

基于机器学习算法的旋成体航行器 表面压力预测

刘玉波¹, 何振民², 林洪涛³, 褚学森^{2,*}, 高琪¹

1. 浙江大学 航空航天学院, 杭州 310027

2. 中国船舶科学研究中心, 无锡 214082

3. 杭州晟视科技有限公司, 杭州 311101

摘要:表面压力是旋成体航行器姿态控制和运动参数设计与评估的重要指标。为了获取作业过程中航行器表面压力的全域分布特性, 本文设计了一套基于机器学习的表面压力重构算法。不同的航行工况下航行器表面压力分布状态不同, 通过在旋成体航行器表面布置压力观测点并利用其压力观测值的分布, 可以反向表征航行工况。本文将有限个航行器表面压力观测点的观测值及其三维点云坐标作为输入信息, 训练得到了一个从有限个离散观测点压力到航行器表面全域压力分布的映射模型。为了探究模型的性能, 在多个不同测试数据集上进行了表面压力的全域预测实验。结果表明, 训练得到的机器学习模型能够高精度地预测全域压力分布, 预测误差可控制在 10% 以内, 同时具备鲁棒性。

关键词:旋成体航行器; 表面压力; 机器学习; 点云; 全域分布

中图分类号: O352; V211.3

文献标识码: A

Surface pressure prediction of convolutional vehicle based on machine learning algorithm

LIU Yubo¹, HE Zhenmin², LIN Hongtao³, CHU Xuesen^{2,*}, GAO Qi¹

1. School of Aeronautics and Astronautics, Zhejiang University, Hangzhou 310027, China

2. China Ship Scientific Research Center, Wuxi 214082, China

3. Shengshi Technology Co., Ltd., Hangzhou 311101, China

Abstract: Surface pressure is an important index in the evaluation of the attitude control and motion characteristics of the convolutional vehicle. In order to determine the full-domain surface pressure distribution of the vehicle during navigation, a surface pressure reconstruction algorithm based on machine learning is proposed. The surface pressure distribution of the convolutional vehicle may vary under different sailing environments. By arranging pressure observation points on the surface of the convolutional vehicle and obtaining the distribution of these pressure data, the corresponding navigational conditions can be characterized. In this paper, the pressure obtained from a finite number of observation points on the surface, as well as their coordinates, are used as input information of the model. Then we can obtain a mapping model from discrete pressure data to the full domain pressure distribution. To investigate the performance of the model, full-domain surface pressure prediction experiments are conducted on several different test datasets. The results demonstrate that our machine learning-based model can achieve high-precision surface pressure reconstruction, and the relative error of the predicted value can be reduced to within 10%.

收稿日期: 2024-01-03; 修回日期: 2024-05-03; 录用日期: 2024-05-27

基金项目: 国家重点研发计划项目(2020YFA0405700)

* 通信作者 E-mail: chuxs@cssrc.com.cn

引用格式: 刘玉波, 何振民, 林洪涛, 等. 基于机器学习算法的旋成体航行器表面压力预测 [J]. 实验流体力学, 2026, 40(3): 55-63.

LIU Y B, HE Z M, LIN H T, et al. Surface pressure prediction of convolutional vehicle based on machine learning algorithm[J]. Journal of Experiments in Fluid Mechanics, 2026, 40(3): 55-63.

Keywords: convolutional vehicle; surface pressure; machine learning; point cloud; full domain distribution

0 引言

随着现代军事技术的不断演进,旋成体类航行器在航空、航海等领域中扮演着关键的角色。导弹、潜射弹是细长的旋成体航行器,具有高机动性、快速响应能力,作为重要的军事武器,关乎国家的国防与安全^[1-2]。旋成体潜航器在海洋勘探、环境监测和排除鱼雷等方面有着重要应用^[3-4]。因此,旋成体航行器的性能和安全一直以来都受到研究者的重点关注。在旋成体航行器的设计和操作过程中,准确获取其表面压力及分布,对于研究旋成体航行器的流体力学特性、运动稳定性和结构强度等方面具有重要的指导作用^[5]。此外,在作业过程中,旋成体航行器表面的压力脉动是产生噪声的主要原因之一^[3]。因此,表面压力的有效预示能为提高航行器的隐蔽性提供关键数据参考。

旋成体航行器发展至今,学者们对其表面压力的分布与演化开展了大量研究。研究采用了计算流体力学(CFD)和实验流体力学(EFD)的相关手段,但根据航行器航行介质的不同,表面压力的测量手段及影响因素也存在区别。肖恒等^[6]设计了一套嵌入式无线压力测量系统,在高速风洞中对旋成体导弹模型关键区域多点的表面压力进行了测量,获取了表面压力的动态变化特征。与传统的传感器测压方式不同,杨庆涛等^[7]在旋成体航行器表面设计了一种新型的变厚度薄壁测温结构,并采用基于引压管和电子压力扫描阀的测量方案,实现了模型飞行实验全弹道的表面压力测量。赵瑞等^[8]使用大涡模拟(LES)方法对典型整流罩旋成体结构的壁面压力脉动进行了非定常数值模拟研究,通过引入空间修正项,提出了一套改进的跨声速旋成体壁面脉动压力经验公式。该方法显著提高了旋成体航行器在跨声速条件下脉动压力分布的预测精度。魏海鹏等^[9]对双锥头型旋成体航行器开展了水洞实验,获得了空泡形态和旋成体的表面压力分布,并研究了各类型空泡流状态下旋成体表面压力的分布特征。时素果等^[10]对旋成体航行器高速入水过程进行了实验研究,通过在航行器表面布置压力传感器,获得了高速入水过程中旋成体多点的表面压力变化规律。潜射弹出水过程中伴随着巨大的冲击载荷,获取出水冲

击载荷需要测量整个表面上的压力分布,但这在工程实践中很难实现。李国良等^[11]通过流固耦合仿真对旋成体潜射弹的整个出水过程进行了数值模拟,获得了完整的表面压力分布及其演化特征。

与空气不同,水是一种相对不可压缩的流体,其密度和产生的阻力更大。由于水下环境的复杂性和水动力学的不确定性,想要精确、全域地计算或测量旋成体航行器表面压力,传统方法(数值模拟与实验)往往非常耗时或花费巨大。近年来,为了简化问题或提高计算效率,部分学者引入了代理模型来近似原始系统或问题的行为和特征。王惠等^[12]基于代理模型技术对旋成体航行器表面附着空泡的非定常发展过程进行了预示研究,同时还对预示压力的变化过程进行了分析,预示结果与实验数据吻合较好。张晓东等^[13]通过代理模型方法建立了影响因素与水下垂直发射航行器表面压力空间分布关系的数学模型,形成了表面压力分布预示方法。与典型工况的实验数据相比,该预示方法能够准确获取压力分布与变化的特征,预示精度较高。代理模型作为一种近似模型,其建立通常基于已有的知识和经验,并采用一种简化的数学函数或算法来近似系统的行为,所以存在较大的局限性。就目前而言,代理模型的适用范围仍受到已有知识的很大限制。

随着计算机技术的进一步发展,人工智能技术逐渐广泛应用到各行业。机器学习作为人工智能的一个重要分支,在许多领域中都有着广泛的应用,如图像识别^[14]、语音识别^[15]、自然语言处理^[16]、金融预测^[17]等。机器学习与代理模型存在类似之处,即都是通过建立数学/物理模型来近似复杂系统或复杂问题的行为和特征。但机器学习不需要依赖已有的知识和经验,而是从数据中学习并自动提取模式,进而建立输入到输出的联系^[18]。通过机器学习算法,模型可以从大量数据中发现规律和关联,并根据这些学习到的规律进行预测和决策。因此,机器学习模型的构建过程主要依赖于数据的质量和数量,通过对数据的训练和优化,模型便可以自动学习并逐步改善其性能。机器学习的优点在于能够适应复杂和非线性的关系,并对大规模和高维度的数据进行建模和预测,适用于复杂环境下精确度和准确度要求较高的预测或决策场景。

机器学习不仅在科学研究和生活中应用广泛,在工程应用中也存在巨大潜力。近年来,有研究人员在航行器的研究中引入了机器学习方法,并取得了一定的成效。准确掌握水下航行器的运动姿态对于实现水下航行器自主运动控制至关重要,但由于海底的工作环境复杂,水下航行器的实验过程中存在一些非合作性因素。于是张春宇等^[19]设计了一套基于径向基函数的神经网络算法对采集数据进行分类。结果表明,该算法对水下航行器基本行为识别的平均召回率可达94%。在自主水下航行器(AUV)的研发过程中,可变操作条件和恶劣环境带来了巨大的挑战。Wehbe等^[20]为AUV的自适应控制开发了一个深度强化学习框架,并在实际的AUV实验中证明了该框架对自主航行器控制问题的适用性。总的来说,机器学习在航行器上的应用目前更多体现在决策方面,如辅助船舶设计、航行安全监测^[21]和路径规划^[22]等。而在旋成体航行器表面压力这类测量问题上,现有的机器学习应用案例很少。虽然旋成体航行器的工作环境往往复杂且非定常,但多年的模拟和实验研究已经积累了大量的可用数据。本工作基于机器学习的优势,提出了一种新的深度学习模型,可实现旋成体航行器表面压力的全域预测。

本研究基于数值模拟数据,主要出于对数据获取的可行性及真值误差分析的考虑来设计研究内容和目标。同时,在数据集构建时考虑了后续向实验发展的可行性,即数据采集点的位置选取参考了实验模型的测压孔位置分布。本文的组织结构如下:第一节首先对表面压力预测问题进行分析 and 简化,然后说明数据的类型和分布形式,并描述所提神经网络的结构,最后阐述对模型进行评估的方法;第二节讨论训练得到的模型在验证集数据上的各项预测结果;第三节给出相关结论。

1 方法

1.1 表面压力问题分析

旋成体航行器的表面压力分布由其周围流场决定,周围流场又由航行器的几何形状及来流的流速、攻角等多方面因素决定。因此,可将旋成体航行器的表面压力用式(1)进行简化描述:

$$\mathbf{P} = f(\mathbf{X}_{\text{geo}}, \mathbf{V}_{\infty}, \alpha, \dots) \quad (1)$$

式中: $\mathbf{P}$ 为航行器表面压力; $\mathbf{X}_{\text{geo}}$ 代表航行器的几何因素; $\mathbf{V}_{\infty}, \alpha, \dots$ 分别代表来流速度、迎角等各种环

境因素; f 表示映射关系。由式(1)可知,当航行器处于不同航行工况时,其表面压力分布也会存在差异,即二者存在一一对应关系。因此,可以用容易测得的压力分布信息来表征难以测量的流场等信息。首先,在航行器表面的特定位置布置压力观测点,得到这些离散观测点的压力分布信息,并假定这些离散的压力分布也与航行器周围流场存在一一对应关系,则表面压力的表达式可进一步简化为:

$$\mathbf{P} = f(\mathbf{X}_{\text{geo}}, \mathbf{X}_{\text{m}}, \mathbf{P}_{\text{m}}) \quad (2)$$

式中: $\mathbf{X}_{\text{m}}$ 和 $\mathbf{P}_{\text{m}}$ 分别为航行器表面离散观测点的坐标和压力。

根据上面的分析,航行器的表面压力可以简单地表达为航行器几何形状和观测点群压力分布的函数。但是,其中的映射关系 f 是高阶且非线性的,无法人为得到其显式表达式。考虑到神经网络拥有很强的非线性拟合能力,理论上能够对任意复杂度函数进行模拟。于是,通过构建一个神经网络模型来代替式(2)中的映射关系 f , 并利用已知的数据对模型不断训练和优化,从而得到从航行器几何形状和离散取值点群压力分布到航行器表面压力全域分布的映射模型。具体技术路线如下:

基于数值模拟数据,在旋成体航行器表面选择一定数量的压力观测点,离散分布在8条母线上,如图1所示。通过高精度数值模拟获取航行器表面全




图1 旋成体结构和压力观测点沿各母线分布

Fig. 1 Convolutional vehicle structure and distribution of pressure observation points along generatrix

域压力值,并按照是否位于观测点位置将其分为观测点压力和预测点压力两部分。其中,观测点压力值及其位置坐标作为模型的输入,即式(2)中的 P_m 和 X_m ,用于给模型提供航行器的状态信息。同时将预测点的坐标也作为模型的输入,代表式(2)中的 X_{geo} 。而这些预测点的压力值则代表式(2)中的 P ,成为模型学习和优化的目标。利用大量数据对模型进行训练优化后,当航行器面对新工况时,不再需要进行耗时的高精度数值模拟,仅需少量观测点信息,即可预测出航行器表面的全域压力分布结果。

1.2 数据及其预处理

由于实验测量直接获取的数据量无法满足机器学习训练的需求,因此利用2个不同长细比的锥头旋成体航行器进行了高精度数值模拟。该算法所得压力预测结果与实测试验的误差保持在15%以内,可靠性较高,且易于采集到大量可用的航行器表面压力数据。数值模拟的无量纲发射水深为2.5,以一定倾角发射,出筒时的无量纲速度为0.5。在获取的数据中,2个航行器模型各采集了795个时刻,每个时刻都包含观测点和预测点两部分数据,如表1所示。观测点和预测点的划分方式已在第1.1节描述。其中,观测点个数为140,其位置固定。图1(b)给出了压力观测点的雷达分布图,展示了观测点位置沿航行器表面周向和轴向的分布。由图1(b)可知,压力观测点只分布在8条母线上,点与点之间的分布较为稀疏。预测点理论上是指航行器表面除观测点以外的其他位置,但在本研究中,用于训练和测试的预测点数据主要分布在144条母线上,每条母线包含368个网格点数据。值得注意的是,一旦模型训练完成,需要进行压力预测的点的坐标并不局限于这144条母线,可以是航行器表面的任意位置。

表1 数据类型及数据量
Table 1 Data types and amount

数据类型	数据量/个
观测点数据	140
预测点数据	144 × 368

为了提高模型的训练效率,需要对数据进行格式化和预处理,形成训练集、测试集和验证集。数据标准化可以有效调整数据之间的尺度差异,是一种常用的数据预处理操作。本研究中采用Z-Score标准化的方式进行预处理,作用对象为抽样前的整体样本数据。标准化操作方式如式(3)所示:

$$x_{nor} = \frac{x - \mu}{\sigma} \quad (3)$$

式中: x 为原始数据; μ 和 σ 分别为原始数据的均值和标准差; x_{nor} 为标准化后的数据。

数据的格式化过程如下:首先从观测点数据中取出所有点的三维坐标(几何形态信息)及其压力值,共140个;然后从预测点数据中随机抽取860个点,保持其原始三维坐标,但将其压力值设置为0。将这两部分提取得到的数据组合,形成一组形状格式为(1000, 4)的输入数据;此外,将这1000个点的真实压力组合,即可形成格式为(1000, 1)的输出数据,作为模型学习和优化的目标。格式化后的数据结构如图2所示。值得注意的是,模型输入数据的压力部分中,只有来自观测点的数据具备真实压力值,来自预测点的数据的压力值均已被初始化为0;而用于模型学习的目标数据中则包含了所有点的压力真值。

x1	y1	z1	p1	p1
x2	y2	z2	p2	p2
...	...	...	...	...
x140	y140	z140	p140	p140
x141	y141	z141	0	p141
x142	y142	z142	0	p142
...	...	...	...	...
x1 000	y1 000	z1 000	0	p1 000
Input				Output

图2 模型的数据格式
Fig. 2 The data format of model

考虑到航行初期表面压力变化很小及航行阶段后期航行器头部空泡破碎的情况,本研究选取了中间的连续500个时刻作为训练和测试数据集生成的来源,该时间段内航行器上存在完整的空泡结构,是重点关注的对象。训练集、测试集和验证集的比例为8:1:1。其中,训练集用于模型训练;测试集用于测试已训练模型的效果,研究人员可根据其结果调整模型超参数及进行模型选择,然后重新训练模型,防止发生过拟合;验证集则用于评估训练好的模型的性能,检测模型在未见过的数据上的泛化能力。测试集和验证集数据均需完全与训练集隔离,因此,我们选择第401~450时刻的50组数据作为测试数据,第451~500时刻的50组数据作为验证数据,分别用于模型调试和评估。剩下的前400个时刻的数据作为训练数据,从而保证训练集、测试集与验证集之间不存在任何数据的重合。按照前述的格式化方式,对于每个时刻,从预测点数据中随机抽取10次,

并与该时刻的观测点数据组合形成相应数据集，最终得到的数据集组成如表 2 所示。

表 2 数据集组成形式
Table 2 Composition of dataset

数据集	数据量/组	输入格式	输出格式
训练集	4000		
测试集	500	(1000, 4)	(1000, 1)
验证集	500		

1.3 表面压力预测模型

本研究采用的模型结构如图 3(图中 n 为模型输入接收的点数量)所示，模型的构建借鉴了 Charles

等^[23]提出的 PointNet，同时根据研究对象进行了适当的设计与改进。模型的基本思想是：首先从输入中接收各点坐标和观测点压力信息，通过多层的卷积操作对坐标和压力信息进行处理，提取各类抽象特征；然后对所有信息进行整合，学习坐标-压力的对应关系；最后输出各点对应的压力预测值。在这个过程中，有 3 点需要注意：①飞行器的姿态改变并不会引起各点位置关系的变化；②随着模型层数增加，前面提取的特征可能会逐渐被弱化；③特征提取操作伴随着抽象特征量的增加，可能会导致坐标-压力对应关系的复杂化。为此，本模型中设计了 3 个关键模块：T-Net 模块、跳连组合模块和最大池化模块。




图 3 模型结构示意图

Fig. 3 Schematic diagram of model structure

1.3.1 T-Net 模块

T-Net 是一种特殊的神经网络结构，全称为“Transformation Network”，由多个一维卷积层和池化层组成。T-Net 通过学习一个变换矩阵，将输入点云映射到一个规范化的、对齐的空间，可以用来学习输入数据的空间变换，从而提高网络的几何变换不变性和鲁棒性。无序性是点云数据的典型特性之一。本研究中，点云输入数据虽为随机抽取，但数据点之间的几何位置信息具备明显的空间不变特性，故利用 T-Net 模块来保证网络对输入数据具备几何不变性尤为重要。

1.3.2 跳连组合模块

跳连结构是一种将不同层之间直接连通的路径，广泛应用于残差神经网络。本研究将不同层级的输出通过跳连进行拼接组合，使底层与高层特征进行直接融合，可以更好地利用低级特征和高级抽象特征之间的关联，降低层数加深带来的特征弱化

效应，使网络能够更加丰富地捕捉不同层次的特征表示，从而提高网络的表征和学习能力。

1.3.3 最大池化模块

最大池化模块本质上是一个对称函数，通过聚合来自所有点的各类特征信息，并从整个特征图中提取最显著的特征，从而提高模型的感知能力。

除了上述 3 个关键模块，模型结构中还融合了多个一维卷积层模块进行特征组合，结合三大模块共同构成了表面压力预测模型。卷积层模块主要由卷积层、标准化层和激活函数层组成，在图 3 中均有详细描述。

1.4 训练与评估

训练过程中，学习率是影响模型收敛速率和学习精度的一个重要超参数。经过调试实验，本研究中学习率最终选定为 10^{-5} ，优化器选择 Adam 优化器。模型中各部分的激活函数均已在图 3 中进行说明和标注。模型训练的目标函数选择均方误差函数

(Mean Squared Error, E_{MS}), 如式(4)所示。通过降低目标函数值, 可以使预测结果最大限度接近真实结果。对预测结果的定量评估主要用到了绝对误差和相对误差 2 个指标, 分别如式(5)和(6)所示:

$$E_{MS} = \frac{1}{N} \sum_{i=1}^N (y_{pred} - y_{true})^2 \quad (4)$$

$$E_a = y_{true} - y_{pred} \quad (5)$$

$$E_r = \frac{y_{true} - y_{pred}}{y_{true}} \quad (6)$$

式中: N 为样本数量, y_{pred} 为预测值, y_{true} 为真实值, E_a 为绝对误差, E_r 为相对误差。

2 结果与分析

模型在训练集的 4000 组数据上进行了 200 轮迭代训练, 约 180 次迭代后模型完成收敛, 最后的损失值收敛于 0.007 左右。

为了验证模型的预测效果和鲁棒性, 在验证集的 500 组数据上对模型进行了测试。图 4 展示了模型在其中一个时刻的预测值和相对误差分布云图。与图 4(a) 的真实压力分布相比, 图 4(b) 中模型预测的表面压力分布在整个旋成体航行器表面呈现出相似的趋势: 旋成体航行器前半段(图中 0.3 以下的部分)为低压区, 后半段(0.4 以上的部分)为中高压区, 中间靠前(0.3~0.4 之间)区域存在一个高压区。这表明模型在捕捉整体压力分布特征方面表现非常好。图 4(c) 展示了预测结果相对误差逐点分布情况。不难看出, 整体相对误差都非常低, 这与图 4(a) 和 (b) 的直接定性对比也是一致的。个别误差较大的点主要分布在 3 个区域: 近头部、尾部和中间靠前(0.3~0.4 之间)的一部分区域。其中, 近头部和尾部区域出现个别高误差数据, 主要是因为原始训练数据在这 2 个区域呈单边分布, 不确定性较高, 导致模型在此区域的预测值时好时坏。而 0.3~0.4 之间的高误差点主要是空泡导致的。从图 4(a) 中可以看出, 旋成体航行器沿轴向的压力分布在 0.3~0.4 之间出现了阶跃, 这是因为空泡到此处逐渐结束, 与旋成体航行器接触的介质从空气变成水, 表面压力值陡增。同时, 在气液交界的区域, 还存在回射流的作用, 进一步使旋成体航行器的表面压力达到了一个峰值, 这也是图 4(a) 中 0.3~0.4 之间压力高于后半段的主要原因。这个由回射流引起的压力峰值称为回射峰压力。回射峰压力及其位置也是本




图 4 真实值、预测值以及相对误差云图

Fig. 4 Cloud plot of ground truth, predicted value and relative error

研究的一个重点关注对象。由于空泡结束的位置沿旋成体航行器周向的分布存在差异, 同时会随着时

间变化,因此回射峰位置在旋成体航行器表面也不是固定的。

为了对预测值的误差进行定量描述,在图 5 中分别展示了某时刻航行器表面压力预测结果绝对误差和相对误差的频率分布直方图。根据图 5 可知,该时刻预测值的绝对误差基本集中在 $[-0.025, 0.025]$, 该区间以外的数据量不到 2%; 而相对误差也基本保持在 10% 以内。这说明模型不仅能对整体的压力分布趋势给出令人满意的结果,还能逐点精准预测压力值。




图 5 预测值绝对误差与相对误差分布

Fig. 5 Distribution of absolute and relative errors in predicted values

为了进一步探究模型的应用性能,在验证集数据上预测了水下旋成体航行器表面回射峰压力、位置,以及单点压力值随时间的变化过程。图 6 展示了模型在 3 条不同母线上的压力预测值沿轴向的分布。其中,蓝色曲线为压力真值,红色曲线为模型预测值。不难看出,模型的预测压力值沿 z 轴的分布与真值基本一致;同时,模型预测得到的回射峰压力与回射峰位置也与实际情况非常吻合。这表明模型能够准确捕捉压力阶跃区域的压力变化特征,面对大梯度压力变化时,也能给出准确的压力分布预测结果。图 7 描述了航行器表面单点压力值的动态变化过程:航行初始阶段,航行器表面直接与水接触,表

面压力稳定在较高值。随着空泡长度推进,回射区逐步向后移动。在回射区靠近并逐渐穿过某一点的过程中,该点的压力值逐步升高,直到达到峰值,然后迅速降低至极低数值并基本保持不变。此时,该点已经入侵到了空泡内部,其压力值代表了空泡内部的压力状况。




图 6 不同角度母线上压力值沿 z 轴的分布

Fig. 6 Pressure distribution along the z -axis on different angle busbars




图 7 单点压力值随时间变化曲线

Fig. 7 Pressure curve at fixed points over time

图 8 展示了模型在验证集 50 组数据上的预测结果相对误差的均值和标准差。其中,均值整体基本保持在 0 附近,标准差集中在 $[0.04, 0.08]$ 区间内,2 个参数的波动范围都比较小,与图 5(b)中所描述的情况一致。这说明该模型具有很好的鲁棒性,面

对航行器不同时刻与状态的测试数据,都能够给出稳定的预测结果。




图8 不同测试数据预测结果相对误差的均值和标准差

Fig. 8 Mean and standard deviation of relative errors in different test data

3 结 论

本研究基于机器学习算法对旋成体航行器表面压力进行了预测研究,可为实验过程中表面压力测量提供技术支持。研究结果表明:

1)该模型能够在大量数据中学习表面压力的分布模式,并通过有限测点的压力信息对旋成体航行器表面压力进行全域重构。

2)该模型的研究结果对锥头旋成体航行器的空化绕流问题有很好的适用性,能够准确捕捉回射峰压力及其位置,进而推测空泡长度的推进过程。在实际实验过程中,能够帮助研究人员快速判断空泡覆盖区域,提高测量精度和工作效率。

3)模型具备良好的鲁棒性,面对不同的测试数据,依然能得到高精度的预测结果。

下一步将拓展模型可预测的航行器和工况类型,从多种类外形、复杂工况环境入手,提高模型的泛化性能;同时开发算法模型的时序预测能力,进一步探索人工智能在旋成体航行器表面压力预测中的应用。

参考文献:

[1] 陈立立, 郭正, 侯中喜, 等. 高超声速飞行器气动布局研究综述[J]. 空天技术, 2022(3): 42-61.
CHEN L L, GUO Z, HOU Z X, et al. Overview on aerodynamic configuration study of hypersonic vehicles[J]. Aerospace Technology, 2022(3): 42-61.

[2] 王一伟, 黄晨光. 高速航行体水下发射水动力学研究进展[J]. 力学进展, 2018, 48: 259-298.
WANG Y W, HUANG C G. Research progress on hydrodynamics of high speed vehicles in the underwater launching process[J]. Advances in Mechanics, 2018, 48: 259-298.

[3] YANG Y, XIAO Y, LI T S. A survey of autonomous underwater vehicle formation: performance, formation control,

and communication capability[J]. IEEE Communications Surveys & Tutorials, 2021, 23(2): 815-841.
doi: 10.1109/COMST.2021.3059998

[4] SAHOO A, DWIVEDI S K, ROBI P S. Advancements in the field of autonomous underwater vehicle[J]. Ocean Engineering, 2019, 181: 145-160.
doi: 10.1016/j.oceaneng.2019.04.011

[5] LI Y H, MIAO X H, JIA D, et al. Research on prediction method of pulsating pressure of underwater vehicles[J]. Ocean Engineering, 2021, 219: 108267.
doi: 10.1016/j.oceaneng.2020.108267

[6] 肖恒, 顾蕴松, 孙之骏, 等. 旋转导弹模型非定常表面压力测试技术研究[J]. 实验流体力学, 2020, 34(4): 62-67.
XIAO H, GU Y S, SUN Z J, et al. Unsteady surface pressure measurements of standard spinning missile model in supersonic flow[J]. Journal of Experiments in Fluid Mechanics, 2020, 34(4): 62-67.
doi: 10.11729/syltlx20190100

[7] 杨庆涛, 周宇, 袁先旭, 等. MF-1 模型飞行试验表面压力与温度测量技术研究[J]. 空气动力学学报, 2017, 35(5): 732-741.
YANG Q T, ZHOU Y, YUAN X X, et al. Surface pressure and temperature measurement technology in MF-1 modelling flight test[J]. Acta Aerodynamica Sinica, 2017, 35(5): 732-741.
doi: 10.7638/kqdlxxb-2017.0167

[8] 赵瑞, 荣吉利, 任方, 等. 一种改进的跨声速旋成体壁面脉动压力经验预测公式[J]. 宇航学报, 2016, 37(10): 1179-1184.
ZHAO R, RONG J L, REN F, et al. Improvement of the fluctuating pressure empirical functions for a body of revolution at transonic Mach numbers[J]. Journal of Astronautics, 2016, 37(10): 1179-1184.

[9] 魏海鹏, 权晓波, 孔德才. 双锥头型回转体空化特性实验研究[J]. 水动力学研究与进展 (A 辑), 2017, 32(2): 175-181.
WEI H P, QUAN X B, KONG D C. Experimental investigation of cavitating flows around an axisymmetric body with double-taper headform[J]. Chinese Journal of Hydrodynamics, 2017, 32(2): 175-181.

[10] 时素果, 杨晓光, 王亚东, 等. 细长体高速入水过程压力特性试验研究[J]. 应用力学学报, 2018, 35(2): 223-227.
SHI S G, YANG X G, WANG Y D, et al. Experimental study on the pressure characteristic of high-speed slender body water entry[J]. Chinese Journal of Applied Mechanics, 2018, 35(2): 223-227.

[11] 李国良, 袁湘江, 敖林. 潜射导弹出水载荷数值算法研究[J]. 力学与实践, 2013, 35(4): 25-30.
LI G L, YUAN X J, AO L. Simulation of under-water launched missile's water-exit load[J]. Mechanics in Engineering, 2013, 35(4): 25-30.

[12] 王惠, 权晓波, 魏海鹏, 等. 水下航行体空泡非定常发展预示方法研究[J]. 导弹与航天运载技术, 2017(6): 11-15.
WANG H, QUAN X B, WEI H P, et al. Prediction method on unsteady cavity development of underwater vehicle[J]. Missiles and Space Vehicles, 2017(6): 11-15.

[13] 张晓东, 权晓波, 王占莹, 等. 代理模型在水下航行体空泡压力预示的应用研究[J]. 船舶力学, 2018, 22(1): 12-21.
ZHANG X D, QUAN X B, WANG Z Y, et al. Research on the prediction method of unsteady cavity pressure development of underwater vehicle based on surrogate model[J].

- Journal of Ship Mechanics, 2018, 22(1): 12-21.
- [14] CAI L, GAO J Y, ZHAO D. A review of the application of deep learning in medical image classification and segmentation[J]. *Annals of Translational Medicine*, 2020, 8(11): 713.
doi: [10.21037/atm.2020.02.44](https://doi.org/10.21037/atm.2020.02.44)
- [15] NASSIF A B, SHAHIN I, ATTILI I, et al. Speech recognition using deep neural networks: a systematic review[J]. *IEEE Access*, 2019, 7: 19143-19165.
doi: [10.1109/ACCESS.2019.2896880](https://doi.org/10.1109/ACCESS.2019.2896880)
- [16] OTTER D W, MEDINA J R, KALITA J K. A survey of the usages of deep learning for natural language processing[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(2): 604-624.
doi: [10.1109/TNNLS.2020.2979670](https://doi.org/10.1109/TNNLS.2020.2979670)
- [17] SEZER O B, GUDELEK M U, OZBAYOGLU A M. Financial time series forecasting with deep learning: a systematic literature review: 2005-2019[J]. *Applied Soft Computing*, 2020, 90: 106181.
doi: [10.1016/j.asoc.2020.106181](https://doi.org/10.1016/j.asoc.2020.106181)
- [18] LISBOA P J G. Interpretability in machine learning—principles and practice[M]//Fuzzy Logic and Applications. Cham: Springer International Publishing, 2013: 15-21.
doi: [10.1007/978-3-319-03200-9_2](https://doi.org/10.1007/978-3-319-03200-9_2)
- [19] 张春宇, 刘福才, 程雪聪, 等. 基于微机电系统与径向基函数的水下航行器姿态检测[J]. 计量学报, 2022, 43(9): 1135-1141.
ZHANG C Y, LIU F C, CHENG X C, et al. Attitude detection of underwater vehicle based on MEMS and radial basis function[J]. *Acta Metrologica Sinica*, 2022, 43(9): 1135-1141.
- [20] WEHBE B, HILDEBRANDT M, KIRCHNER F. Experimental evaluation of various machine learning regression methods for model identification of autonomous underwater vehicles[C]//Proc of the 2017 IEEE International Conference on Robotics and Automation (ICRA). 2017: 4885-4890.
doi: [10.1109/ICRA.2017.7989565](https://doi.org/10.1109/ICRA.2017.7989565)
- [21] ELLEFSEN A L, ÆSOY V, USHAKOV S, et al. A comprehensive survey of prognostics and health management based on deep learning for autonomous ships[J]. *IEEE Transactions on Reliability*, 2019, 68(2): 720-740.
doi: [10.1109/TR.2019.2907402](https://doi.org/10.1109/TR.2019.2907402)
- [22] SUN Y S, CHENG J H, ZHANG G C, et al. Mapless motion planning system for an autonomous underwater vehicle using policy gradient-based deep reinforcement learning[J]. *Journal of Intelligent & Robotic Systems*, 2019, 96(3): 591-601.
doi: [10.1007/s10846-019-01004-2](https://doi.org/10.1007/s10846-019-01004-2)
- [23] CHARLES R Q, HAO S, MO K C, et al. PointNet: deep learning on point sets for 3D classification and segmentation[C]//Proc of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017: 77-85.
doi: [10.1109/CVPR.2017.16](https://doi.org/10.1109/CVPR.2017.16)



作者简介:

刘玉波(1996—), 男, 湖南常德人, 博士研究生。研究方向: 机器学习在航行器水动力特性分析中的应用研究。

E-mail: qianyue@zju.edu.cn

(编辑: 宋嘉慧)