基于气泡物理规律的航行体水动力深度学习预测方法

岳杰顺，王静竹，叶舒然，王一伟

(中国科学院 力学研究所，北京，100190，Email: yuejieshun@imech.ac.cn)

摘要：空泡带来的水动力演化在水下航行体运动中有非常重要的意义。为了能够快速预测航行体水下发射过程中空泡造成的尾部压力的复杂变化，提出了一种具有物理约束的深度学习网络。该网络模型以一维卷积网络为基础，构建了一种编码-解码型网络结构。结合空泡的理论机理构建了具有物理性的输入数据集，从而实现对不同物理过程的响应和捕捉。并通过测试和验证说明本文提出的网络对于任何发射条件，能够实现航行体受力特征的快速准确的预测，光滑曲线、压力突变、震荡的趋势都和数值模拟的结果吻合。证明本文的方法能够为运动和弹道的预测提供依据。

关键词：空泡；水动力；水下航行体；物理约束；深度学习

1 引言

航行体出水过程中的出筒、水下航行阶段，常常伴随着自然空泡和通气空泡的产生、断裂、溃灭、压力脉动等现象[1]。形成复杂的汽-液-固耦合效应，对航行体载荷和运动的预测造成困难[2]。剧烈的压力脉动也很给航行体水下发射的稳定性及机动性带来了极大的挑战。因此对空泡的演化和压力特征进行预测研究，对航行体的结构强度设计以及安全发射有着非常重要的意义。实际工程需求中，在给定基本几何构型和水深、压差等初始条件下，需要能够迅速获得航行体的尾部压力脉动响应，进而获得弹道曲线[3]。传统的方法着重对整体过程进行实验观测或数值模拟[4]，效率比较低，很难满足工程中的优化问题。势流理论、摄动理论这类简化方法能够在一定程度上提高空泡和弹道预测的效率，但是其适用的情况有限。

近年来，随着人工智能技术的发展，机器学习和神经网络的方法在参数预测中逐渐广泛应用。利用训练神经网络替代 CFD 模拟分析,可以迅速给出参数结果或者设计。燃气尾泡的形状以及弹体受力会受到发射参数的影响，因此对神经网络多参数识别的能力提出了较高的要求。深度学习网络由于所需的输入数据集少，训练效率更高，预测能力更好等特点，被广泛运用到这类参数的预测中。魏倩等[5]提出了一种基于 BP 神经网络的中制导改进

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

算法，预先离线训练、学习，大大缩短了计算时间。张秦浩等[6]使用 Q-learning 强化学习预测弹道，提高了制导精度。Tang 等[7]建立了基于残差 U-Net 和卷积长期短期记忆（LSTM）递归网络的深度学习代理模型，并将其用于预测地质模型中的动态地下流动。李江[8]提出一种将深度卷积神经网络用于弹道目标微动分类的方法，实现目标预测。这些例子充分说明可以基于数值模拟的结果，利用深度学习网络的泛化性构建模型，具有预测航行体的水动力和弹道的潜力。

目前大多深度学习网络仅依靠数据独立运行于求解器之外，缺乏一定的物理约束。水下发射涵盖的出筒、水下航行中的空泡断裂、溃灭现象，造成压力非线性的剧烈脉动，要求神经网络满足一定的物理约束，而不是简单的完全基于数据。引入物理约束主要有几种方式：以物理模型作为监督、学习具有物理意义的中间变量或将物理模型转化为损失函数构建无监督网络。Jagtap[9]采用具有物理信息的神经网络进行回归预测方程的解，获得了线性和非线性偏微分方程的解的曲线。Ling 等[10]提出了将深度学习网络用于修正 RANS 模型的方法，构建了一种嵌入伽利略不变性满足物理约束的网络体系结构，获得各向异性雷诺应力张量。Zhang 等[11]将偏微分方程的残差与求解的误差结合起来制定网络的损失函数，实现具有物理约束的深度学习网络，预测 Poisson 方程。

通过发射过程的数值模拟、气泡演化的理论分析和深度学习的智能方法研究了空泡与航行体相互作用的问题，在模拟数据和理论公式的基础上，提出了一种具有物理约束的深度学习模型。该网络模型以一维卷积网络为基础，构建了一种编码-解码型网络结构，通过在输入数据中引入小尺度空泡演化的机理进行监督，实现对空泡物理过程的响应和捕捉。并通过测试和验证说明给定不同发射条件下，该深度学习网络模型能够实现航行体受力特征的快速预测，从而为运动和弹道的预测提供依据。

2 输入数据集的构建

2.1 航行体载荷的数值模拟及航行条件的参数化方法

采用人工智能的深度学习网络，需要采用数值模拟方法建立大量的输入数据进行网络的训练。采用商业 CFD 软件 Fluent 对发射过程进行动态数值模拟，将获得的尾部峰值压力曲线作为输入数据和预测目标。此外，需要将发射条件转化为相同维度的时序数据张量才能用于网络的训练。流场分析中不需过多考虑三维外形的流场细节，但是需要实现出筒过程的气泡膨胀、收缩和断裂等关键过程。

将计算的航行体模型简化为圆柱回转体构型，并将复杂的三维发射过程简化为二维轴对称问题。此外，由于仅研究尾部的压力脉动，仅模拟尾部的通气空泡，忽略肩部的附着空泡。采用动网格的动态层状网格技术实现出筒过程和航行过程的刚体运动的过程，整个流场的网格均是四边形单元。建立 3 个区域的网格，一个是周围的静止区域，另两个分别是中间上下两部分的变形区域，之间以 interface 连接，如图 1。多相流物理模型采用 VOF 模型，湍流模型采用 k-ε RNG 模型，物理时间步长取 dt=0.0005s，计算到总时间 t=0.8s。

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

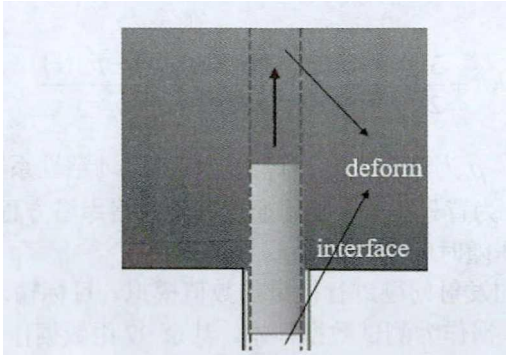

图 1　边界层基本速度分布

由于发射参数对航行体水下运动的影响较大，所以需要综合考虑发射速度、发射水深和出筒压差对空泡的影响。航行体直径为 2m，规定发射筒内初始静温为 800K。定义不同水深，背景压力随水深变化。不同出筒压差、不同出筒初始速度。考虑到计算效率的限制，所取工况数量有限，但应该尽可能均匀的涵盖上述范围内的情况，使预测工况作为内插而不是外插条件，这样更有利于获得可靠的神经网络。形成了共计 108 组样本的输入数据。

图 2 是数值计算的流场图（气体体积分数）。导弹出筒后在筒口形成一个大气泡，气泡逐渐膨胀。随着导弹运动弹尾气泡被拉断，断裂后从中心形成一个回射流，将尾空泡铲离壁面，形成气泡旋流，这个阶段的气泡呈现剧烈膨胀和收缩的脉动规律。

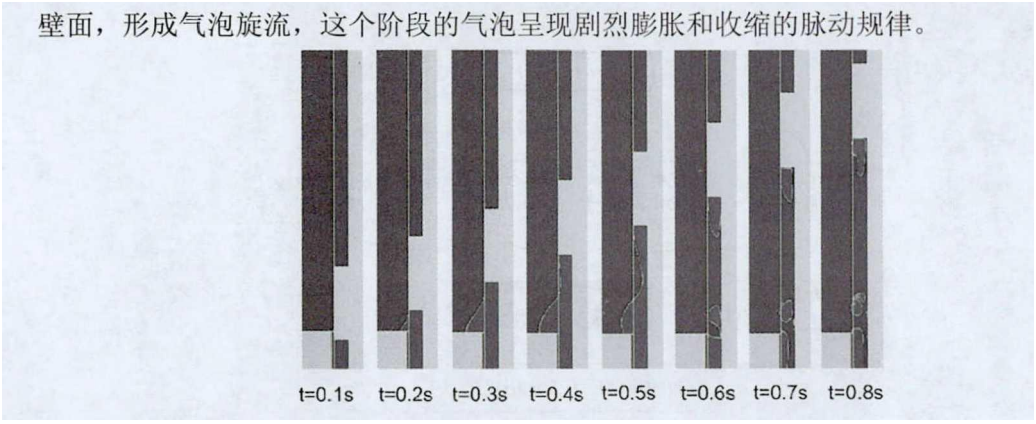

图 2　数值计算的流场图（气体体积分数）

2.2 考虑物理规律的深度学习网络

出筒过程中尾空泡膨胀的规律类似气泡自然演化的过程，因此在构建网络模型时考虑引入小尺度空泡演化的机理。使该深度学习网络的训练过程具有一定的物理性和泛化性，提高预测精度。可以将空泡演化的机理看作是物理过程未受干扰的线性过程，这一部分作为输入引入网络；而航行体和壁面的影响可以看作是非线性因素，这部分不通过理论模型处理，而只通过数据和预测实现。因此通过描述液体中球形空泡半径随时间变化规律的 Rayleigh-Plesset（R-P）方程，在给定气泡尺寸、泡内初始压力以及背景压力的情况下，获得气泡内压曲线，作为输入数据，为预测提供监督量。R-P 方程如下：

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

$$R\ddot{R}+\frac{3}{2}\dot{R}^2+\frac{4\nu_l\dot{R}}{R}+\frac{2\sigma}{\rho_l R}=\frac{p_B(t)-p_\infty(t)}{\rho_l} \tag{1}$$

其中，R为气泡半径，ρ_l为液相密度，ν_l为液相的运动粘性系数，σ为相间表面张力系数，p_B为泡内压力，p_∞为背景压力。使用通过四阶龙格库塔方程求解 R-P 气泡方程式，最终得到气泡半径和泡内压随时间变化的关系[12]。

分别对上述初始条件的发射问题进行批量的数值模拟。目标输入共计 108 组数据。从其中随机取 10%即 11 组数据作为测试数据样本，其余 97 组数据作为训练数据样本。以速度曲线、背景压力曲线以及理论公式的结果曲线构建 108×400×3 的数组（网络的通道数 channel=3），作为输入数据的 x；以底部峰值压力曲线构建 108×400×1 的数组，作为输入数据的 y。建立映射 $y=f(x)$，通过神经网络训练寻找映射关系。输入的数据分别为：底部压力 p_{btm}、运动速度 U、理论结果 p_{rp}、背景压力 p_{bg}。建立映射 $p_{btm}=f\left(U,p_{rp},p_{bg}\right)$。进行网络的训练，导入新的一组 $\left(U',p'_{rp},p'_{bg}\right)$ 进行预测，就可以得到新的 p'_{btm}。预测流程图如图 3 所示。

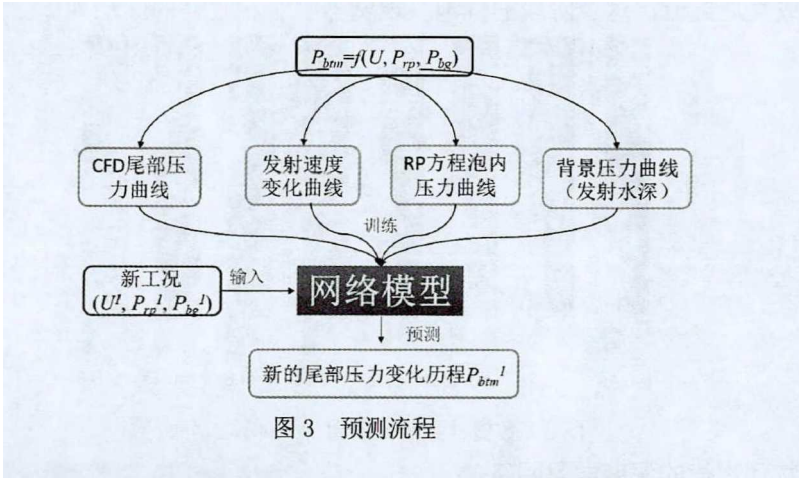

图 3　预测流程

深度神经网络进行数据训练前训练数据样本需要进行归一化或无量纲化处理，其目的是取消各维数据间数量级差别，避免因为输入输出数据数量级差别过大而造成网络预测误差较大。考虑到数据的物理性质，本文采用无量纲参数对原始数据进行无量纲化，速度和压力的无量纲参数分别取 U_∞ 和 $\rho_\infty U_\infty^2$。对神经网络数据进行无量纲处理获得的曲线如图 4。可以看出各通道的数据达到了近似的量级，且真实空泡的膨胀收缩规律大致符合理论公式的气泡演化。

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

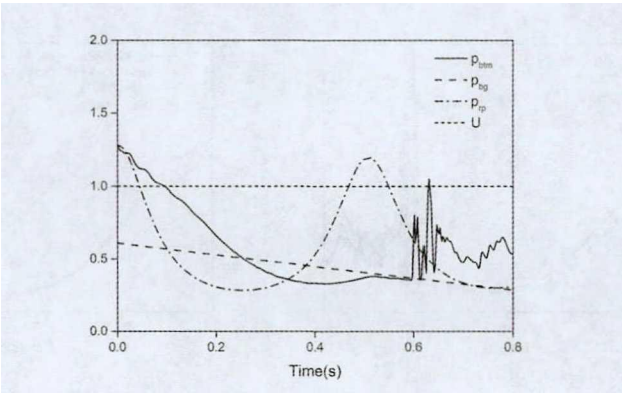

图 4 无量纲化后的输入数据

采用通常用在处理文本中的一维卷积网络构建深度学习模型。卷积神经网络凭借其局部连接、权值共享、下采样等特性可以保留重要的参数，来达到更好的学习效果。。实际的网络模型搭建中，在基于 Keras 库的 TensorFlow 框架中通过 Convolution1D 函数实现。

本文的网络结构包含多层一维卷积，构成一种编码器-解码器网络结构[13]。编码器的任务是在给定输入数据后，通过神经网络学习得到输入数据的特征谱；而解码器则在编码器提供特征谱后，逐步实现每段数据的预测。可以解决卷积-全连接结构网络的存储开销很大、计算效率低下、感受野太小的问题，提高预测精度。

对输入层使用三层一维卷积+池化进行编码，再使用三层一维卷积+上采样进行解码。该网络可以接受任意尺寸的输入数据，采用反卷积层和上采样，使它恢复到输入数据相同的尺寸。在卷积层之后设置池化层和上采样层，能够减小参数的数量和计算量，在一定程度上也控制过拟合。为了让神经网络学习复杂的非线性曲线，将非线性激活函数 ReLU 应用于某些层。采用 Adam 优化器训练网络，并采用反向传播算法更新神经元。

3 结果

3.1 数值模拟结果

图 5 和图 6 分别是不同初始速度、不同出筒压力数值模拟压力曲线。可以看出，发射初始阶段压力变化比较光滑，随着气泡膨胀，压力开始下降。到一定程度后，空泡开始收缩，压力上升。收缩到一定程度空泡的形态无法维持，产生断裂。断裂后产生剧烈的压力震荡，振荡的频率非常高，随着时间发展，压力脉动逐渐衰减，幅值逐渐降低。

不同的发射条件对底部压力曲线的影响比较大。在不同初始速度下，光滑阶段空泡膨胀速率不同，空泡断裂时间不同，断裂后峰值压力不同。不同出筒压差下，初始压力不同，空泡断裂时间不同，断裂后震荡幅值不同。这些规律与文献[14]中的结果类似，证明了本文数值模拟结果的可靠性。

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

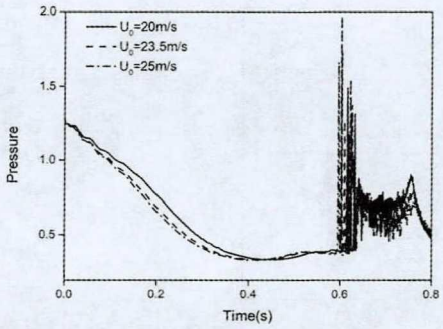

图 5　不同初始速度的数值模拟压力曲线

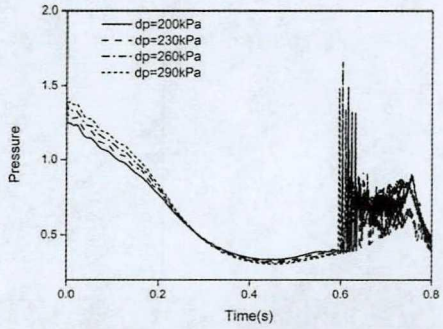

图 6　不同出筒压差的模拟压力曲线

3.2 网络预测结果

数值模拟的光滑阶段和压力脉动阶段的不同分辨率对网络模型的灵活性提出了较高的需求，网络的预测能力受限于固定的分辨率，导致产生过拟合，预测精度降低。因此对数据进行前处理，将曲线进行过滤，剔除高频的压力脉动。而且，弹道的位移是对压力脉动产生加速度的二次积分，对瞬时突变的压力脉动效应并不太敏感，所以可以将压力脉动进行一定程度的简化，这一点支撑了该方法的合理性。在 MATLAB 中对原始数据进行移动平均低通滤波，滤波窗口宽度 N 选择 10。尽可能使过滤后的曲线光滑，但保证不抹去基本物理规律。

图 7 对比了物理约束的网络和无物理约束的网络的预测结果，可以看出，不考虑理论方程的情况下，曲线预测的效果比较差。光滑区的曲线出现了很多波动，而且整体趋势与数值模拟相差比较大。而有物理约束的网络无论是光滑曲线、压力突变的位置都和数值模拟的结果吻合很好，只有震荡区的频率和幅值的预测有待进一步提高。验证了理论公式对网络训练的指导和监督作用。

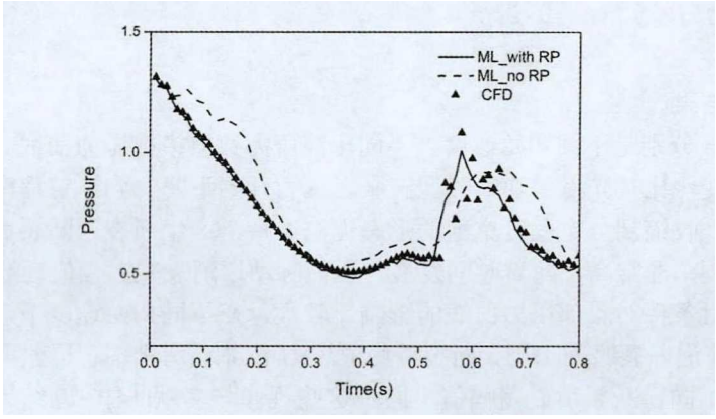

图 7 不考虑气泡理论方程的结果

图 8 分别给出了一个测试集（8 组测试样本）与 CFD 结果的平均绝对误差（MAE）和均方根误差（RMSE），对物理约束的网络和无物理约束的网络进行了对比。可以看出，本

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

文提出的有物理约束的网络在平均绝对误差和均方根误差方面和 CFD 结果都比较接近。对曲线所有区域预测都达到了理想的精度，说明了该网络的合理性。考虑理论方程的情况下，对于任何发射初始条件，网络都能获得比较好的预测结果，说明该网络模型能够总结出不同发射条件下底部压力曲线的规律。证明了本文提出网络预测模型具有很强的物理约束性。

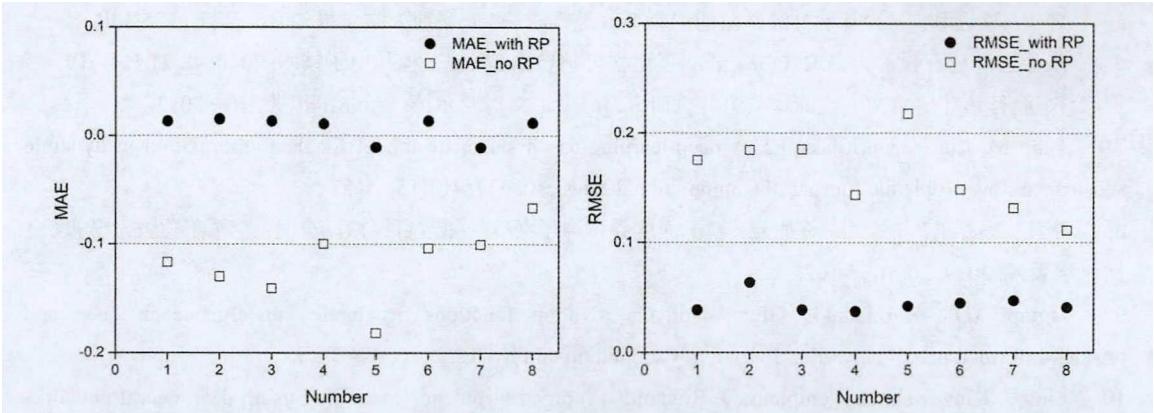

图 8 测试集与 CFD 结果的平均绝对误差（左）均方根误差（右）

4 结论

通过对航行体发射和水下航行的动态数值求解的和空泡演化理论机理的研究，建立了深度学习预测模型的输入数据库，提出了一种具有物理约束的深度学习神经网络，并对其进行了训练和验证。

数值模拟结果显示，底部压力曲线的计算符合物理规律。发射初始阶段压力变化比较光滑，随着气泡膨胀，压力开始下降。到一定程度后，空泡开始收缩，压力上升。收缩到一定程度空泡的形态无法维持，产生断裂。断裂后产生剧烈的压力震荡，随着时间发展，压力脉动逐渐衰减，幅值逐渐降低。发射条件对空泡的发展和底部压力影响比较大。会导致不同的空泡膨胀速率、空泡断裂时间、断裂后震荡幅值等。

本文提出的具有物理约束的网络通过将气泡演化的理论机理作为监督量，在数据较少的情况下，对于任何发射初始条件，网络都能获得很好的预测结果。无论是光滑曲线的走势、压力突变的位置、震荡的大致趋势都和数值模拟的结果吻合很好，误差分析也说明网络的预测精度十分优秀，能够实现对不同物理过程的响应和捕捉。今后的研究中可以对震荡区的频率和幅值的预测进一步优化，继续提高预测的精度。

参考文献

1 王一伟, 黄晨光. 高速航行体水下发射水动力学研究进展. 力学进展, 2018, 048(001):259-298.

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

2 杜特专, 王一伟, 黄晨光,等. 航行体水下发射流固耦合效应分析. 力学学报, 2017, 49(4): 782-792.

3 燕国军, 梁欣欣, 张健, 等. 水下航行体垂直发射环境流场与弹道耦合数值模拟研究. 节能技术, 2019,

4 王晓辉, 张珂, 褚学森, 等. 水下点火推进尾空泡振荡的研究. 船舶力学, 2020, 24(2):136-144.

5 魏倩, 蔡远利. 一种基于神经网络的中制导改进算法. 西安交通大学学报, 2016, 50(7): 125-130.

6 张秦浩，敖百强，张秦雪. Q-learning 强化学习制导律. 系统工程与电子技术, 2020, 42(2):414-419.

邢彦江. 航行体非定常空泡流流体动力特性研究. [博士论文]. 哈尔滨：哈尔滨工业大学, 2013.

7 Tang M, Liu Y, Durlofsky LJ. A deep-learning-based surrogate model for data assimilation in dynamic subsurface flow problems, Journal of Computational Physics, 2020, 413(15): 1-57.

8 李江, 冯存前, 王义哲, 许旭光. 基于深度卷积神经网络的弹道目标微动分类. 空军工程大学学报（自然科学版）, 2019, 20(4):97-102.

9 Jagtap AD，Karniadakis GE. Adaptive activation functions accelerate convergence in deep and physics-informed neural networks. Journal of Computational Physics, 2020, 404:1-23.

10 Ling J, Kurzawski A, Templeton J. Reynolds averaged turbulence modelling using deep neural networks with embedded invariance. Journal of Fluid Mechanics. 2016. 807:155-166.

11 Zhang Z. Zhang L. Sun Z. Solving Poisson's Equation using Deep Learning in Particle Simulation of PN Junction. Sapporo/APEMC 2019., Sapporo, Japan. 2019: Jun. 3-7.

12 Alehossein H, Qin Z. Numerical analysis of Rayleigh–Plesset equation for cavitating water jets. International Journal for Numerical Methods in Engineering. 2007, 72(7): 780-807.

13 叶舒然, 张珍, 宋旭东,等.自动编码器在流场降阶中的应用. 空气动力学学报, 2019, 37(03): 498-504.

14 孙健. 水下垂向运动超空泡航行体弹道仿真研究. [硕士论文]. 哈尔滨：哈尔滨工业大学, 2013.

Deep learning prediction method for hydrodynamics of underwater vehicle based on bubble physics

YUE Jie-shun, WANG Jing-zhu, YE Shu-ran, WANG Yi-wei

(Institute of Mechanics，Chinese Academy of Sciences，Beijing 100190.

Email: yuejieshun@imech.ac.cn)

Abstract: The hydrodynamics evolution caused by cavitation is of great significance in the movement of underwater vehicles. In order to be able to quickly predict the complex bottom pressure fluctuation caused by cavitation during the underwater launch, a deep learning network with physical constraints is proposed. This network model is constructed based on one-dimensional convolutional network and an encoding-decoding. A physical-constrained input data set is constructed by introducing the theoretical mechanism of bubble, realizing the capture

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

of different physical processes. The testing and verification show that the network proposed in this paper can quickly and accurately predict the hydrodynamics of the vehicle for any launching conditions. The predicted pressure curve during any stage, including the smooth stage, the transitional stage, as well as the oscillation are consistent with the numerical simulation results. As a result, this method can provide a basis for the prediction of motion and trajectory of the underwater vehicle.

Key words: Cavitation; hydrodynamics; underwater vehicle; physical constraints; deep learning.

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net