



# 基于长短期记忆网络的非定常空化水翼表面压力预测

张珍<sup>1,2,3</sup>, 刘庆宽<sup>1,2,3</sup>, 王静竹<sup>4</sup>, 王一伟<sup>4,5,6\*</sup>

1. 石家庄铁道大学省部共建交通工程结构力学行为与系统安全国家重点实验室, 石家庄 050043;
2. 河北省风工程和风能利用工程技术创新中心, 石家庄 050043;
3. 石家庄铁道大学土木工程学院, 石家庄 050043;
4. 中国科学院力学研究所, 北京 100190;
5. 中国科学院大学工程科学学院, 北京 100049;
6. 中国科学院大学未来技术学院, 北京 100049

\*联系人, E-mail: wangyw@imech.ac.cn

收稿日期: 2022-05-29; 接受日期: 2022-07-16; 网络出版日期: 2022-09-14

国家自然科学基金(编号: 12122214)和中国科学院青年创新促进会(编号: Y201906, 2022019)资助项目

**摘要** 非定常空化流动作为典型的非线性动力学问题, 其演变规律及其水动力特性受噪声和计算机精度的影响, 难以实现长时间预测. 本文利用长短期记忆(Long Short-Term Memory, LSTM)网络开发了一种多变量压力预测模型, 其中, 输入为不同时间序列的速度值和气体体积分数, 输出为压力系数的时间序列. 研究采用水翼的大涡模拟数据进行了外插预测, 结果表明, 预测输出与大涡模拟结果吻合较好, 并显示出良好的泛化性和预测更多未来结果的能力.

**关键词** 长短期记忆, 压力系数, 空化流, 大涡模拟

**PACS:** 47.27.-i, 47.27.E-, 47.61.Jd

## 1 引言

空化作为高速水动力学研究领域的核心问题, 常见于水下航行体周围的局部低压区, 当空化发生时, 往往涉及多种复杂流动现象, 如湍流、多相和非定常特征等<sup>[1]</sup>. 空泡周期性脱落引起的载荷波动以及空泡溃灭引起的压力脉动易造成航行体结构的破坏<sup>[2]</sup>. 因此, 实现对空化流动演变规律及其水动力特性的准确

预测对高速水下航行体等水力工程领域具有重要意义.

压力是影响空化的重要因素, 一直受到研究学者的关注<sup>[3,4]</sup>. Kawanami等人<sup>[5]</sup>在水翼表面布置了多个压力测点, 准确测得了脱落的空化云向下游运动过程中诱发的剧烈压力脉动, 并提出了一种经典的空化云脱落机制. 但由于空化流动非定常特性的复杂性, 实验手段面临着周期长和成本高等的局限性. 随着计算机

**引用格式:** 张珍, 刘庆宽, 王静竹, 等. 基于长短期记忆网络的非定常空化水翼表面压力预测. 中国科学: 物理学 力学 天文学, 2022, 52: 104709  
Zhang Z, Liu Q K, Wang J Z, et al. Unsteady cavitating hydrofoil surface pressure prediction based on long short-term memory network (in Chinese).  
Sci Sin-Phys Mech Astron, 2022, 52: 104709, doi: 10.1360/SSPMA-2022-0217

性能不断提升, 数值模拟技术已经成为空化研究中的另一重要手段. 在空化流动的数值模拟中, 空化模型和湍流模型对模拟结果均起着至关重要的作用. 空化模型是用于描述气液两相之间质量运输的数学模型, 如何构建合理的空化模型是数值模拟研究的关键所在. 目前, 广泛应用的空化模型主要分为基于正压流体状态方程的空化模型和基于质量运输的空化模型<sup>[1]</sup>. 在湍流建模方面, 研究学者大多基于Navier-Stokes (N-S)方程来模拟空化流场, 采用雷诺时均(Reynolds-Averaged Navier-Stokes, RANS)方程结合湍流闭合模型是应用最广泛的方式, 尽管这种方法具有计算量小的优势, 但是预测精度存在不足<sup>[6]</sup>. 大涡模拟(Large Eddy Simulation, LES)方法已逐渐成为空化流动研究的主流方法, 但是在复杂工业设计中应用时, 却面临着网格分辨率高和计算量大的困境<sup>[7,8]</sup>.

随着机器学习技术的发展, “黑盒”建模方法已被证明在湍流中具有广泛的应用前景<sup>[9-11]</sup>. 湍流通常呈现混沌、时空、多尺度的非线性现象, 神经网络的非线性逼近能力为解决这一问题提供了一种新的方法与可能. Ye等人<sup>[12]</sup>基于卷积神经网络, 提出了一种压力系数预测模型, 很好地重构出了圆柱表面的压力变化曲线. Zhang等人<sup>[13]</sup>基于神经网络构建了非定常气动力模型, 准确地表达了气动力非定常特性. 非定常空化流动的典型特征是其状态随时间的变化表现为混沌运动, 属于非线性动力学问题. 由于受噪声和计算机精度的影响, 空化流动的演变规律及其水动力特性很难被长时间预测. 因此, 在未知系统运动方程的情况下, 利用已求解的时间序列结果, 如何尽可能长地预测后续时间序列的结果变化已经成为当前研究热点之一.

对于随时间演化的序列数据建模, 循环神经网络(Recurrent Neural Network, RNN)<sup>[14]</sup>具有巨大的潜力, 因为它可以使用内部状态来处理可变长度的输入序列. 然而, RNN难以训练, 特别是对于具有长期时间依赖性的序列, 因为它们经常遇到梯度消失问题<sup>[15-17]</sup>. 为了让网络长时间记住输入, 引入显式记忆, 即长短期记忆(Long Short-Term Memory, LSTM)来增强网络.

为了克服RNN的这一缺点, LSTM的架构被提出<sup>[18]</sup>, 并广泛应用于许多领域, 如时间序列预测<sup>[19]</sup>、语言处理<sup>[20]</sup>和计算机视觉<sup>[21]</sup>. 这种方法通过用LSTM单元替换隐藏层中的传统神经元来避免RNN中出现的梯度消失和爆炸.

最近, LSTM网络在非定常流的预测和建模中得到广泛应用<sup>[22,23]</sup>. Srinivasan等人<sup>[24]</sup>将LSTM应用到湍流剪切流的九方程ROM, 结果展示了LSTM在预测模型系数的混沌行为方面的能力, 并表明了在没有递归方案的情况下对抗多层感知器的优势. 此外, 与多层感知器相比, LSTM可以更好地再现时间平均湍流统计数据.

因此本文基于LSTM网络, 建立了一种多元变量压力预测模型, 并采用LES方法获得的非定常空化水翼数据对模型进行了外插验证, 以评估模型的预测精度和泛化性能. 本文的其余部分安排如下, 在第2节中概述了模型建立的方法, 第3节介绍了用于模型训练与预测的数据集, 第4节针对模型预测结果进行了分析与讨论, 最后一节进行了总结和展望.

## 2 方法

### 2.1 长短期记忆模型

RNN类似一个标准的多层感知机, 已被证明能够有效地处理序列问题, 然而, 在实际应用中, 由于RNN编码序列长, 在反向传播算法的优化中容易受到梯度消失和梯度爆炸的影响, 难以捕获到序列之间的长期依赖. LSTM作为缓解该问题最成功的模型被广泛使用. 因此在预测混沌系统的任务中, 本文选择LSTM作

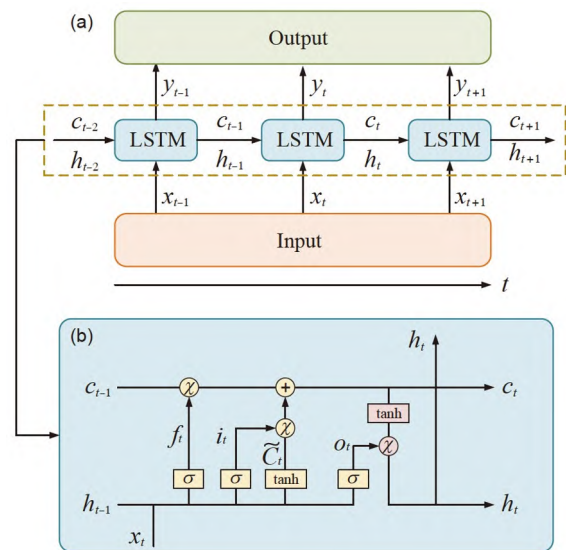


图1 (网络版彩图) LSTM网络结构(a)和单元结构(b)  
Figure 1 (Color online) LSTM network (a) and cell (b).

为基础单元, 模型结构如图1(a)所示. LSTM选择用“记忆块”代替传统的隐藏层节点, “记忆块”包含输入门、遗忘门和输出门三个门函数, 每个门都使用激活函数控制, 内部具体结构如图1(b)所示. 每个“记忆块”的具体计算公式如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (2)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (3)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tanh(W_C \cdot [h_{t-1}, x_t] + b_C), \quad (4)$$

$$h_t = o_t \times \tanh(C_t), \quad (5)$$

式中,  $f_t, i_t, o_t, C_t$  分别为遗忘门、输入门、输出门和记忆细胞的输出;  $W_f, W_i, W_o, W_C$  分别为4种输出的权重矩阵;  $b_f, b_i, b_o, b_C$  分别为4种输出的偏置;  $\sigma$  为sigmoid函数, 该函数和  $\tanh$  均为激活函数.

## 2.2 单变量时间序列预测压力

假设  $\mathbf{X} = [C_p^1, C_p^2, \dots, C_p^i, \dots, C_p^N]^T$  为模拟获得的水翼表面某点的压力系数数据 ( $N$  为时间采样点数), 选择前  $M$  个样本点作为训练集, 并基于此数据确定 LSTM 网络训练集的输入  $\mathbf{X}_{\text{train}}$  和输出  $\mathbf{Y}_{\text{train}}$ , 具体的表达式如下:

$$\mathbf{X}_{\text{train}} = \begin{bmatrix} C_p^1 & C_p^2 & C_p^3 & \dots & C_p^L \\ C_p^2 & C_p^3 & C_p^4 & \dots & C_p^{L+1} \\ \dots & \dots & \dots & \dots & \dots \\ C_p^{M-L} & C_p^{M-L+1} & C_p^{M-L+2} & \dots & C_p^{M-1} \end{bmatrix}_{(M-L) \times L}, \quad (6)$$

$$\mathbf{Y}_{\text{train}} = [C_p^{L+1} \ C_p^{L+2} \ C_p^{L+3} \ \dots \ C_p^M]^T_{1 \times (M-L)}. \quad (7)$$

在模型的预测阶段, 本文将后  $N-M$  点的压力系数均赋值为 0, 形成如下形式的测试集的输入:

$$\mathbf{X}_{\text{test}} = \begin{bmatrix} C_p^{M-L+1} & C_p^{M-L+2} & C_p^{M-L+3} & \dots & C_p^M \\ C_p^{M-L+2} & C_p^{M-L+3} & C_p^{M-L+4} & \dots & C_p^{M+1}=0 \\ \dots & \dots & \dots & \dots & \dots \\ C_p^{N-L}=0 & C_p^{N-L+1}=0 & C_p^{N-L+2}=0 & \dots & C_p^{N-1}=0 \end{bmatrix}_{(N-M) \times L}. \quad (8)$$

基于训练好的模型预测后  $N-M$  个的压力系数变化时: 第一步, 由式(8)中  $\mathbf{X}_{\text{test}}$  矩阵的第一行数据进行输入, 可

以预测出下一时刻的压力数据  $C_p^{M+1}$ ; 第二步, 由第一步预测的  $C_p^{M+1}$  自动覆盖第二行中  $C_p^{M+1} = 0$ , 进而预测  $C_p^{M+2}$ ; 以此类推, 直至预测到  $C_p^N$ , 预测完成.

在非线性非定常空化流动中, 当前时刻的水翼压力系数不仅取决于水翼当前的运动状态, 还取决于流体记忆效应的运动历史<sup>[25]</sup>. 此外, 流体记忆对水翼动力学的影响呈现衰减特征, 这意味着结构上的压力系数不依赖于无限过去的输入. 因此, 本文采用过去 15 个时刻作为输入, 来预测当前时刻的输出, 即式(6)–(8)中的  $L=15$ .

## 2.3 多元变量时间序列预测压力

空化水翼表面的压力系数与速度分布和体积分数密切相关, 为了使得模型的泛化性能更强, 本文建立了一个多元变量时间序列压力预测模型. 假设

$$\mathbf{X} = \begin{bmatrix} u^1 & v^1 & \alpha^1 & C_p^1 \\ u^2 & v^2 & \alpha^2 & C_p^2 \\ \dots & \dots & \dots & \dots \\ u^i & v^i & \alpha^i & C_p^3 \\ \dots & \dots & \dots & \dots \\ u^N & v^N & \alpha^N & C_p^N \end{bmatrix} \quad (9)$$

为模拟获得的水翼近壁面某点不同时刻的水平速度  $u^i$ 、垂直速度  $v^i$ 、体积分数  $\alpha^i$  和压力系数  $C_p^i$ . 选择数据  $\mathbf{X}$  的前  $M$  个样本点构建训练集, 并基于后  $N-M$  个样本点构建测试集, 具体的训练与预测流程如下:

(1) 基于前  $M$  个样本点构建如图2所示的训练集, 输入为模拟获得的前  $L$  时刻 ( $L=15$ ) 的水平速度  $u^i$ , 垂直速度  $v^i$  和体积分数  $\alpha^i$ , 输出为下一时刻的压力系数  $C_p^i$ , 共构建出如图2所示的  $M-L$  组训练集;

(2) 基于 LSTM 网络开展模型训练;

(3) 模型训练完成后, 开展模型预测, 采用模拟获得其余样本点构建测试集的输入集, 即水平速度、垂直速度和气体体积分数, 用于预测翼型表面的压力系数, 并基于数值模拟结果对神经网络预测结果进行验证和分析.

## 2.4 模型评价指标

选择均方误差 (Mean Square Error, MSE) 和平均绝对误差 (Mean Absolute Deviation, MAE) 作为评估预测




图2 (网络版彩图) LSTM输入输出映射关系

Figure 2 (Color online) The mapping relationship between input and output data of LSTM.

模型精确程度的评价指标, 具体计算公式如下:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2, \quad (10)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|, \quad (11)$$

式中,  $y_i$  为真实值,  $\hat{y}_i$  为预测值,  $N$  为预测样本个数.

### 3 数据集

如图3所示, Clark-Y水翼表面的P1和P2点的压力系数变化被用于单变量时间序列压力预测模型的训练和测试, 压力数据来源于Long等人<sup>[26]</sup>的大涡模拟结果.

三维水翼NACA0015空化流场的LES数据被选择用于训练和预测多变量时间序列压力预测模型. LES方程由Navier-Stokes方程进行滤波获得, 直接求解大尺度涡, 对小尺度涡进行建模求解:

$$\frac{\partial \rho_m}{\partial t} + \frac{\partial \rho_m \tilde{u}_j}{\partial x_j} = 0, \quad (12)$$

$$\frac{\partial \rho_m \tilde{u}_i}{\partial t} + \frac{\partial \rho_m \tilde{u}_i \tilde{u}_j}{\partial x_j} = -\frac{\partial \tilde{p}}{\partial x_i} + \frac{\partial}{\partial x_j} \left( \mu \frac{\partial \tilde{u}_i}{\partial x_j} + \tau_{ij} \right), \quad (13)$$

式中,  $\tilde{u}_i$  为  $i$  方向滤波后的速度分量,  $\rho_m$  和  $\mu$  分别为混合密度和混合动力黏度, 定义分别如下:

$$\mu = (1 - \alpha_v) \mu_l + \alpha_v \mu_v, \quad (14)$$

$$\rho_m = (1 - \alpha_v) \rho_l + \alpha_v \rho_v, \quad (15)$$

其中,  $\rho_l$  和  $\rho_v$  分别为水和蒸气的密度,  $\mu_l$  和  $\mu_v$  分别为水和蒸气的动力黏度,  $\tilde{p}$  为滤波后的压力,  $\tau_{ij} = \rho_m (\tilde{u}_i \tilde{u}_j - \tilde{u}_i \tilde{u}_j)$  为亚格子应力, 采用壁式局部涡流(Wall-Adapting Lo-

cal-Eddy Viscosity, WALE)模型<sup>[27]</sup>进行计算.

气体的体积分数输运方程为

$$\frac{\partial \rho_v \alpha_v}{\partial t} + \frac{\partial \rho_v \alpha_v \bar{u}_i}{\partial x_i} = R^e - R^c, \quad (16)$$

其中,  $R^e$  是蒸发率,  $R^c$  是冷凝率, 由Zwart等人<sup>[28]</sup>建立的Zwart-Gerber-Belamari (ZGB)模型进行模拟:

$$R^e = C_e \frac{3 \alpha_{\text{nuc}} (1 - \alpha_v - \alpha_{\text{ncg}}) \rho_v}{R_B} \sqrt{\frac{2 \max(p - p_{\text{sat}}, 0)}{3 \rho_l}}, \quad (17)$$

$$R^c = C_c \frac{3 \alpha_{\text{nuc}} \alpha_v \rho_v}{R_B} \sqrt{\frac{2 \max(p - p_{\text{sat}}, 0)}{3 \rho_l}},$$

其中,  $\alpha_{\text{nuc}}$  是成核体积分数,  $R_B$  是气泡直径,  $p_{\text{sat}}$  是饱和蒸汽压,  $p$  是局部流体压力,  $C_e$  是蒸发速率系数,  $C_c$  是冷凝速率系数.

计算域和边界条件如图4所示. 水翼弦长  $C=0.1$  m, 攻角  $\alpha=8^\circ$ . 水翼翼展方向长度为  $0.3C$ , 计算域的长度和高度分别为  $10C$  和  $3C$ . 计算域的前后面设置为对称边界条件, 上下面为自由滑移壁面边界条件, 水翼表明采用无滑移边界条件, 入口速度  $U=8$  m/s.




图3 (网络版彩图) Clark-Y水翼表面监测点P1和P2

Figure 3 (Color online) Monitoring points P1 and P2 on the surface of the Clark-Y hydrofoil.




图4 (网络版彩图) 计算域和边界条件

Figure 4 (Color online) Computational domain and imposed boundary conditions.

基于LES模拟获得了4组空化数( $\sigma=0.8, 1.1, 1.4$ 和 $1.7$ )下水翼空化结果, 其中, 空化数 $\sigma$ 定义如下:

$$\sigma = \frac{p_\infty - p_v}{\frac{1}{2}\rho_l u_\infty^2} \quad (18)$$

空化数为1.7时, 水翼表面流动为片状空化, 形成稳定的附着型空穴, 且尾部产生准周期性的生长脱落过程; 随着空化数降低到1.4, 尾部脱落现象更为剧烈, 形成局部片空化加云空化现象; 当空化数为1.1和0.8时, 水翼表面空泡形态均表现为云空化, 呈现大尺度空泡团周期性脱落.

对三维翼型模拟结果进行展向空间平均, 获得如图5所示的近壁面处P1和P2的不同时刻下的水平方向速度、垂直方向速度、气体体积分数以及压力系数分布.

## 4 结果与分析

### 4.1 单变量压力预测结果

用于单变量模型训练和预测的数据如表1所示, 将Clark-Y水翼的P1和P2点压力系数随时间的变化插值成1300个时间点, 采用前800个数据进行模型训练, 后500个数据进行预测.

由图6(a)和(b)所示的点P1和P2的预测结果, 可以看出, 构建的单变量压力预测模型能够较好地重构出




图5 (网络版彩图) NACA0015水翼表面监测点 $x/c=0.5$ 和 $x/c=1.0$

Figure 5 (Color online) Monitoring points  $x/c=0.5$  and  $x/c=1.0$  on the surface of the NACA0015 hydrofoil.

表1 用于单变量压力预测的数据集

Table 1 Data set for univariate pressure prediction

Case	Training set	Testing set
Case1: P1	1-800	801-1300
Case2: P2	1-800	801-1300

压力系数的时间系列变化.

### 4.2 多变量压力预测结果

用于多变量模型训练和预测的数据如表2所示, 首先将如图5所示的NACA0015水翼的 $x/c=0.5$ 和 $x/c=1.0$ 两点的瞬时速度、气体体积分数和压力系数随时间的变化插值成1300个时间点. 之后, 采用4种训练-测试方案, Prediction 1和Prediction 2分别基于 $\sigma=1.1$ 和 $\sigma=1.4$ 时的前800个数据进行训练, 后500个数据进行预测; Prediction 3和Prediction 4采用同一套训练集, 即 $\sigma=1.1$ 和 $\sigma=1.4$ 的全时间序列数据, 并分别对 $\sigma=0.8$ 和 $\sigma=1.7$ 的后500个数据进行外插预测.

$\sigma=1.1, x/c=0.5$ 和 $\sigma=1.1, x/c=1.0$ 水翼表面压力系数




图6 (网络版彩图) Clark-Y水翼表面压力系数的LSTM时间历史预测. (a) P1; (b) P2

Figure 6 (Color online) LSTM time history predictions of Clark-Y hydrofoil surface pressure coefficients. (a) P1; (b) P2.

表2 用于多变量压力预测的数据集

Table 2 Data set for multivariate pressure prediction

Prediction	Training set	Testing set
Prediction 1	$\sigma=1.1: 1-800$	$\sigma=1.1: 801-1300$
Prediction 2	$\sigma=1.4: 1-800$	$\sigma=1.4: 801-1300$
Prediction 3	$\sigma=1.1: 1-1300$ $\sigma=1.4: 1-1300$	$\sigma=0.8: 801-1300$
Prediction 4	$\sigma=1.1: 1-1300$ $\sigma=1.4: 1-1300$	$\sigma=1.7: 801-1300$

的LSTM时间历史预测结果如图7(a)和(b)所示. 从图中可以看出, 预测结果与LES结果趋势一致, 吻合较好. 图8(a)和(b)分别是 $\sigma=1.4$ ,  $x/c=0.5$ 和 $\sigma=1.4$ ,  $x/c=1.0$ 的预测结果, 显示出了预测模型对水翼表面压力系数时间

演化的高精度重构. 表3给出了多元变量压力预测模型针对 $x/c=0.5$ 和 $x/c=1.0$ 处的MSE和MAE结果, 进一步验证了Prediction 1和Prediction 2方案的预测结果与真实LES结果较为一致.

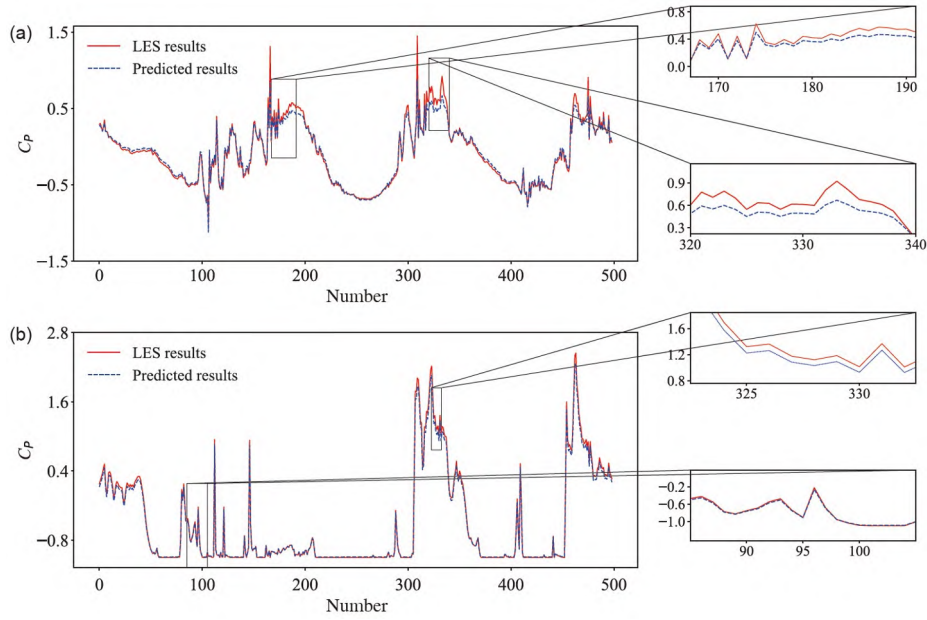


图7 (网络版彩图)  $\sigma=1.1$ ,  $x/c=0.5$  (a)和 $\sigma=1.1$ ,  $x/c=1.0$  (b)水翼表面压力系数的LSTM时间历史预测

Figure 7 (Color online) LSTM time history predictions of hydrofoil surface pressure coefficients for  $\sigma=1.1$ ,  $x/c=0.5$  (a) and  $\sigma=1.1$ ,  $x/c=1.0$  (b).

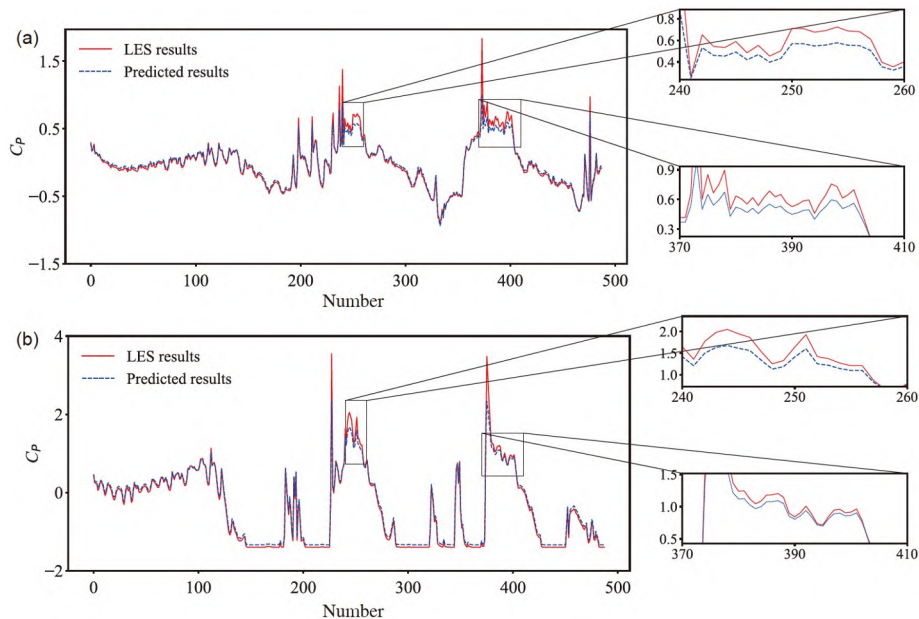


图8 (网络版彩图)  $\sigma=1.4$ ,  $x/c=0.5$  (a)和 $\sigma=1.4$ ,  $x/c=1.0$  (b)水翼表面压力系数的LSTM时间历史预测

Figure 8 (Color online) LSTM time history predictions of hydrofoil surface pressure coefficients for  $\sigma=1.4$ ,  $x/c=0.5$  (a) and  $\sigma=1.4$ ,  $x/c=1.0$  (b).

图9和10分别是Prediction 3和Prediction 4的外插预测结果, 从图中可以明显地看出, LSTM针对压力系数的时间历史预测与LES结果仍能满足一致性. 除此

之外, 表3的MSE和MAE结果也表明Prediction 3和Prediction 4的外插预测误差仅略高于Prediction 1和Prediction 2的预测结果. 因此, 可以发现本文构建的多元

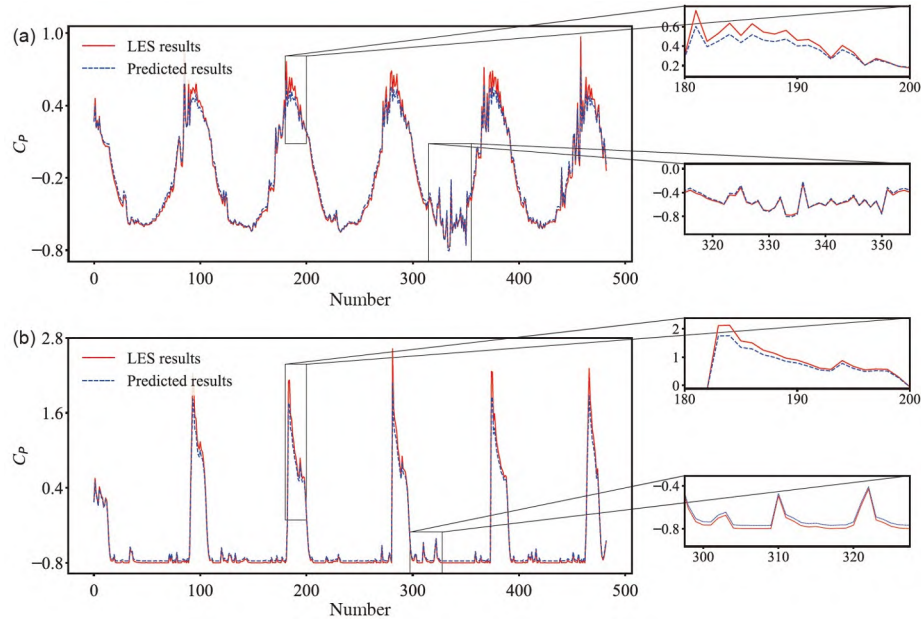


图9 (网络版彩图)  $\sigma=0.8$ ,  $x/c=0.5$  (a)和 $\sigma=0.8$ ,  $x/c=1.0$  (b)水翼表面压力系数的LSTM时间历史预测

Figure 9 (Color online) LSTM time history predictions of hydrofoil surface pressure coefficients for  $\sigma=0.8$ ,  $x/c=0.5$  (a) and  $\sigma=0.8$ ,  $x/c=1.0$  (b).

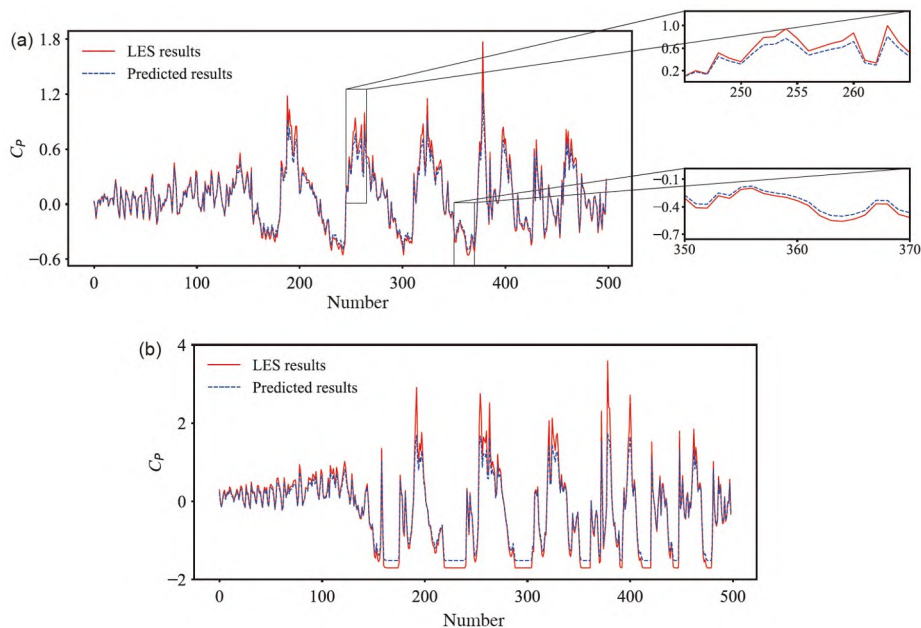


图10 (网络版彩图)  $\sigma=1.7$ ,  $x/c=0.5$  (a)和 $\sigma=1.7$ ,  $x/c=1.0$  (b)水翼表面压力系数的LSTM时间历史预测

Figure 10 (Color online) LSTM time history predictions of hydrofoil surface pressure coefficients for  $\sigma=1.7$ ,  $x/c=0.5$  (a) and  $\sigma=1.7$ ,  $x/c=1.0$  (b).

表3 用于多变量压力预测的数据集

Table 3 Data set for multivariate pressure prediction

Prediction	$\sigma-x/c$	MSE	MAE
Prediction 1	1.1-0.5	0.0265	0.0912
	1.1-1.0	0.0719	0.1113
Prediction 2	1.4-0.5	0.0166	0.0784
	1.4-1.0	0.0786	0.0993
Prediction 3	0.8-0.5	0.0296	0.0962
	0.8-1.0	0.1259	0.1708
Prediction 4	1.7-0.5	0.0325	0.1245
	1.7-1.0	0.3279	0.3543

压力预测模型可以很好地重构压力系数时间序列, 并具有一定的泛化性能.

## 5 讨论和结论

本文基于LSTM网络构建了一种多元变量压力预测模型, 其中模型的输入为水平速度、垂直速度和气体体积分数, 模型输出为空化水翼压力系数. 数值算例表明, 在适当选择输入信号进行良好训练后, LSTM网络能够高效和准确预测非定常空化水翼表面的压力系数, 其外插预测结果和误差也表明了该模型具有一定的泛化性能.

在下一步的工作中, 考虑将LSTM与基于神经网络的模型降阶相结合, 来寻找低维表示并识别高维流体动力学系统的相干结构, 以捕捉时间演化特征并预测未来的时间步长.

## 参考文献

- Ji B, Cheng H Y, Huang B, et al. Research progresses and prospects of unsteady hydrodynamics characteristics for cavitation (in Chinese). *Adv Mech*, 2019, 49: 201900 [季斌, 程怀玉, 黄彪, 等. 空化水动力学非定常特性研究进展及展望. *力学进展*, 2019, 49: 201900]
- Arakeri V H, Acosta A J. Viscous effects in the inception of cavitation on axisymmetric bodies. *J Fluids Eng*, 1973, 95: 519–527
- Astolfi J A, Dorange P, Billard J Y, et al. An experimental investigation of cavitation inception and development on a two-dimensional Eppler hydrofoil. *J Fluids Eng*, 2000, 122: 164–173
- Wang G, Senocak I, Shyy W, et al. Dynamics of attached turbulent cavitating flows. *Prog Aerosp Sci*, 2001, 37: 551–581
- Kawanami Y, Kato H, Yamaguchi H, et al. Mechanism and control of cloud cavitation. *J Fluids Eng*, 1997, 119: 788–794
- Wilcox D C. *Turbulence Modeling for CFD*. 2nd ed. La Canada: DCW Industries, Inc., 1998
- Deardorff J W. The use of subgrid transport equations in a three-dimensional model of atmospheric turbulence. *J Fluids Eng*, 1973, 95: 429–438
- Wang G, Ostojca-Starzewski M. Large eddy simulation of a sheet/cloud cavitation on a NACA0015 hydrofoil. *Appl Math Model*, 2007, 31: 417–447
- Wu J L, Sun R, Laizet S, et al. Representation of stress tensor perturbations with application in machine-learning-assisted turbulence modeling. *Comput Methods Appl Mech Eng*, 2019, 346: 707–726
- Kobayashi W, Shimura T, Mitsuishi A, et al. Prediction of the drag reduction effect of pulsating pipe flow based on machine learning. *Int J Heat Fluid Flow*, 2021, 88: 108783
- Kim D H, Zohdi T I, Singh R P. Modeling, simulation and machine learning for rapid process control of multiphase flowing foods. *Comput Methods Appl Mech Eng*, 2020, 371: 113286
- Ye S, Zhang Z, Song X, et al. A flow feature detection method for modeling pressure distribution around a cylinder in non-uniform flows by using a convolutional neural network. *Sci Rep*, 2020, 10: 4459
- Zhang W, Wang B, Ye Z, et al. Efficient method for limit cycle flutter analysis based on nonlinear aerodynamic reduced-order models. *AIAA J*, 2012, 50: 1019–1028
- Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors. *Nature*, 1986, 323: 533–536
- Xiong Y C, Zhao H. Chaotic time series prediction based on long short-term memory neural networks (in Chinese). *Sci Sin-Phys Mech Astron*, 2019, 49: 120501 [熊有成, 赵鸿. 长短期记忆网络预测混沌时间序列. *中国科学: 物理学 力学 天文学*, 2019, 49: 120501]
- Yan Y H, Cheng G F. Thinking and exploration into intellectualization of speech and medical acoustics (in Chinese). *Sci Sin-Phys Mech Astron*, 2022, 52: 244305 [颜永红, 程高峰. 语言声学智能化的思考与探索. *中国科学: 物理学 力学 天文学*, 2022, 52: 244305]
- Bengio Y, Simard P, Frasconi P. Learning long-term dependencies with gradient descent is difficult. *IEEE Trans Neural Netw*, 1994, 5: 157–166
- Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Computat*, 1997, 9: 1735–1780



- 19 Yang J, Guo Y, Zhao W. Long short-term memory neural network based fault detection and isolation for electro-mechanical actuators. *Neurocomputing*, 2019, 360: 85–96
- 20 Ryu S, Kim S, Choi J, et al. Neural sentence embedding using only in-domain sentences for out-of-domain sentence detection in dialog systems. *Pattern Recognit Lett*, 2017, 88: 26–32
- 21 Núñez J C, Cabido R, Vélez J F, et al. Multiview 3D human pose estimation using improved least-squares and LSTM networks. *Neurocomputing*, 2019, 323: 335–343
- 22 Pawar S, Ahmed S E, San O, et al. Data-driven recovery of hidden physics in reduced order modeling of fluid flows. *Phys Fluids*, 2020, 32: 036602, arXiv: [1910.13909](https://arxiv.org/abs/1910.13909)
- 23 Hasegawa K, Fukami K, Murata T, et al. Machine-learning-based reduced-order modeling for unsteady flows around bluff bodies of various shapes. *Theor Comput Fluid Dyn*, 2020, 34: 367–383, arXiv: [2003.07548](https://arxiv.org/abs/2003.07548)
- 24 Srinivasan P A, Guastoni L, Azizpour H, et al. Predictions of turbulent shear flows using deep neural networks. *Phys Rev Fluids*, 2019, 4: 054603, arXiv: [1905.03634](https://arxiv.org/abs/1905.03634)
- 25 Wu T, Kareem A, Ge Y. Linear and nonlinear aeroelastic analysis frameworks for cable-supported bridges. *Nonlinear Dyn*, 2013, 74: 487–516
- 26 Long X, Cheng H, Ji B, et al. Numerical investigation of attached cavitation shedding dynamics around the Clark-Y hydrofoil with the FBDCM and an integral method. *Ocean Eng*, 2017, 137: 247–261
- 27 Nicoud F, Ducros F. Subgrid-scale stress modelling based on the square of the velocity gradient tensor. *Flow Turbulence Combust*, 1999, 62: 183–200
- 28 Zwart P J, Gerber A G, Belamri T. A two-phase flow model for predicting cavitation dynamics. In: Proceedings of the 5th International Conference on Multiphase Flow. Yokohama, Japan, 2004.

## Unsteady cavitating hydrofoil surface pressure prediction based on long short-term memory network

ZHANG Zhen<sup>1,2,3</sup>, LIU QingKuan<sup>1,2,3</sup>, WANG JingZhu<sup>4</sup> & WANG YiWei<sup>4,5,6\*</sup>

<sup>1</sup> State Key Laboratory of Mechanical Behavior and System Safety of Traffic Engineering Structures, Shijiazhuang Tiedao University, Shijiazhuang 050043, China;

<sup>2</sup> Innovation Center for Wind Engineering and Wind Energy Technology of Hebei Province, Shijiazhuang 050043, China;

<sup>3</sup> School of Civil Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050043, China;

<sup>4</sup> Institute of Mechanics, Chinese Academy of Sciences, Beijing 100190, China;

<sup>5</sup> School of Engineering Science, University of Chinese Academy of Sciences, Beijing 100049, China;

<sup>6</sup> School of Future Technology, University of Chinese Academy of Sciences, Beijing 100049, China

As a typical nonlinear dynamic problem, the evolution law and hydrodynamic characteristics of an unsteady cavitating flow are affected by noise and computer accuracy, thus, rendering it difficult to be predicted for a long time. In this paper, a long short-term memory network is used to develop a multivariable pressure prediction model, wherein the input is the velocity value and the vapor volume fraction, and the output is the time series of the pressure coefficient. The large eddy simulation (LES) data of the hydrofoil is predicted via extrapolation. The results show that the prediction results agree with LES simulation results well, demonstrating good generalization and the ability to predict more future results.

**LSTM, pressure coefficient, cavitating flow, LES**

**PACS:** 47.27.-i, 47.27.E-, 47.61.Jd

**doi:** [10.1360/SSPMA-2022-0217](https://doi.org/10.1360/SSPMA-2022-0217)