

# 基于 PINN 神经网络模型的 NACA0012 翼型流场周期性振荡运动的流场重构方法初探

刘江硕<sup>1</sup> 彭瑞东<sup>1</sup> 郑冠男<sup>2</sup> 陈军屹<sup>3</sup>

(1.中国矿业大学(北京) 力学与土木工程学院, 北京 100083

2.中国科学院力学研究所, 北京市海淀区北四环西路 12 号, 100190

3.中国科学院大学, 北京市石景山区玉泉路 19 号(甲), 100049)

**摘要:** 翼型的设计直接影响整个飞行器的设计, 传统对于翼型外流场的研究主要是通过风洞试验和数值仿真, 存在着操作不便、耗时长等现象。本研究提出基于物理信息的神经网络模型, 针对二维 NACA0012 翼型在流场中周期性振荡运动进行流场重构工作, 将模型预测结果与 CFD 数值仿真结果对比, 证明该模型可以完成对于二维 NACA0012 翼型在流场中周期性振荡运动外流场的流场重构工作。

**关键词:** 深度学习; 流体力学; PINN 方法

## 0 引言

翼型的设计对于飞行器的性能至关重要。除了提供升力外, 翼型还直接影响飞行器的操纵性和稳定性<sup>[1]</sup>。因此, 如何快速、准确地获取与机翼相互作用的外流场信息, 对于提升飞行器整体性能和安全性具有重要意义。流场重构是解决流体力学领域中流场信息获取和重建的问题, 传统解决这类问题可以通过地面风洞试验、飞行试验等方法获取的真实直接的流场数据, 也可以运用计算流体力学(CFD)的方法进行数值模拟计算, 但这类方法在计算速度、准确性和效率等方面存在一定的局限性。

近年来, 随着人工智能技术的高速发展, 为解决翼型外流场的计算提供了一种新的方法, 人工智能与流体力学的结合是当今的一个热点发展方向<sup>[2-4]</sup>。传统机器学习的方法在面对流场重构问题时对高质量数据集的依赖性较高, 无法处理稀疏数据的问题。现阶段对于稀疏数据的流场结构重构方法的研究, 源于 Raissi 学者率先提出了一种

基于物理信息驱动的神经网络框架, 他通过在原先的神经网络模型中耦合流场物理约束方程, 利用少量数据训练神经网络便可以输出全流场数据。结果表明, 物理信息驱动型神经网络通过耦合 N-S 方程, 仅使用极其有限的流场数据即可实现对全流场的高精度重构。针对重构翼型外流场的问题, 国内学者曹晓峰采用了改进后的 U-Net 结构深度神经网络模型<sup>[5]</sup>。先根据给定的来流速度、迎角和气压等参数, 通过 CFD 计算得到翼型周围可压缩流的速度和压力, 然后将计算结果映射到矩阵中用于制作神经网络的数据集。运用该模型可以快速获得当前翼型的流场分布, 其方法大大的提高了流场计算的效率, 并在可保证计算精度的前提下进行流场重构。国内学者余柏杨基于机器学习, 通过构建 BP 神经网络完成对机翼的气动载荷的重构工作<sup>[6]</sup>。总而言之, 目前深度学习技术在流场重构问题中取得了较为广泛的应用, 但在高精度流场信息的获取以及对于三维流场、非定常流场和包含转捩的自然层流翼型的预测能力有待提升。本文针对二维 NACA0012 翼型在流场中周期性振荡的流

场重构问题，基于 PINN 方法构建神经网络模型以实现流场的预测和重构，研究了运用 PINN 方法预测周期性工况的适配度和优越性。

## 1 NACA0012 翼型周期性震荡运动流场计算

本研究选取二维 NACA0012 翼型作为研究对象，主要是考虑到其具有对称的几何特征以及较为典型的气动特性和流场特性。此外，可以将二维翼型视为在三维翼型的中心截面处进行切片处理，运用该方法在简化

模型、减少数值模拟的计算量的同时，可以更直观地反映局部区域的流动特性，如湍流结构、涡流生成和演化等，以及翼型表面处的流动分离区域和压力分布，有助于更加深入地理解翼型表面流动的细节。

运用 ICEM 完成几何模型的建立以及网格的划分，为考虑来流空气不受到翼型结构的影响，选择建立重叠网格进行计算。首先建立  $400\text{m} \times 200\text{m}$  的矩形计算域为背景网格以及半径为  $40\text{m}$  的圆形区域为前景网格，对矩形区域选择均匀划分网格，对圆形区域选择对翼缘处进行网格加密划分，圆形区域网格数量为 71320，矩形区域网格数量为 161202。

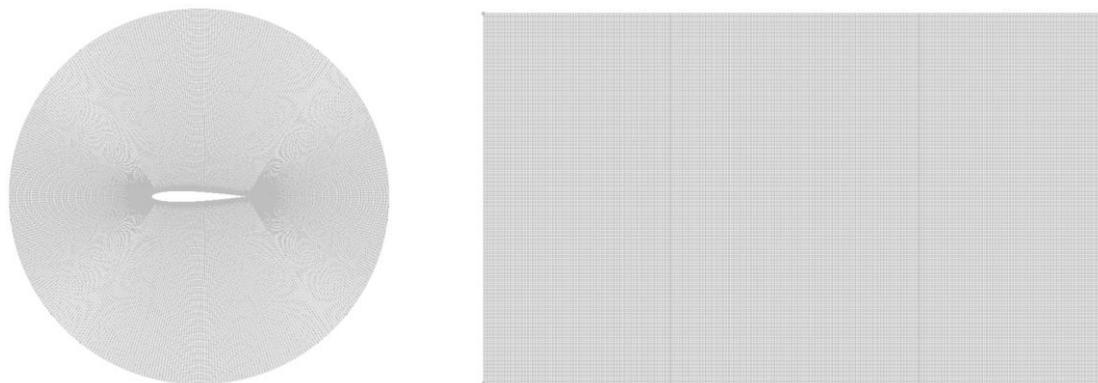


图 1 前景网格图（左）、背景网格图（右）

将网格分别导入 CFD 计算软件 FLUENT 中，设置该模型中选用 SST 中  $k-\epsilon$  模型，选择速度入口以及压力远端，并设置来流速度为  $10\text{m/s}$ ，翼面边界设置为不滑移，通过编写 udf 使翼型绕其中心进行周期性振荡运动，以此为模型设立沉浮条件。设置计算步长为  $0.005\text{s}$ ，待模型计算收敛后保存模型压力云图、速度云图等流场信息。

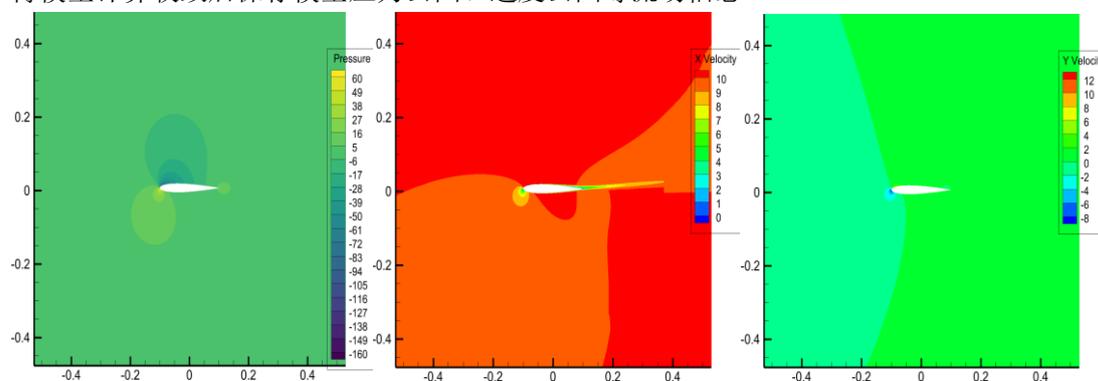


图 2 0s 时，流场中压力云图、x 方向速度云图、y 方向速度云图

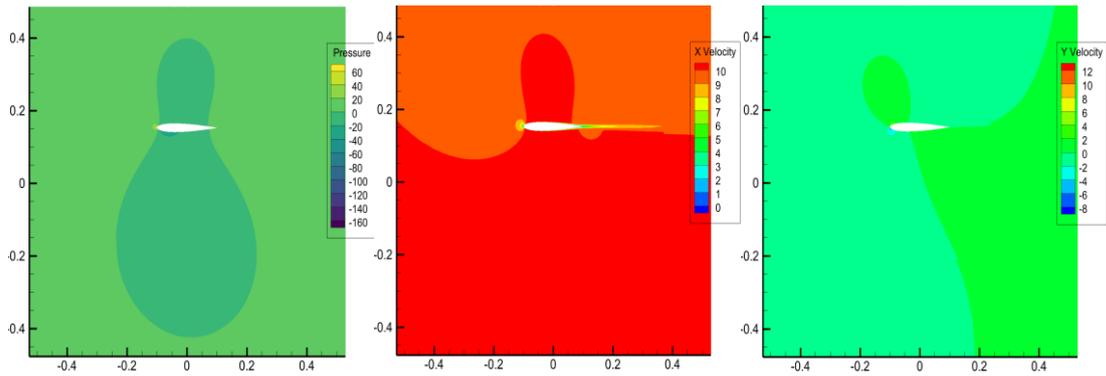


图 3 0.25s 时, 流场中压力云图、x 方向速度云图、y 方向速度云图

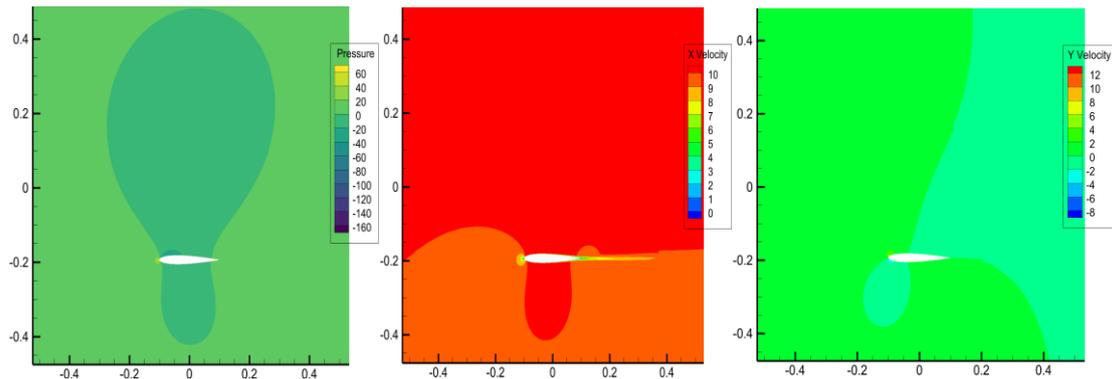


图 4 0.75s 时, 流场中压力云图、x 方向速度云图、y 方向速度云图

## 2 基于物理原理的神经网络模型

数值计算完成后, 针对 NACA0012 翼型的尾流场信息, 开始使用基于物理约束神经网络 (PINN) 方法进行流场重构工作。考虑到周期性数据往往具有复杂的变化趋势, 传统的处理方法可能无法很好地拟合这些数据。而神经网络本身具有多层次的结构和非线性激活函数, 可以拟合出更好地逼近周期性变化中复杂的数据的函数, 从而提高了预测的准确性。除此以外, 神经网络模型具有较好的自适应性, 能够根据数据的特点自动调整模型参数。在该模型中, 流场数据会随着翼型攻角的改变而受到影响, 因此需要模型能够灵活地适应这些变化。神经网络本身可以通过反向传播算法和梯度下降等优化方法, 在训练过程中自动调整权重和偏置, 提高了模型的稳健性和预测能力。显然, PINN 方法在处理周期性工况时具有独特的优势。

首先运用 `tecplot` 对翼型周围流场在计算收敛后的 10s 内的流场信息进行插值提取, 并将插值的到的信息作为数据集。运用 `Pycharm` 软件完成神经网络模型的编程构建, 通过调试各参数的权重, 并将 Navier-Stokes 方程作为损失函数的一部分, 使得神经网络不仅满足自身精度要求, 还受到物理方程的约束使得神经网络具有物理意义, 定义新的损失函数为  $Loss = Loss_u + Loss_v$ , 其中:

$$Loss_u = \frac{1}{N_u} \sum_{i=1}^{N_u} |u^N(t_u^i, x_u^i) - u^i|^2 \quad (2.1)$$

式 (2.1) 表示损失函数中的数据驱动部分, 另一部分的损失函数由物理驱动部分组成, 如公式 (2.2) 所示:

$$Loss_r = \frac{1}{N_u} \sum_{i=1}^{N_u} |r(t_u^i, x_u^i)|^2 \quad (2.2)$$

通过上式损失函数中两部分, 可以使神

神经网络模型不仅与已知训练数据的误差尽可能小，而且还满足偏微分方程的约束条件。由此可推导出在该模型中所构造的损失函数如公式 (2.3) 所示：

$$\begin{aligned} e_1 &= u_t + uu_x + vu_y + p_x - Re^{-1}(u_{xx} + u_{yy}) \\ e_2 &= u_t + uv_x + vv_y + p_x - Re^{-1}(v_{xx} + v_{yy}) \\ e_3 &= u_x + u_y \end{aligned} \quad (2.3)$$

构建出基于物理信息的神经网络，它既考虑了训练数据样本的分布规律，也遵守了由偏微分方程描述的物理定律。与纯数据驱动的神经网络相比，PINN 在训练过程中施加了物理信息的约束，因此能够用更少的数据样本学习得到具有更好泛化能力的模型。

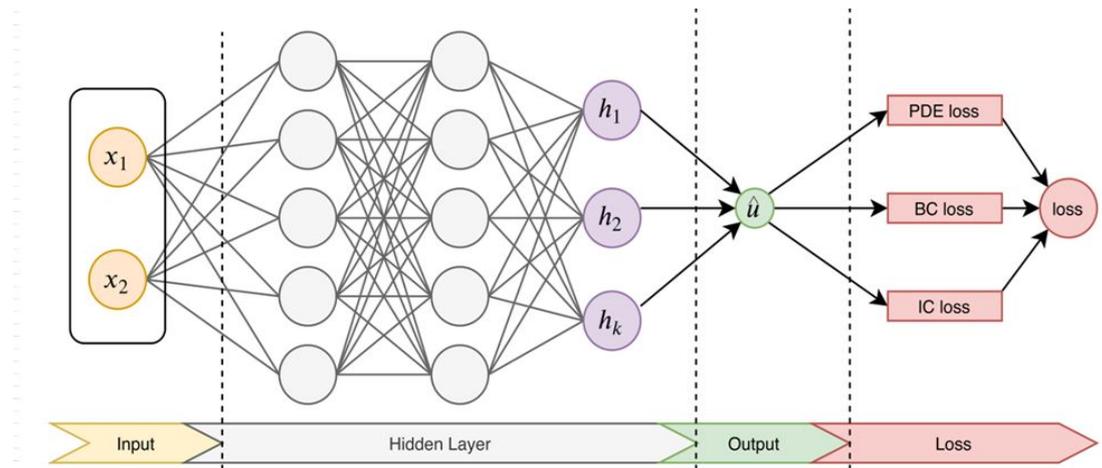
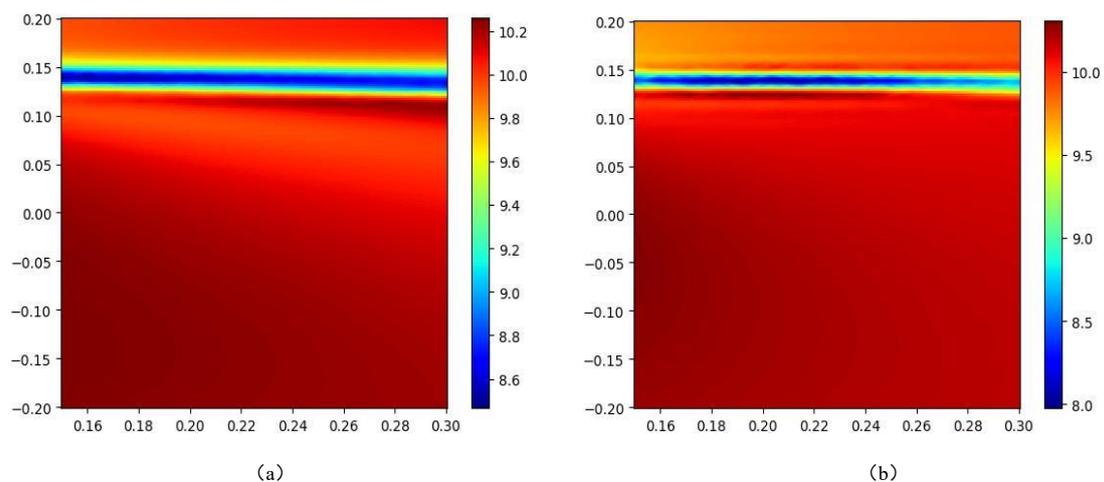
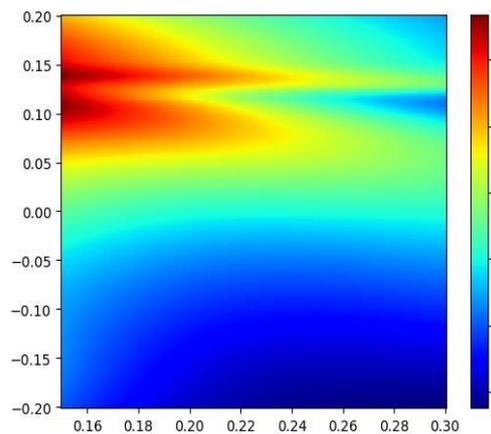


图 5 基于物理信息的神经网络示意图

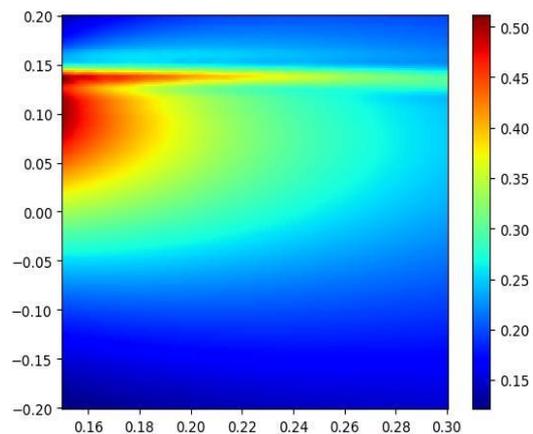
最后，选取十个周期的数据用于神经网络构建，其中，60%的数据用于神经网络训练，20%的数据用于测试，20%的数据用于预测验证。将模型输出的重构的流场信息与真实流场信息进行比较，计算其预测结果的精确度。根据训练结果对模型进行进一步修正和完善，并分析影响模型准确性的因素。

分别提取翼型尾流场和前缘流场的相关流场数据，制作数据集。其中，神经网络经过学习后输出的 0.5s 时翼型尾部流场预测结果与数值仿真结果如下图所示：

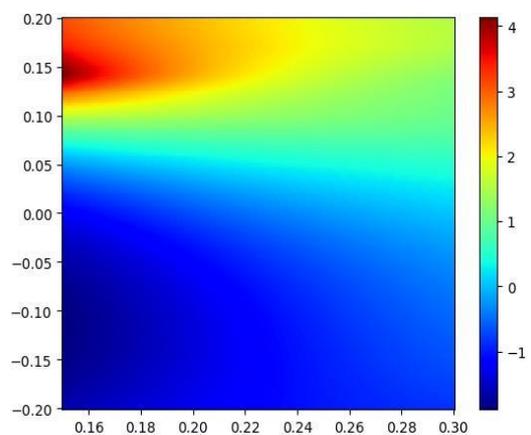




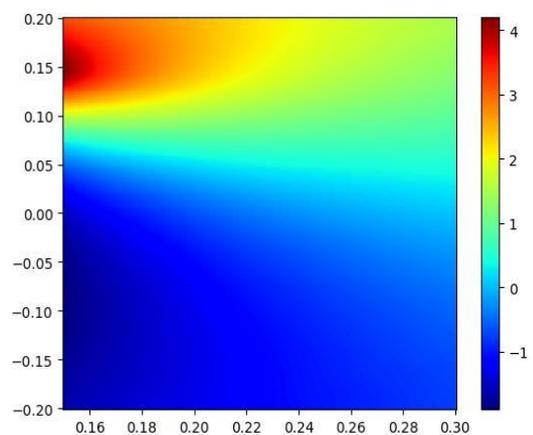
(c)



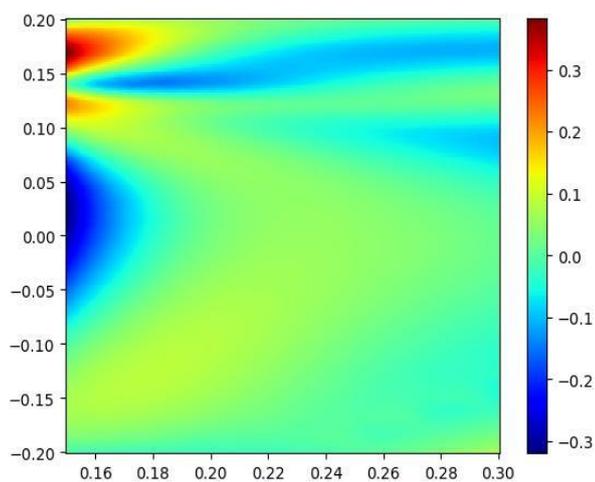
(d)



(e)



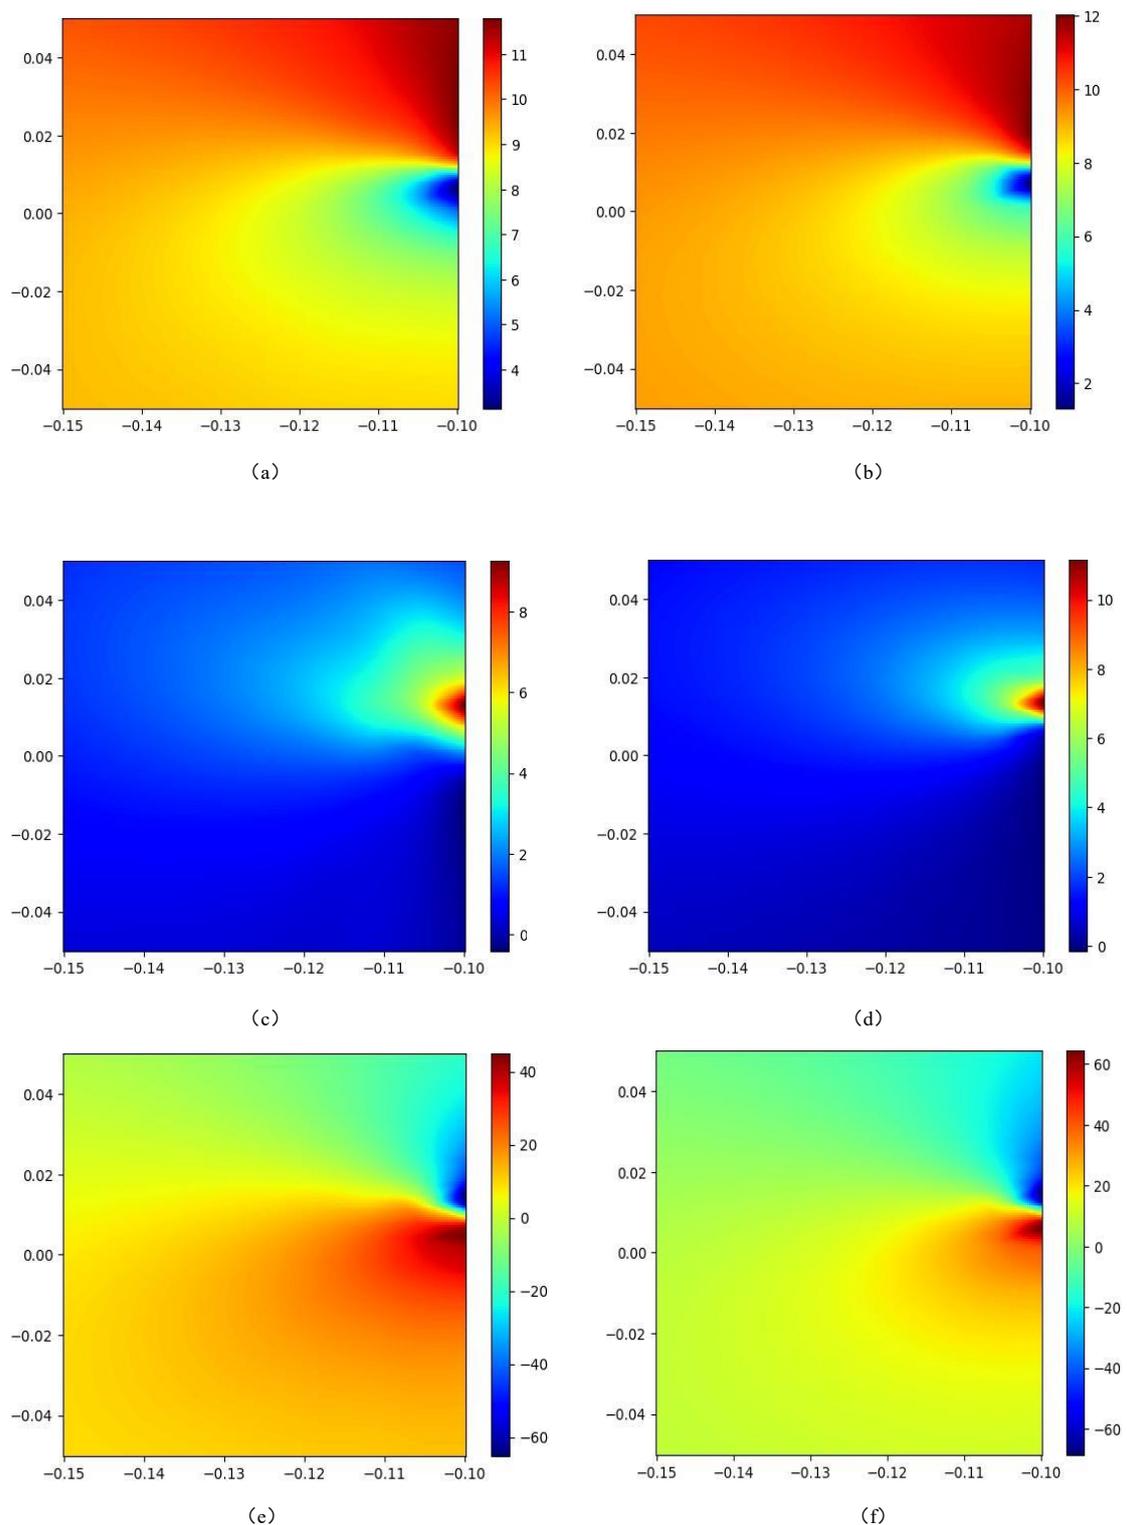
(f)

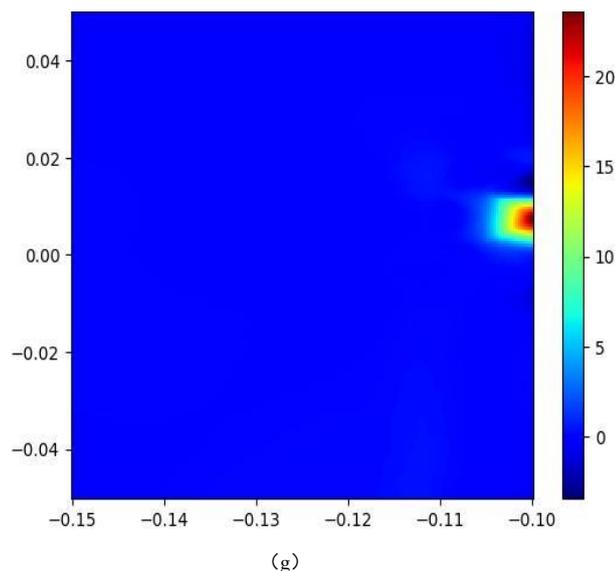


(g)

图注: (a) 流场预测 x 方向速度云图; (b) 数值模拟的 x 方向速度云图  
 (c) 流场预测 y 方向速度云图; (d) 数值模拟的 y 方向速度云图  
 (e) 流场预测压力云图; (f) 数值模拟的压力云图  
 (g) x 方向速度流场预测结果与数值模拟结果的差值图

接着，运用神经网络模型对翼型前缘流场进行流场重构工作，0.5s 时翼型前缘流场预测结果与数值仿真结果如下图所示：





图注: (a) 流场预测 x 方向速度云图; (b) 数值模拟的 x 方向速度云图  
(c) 流场预测 y 方向速度云图; (d) 数值模拟的 y 方向速度云图  
(e) 流场预测压力云图; (f) 数值模拟的压力云图  
(g) x 方向速度流场预测结果与数值模拟结果的差值图

从神经网络模型的预测结果与数值模拟结果的对比图可以直观地发现:该模型可以较为精确地完成二维翼型的流场重构工作,对于前缘流场的压力预测结果的全局误差在 0.012 左右,但对于梯度变化较大的区域预测精度仍存在误差,将在下一步的工作中尝试对神经网络模型进行进一步的优化。

### 3 结果与展望

本文基于 PINN 神经网络模型,探究二维 NACA0012 翼型在周期性振荡中的流场重构工作,并通过权重参数调整提高了翼型尾流场的预测能力。结果表明:该方法在处理翼型周期性振荡运动中有着自己的优势,可以积极推动深度学习与流体力学学科的融合,促进流体力学与深度学习等交叉学科的交流和合作,推动相关技术和方法的创新与发展。

在此项研究的基础上,将在未来为二维翼型添加弹簧约束,从而为该模型增加固体形变的部分,探究其与翼型外流场之间的相

互作用关系,为后续深度学习与流固耦合的研究奠定基础。

### 参 考 文 献

- [1] 阮胤,邱展,王福新.周期激励下 NACA 0012 翼型单自由度失速颤振研究[J].浙江大学学报:工学版,2017,51(9):1870-1880.
- [2] Ji P, Wang T T, Wu F. Calculation grid and turbulence model for numerical simulating pressure fluctuations in high-speed train tunnel[J]. Journal of Central South University, 2019, 26(10): 2870-2877.
- [3] 陈皓,郭明明,田野,等.卷积神经网络在流场重构研究中的进展[J].力学学报,2022, 54(9):2343-2360.
- [4] Han J, Tao J, Zheng H, et al. Flow field reduction via reconstructing vector data from 3-D streamlines using deep learning[J]. IEEE computer graphics and applications, 2019, 39(4): 54-67.
- [5] 曹晓峰,李鸿岩,郭承鹏,等.基于深度学习的二维翼型流场重构技术研究[J].航空科学技术,2022,33(07):106-112.
- [6] 余柏杨,王明振,王婷婷,等.基于机器学习的机翼气动载荷重构及传感器优化布置[J].南京航空航天大学学报,2023,55(5):798-807.