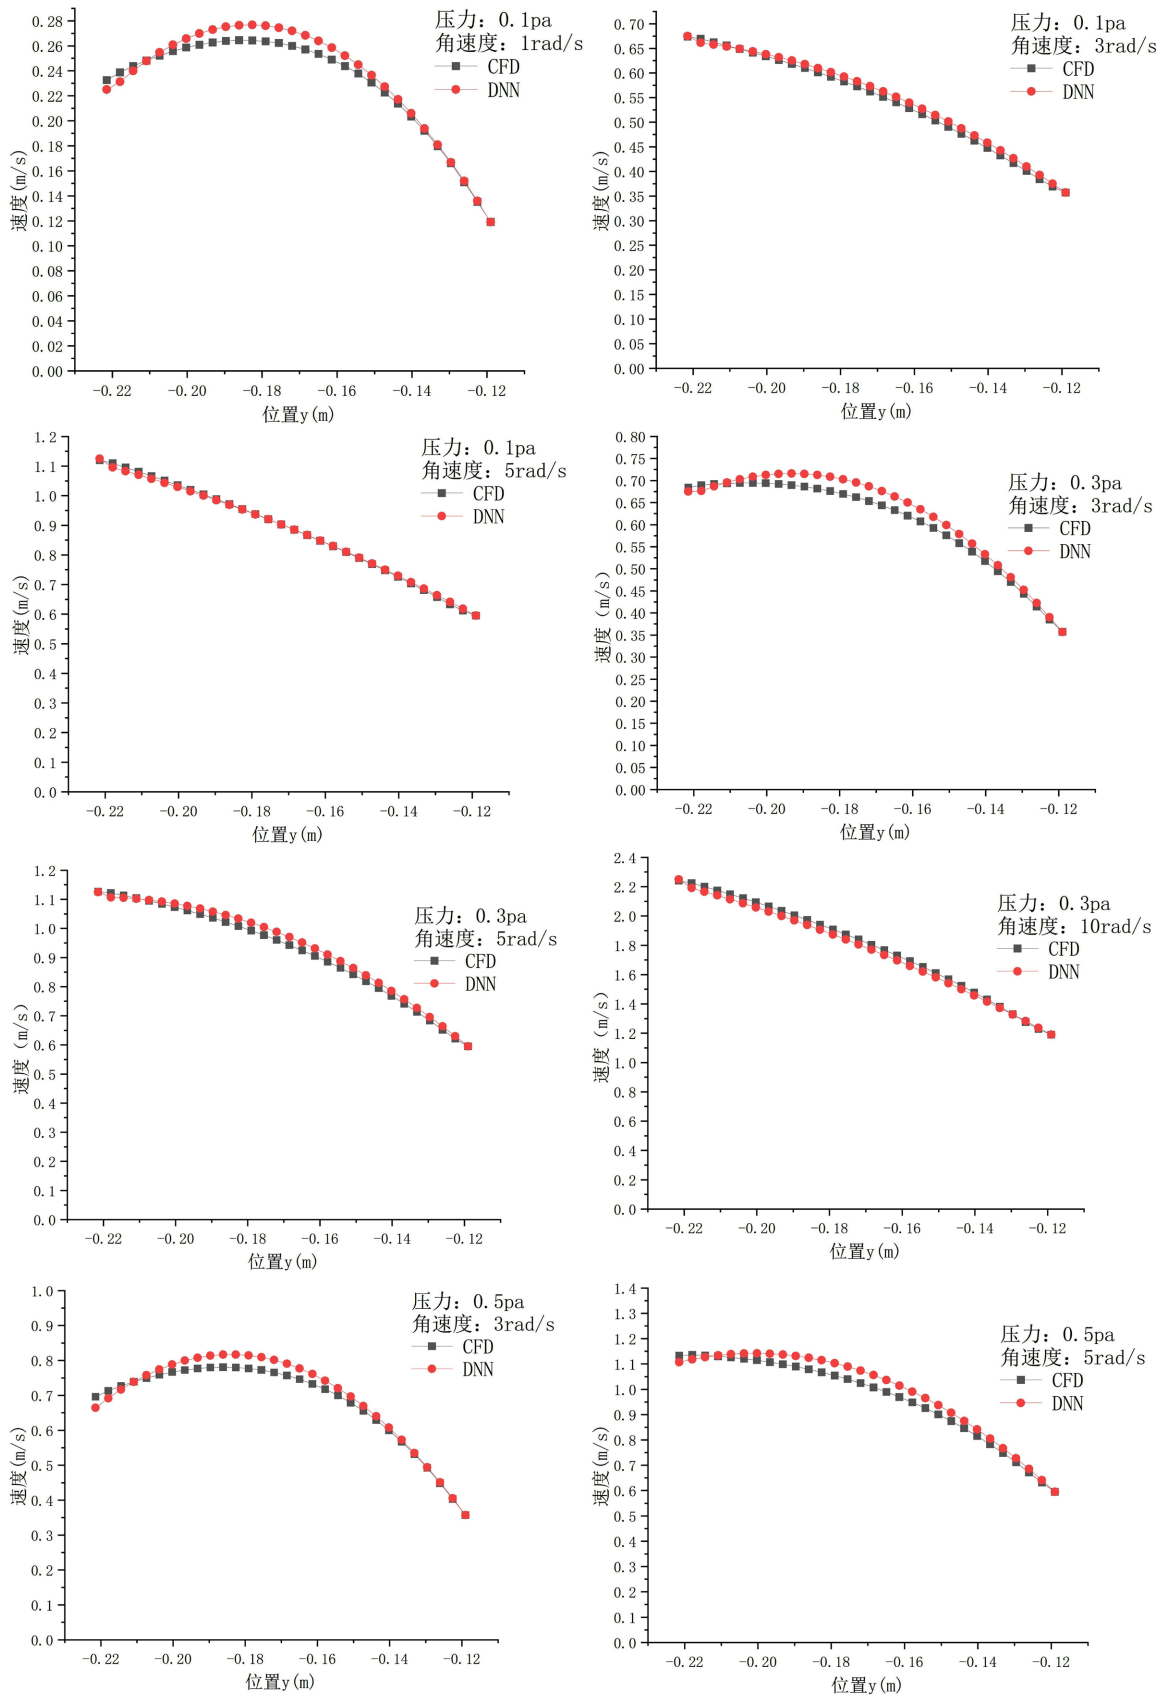


Figure 3. Flow velocity cloud of decanter centrifuge column section flow field

图 3. 卧螺离心机柱段流场流速云图

将图 2 所示红线区域作为测试区域,对径向 y 均匀采样,预测每个节点的流速。分别测试了压力差为 0.1 pa、0.3 pa、0.5 pa,角速度为 1 rad/s、3 rad/s、5 rad/s、10 rad/s 的流速,将模型的预测结果与 CFD 结果进行了比较,如图 4 所示,其中横坐标为 y 方向相对位置。从图 4 中可以看出:当压力相同时,随角速度增大,模型能够对流速变化趋势进行有效预测,但对于角速度较低的情况下模型预测值略有偏差,但总体来说模型预测结果与 CFD 计算结果趋于一致;角速度相同时,模型对于不同压力差下的流速预测都有较好的效果,与 CFD 结果之间的微小偏差基本不变。总体上基于 DNN 的模型与 CFD 的计算结果高度拟合,证明了所构建的模型对于不同压力差、角速度下均能够对螺旋流场流速进行有效预测。



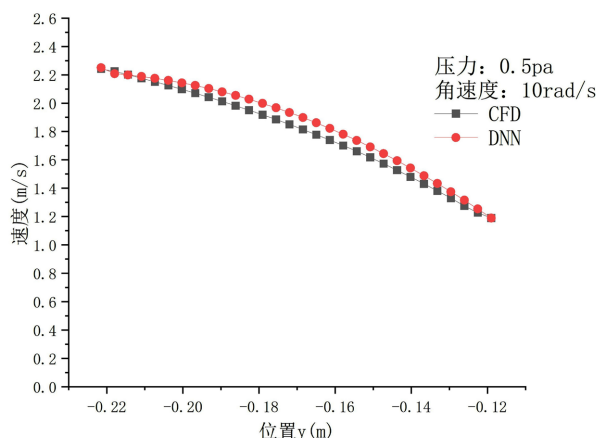


Figure 4. Flow velocity prediction curve of decanter centrifuge column section flow field
图 4. 卧螺离心机柱段流场流速预测曲线

4. 结论

本文提出了一种物理驱动的 DNN 螺旋流场流速预测模型。具体地说, 首先使用一个结构化的神经网络模型来近似参数 Navier-Stokes 方程的解, 然后通过螺旋流场特征参数施加初始边界条件, 使得构建的模型能够对螺旋流场进行流速预测, 并将模型引入卧螺离心机流场进行测试。

将训练后的模型在不同压力、角速度下的工况进行测试, 结果表明: 基于 DNN 的流速预测模型与 CFD 模拟结果具有较高的一致性, 虽然对于角速度较低情况下(流速受压力影响主导)模型的预测与 CFD 结果略有偏差, 但仍然能够对流速分布进行有效预测。研究结果证明了所提方法的有效性, 并且所构建的模型不需要计算流体力学模拟数据, 能够大大降低计算成本, 模型经过多个具有不同螺旋流动特征数据集的训练和测试后, 就可以将其应用于复杂螺旋流场流动预测问题中。

参考文献

- [1] 王福军. 计算流体力学分析——CFD 软件原理与应用[M]. 北京: 清华大学出版社, 2004.
- [2] 刘凡平. 神经网络与深度学习应用实战[M]. 北京: 电子工业出版社, 2018.
- [3] 武煜坤, 李政权, 王贻得, 等. 基于神经网络与多相流模拟技术的搅拌过程研究[J/OL]. 有色金属科学与工程, 2024: 1-14. <http://kns.cnki.net/kcms/detail/36.1311.TF.20240115.1409.004.html>, 2024-03-15.
- [4] 王龙滢, 陈梦, 袁建平. 耦合风速测量的风力机时空尾流重构[J/OL]. 排灌机械工程学报, 2023: 1-8. <http://kns.cnki.net/kcms/detail/32.1814.TH.20231228.1710.004.html>, 2024-03-15.
- [5] 韩仁坤, 杜焦喜, 刘子扬, 等. 基于深度神经网络的含运动边界非定常流场预测方法研究[J]. 航空科学技术, 2023, 34(12): 37-42.
- [6] Nabian, M.A. and Meidani, H. (2019) A Deep Neural Network Surrogate for High-Dimensional Random Partial Differential Equations. *Probabilistic Engineering Mechanics*, **57**, 14-25. <https://doi.org/10.1016/j.probengmech.2019.05.001>
- [7] Karumuri, S., Tripathy, R., Bilionis, I., et al. (2020) Simulator-Free Solution of High-Dimensional Stochastic Elliptic Partial Differential Equations Using Deep Neural Networks. *Journal of Computational Physics*, **404**, Article ID: 109120. <https://doi.org/10.1016/j.jcp.2019.109120>
- [8] 秦婧. 卧螺离心机内外筒转速比对分离特性的影响研究[D]: [硕士学位论文]. 西安: 西安石油大学, 2023.