

【引用格式】邵兴, 朱海龙. 基于 LSTM 神经网络的半潜式机器人垂直面控制研究[J]. 数字海洋与水下攻防, 2025, 8(4): 508-516.

# 基于 LSTM 神经网络的半潜式机器人 垂直面控制研究

邵 兴<sup>1</sup>, 朱海龙<sup>2</sup>

(1. 宜昌测试技术研究所, 湖北 宜昌 443003; 2. 陆装防化局驻宜昌地区防化室, 湖北 宜昌 443000)

**摘 要** 在简要分析半潜式机器人作业特点的基础上, 指出了半潜式机器人垂直面运动控制的难点, 介绍了近水面航行器相关控制技术。系统地论述了半潜式机器人基本控制原理以及反馈控制方法, 提出了一种基于长短期记忆循环神经网络的半潜式机器人垂直面运动控制策略, 给出了该控制策略的构建方法, 并通过试验验证了该控制策略的有效性。

**关键词** 半潜式机器人; 垂直面; 运动控制; 深度学习; 长短期记忆循环神经网络

**中图分类号** TP273

**文献标识码** A

**文章编号** 2096-5753(2025)04-0508-09

**DOI** 10.19838/j.issn.2096-5753.2025.04.014

## Research on Vertical Plane Motion Control of Semi-Submersible Vehicles Based on LSTM Recurrent Neural Network

SHAO Xing<sup>1</sup>, ZHU Hailong<sup>2</sup>

(1. Yichang Testing Technique Research Institute, Yichang 443003, China; 2. Chemical Defense Representative Office of Equipment Department Located in Yichang Area, Yichang 443000, China)

**Abstract** In this paper, the working characteristics of semi-submersible vehicles are analyzed briefly. The difficulties of vertical plane motion control are pointed out, and the control technologies related to near-surface vehicles are introduced. Then, the basic control principles and feedback control methods of semi-submersible vehicles are explained systematically. After that, the vertical plane motion control strategy of semi submersible vehicles based on long short-term memory recurrent neural networks is put forward. Finally, the construction method of the control strategy is provided, and the effectiveness of the control strategy is verified through tests.

**Key words** semi-submersible vehicle; vertical plane; motion control; deep learning; long short-term memory recurrent neural network

## 0 引言

本文所研究的半潜式机器人是一种近水面航行器, 其由航行主体(含导航系统、鳍舵系统、动

力系统、电力系统)、通气桅杆、作业装置组成。航行时, 以柴油机作为动力源, 主体潜于水下 2~5 m, 通气级桅杆穿透水面, 桅杆顶部位于水面之上, 可搭载多种天线; 通过艏/艉水平鳍舵保持

半潜式机器人的深度和姿态稳定, 类似于潜艇在近水面的航行状态<sup>[1]</sup>。半潜式机器人独特的设计以及特殊的作业方式, 使其具备长时间的续航力、较强的耐波性和较好的隐蔽性。因此半潜式机器人在远海反水雷作战、航道搜索、海洋探测、弱通信条件下的无人通信中继<sup>[2]</sup>等方面得到了较好地应用。

半潜式机器人处于近水面航行, 下潜深度较小, 所受外界环境干扰较大<sup>[2]</sup>, 其航行状态时时刻刻会受到风、浪、流的冲击, 在高海况下这种情况尤为剧烈, 因此保持半潜式机器人稳定地近水面航行是其控制研究的重点。

针对航行器近水面航行控制问题, 文献[2]提出一种基于深度辨识模型集的无人半潜水下机器人定深控制方法, 文献[3]提出了基于模型预测控制的 AUV 运动控制方法。考虑到半潜式机器人这种强非线性系统, 除自身复杂外其携带载体的不规则以及外部环境的不确定, 要建立其运动控制模型几乎是不可能的, 基于模型的控制策略也无法实现。文献[4]给出了潜艇运动控制的 3 种常规方法, 都是基于比例-积分-微分的 PID 控制。由于半潜式机器人与潜艇在近水面的航行状态类似, 可借鉴文献[4]中关于潜艇运动控制的 PID 控制方法, 将其运用到半潜式机器人垂直面运动控制。该 PID 控制通过误差直接给出操舵指令, 迅速地对垂直面运动进行调节, 具有响应快、实现简单等优点。但由于其操舵频繁且舵幅较大, 易超调, 导致系统能耗巨大、辐射噪声增加, 同时也降低了舵机使用寿命。

文献[5]~[7]提出了基于自抗扰控制方法的垂直面运动控制策略, 利用跟踪微分器抑制信号传输时的噪声干扰, 通过扩张状态观测器实时跟踪、估计扰动并及时进行补偿<sup>[8]</sup>。该方法降低了操舵幅度和操舵频率, 但由于该控制方法具有一定的滤波性能<sup>[7]</sup>, 当系统垂直面运动发生骤变时无法及时有效地进行控制。若此时采用响应更迅捷的 PID 控制, 可迅速达到控制效果。两种控制方法互为补充在很大程度上可提高半潜式机器人垂直面整体控制性能。

基于以上分析, 可从 2 种控制策略中提取控制效果良好的数据集, 以深度学习模型对该数据集进行学习训练, 提取数据集中蕴含的非线性特征, 使得该深度学习模型融合 2 种控制策略的优点。基于这种研究思路, 本文提出了一种基于长短期记忆

(Long Short-Term Memory, LSTM) 循环神经网络的半潜式机器人垂直面运动控制策略。

首先以 PID 控制方法和自抗扰控制方法为基础制定半潜式机器人垂直面运动控制的 2 种策略, 半潜式机器人采用这 2 种策略进行航行试验, 试验过程中记录两种策略产生的试验数据, 从 2 种试验数据中筛选出控制效果良好的优秀数据, 生成控制数据集; 然后构建基于 LSTM 循环神经网络的深度学习模型, 利用控制数据集对该 LSTM 循环神经网络模型进行学习训练, 以此构建半潜式机器人的俯仰、深度、速度等已知输入量和输出量鳍舵命令舵角之间的映射关系, 该映射关系就是基于 LSTM 循环神经网络的半潜式机器人垂直面运动控制策略。

## 1 半潜式机器人垂直面运动控制的基本原理

半潜式机器人垂直面控制系统主要由航行主体、鳍舵系统和控制器组成, 该系统为多输入(半潜式机器人俯仰角、深度等)多输出(艏、艉水平鳍舵舵角)系统。

如图 1 所示,  $H_0$  为目标定深度值,  $H$  为当前深度;  $\theta_0$  为目标定俯仰值,  $\theta$  为当前俯仰;  $\delta_0$  为命令舵角,  $\delta$  为当前舵角,  $v$  为当前航行速度,  $\omega$  为波浪干扰。




图 1 半潜式机器人垂直面控制系统原理图  
Fig. 1 Schematic diagram of vertical plane motion control of semi-submersible vehicles

根据俯仰目标值、当前半潜式机器人的俯仰值以及深度目标值、当前半潜式机器人的深度值, 结合当前的航行速度按照某种控制策略生成鳍舵命令舵角; 根据命令舵角进行鳍舵角度调节, 鳍舵角度调节改变半潜式机器人的航行俯仰和深度, 从而形成了一个闭环控制系统, 实现了系统的垂直面运动控制, 维持系统的稳定航行。

## 2 基于长短期记忆循环神经网络的控制模型

### 2.1 深度学习

深度学习本质上是具有多层隐藏层的神经网络

络, 其基本思想是面向高维数据, 通过多层的网络结构和非线性变换, 组合低层特征, 形成抽象的、易于区分的高层表示, 以发现数据的分布式特征表示<sup>[9]</sup>。

由图 1 可知, 半潜式机器人当前的俯仰、深度等航行状态依赖于上一时刻的鳍舵命令舵角, 上一时刻的鳍舵命令舵角又依赖于上上时刻的航行状态, 因此为了更好地得到航行状态与鳍舵命令舵角之间的映射关系, 选用的深度学习框架要能很好地反映各状态在时间序列上的依赖关系。

在众多的深度学习框架中, 长短期记忆循环神经网络能很好地学习时间序列数据中隐含的分布式特征<sup>[9]</sup>, 因此本文提出的控制策略采用长短期记忆循环神经网络作为学习框架。

## 2.2 长短期记忆循环神经网络

传统循环神经网络存在“梯度消失”和“梯度爆炸”的问题, 长短期记忆循环神经网络在传统循环神经网络的基础上引入“门控”的概念, 巧妙地解决了传统循环神经网络存在的这些问题<sup>[10-13]</sup>。图 2 为 LSTM 网络的基本单元结构。

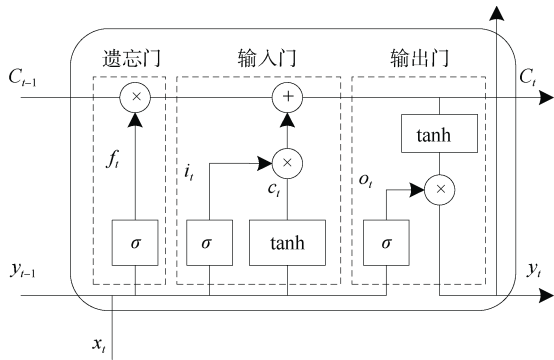


图 2 LSTM 循环神经网络的基本单元结构图

Fig. 2 Structure diagram of basic units of LSTM recurrent neural network

长短期记忆循环神经网络基本单元中包含遗忘门、输入门和输出门 3 种门控结构。遗忘门决定上一时刻的记忆单元  $C_{t-1}$  有多少信息保存到当前记忆单元  $C_t$  中; 输入门控制当前时刻的输入  $x_t$  中有多少信息保存到当前记忆单元  $C_t$  中; 输出门决定当前时刻的记忆单元  $C_t$  有多少信息被更新到输出  $y_t$  中<sup>[10-15]</sup>。 $x_t$ ,  $y_t$  和  $C_t$  分别为 LSTM 循环神经网络层  $t$  时刻的输入、输出和记忆单元。

当前输入  $x_t$ 、上一时刻的记忆单元  $C_{t-1}$  和上一时刻的输出  $y_{t-1}$ , 以公式 (1) 运算<sup>[10-15]</sup>并产生新的记忆单元  $C_t$  和新的输出  $y_t$ 。

$$\begin{cases} f_t = \sigma(W_f \cdot [y_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [y_{t-1}, x_t] + b_i) \\ c_t = \tanh(W_c \cdot [y_{t-1}, x_t] + b_c) \\ C_t = f_t \otimes C_{t-1} + i_t \otimes c_t \\ o_t = \sigma(W_o \cdot [y_{t-1}, x_t] + b_o) \\ y_t = o_t \otimes \tanh(C_t) \end{cases} \quad (1)$$

式中:  $i_t$ ,  $f_t$ ,  $o_t$  和  $c_t$  分别为 LSTM 循环神经网络内部 4 个输出;  $\sigma$  和  $\tanh$  分别为 Sigmoid 和 tansig 激活函数;  $W_f$ ,  $W_i$ ,  $W_c$ ,  $W_o$  和  $b_f$ ,  $b_i$ ,  $b_c$ ,  $b_o$  分别为不同门层的权重和偏置值; 符号  $\cdot$  代表点乘; 符号  $\otimes$  代表向量逐元素相乘。

## 2.3 基于长短期记忆循环神经网络的控制模型构建

本文构建的长短期记忆循环神经网络模型结构如图 3 所示, 由输入层、隐藏层和输出层组成。输入层为半潜式机器人当前的航行状态  $\mathbf{x}(t)$ ; 输出层为下一时刻的鳍舵命令舵角矩阵  $\delta'(t)$ ; 隐藏层由 3 个长短期记忆循环神经网络层和 2 个全连层组成, 其对输入数据进行处理, 输出下一时刻的鳍舵命令舵角矩阵。

输入矩阵  $\mathbf{x}(t)$  为半潜式机器人的俯仰  $\theta$ , 深度  $H$ , 航速  $v$ , 艏水平舵角  $\delta_1$  和  $\delta_2$ , 艉水平舵角  $\delta_3$  和  $\delta_4$ ; 输出矩阵  $\delta'(t)$  为半潜式机器人的艏水平舵命令舵角  $\delta'_1$  和  $\delta'_2$ , 艉水平舵命令舵角  $\delta'_3$  和  $\delta'_4$ :

$$\begin{cases} \mathbf{x}(t) = [\theta(t), H(t), v(t), \delta_1(t), \delta_2(t), \delta_3(t), \delta_4(t)] \\ \delta'(t) = [\delta'_1(t), \delta'_2(t), \delta'_3(t), \delta'_4(t)] \end{cases} \quad (2)$$

每次 LSTM 循环神经网络学习训练输入序列为  $50 \times 7$  矩阵, 每个输入特征量每秒取 2 个数据, 每次输入数据的时间长度为 25 s, 共 50 个数据。

LSTM 循环神经网络模型中隐藏层为 3 层、隐藏层神经元数量为 32 个、第 1 个全连层神经元数量为 16 个, 第 2 个全连层神经元数量为 4 个。全连接层以式 (3) 的方式进行维度变换<sup>[11]</sup>, 第 1 个全连层将 LSTM 层输出的 32 维向量压缩为 16 维,

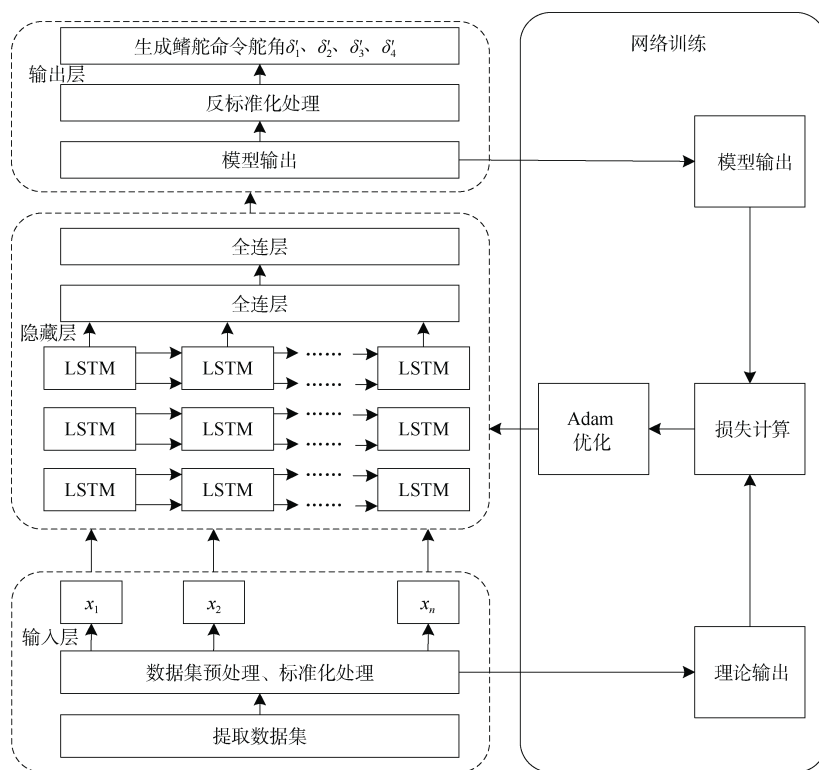


图3 LSTM 循环神经网络模型结构图

Fig. 3 Structure diagram of LSTM recurrent neural network model

第2个全连层将第1个全连层输出的16维向量压缩为1维向量,经处理后最终输出下一时间节点的鳍舵命令舵角。

$$y(t) = W \cdot x(t) + b \quad (3)$$

式中:  $y(t)$  和  $x(t)$  分别为全连层  $t$  时刻的输出和输入;  $W$  和  $b$  分别为权重和偏置值。

如式(1)和(3)所示, LSTM 循环神经网络模型的关键就是各神经网络层中的权重和偏置值。在 LSTM 循环神经网络模型结构确定后,利用已知数据集对模型进行学习训练来调整模型参数,可以构建出半潜式机器人的俯仰、深度、航速与鳍舵命令舵角之间的非线性映射关系。利用这种非线性映射关系,结合半潜式机器人的当前俯仰、深度、航速就可以得到鳍舵命令舵角,从而实现半潜式机器人垂直面的运动控制。

### 3 长短期记忆循环神经网络模型学习训练

#### 3.1 数据预处理

##### 3.1.1 数据集提取

半潜式机器人采用PID控制和自抗扰控制这2种策略在静水和复杂环境下进行试验,试验过程中

以文本形式记录2种策略产生的试验数据。记录的数据总共为8列,依次为时间、俯仰、深度、航速、艏舵舵角1、艏舵舵角2、艉舵舵角1和艉舵舵角2。每隔0.1 s记录一组数据。

每隔0.5 s从记录的原始试验数据中提取一组数据,从半潜式机器人的航行稳定与航行安全2个方面对数据进行优劣评定,优秀的数据计入控制数据集中。

航行稳定性要求操舵次数较少、操舵幅较小;航行安全性要求半潜式机器人的俯仰不超过 $-6^\circ$ 、深度不超过5 m。如果在某段时间内无法从原始试验数据中提取满足稳定性要求的数据,就舍弃稳定性保证安全性,提取满足安全型要求的数据;在某段时间内无法从原始试验数据提取满足安全性要求的数据,此时需结合流体动力仿真生成数据,保证该时间段内系统的航行安全。

生成控制数据集后,以时间长度为25 s的窗口对该数据集进行分割,划分出成若干个批次的时间序列数据集,每批次数据集为 $50 \times 7$ 矩阵,该矩阵作为LSTM循环神经网络模型的输入,参与模型学习训练。

##### 3.1.2 数据集标准化

时间序列数据集中俯仰、深度、速度、鳍舵舵



角等特征量的物理量纲不同,采用 Z-Score 标准化方法进行归一化处理,将数据统一转化为同一个量级。Z-Score 标准化公式<sup>[16-17]</sup>:

$$x' = \frac{x - \bar{x}}{\sigma_x} \quad (4)$$

式中:  $x'$  为变量经标准化处理后的数值;  $x$  为待标准化处理的变量;  $\bar{x}$  为变量的均值;  $\sigma_x$  为变量的标准差。

模型输出数据为标准化处理后的数据,需进行反标准化处理。反标准化公式<sup>[16-17]</sup>:

$$x = \sigma_x \times x' + \bar{x} \quad (5)$$

### 3.2 训练流程

LSTM 循环神经网络的数据处理与训练流程为:

1) 从原始数据中提取出控制数据集,对控制数据集进行分割,划分为  $50 \times 7$  矩阵的若干批次时间序列数据集。

2) 对时间序列数据集进行标准化处理;按 7:3 的比例<sup>[10, 18]</sup>划分出训练集和测试集;

3) 初始化 LSTM 循环神经网络模型的权重、偏置等参数。

4) 将训练集输入 LSTM 循环神经网络,按从左到右的前向传播方向顺序计算 LSTM 循环神经网络的输出值。

5) 计算 LSTM 循环神经网络的输出值与真实值的误差,再根据计算得到的误差从后往前反向计算各隐藏层之间以及隐藏层细胞之间的误差;此时的真实值为训练集中的鳍舵舵角。

6) 依据这些误差计算对应的权重梯度,使用优化器根据权重梯度更新模型参数。

7) 重复步骤 4-6,反复迭代训练,直到模型收敛或达到预定的训练次数。

8) 完成学习训练后,将测试集数据代入训练好的 LSTM 循环神经网络中验证模型的准确性。

### 3.3 模型部署

在 Linux 系统下安装 Python 环境和必要的数学运算库以及 Pytorch 深度学习框架;定义 LSTM 模型,包括 3 个 LSTM 层、2 个全连接层以及每层的神经元数,如 2.3 章节描述。定义损失函数和优化器,选择均方误差损失函数为模型训练的损失函数,并使用 Adam 作为优化器。模型训练,将训练数据集导入模型进行学习训练,设定学习率为

0.005,迭代次数为 100。模型测试,将测试集数据代入训练好的模型中验证模型的准确性。

## 4 基于长短期记忆循环神经网络控制模型的试验

在试验水域规划出  $6 \text{ km} \times 500 \text{ m}$  作业区域,作业区域内无船只、渔网等影响航行的障碍物。母船位于作业区域外,离作业区域横距 500 m,负责远程操控以及警戒。

在作业区域内制作一条长度 5 km 的航线,以 10 kn 速度往返 1 趟作为 1 个航次。分别以 PID 控制策略和 ADRC 控制策略控制半潜式机器人完成 1 个航次的试验。试验过程中按照 3.1.1 章节的方法记录原始试验数据。

2 种控制策略完成航行试验后,对原始试验数据进行处理,提取出供模型学习训练的控制数据集。

按照 LSTM 循环神经网络模型训练步骤,对已构建的 LSTM 循环神经网络模型进行学习训练。然后导入测试数据集对已训练的模型进行测试,测试合格后以该 LSTM 循环神经网络模型控制半潜式机器人按照原规划的航线完成 1 个航次的航行试验。

### 4.1 静水试验

静水试验过程中试验水域微风、无浪。半潜式机器人以 3 种控制策略完成湖上静水航行试验的航行效果如图 4-6 所示。




图 4 湖上试验姿态曲线图

Fig. 4 Attitude curves of lake tests




图5 湖上试验深度曲线图  
Fig. 5 Depth curves of lake tests

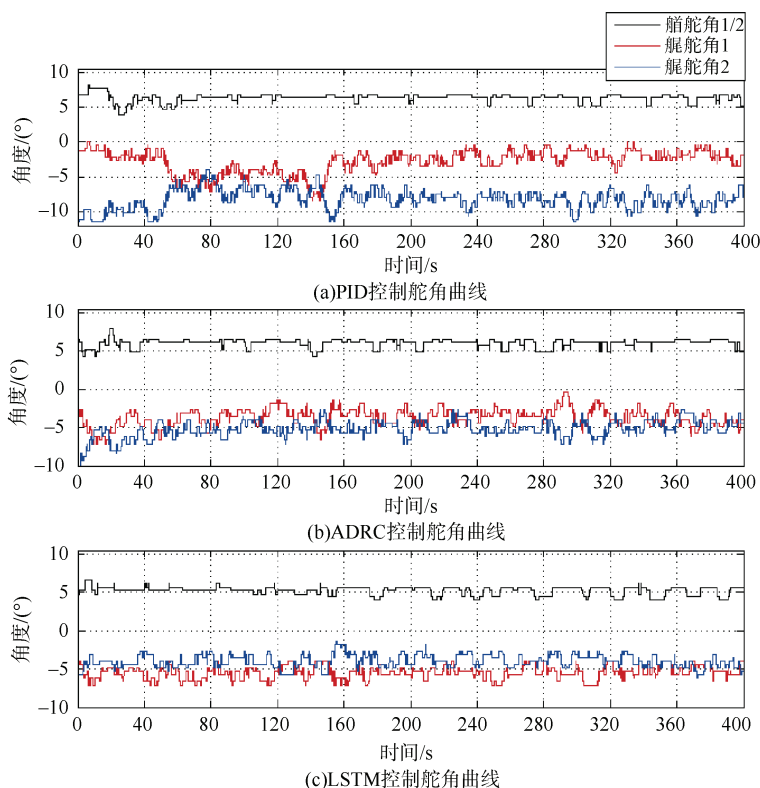


图6 湖上试验舵角曲线图  
Fig. 6 Rudder angle curves of lake tests

如图4-6所示,湖上航行试验时,3种控制策略实现的半潜式机器人航行效果都较理想。静水试验数据分析见表1。

PID控制时半潜式机器人的俯仰和深度较为

平稳,但是俯仰和深度存在轻微的震荡,可能是PID超调引起。舵角角度最大为 $8.2^{\circ}$ ,操舵频率为 $0.25\text{ Hz}$ ;舵角2角度到达了 $-11.5^{\circ}$ ,操舵频率为 $1.4\text{ Hz}$ ,操舵幅度和频率都较大。

表 1 静水试验数据分析表  
Table 1 Data analysis table of lake tests

控制策略	俯仰/(°)	深度/m	艏舵 1/2		艉舵		
			舵角/(°)	操舵频率/Hz	舵角 1/(°)	舵角 2/(°)	操舵频率/Hz
PID 控制	-2.4~-0.9	4.0~4.3	8.2~3.8	0.25	-8.4~0	-11.5~-4	1.4
ADRC 控制	-2~-1.2	4.05~4.25	8.0~4.3	0.22	-7.1~-0.4	-9.6~-3.5	1
LSTM 循环神经网络控制	-1.8~-1.0	4.15	6.5~4.0	0.2	-7.1~-2.6	-6.2~-1.3	0.8

ADRC 控制时半潜式机器人的俯仰和深度很平稳。艏舵角度最大为 8.0°, 操舵频率为 0.22 Hz; 艉舵 2 角度最大为-9.6°, 操舵频率为 1 Hz。与 PID 控制相比, 其操舵幅度和频率有较大的减小, 控制效果有提高。

LSTM 循环神经网络控制时半潜式机器人的俯仰和深度最平稳。艏舵角度最大只有 6.5°, 操舵频率只有 0.2 Hz; 艉舵角度最大为-7.1°, 操舵频率为 0.8 Hz。与 PID 控制和 ADRC 控制相比, 其操舵幅度和频率最小, 但其控制效果最佳。

#### 4.2 复杂环境试验

按照上述试验方法开展半潜式机器人在复杂

环境下的航行试验。试验过程中试验水域浪高约 1.2 m, 风速为 8.0 m/s, 流速为 0.8 m/s。

半潜式机器人在复杂环境下以 3 种控制策略完成航行试验的航行效果如图 7-9 所示。

对复杂环境下的试验数据进行分析, 分析结果见表 2。

从复杂环境下的试验数据分析, PID 控制时半潜式机器人的艉舵角度到达了-16.5°, 操舵频率为 2.2 Hz; ADRC 控制时艉舵角度到达了-17.7°, 操舵频率为 3.28 Hz; LSTM 循环神经网络控制时艉舵角度最大为-13.8°, 操舵频率为 1.35 Hz。

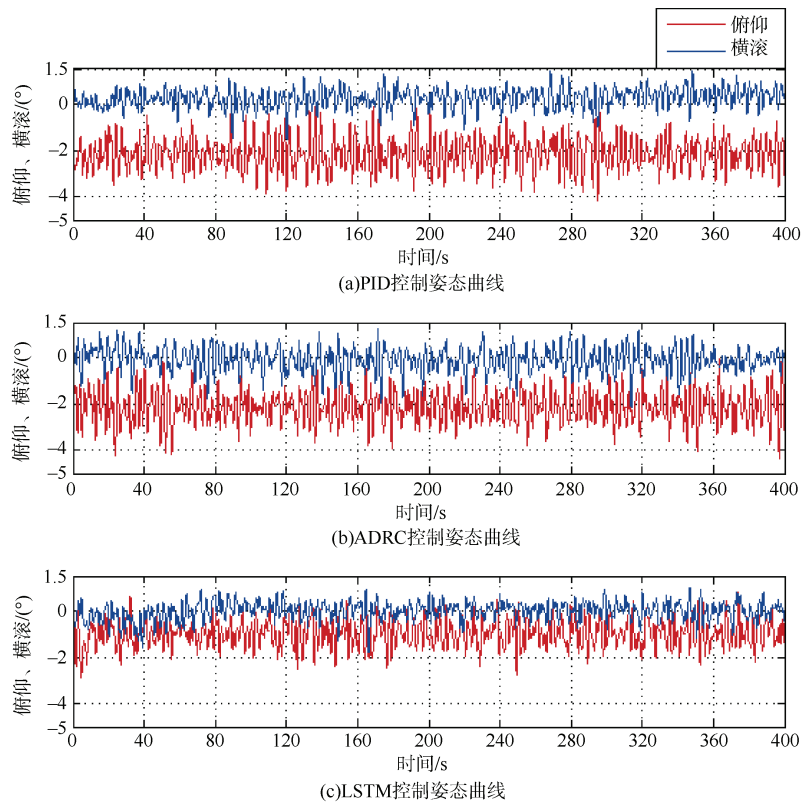


图 7 试验姿态曲线图  
Fig. 7 Attitude curves of tests

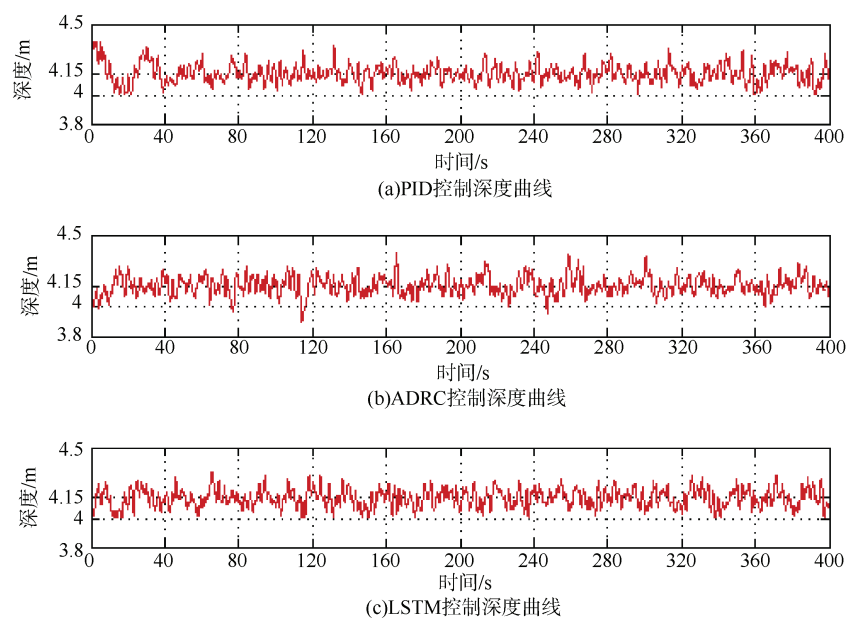


图8 试验深度曲线图  
Fig. 8 Depth curves of tests

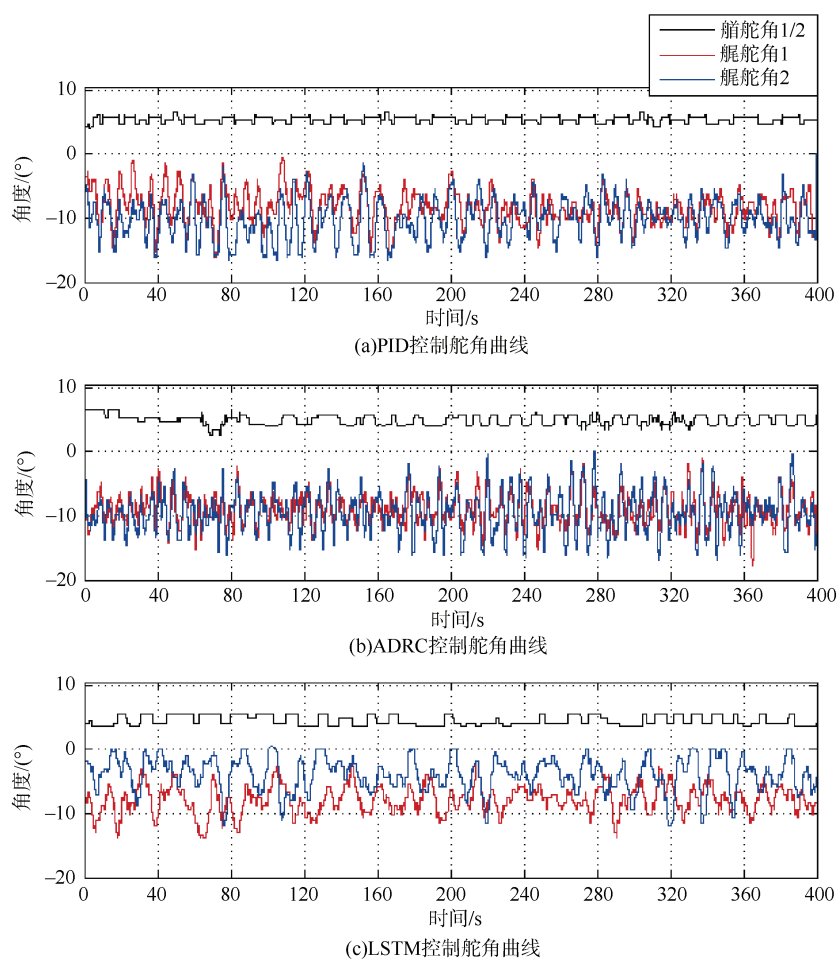


图9 试验舵角曲线图  
Fig. 9 Rudder angle curves of tests



表 2 试验数据分析表  
Table 2 Test data analysis

控制策略	俯仰/(°)	深度/m	艏舵 1 和艏舵 2		艉舵		
			舵角/(°)	操舵频率/Hz	舵角 1/(°)	舵角 2/(°)	操舵频率/Hz
PID 控制	-4.1~-0.5	4.0~4.4	6.6~3.8	0.34	-16.1~0	-16.5~0	2.2
ADRC 控制	-4.5~0.4	3.9~4.5	6.6~2.5	0.6	-17.7~-0.9	-17~0	3.28
LSTM 循环神经网络控制	-2.5~0.5	4.0~4.3	5.5~3.7	0.28	-13.8~-1.5	-12~0.5	1.35

无论是从航行稳定还是从航行安全角度来说，LSTM 循环神经网络控制效果均优于 PID 控制和 ADRC 控制，不仅姿态和深度波动较小、更平稳，而且操舵频率和操舵幅度也较小；PID 控制响应更快，对突然地变化响应更及时，其控制效果略逊于 LSTM 循环神经网络控制；ADRC 控制效果最不理想，主要由于 ADRC 控制存在滤波特性，导致控制滞后造成操舵幅度增大，姿态震荡幅度较大。

与静水试验相比，复杂环境下半潜式机器人的俯仰和深度都有较大幅度的波动，由于风、浪、流等因素的影响使得半潜式机器人的垂直面运动控制变得困难，只能通过增大操舵幅度和提高操舵频率来保持半潜式机器人的航行稳定。

5 结束语

本文提出了一种基于 LSTM 循环神经网络的半潜式机器人垂直面控制策略，该策略构建了 LSTM 循环神经网络模型，利用优秀试验数据集对该模型进行学习训练，使得该模型能融合数据集中蕴含的优良控制特性。相比于 PID 控制策略和 ADRC 控制策略，该控制策略能有效地降低操舵频率和减少操舵幅度。

该控制策略虽然有明显的优点，但也存在不足。本文中 LSTM 循环神经网络模型的训练过程是离线且基于有限数据集，若试验过程中外部环境与获取训练集数据时环境相差较大，离线学习训练的模型可能无法很好的适应当前的外部环境，控制效果会大幅下降，因此后续需优化模型算力，力争模型在线学习训练，提升该 LSTM 循环神经网络控制策略应对未知环境的能力。

参考文献

[1] 龚喜, 于亦凡, 刘诗玉. 基于 PID 控制的半潜式航行器缩比模型耐波性分析[J]. 水雷战与舰船防护,

2017, 25(4): 20-24.

[2] 周焕银, 刘亚平, 胡志强, 等. 基于辨识模型集的无人半潜水下机器人系统深度动态滑模控制切换策略研究[J]. 兵工学报, 2017, 38(11): 2198-2206

[3] 张荣浩. 基于模型预测控制的 AUV 运动控制方法研究[J]. 哈尔滨: 哈尔滨工程大学, 2024.

[4] 施生达, 王京齐, 吕帮俊, 等. 潜艇操纵性[M]. 北京: 国防工业出版社, 2021.

[5] 施小成, 陈江, 严浙平. 基于自抗扰方法的 UUV 近水面垂直面运动控制[J]. 鱼雷技术, 2011, 19(3): 209-213.

[6] 陶泽. 基于自抗干扰控制器的水下机器人姿态控制研究[D]. 大庆: 东北石油大学, 2024.

[7] 胡坤, 刘常波. 基于 PSO 优化的潜艇近水面 ADRC 深度控制研究[C]// 第 30 届中国控制会议. 北京: 中国自动化学会控制理论专业委员会, 2011.

[8] 韩京清. 自抗扰控制技术——估计补偿不确定因素的控制技术[M]. 北京: 国防工业出版社, 2008.

[9] 阿斯克·普拉特. 深度强化学习[M]. 北京: 清华大学出版社, 2024.

[10] 王俊, 曹俊兴, 刘哲哥, 等. 基于长短期记忆网络的钻前测井曲线预测方法[J]. 成都理工大学学报: 自然科学版, 2024, 27(2): 229-230.

[11] 杨韬燃. 基于长短期记忆模型循环神经网络的风力发电机故障诊断[D]. 北京: 华北电力大学, 2021.

[12] 薛丰昌, 杨猛, 陈剑飞, 等. 城市内涝监测点积水深度 LSTM 预测模型[J]. 测绘科学, 2025, 50(3): 161-163.

[13] 董雪情, 荆澜涛, 田瑞. 基于 LSTM 模型的变压器顶层油温预测方法[J]. 电力学报, 2023, 38(1): 40-41.

[14] 孜来布·阿布来提. 基于 LSTM 深度学习模型的融雪性洪水径流预测方法[J]. 陕西水利, 2025(2): 59-60.

[15] 张云涵, 邓涛, 龚琦皓. 基于 LSTM-EKF 的无人机航迹追踪算法[J]. 导航定位学报, 2024, 12(6): 63-65.

[16] 张燕鲁. 基于 LSTM 神经网络的仿生机械鱼运动控制研究[D]. 山东: 山东建筑大学, 2020.

[17] 苍宏宇, 谭宗颖. 国内外信息检索研究热点分析: 基于 ZScore 标准化的词频[J]. 图书馆建设, 2009(1): 93-98.

[18] 陈兆雄. 基于长短期记忆网络的心律失常预测研究[D]. 南京: 南京邮电大学, 2022.

(责任编辑: 曹晓霖)