

8-15-2024

A Method Based on Deep Learning for Assisting SINS/DVL Integrated Navigation

Xinghong Kuang

College of Engineering Science and Technology, Shanghai Ocean University, Shanghai 201306, China

Aowei Huang

College of Engineering Science and Technology, Shanghai Ocean University, Shanghai 201306, China

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Special Column: Digital Twin and Intelligent Simulation of Marine and Maritime is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

A Method Based on Deep Learning for Assisting SINS/DVL Integrated Navigation

Abstract

Abstract: The navigation and positioning accuracy of an Autonomous Underwater Vehicle (AUV) affects the efficiency of the AUV to a certain extent, and since GNSS cannot be used underwater, the integrated navigation system of Strapdown Inertial Navigation System/ Doppler Velocity Log (SINS/DVL) has been widely favored. However, DVL will fail in some cases, and if DVL is isolated directly, the system will become a pure inertial navigation system, which seriously affects the accuracy of navigation and positioning. In order to cope with the situation that DVL is missing in some beams, a DLinear-Informer assisted integrated navigation algorithm is proposed. Through DLinear's unique decomposition of the original input data, the algorithm enhances the extraction and learning of the nonlinear information of AUV and improves the velocity prediction accuracy. The experimental results show that the proposed algorithm can accurately predict the velocity of the lost beam during the DVL failure, reduce the position error of the integrated navigation, and improve the robustness and positioning accuracy of the system.

Keywords

autonomous underwater vehicle(AUV), strapdown inertial navigation system/doppler velocity logger, integrated navigation, missing beams, DLinear-informer

Recommended Citation

Kuang Xinghong, Huang Aowei. A Method Based on Deep Learning for Assisting SINS/DVL Integrated Navigation[J]. Journal of System Simulation, 2024, 36(8): 1810-1822.

一种基于深度学习辅助的SINS/DVL组合导航方法

匡兴红, 黄傲威

(上海海洋大学 工程学院, 上海 201306)

摘要: 水下机器人(autonomous underwater vehicle, AUV)导航定位精度一定程度上影响了AUV的工作效率, 由于GNSS无法在水下使用, 以捷联惯导系统/多普勒计程仪(SINS/DVL)的组合导航系统受到众多青睐。DVL在部分情况下会失效, 若直接将DVL隔离, 系统将变为纯惯性导航系统, 严重影响导航定位的精度。为了应对DVL在部分波束缺失的情况, 提出了一种DLinear-informer辅助组合导航算法。通过DLinear对原始输入数据特有的分解方式, 增强了算法对AUV非线性信息的提取与学习, 提高了速度预测精度。实验结果表明: 所提算法能够准确预测DVL失效期间丢失波束的速度, 降低组合导航的位置误差, 提高了系统的鲁棒性和定位精度。

关键词: 水下机器人; 捷联惯导系统/多普勒计程仪; 组合导航; 波束缺失; DLinear-informer

中图分类号: TP391.9;U666.1 文献标志码: A 文章编号: 1004-731X(2024)08-1810-13

DOI: 10.16182/j.issn1004731x.joss.24-0273

引用格式: 匡兴红, 黄傲威. 一种基于深度学习辅助的SINS/DVL组合导航方法[J]. 系统仿真学报, 2024, 36(8): 1810-1822.

Reference format: Kuang Xinghong, Huang Aowei. A Method Based on Deep Learning for Assisting SINS/DVL Integrated Navigation[J]. Journal of System Simulation, 2024, 36(8): 1810-1822.

A Method Based on Deep Learning for Assisting SINS/DVL Integrated Navigation

Kuang Xinghong, Huang Aowei

(College of Engineering Science and Technology, Shanghai Ocean University, Shanghai 201306, China)

Abstract: The navigation and positioning accuracy of an Autonomous Underwater Vehicle (AUV) affects the efficiency of the AUV to a certain extent, and since GNSS cannot be used underwater, the integrated navigation system of Strapdown Inertial Navigation System/ Doppler Velocity Log (SINS/DVL) has been widely favored. However, DVL will fail in some cases, and if DVL is isolated directly, the system will become a pure inertial navigation system, which seriously affects the accuracy of navigation and positioning. In order to cope with the situation that DVL is missing in some beams, a DLinear-Informer assisted integrated navigation algorithm is proposed. Through DLinear's unique decomposition of the original input data, the algorithm enhances the extraction and learning of the nonlinear information of AUV and improves the velocity prediction accuracy. The experimental results show that the proposed algorithm can accurately predict the velocity of the lost beam during the DVL failure, reduce the position error of the integrated navigation, and improve the robustness and positioning accuracy of the system.

Keywords: autonomous underwater vehicle(AUV); strapdown inertial navigation system/doppler velocity logger; integrated navigation; missing beams; DLinear-informer

0 引言

水下机器人(autonomous underwater vehicle, AUV)作为人类探索海洋的重要载体,在海洋搜救、海洋未知领域探索、环境探测等领域具有重要作用。获取精确的位置信息是水下机器人有效执行任务的前提^[1]。捷联惯导系统(strapdown inertial navigation system, SINS)具有自主性、隐蔽性、高频率等优点,被广泛应用于水下导航^[2-3]。然而,单个传感器无法应对AUV面临的复杂环境。因此,一般采用其他导航定位系统辅助SINS组合使用。在辅助传感器的选择中,多普勒计程仪(doppler velocity log, DVL)利用多普勒效应进行速度测量,通过对底跟踪模式提供AUV相对于海底的高精度速度信息,能够有效抑制SINS的位置误差累积问题^[4-5]。因此,SINS/DVL组合导航系统被广泛应用于各水下航行器上^[6]。

对于SINS/DVL组合导航系统,AUV在遇到地形变化、鱼群、大角度的俯仰或急速转弯等情况时,DVL不能接受反射的部分波束或者全部波束,会导致DVL输出的速度值异常甚至输出中断^[7]。针对DVL故障,一种是通过增加传感器数量,实现硬件冗余^[8];另一种是通过数学模型计算“伪测量值”替代失效传感器的测量信息。通过增加多余传感器的方法虽然可以处理短时故障和中断,但增加了成本,更多传感器的融合也增加了系统的复杂度。因此,采用数学模型的方法更受青睐。

针对数学模型的方法,国内外文献研究了动力学模型、支持向量机、深度学习网络构造伪DVL代替故障DVL的输出速度^[9]。文献[10]利用牛顿-欧拉方程得到AUV的三维平动动力学模型,对动力学模型进行积分得到航行器参考系坐标下的速度,有效校正了SINS的输出,但导航性能略有下降。文献[11]对SVM进行了改进,同时采用滑动窗口方检测算法,可以应对DVL短时失效问题并且避免野值导致的滤波精度下降问题,但对于AUV运动状态改变时,模型预测精度将会降低。对于波

束缺失的情况,文献[12]提出了一种数据驱动的多输出最小二乘支持向量回归机(MLS-SVR)虚拟波束预测器,在DVL波束有限的情况下提高了AUV定位精度,但模型参数选择复杂,不准确的参数会影响模型的泛化能力。文献[13]将长短期记忆网络(LSTM)和SVR用于辅助自适应滤波算法,有效降低了组合导航过程中出现的野值干扰问题,提高了系统的精度和对输出故障的处理能力,但未有效利用DVL过去的速度信息。文献[14]针对DVL完全失效的情况,提出了一种ST-BeamsNet(Set-transformer-based)网络,利用IMU数据和先前的DVL速度测量值回归当前的AUV速度,防止了导航解的漂移,但未对模型预测后的组合导航定位结果进行分析。上述方法在模型输入选择时都未单独提取AUV模型的非线性、强耦合性信息。由于水下未知、复杂的环境,AUV是一个多自由度的非线性系统。因此,有必要在模型输入选择时提取系统的非线性信息。

针对上述问题,本文提出了一种基于DLinear-Informer的虚拟波束预测器,并嵌套在SINS/DVL组合系统。DLinear-Informer模型在输入选择时,充分考虑了AUV过去的状态信息,通过DLinear提取原始输入数据的残差序列,分离了输入数据的非线性信息,便于Informer模型的学习,通过Informer网络高效快速地输出预测结果。陆地车载数据实验表明,回归缺失波束的速度信息对提升组合导航定位准确性至关重要,相比深度学习网络,DLinear-Informer可以有效解决DVL在测量过程中出现的波束缺失、野值干扰等问题,并且在AUV运动状态发生改变时,依然有较强的预测能力,在预测波束与可用波束的作用下,显著提高了组合导航定位系统的鲁棒性和精度。

1 SINS/DVL组合导航系统模型

由于SINS中所有的参数均在特定的框架下,不同框架之间的参数频繁相互交换^[13]。本文常见的坐标系定义如下:选用“东-北-天”坐标系作

为导航坐标系，即 n 系；“右-前-上”坐标系作为 AUV 载体坐标系，即 b 系；DVL 自身测量坐标系为 d 系。 b 系到 n 系的方向余弦矩阵为 ${}^n_b C$ ； d 系到 b 系的方向余弦矩阵为 ${}^b_d C$ 。

1.1 DVL 速度计算

DVL 通常具有 4 个换能器，大多数的四束波换能器具有相同的俯仰角，称为詹纳斯(Janus)结构，根据波束指向的不同，可以分为“+”配置和“×”配置。以“×”配置为例，如图1所示。




图1 “×”配置
Fig. 1 “×” configuration

定义 DVL 四束波 Beam1-4 的速度矢量为 $\mathbf{v}^D = [V_1^D \ V_2^D \ V_3^D \ V_4^D]^T$ ，DVL 在 d 系下的三维速度矢量为 ${}^d \mathbf{v} = [{}^d v_x \ {}^d v_y \ {}^d v_z]^T$ ，从 ${}^d \mathbf{v}$ 到 \mathbf{v}^D 的方向向量可由文献[14]得到

$$\mathbf{b}_j = \begin{bmatrix} \sin \varphi_j \cos \alpha \\ \cos \varphi_j \cos \alpha \\ -\sin \alpha \end{bmatrix} \quad (1)$$

式中： $j=1, 2, 3, 4$ 为 DVL 四束波的编号； α 为 DVL 波束的发射倾角，通常为 70° 。

$$\varphi_j = (j-1)90^\circ + \varphi, \quad j=1, 2, 3, 4 \quad (2)$$

在“×”配置中， $\varphi = 45^\circ$ 。

定义 ${}^d \mathbf{v}$ 到 \mathbf{v}^D 的方向矩阵为 \mathbf{M} ，则

$$\mathbf{M} = [b_1 \ b_2 \ b_3 \ b_4]^T \quad (3)$$

因而 \mathbf{v}^D 可以表示为

$$\mathbf{v}^D = \mathbf{M} {}^d \mathbf{v} = \mathbf{M} {}^d_b C {}^b_d C {}^b \mathbf{v} \quad (4)$$

当 DVL 能够接收的波束不少于 3 束波时，

DVL 在 d 系下的速度可由文献[15]得到

$${}^d \mathbf{v} = (\mathbf{M}^T \mathbf{M})^{-1} \mathbf{M}^T \mathbf{v}^D \quad (5)$$

在实际情况下，DVL 不可避免地存在安装误差、刻度因数误差，对 DVL 误差参数进行标定，DVL 在 b 系下的速度可表示为

$${}^b \tilde{\mathbf{v}} = (1 + \delta k)(\mathbf{I} - \mathbf{e} \times)_d^b C {}^d \mathbf{v} \quad (6)$$

式中： δk 为刻度因数误差；“~”为变量含有误差； $\mathbf{e} = [e_x \ e_y \ e_z]^T$ 为 DVL 和 AUV 之间的安装误差角； \times 为矢量的反对称矩阵。

1.2 SINS/DVL 系统模型

在传统的扩展卡尔曼滤波器中，组合导航的系统状态空间模型通常由 SINS 的误差参数组成。选取 15 维状态空间变量。状态变量为

$$\mathbf{X} = [\phi_x \ \phi_y \ \phi_z \ \delta^n V_E \ \delta^n V_N \ \delta^n V_U \ \delta \lambda \ \delta L \ \delta h \ \varepsilon_x^b \ \varepsilon_y^b \ \varepsilon_z^b \ \nabla_x^b \ \nabla_y^b \ \nabla_z^b]^T \quad (7)$$

式中： ϕ_x 、 ϕ_y 、 ϕ_z 为姿态失准角； $\delta^n V_E$ 、 $\delta^n V_N$ 、 $\delta^n V_U$ 为东向、北向、天向的速度误差； $\delta \lambda$ 、 δL 、 δh 为经度、纬度和高度误差； ε_x^b 、 ε_y^b 、 ε_z^b 和 ∇_x^b 、 ∇_y^b 、 ∇_z^b 分别为陀螺仪和加速计在载体坐标系下的零偏。

系统的状态空间模型和量测方程可以表示为

$$\begin{cases} \dot{\mathbf{X}} = \mathbf{F}\mathbf{X} + \mathbf{G}^b \mathbf{W} \\ \mathbf{Z} = \mathbf{H}\mathbf{X} + \mathbf{V} \end{cases} \quad (8)$$

式中： $\dot{\mathbf{X}}$ 为 \mathbf{X} 的倒数； \mathbf{F} 为 SINS 误差参数的状态转移矩阵； \mathbf{G} 为系统的噪声驱动矩阵； \mathbf{W} 为陀螺仪和加速计的状态噪声； \mathbf{Z} 为系统观测量； \mathbf{H} 为量测矩阵； \mathbf{V} 为量测噪声。

DVL 在 n 系下的速度为

$${}^n \tilde{\mathbf{v}}_{\text{DVL}} = {}^n_b \tilde{C} {}^b \tilde{\mathbf{v}} = (\mathbf{I} - \boldsymbol{\phi})_b^n C (1 + \delta k)(\mathbf{I} - \mathbf{e} \times)_d^b C {}^d \mathbf{v} + {}^n \mathbf{w} \quad (9)$$

式中： $\boldsymbol{\phi} = [\phi_x \ \phi_y \ \phi_z]$ 为姿态失准角； ${}^n_b \tilde{C}$ 为包含姿态误差角的方向余弦矩阵； ${}^n \mathbf{w}$ 为高斯白噪声。

松组合下，SINS/DVL 组合导航的量测向量可以构造为

$$\mathbf{Z} = \begin{bmatrix} Z_{\text{DVL}} \\ Z_{\text{PS}} \end{bmatrix} \quad (10)$$

由式(9)可得 DVL 测量的速度和 SINS 解算的速度在导航系 n 系下的速度之差为

$$\begin{aligned}
 Z_{DVL} &= {}^n\tilde{V}_{SINS} - {}^n\tilde{V}_{DVL} = \\
 &({}^nV + \delta^n V_{SINS}) - ({}^nV + \delta^n V_{DVL}) = \\
 &({}^nV + \delta^n V_{SINS}) - (I - \phi \times)_b^n C(1 + \delta k) \\
 &(I - e \times)_d^b C^d v - {}^n w \approx ({}^nV + \delta^n V_{SINS}) - {}^nV - \\
 &{}^nV \times \phi - ({}^nV_{DVL} \times)_b^n C e - \delta k^n V - {}^n w \approx \\
 &-{}^nV \times \phi - ({}^nV_{DVL} \times)_b^n C e - \delta k^n V + \delta^n V_{SINS} - {}^n w
 \end{aligned}
 \tag{11}$$

式(11)在推导展开过程中, 忽略了二阶小量。DVL 在导航过程中需要先进行预对准, 因此式(11)中的误差参数可以被忽略。

一般情况下, 压力传感器 (pressure sensor, PS) 被集成在 DVL 设备中, 为 AUV 提供深度信息。PS 的配备为 AUV 提供了深度观测量, 因此, PS 的观测方程为

$$Z_{PS} = H_{SINS} - H_{PS} - w_{PS} \tag{12}$$

式中: H_{PS} 为压力传感器的测量值; H_{SINS} 为捷联惯性系统的深度更新值; w_{PS} 为高斯白噪声。

由式(11), (12)可得系统量测矩阵 H 的具体形式为

$$H = \begin{bmatrix} -{}^n v \times & I_{3 \times 3} & 0_{3 \times 9} \\ 0_{1 \times 8} & 1 & 0_{1 \times 6} \end{bmatrix}
 \tag{13}$$

组合导航的具体原理图如图 2 所示。




图 2 组合导航系统的原理示意图

Fig. 2 Schematic diagram of principle of integrated navigation system

2 神经网络辅助组合导航系统模型

2.1 DLinear-Informer 模型

DLinear 是一种结构简单的长时间序列预测模

型, 是一个分解方案和一个线性网络的组合。在 DLinear 模型中, 原始输入数据被分解为一个趋势序列 X_t 和残差序列 $X_s = X - X_t$, 然后使用 2 个单层的线性网络层对 2 个序列直接多步预测。对水下机器人的运动而言, AUV 的运动模型具有强非线性, 同时易受水下环境的干扰。而 DLinear 对原始输入数据的分解方法, 很好地分离了 AUV 模型中的非线性信息, 便于下层网络对非线性部分的学习, 提高了学习效率和预测精度。DLinear 结构如图 3 所示。

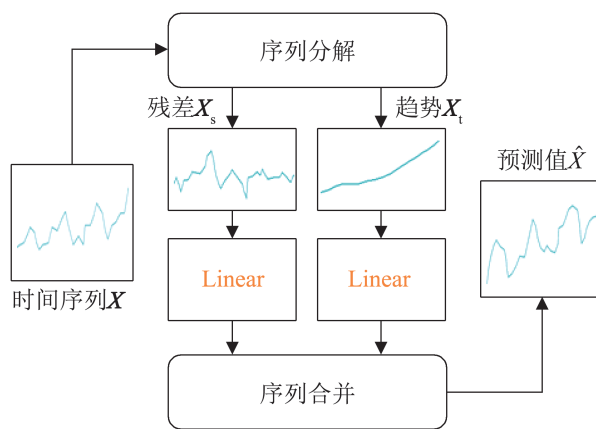


图 3 DLinear 结构

Fig. 3 Architecture of DLinear

传统注意力机制在计算关注度时会将所有信息考虑进去, 导致计算复杂度增加。针对长输入序列网络预测效果不佳的情况, Informer 使用多头概率稀疏自注意力机制对主要特征的优势特征赋予更高的权重, 在降低时间复杂度和空间复杂度的同时提取了更加关键的历史时刻信息。在处理 SINS/DVL 这类时间与非线性相结合的参数时, Informer 的一步解码结构, 提高了预测效率的同时降低了误差累积。Informer 的模型结构如图 4 所示。

(1) Informer 模型的编码器

在编码器层, Informer 使用多头概率稀疏自注意力代替传统的自注意力机制提取长序列输入的鲁棒长范围依赖, 使用自注意力蒸馏的方法减少了输入和网络维度。传统的自注意力机制使用

键-值-查询(key-value-query)的方式, 通过比较key和query之间的相关程度分配权重来赋予key相应的value值。由于稀疏注意力中, 少数query和key的点乘贡献了主要的注意力, 其他点乘产生的作用微不足道, 因而在Informer中key只关注 u 个主要的query, 即^[16]

$$A(Q, K, V) = \text{softmax}\left(\frac{\overline{Q}K^T}{\sqrt{d}}\right)V \quad (14)$$

式中: \overline{Q} 为只包含前 u 个query的查询向量; K 为键向量; V 为值向量; d 为输入特征维度。

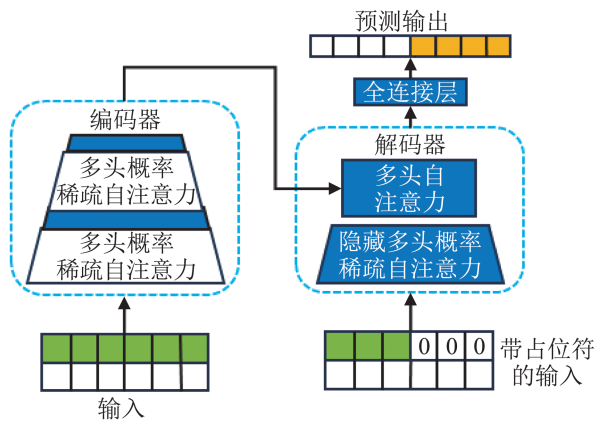


图4 Informer模型结构

Fig. 4 Informer model architecture

由于稀疏自注意力机制的存在, Informer编码器层的特征映射存在值 V 的冗余组合, 通过自注意力蒸馏的方法在下一层中对强势地位的高级特征进行特权化, 并生成聚焦的自注意力特征图, 其中从 i 到 $i+1$ 层的蒸馏操作过程为^[17]

$$X'_{i+1} = \text{Maxpool}(\text{ELU}(\text{Conv1d}([X'_i]_{AB}))) \quad (15)$$

式中: $[X'_i]_{AB}$ 包含了注意力模块的关键操作和稀疏自注意力; $\text{Conv1d}(\cdot)$ 为时间序列的一维卷积函数; $\text{ELU}(\cdot)$ 为指数线性单元的激活函数; $\text{Maxpool}(\cdot)$ 为卷积过程中的最大池化操作。自注意力蒸馏机制的使用使输入Informer模型中的序列长度减半, 减少了模型计算量和内存使用。

(2) Informer模型的生成式解码器

Informer的生成式解码器由2个完全相同的多头注意力层组成, 可以避免在长期预测中推理速

度下降的问题。解码器在 t 时刻的输入序列可表示为^[17]

$$X'_{\text{feed_de}} = \text{Concat}(X'_{\text{token}}, X'_0) \in \mathbf{R}^{(L_{\text{token}} + L_y) \times d_{\text{model}}} \quad (16)$$

式中: $X'_{\text{feed_de}}$ 为系统输入序列向量; X'_{token} 为输入历史序列; X'_0 为值为0的目标序列占位符; $\text{Concat}(\cdot)$ 为序列连结的函数。

2.2 DLinear-Informer辅助SINS/DVL组合导航系统

DLinear-Informer模型辅助组合导航基本原理是在DVL正常工作时保存各参数信息, 将SINS和DVL的输出信息作为训练样本存储起来。一旦DVL波束缺失, 则利用存储的样本训练虚拟波束预测器, 建立丢失波束与输入序列之间的映射模型。波束预测器的训练过程如图5所示, 如文献[13]所述, 为了提高模型预测的精确性和可靠性, 神经网络模型应该合理选择输入作为训练集。因此, 为了探索AUV速度与组合导航各参数之间的关系, 从DVL的波束速度方程入手, DVL波束可以由SINS的参数计算得到。

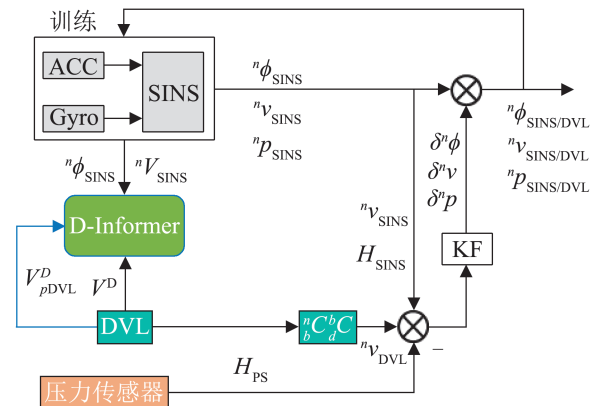


图5 波束预测器训练流程图

Fig. 5 Training flowchart of beam predictor

$$V_{\text{SINS}}^D = M_n^b \tilde{C}^n \tilde{v} \quad (17)$$

式中: V_{SINS}^D 是SINS在 d 系下的波束速度, 在DVL正常工作的情况下有 $V_{\text{SINS}}^D = V_{\text{DVL}}^D$, ${}_n^b \tilde{C}$ 包含姿态信息, 因而SINS输出的速度和姿态可以反映DVL波束速度信息。此外, Janus构型下的DVL, 各波

束之间存在明显的几何对称关系, 因此可用的波束包含一定丢失波束的信息。同时, DVL过去的波束信息也可反映AUV的运动信息。因此, 当部分DVL波束不可用时, DLinear-Informer模型可以根据SINS输出的姿态、速度, DVL过去的波束和当前可用波束计算丢失的波束。

$$V_{u,j}^D \in ({}^n\phi_{SINS,j}, {}^nV_{SINS,j}, V_{pDVL}^D, V_{a,j}^D) \quad (18)$$

式中: V_{pDVL}^D 为DVL过去测量的波束。此时, 回归的伪测量波束 $V_{u,j}^D$ 和可用波束 $V_{a,j}^D$ 被插入基于模型的最小二乘(LS)估计器中, 以估计AUV三维速度矢量辅助SINS导航。因此, 在DVL部分波束丢失的情况下, 基于DLinear-Informer-LS的模型都可以提供AUV的三维速度矢量, 提高SINS/DVL组合导航系统的定位精度和鲁棒性。波束预测器辅助SINS导航的预测流程图如图6所示。

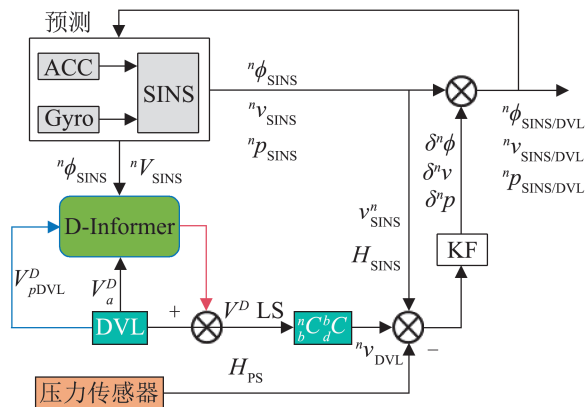


图6 波束预测器预测流程图
Fig. 6 Prediction flowchart of the beam predictor

综上所述, 本文所提出的方法可分为3个步骤进行。

步骤1: DVL输出三维速度矢量辅助SINS导航

当DVL的4个波束均正常时, 执行传统的SINS/DVL松组合导航, 并将DVL和SINS的输出值作为训练样本进行存储。

步骤2: DLinear-Informer模型训练

一旦发现波束缺失, 模型切换到训练模式, 将存储的数据分为输入驱动序列和目标序列来训练DLinear-Informer模型。

步骤3: 虚拟波束辅助SINS导航

在训练好模型之后, 模型切换到预测模式。通过训练好的DLinear-Informer, 利用可用的传感器信息预测虚拟波束值。然后将可用波束与虚拟波束插入LS中输出三维速度矢量, 辅助SINS导航。

3 实验和分析

AUV在做平面运动时, 其运动学模型和车载系统相似, 车载系统不仅包含了加速、减速、转弯、静止等AUV平面运动状态, 同时运动数据集包含了时间序列和空间位置信息, 两者具有很多共通之处。因此, 车载模型可以替代AUV在部分情况下的运动状态。为了评估本文所提模型的性能, 由于实验条件的限制, 因此参考文献[18]的方法, 采用车载测试的实验来模拟水下运动, 为了使车载数据更好逼近真实情况下DVL的速度信息, DVL的速度通过在imuFOG/GPS组合导航的速度中添加比例因子、偏差和零均值高斯白噪声来模拟, 其中比例因子为0.5%, 偏差为0.000 1 m/s, 零均值高斯白噪声为0.038 m/s。实验数据时长约3 h, 选取数据的前5 200 s作为本次实验的数据集, 惯性测量单元为imuFOG, 陀螺仪的零偏为0.1(°)/h, 加速计的零偏为100 μ g, IMU采样频率为100 Hz, GPS输出频率为5 Hz, 以imuFOG/GPS组合导航的结果作为实验参考基准。用于评估模型的指标: ①均方根误差(RMSE); ②平均绝对误差(MAE); ③标准差(STD); ④决定系数(R^2); ⑤方差占比(VAF)。 R^2 和VAF无单位, 定义如下^[19]:

$$RMSE(y_i, \hat{y}_i) = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (19)$$

$$MAE(y_i, \hat{y}_i) = \frac{\sum_{i=1}^N |y_i - \hat{y}_i|}{N} \quad (20)$$

$$STD(y_i, \hat{y}_i) = \sqrt{\frac{\sum_{i=1}^N (y_i - \bar{y}_i)^2}{N}} \quad (21)$$

$$R^2(y_i, \hat{y}_i) = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (22)$$

$$VAF(y_i, \hat{y}_i) = \left[1 - \frac{\text{var}(y_i - \hat{y}_i)}{\text{var}(y_i)} \right] \times 100 \quad (23)$$

式中： N 为样本数； y_i 为矢量真值； \hat{y}_i 为模型预测的矢量； \bar{y}_i 为矢量真值的均值； $\text{var}(\cdot)$ 为方差。实验的轨迹图如图7所示。



图7 ImuFOG/GPS组合导航轨迹

Fig. 7 ImuFOG/GPS integrated navigation trajectory

选择“×”配置作为DVL的结构，DVL四束波束速度如图8所示。为了验证本文方法在DVL部分波束缺失情况下的有效性，假设DVL故障时间段为3 200~4 320 s，包含直行、转弯等运动状态共1 120 s作为测试集；其余时间段DVL四束波束正常可用，作为训练集。




图8 DVL波束速度

Fig. 8 DVL beam velocity

为了体现本文模型的优势，设计了另外3种模型进行比较，分别是MLP模型、CNN模型、LSTM模型。DLinear-Informer模型的超参数影响着模型的训练效果，参考文献[16-17]对超参数设置，本文模型的超参数设置如表1所示。为了确定要使用的过去波束测量次数，对比了不同波束测量值，图9给出了预测的波束速度RMSE随过去波束测量次数的变化。可以看出，在sequence_length=16时，RMSE最小，因此，本文的输入序列长度为16。波束预测的详细内容将在下面的实验中展现。

表1 DLinear-Informer模型的参数和值

Table 1 Parameters and values of the DLinear-Informer model

参数	值
Learning rate	0.000 1
Epoces	50
Batch size	32
Num_heads	8
Encoder_layers	2
Decoder_layers	1
Dropout	0.001
Hidden_layers	512




图9 DVL波束预测值的RMSE随过去DVL的波束测量次数的变化

Fig. 9 Variation of RMSE of DVL beam predictions with the number of beam measurements of past DVL

DVL在部分波束失效情况下选择以下3种情况：

(1) 1个波束缺失: Beam4

当1个束波缺失时,如图10所示,基于CNN、LSTM和DLinear-Informer的模型都能在DVL故障期间准确跟踪丢失的Beam4信息。对于MLP、CNN、LSTM和DLinear-Informer模型,虚拟波束4的速度均方根误差(RMSE)分别为0.0821、0.0384、0.0294、0.0169 m/s,速度均方根误差都在cm/s级别。图11给出了4种模型在单束波缺失情况下的虚拟预测波束误差统计结果,其中柱高表示波束速度平均绝对误差(MAE),误差线长度为波束速度误差标准差(STD)。

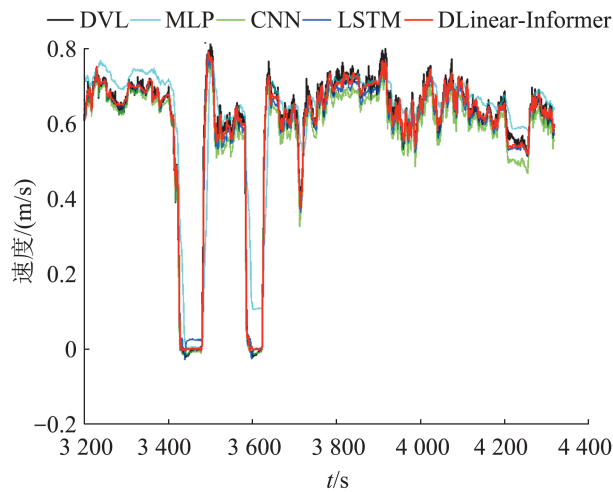


图10 4种模型的波束4输出

Fig. 10 Beam4 outputs of DVL, MLP, CNN, LSTM, and DLinear-Informer models

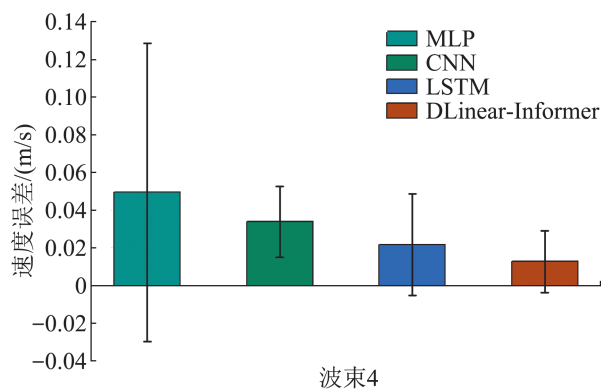


图11 不同或4种模型在一束波缺失情况下的MAE和STD

Fig. 11 MAE and STD of MLP, CNN, LSTM, and DLinear-Informer models in the case of a missing beam

图10~11和表2可以看出,DLinear-Informer模型相对MLP、CNN和LSTM模型在Beam4的平均绝对速度误差上分别降低了74.49%,62.61%和57.14%。此外,相对于速度误差标准差,与MLP模型相比,降低了79.42%。与CNN模型相比,降低了13.3%。与LSTM模型相比,降低了39.41%。因此,DLinear-Informer模型对缺失波束的预测精度更高。

表2 波束4缺失时4种模型的MAE和STD具体值
Table 2 Specific values of MAE and STD for four models in the absence of a beam m/s

模型	MAE	STD
MLP	0.049 4	0.079 2
CNN	0.033 7	0.018 8
LSTM	0.029 4	0.026 9
DLinear-Informer	0.012 6	0.016 3

仅参考深度学习网络对缺失波束的拟合效果不能够说明组合导航结果的优劣,采用组合导航的位置误差进行评估。图12比较了4种方法以及仅使用可用的3个束波在3200~4320s期间进行松组合导航的绝对位置误差。在组合导航结束时,MLP模型、CNN模型、LSTM模型、DLinear-Informer模型以及3束波的导航绝对位置误差分别为59.2825、53.3936、37.2635、26.0528、802.6746 m,导航绝对位置误差的RMSE分别为28.133、19.0271、13.0159、6.908、417.948 m。从图12及上述数据可以得出在虚拟波束补偿的情况下,4种深度学习模型的位置误差相对仅使用三束波进行组合导航,位置误差显著降低。由此可见,尽管可用的3个波束中包含了三维速度的全部信息,回归第4个波束对提高组合导航定位精度至关重要。DLinear-Informer模型辅助组合导航的绝对位置误差相对以上3种模型分别降低了75.44%、63.69%、46.93%,相对于仅使用可用的三束波进行组合导航降低了98.35%。因此,在1个波束缺失的情况下,DLinear-Informer模型辅助的组合导航系统定位精度优于其他方法。

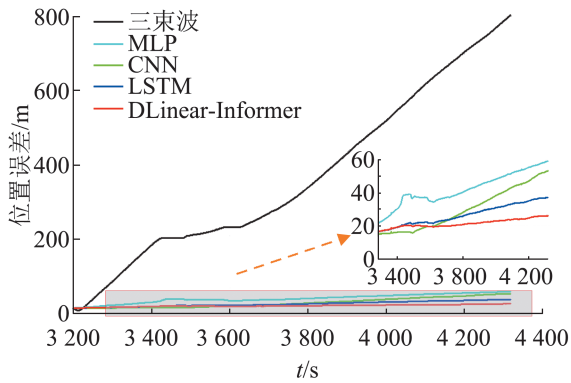


图 12 一束波缺失绝对位置误差
Fig. 12 Absolute position error of a missing beam

(2) 2 个波束缺失: Beam3~4

当 DVL 的 2 个波束缺失时, 可用的波束信息已经无法估计 AUV 的三维速度矢量。与 1 个波束丢失的步骤一样, 图 13 给出了 4 种模型预测的虚拟波束速度。由于 DLinear-Informer 模型对输入特有的分解方式, 使得对非线性部分具有强逼近能力, 在两束波丢失时, 相对 MLP、CNN、LSTM 模型依然能够准确预测丢失波束的速度。对于 MLP、CNN、LSTM、DLinear-Informer 模型, Beam3 的 RMSE 分别为 0.180 9、0.080 3、0.058 3、0.037 6 m/s; Beam4 的 RMSE 分别为 0.073 4、0.063 4、0.032 4、0.020 1 m/s。因此, 相比其他模型, DLinear-Informer 模型预测的虚拟波束最契合真值。图 14 对比了 4 种模型在两束波丢失情况下对虚拟预测波束 3 和 4 的误差统计结果, 其中柱高表示波束速度 MAE, 误差线长度为波束速度误差 STD。

从表 3 和图 13~14 可以得出, 相比 CNN、MLP、LSTM 模型, 基于 DLinear-Informer 模型预测的波束 3 速度 MAE 分别降低了 80.72%、59.96%、25.69%, 速度误差 STD 分别降低了 73.87%、40.75%、32.57%; 波束 4 的速度 MAE 分别降低了 72.13%、70.87%、30.18%, 速度误差 STD 分别降低了 69.24%、56.19%、41.59%。因此, 在两束波缺失时, 基于 DLinear-Informer 模型的波束预测器整体效果最佳。

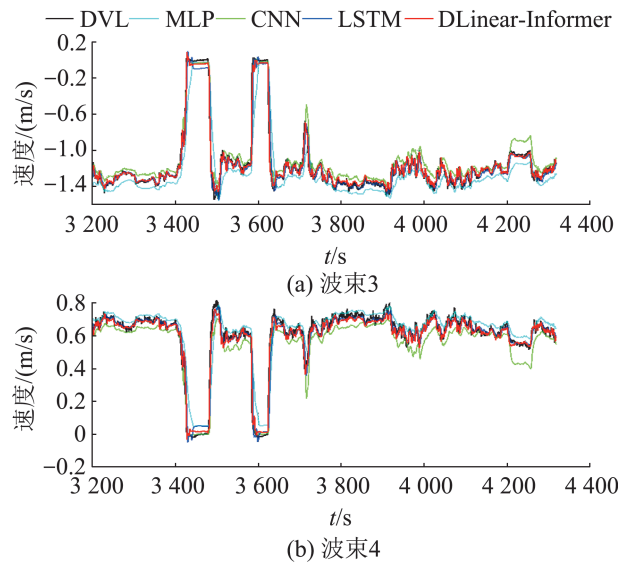


图 13 4 种模型的波束 3 和 4 输出
Fig. 13 Beam3 and Beam4 output of DVL, MLP, CNN, LSTM, and DLinear-Informer models

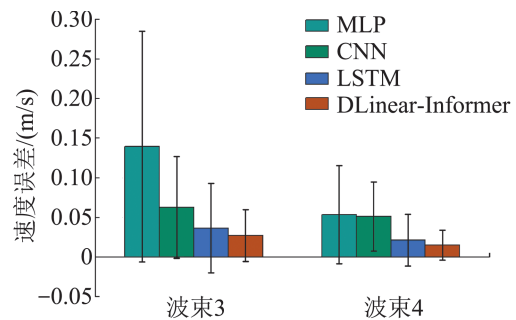


图 14 4 种模型在两束波缺失情况下的 MAE 和 STD
Fig. 14 MAE and STD of MLP, CNN, LSTM, and DLinear-Informer models in the case of two missing beams

表 3 两束波缺失时 4 种模型的 MAE 和 STD
Table 3 MAE and STD for four models in absence of two beams

模型	MAE		STD	
	Beam3	Beam4	Beam3	Beam4
MLP	0.139 5	0.053 1	0.145 8	0.062 1
CNN	0.062 5	0.050 8	0.064 3	0.043 6
LSTM	0.036 2	0.021 2	0.056 5	0.032 7
DLinear-Informer	0.026 9	0.014 8	0.038 1	0.019 1

图 15 对比了两束波缺失情况下, 4 种模型辅助 SINS/DVL 组合导航的绝对位置误差。在深度学习模型辅助组合导航结束时, MLP、CNN、LSTM、DLinear-Informer 模型的绝对位置误差分别为 170.786 5、85.908 5、45.902 8、18.488 m。在

DVL故障期间, MLP模型的RMSE为86.2786 m, CNN模型的RMSE为32.9874 m, LSTM模型的RMSE为18.7818 m, DLinear-Informer模型的RMSE为4.7967 m。相比MLP模型, 绝对位置误差RMSE降低了94.44%; 相比CNN模型, 降低了85.455%; 相比LSTM模型, 降低了74.46%。因此, 在两束波缺失时, DLinear-Informer模型辅助组合导航的定位效果更佳。

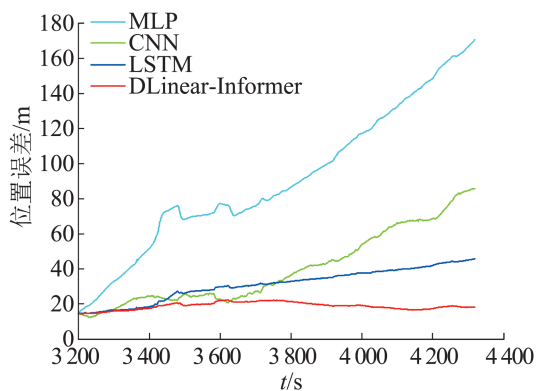


图15 两束波缺失绝对位置误差

Fig. 15 Absolute position error of two missing beams

(3) 3个波缺失: Beam2~4

当3个波束缺失时, 图16对比了4种模型对缺失波束2~4速度的预测, 图17给出了4种模型预测的速度误差。对于MLP模型, 波束2~4的RMSE分别为0.1813、0.1690、0.0761 m/s; 对于CNN模型, 波束2~4的RMSE分别为0.1181、0.1105、0.0701 m/s; 对于LSTM模型, 波束2~4的RMSE分别为0.0838、0.0802、0.0376 m/s; 对于DLinear-Informer模型, 波束2~4的RMSE分别为0.0395、0.0413、0.0199 m/s。正如预期的那样, 1个波束可用时各模型的速度误差大于2个波束可用和3个波束可用。相比MLP、CNN、LSTM模型, DLinear-Informer模型在三束波缺失时依然具有很强的预测能力。

从图16~17以及表4可以得出, 相比MLP、CNN、LSTM模型, 基于DLinear-Informer模型的波束预测器在三束波缺失时, 虚拟波束的速度MAE和速度误差STD依然处于cm/s级别。相对

MLP模型, 波束2~4的速度MAE和速度误差STD分别降低了81.27%、79.63%、77.65%, 71.06%、65.08%、62.99%; 与CNN模型相比, 波束2~4的速度MAE和速度误差STD分别降低了69.57%、63.87%、73.39%, 58.84%、55.61%、68.82%; 与LSTM模型相比, 波束2~4的速度MAE和速度误差STD分别降低了45.93%、41.85%、38.03%, 54.1%、48.43%、50.26%。因此, DLinear-Informer模型在三束波缺失时预测效果最佳。




图16 4种模型的波束2~4输出

Fig. 16 Beam2~4 output of DVL, MLP, CNN, LSTM, and DLinear-Informer models

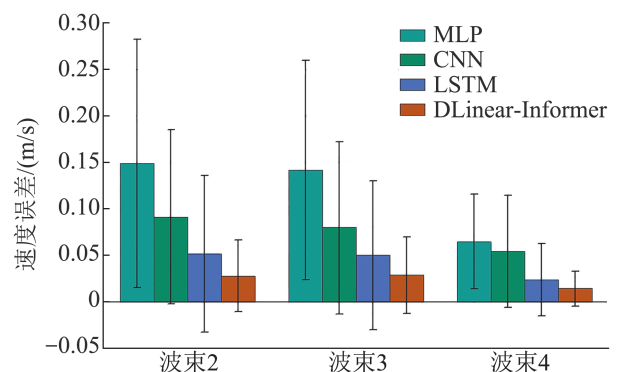
图17 4种模型在三束波缺失情况下的MAE和STD
Fig. 17 MAE and STD of MLP, CNN, LSTM, and DLinear-Informer models in the case of three missing beams

表 4 三束波缺失时 4 种模型的 MAE 和 STD
Table 4 MAE and STD for 4 models in absence of three beams

模型	MAE			STD		
	Beam2	Beam3	Beam4	Beam2	Beam3	Beam4
MLP	0.149 0	0.141 9	0.064 9	0.133 4	0.117 7	0.050 8
CNN	0.091 7	0.080 0	0.054 5	0.093 8	0.092 6	0.060 3
LSTM	0.051 7	0.050 2	0.024 0	0.088 4	0.079 7	0.038 9
DLinear-Informer	0.027 9	0.028 9	0.014 5	0.038 6	0.041 1	0.018 8

图 18 显示了三束波缺失时 4 种模型辅助 SINS/DVL 组合导航系统的绝对误差位置误差。在 1 120 s 组合导航结束时，MLP、CNN、LSTM、DLinear-Informer 模型的绝对位置误差为 303.971 7、160.780 5、57.068 8、31.642 1 m。在辅助组合导航过程中，CNN、MLP、LSTM、DLinear-Informer 模型的绝对位置误差 RMSE 分别为 164.052 1、66.598 9、27.012 6、9.826 9 m，相比以上 3 个模型，DLinear-Informer 模型在组合导航绝对位置误差 RMSE 上分别降低了 94.54%、85.24%、63.62%，因此，DLinear-Informer 模型在应对 DVL 三束波缺失时，显著降低组合导航定位的位置误差。

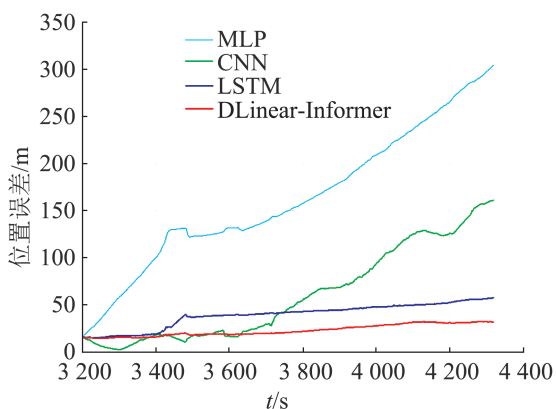


图 18 三束波缺失导航绝对位置误差
Fig. 18 Absolute position error of three missing beams

对 DLinaer-Informer 模型在三种波束缺失情况下的预测结果进行 t-test 分析， p 值和 t 统计的结果如表 5 所示。可以得出 3 种情况下各波束的 $p > 0.05$ ， $|t| < 1$ ，因此，模型预测值和真值的均值无显著差异，模型的输出结果具有可靠性。同时，

3 种波束缺失情况下的 R^2 分别为 0.992 1、0.991 5、0.989 0，VAF 分别为 99.31、99.18、98.96， R^2 接近 1，VAF 接近 100，也表明本文模型具有良好的统计性能。

表 5 DLinear-Informer 在 3 种波束缺失情况下 t-test 分析的 p 值和 t 值

类型	1 个束波丢失		2 个束波丢失		3 个束波丢失	
	Beam4	Beam3	Beam4	Beam2	Beam3	Beam4
p	0.54	0.81	0.40	0.49	0.66	0.37
t	0.61	-0.24	0.84	-0.69	-0.45	0.90

由以上分析和结果图可知，DLinear-Informer 模型在与 AUV 平面运动学模型相似的车载数据集上具有良好的表现能力，相比 MLP、CNN、LSTM 模型，由于 DLinear 很好地分离了初始输入数据的非线性信息，在载体运动状态发生变化时，DLinear-Informer 模型对波束预测的效果具有更好的准确性、鲁棒性和实时性，对动态变化的适应能力、抗干扰能力更强。同时，组合导航结果也验证了无论是直线、转弯、加速、减速等运动，基于 DLinear-Informer 模型的波束预测器都能在 DVL 部分波束丢失时显著降低组合导航定位误差。由此可见，该方法可以应对 DVL 在部分真实水下环境失效的情况，具有一定的工程价值和应用前景。

4 结论

针对 SINS/DVL 组合导航系统在 DVL 部分波束丢的情况下，本文提出了一种基于数据驱动的深度波束预测器方法，提高了组合导航系统

的定位精度和鲁棒性。基于DLinear-Informer模型的波束预测器可以连续提供丢失波束的速度预测值,与可用的波束辅助DVL提供4个波束插入最小二乘估计器(LS),以回归AUV的三维速度矢量进行组合导航。为验证所提方法的有效性,针对部分波束缺失的不同情况进行了车载数据集实验。实验结果表明:在不同数量波束丢失的情况下,基于DLinear-Informer的波束预测器预测精度更高,相比对比模型至少降低了25.69%的波束速度误差,融合后的组合导航绝对位置误差至少降低了46.93%。本文方法是将预测波束与可用波束插入LS之后进行松组合导航的,需要进一步研究,尝试紧组合情况下组合导航定位的效果。

参考文献:

- [1] 郑为, 邹启明, 倪文玺. 水下无人潜航器避障与导航仿真系统设计与应用[J]. 系统仿真学报, 2016, 28(1): 91-98.
Zheng Wei, Zou Qiming, Ni Wenxi. Design and Application of Underwater Unmanned Vehicle Simulation System for Navigation and Obstacle Avoidance[J]. Journal of System Simulation, 2016, 28(1): 91-98.
- [2] 刘沛佳. INS/DVL组合导航关键技术研究[D]. 北京: 北京理工大学, 2018.
Liu Peijia. Research on Key Technologies of INS/DVL Integrated Navigation[D]. Beijing: Beijing Institute of Technology, 2018.
- [3] 宋世磊. SINS/DVL水下组合导航技术研究[D]. 镇江: 江苏科技大学, 2022.
Song Shilei. Research on SINS/DVL Integrated Navigation Technology[D]. Zhenjiang: Jiangsu University of Science and Technology, 2022.
- [4] 龙瑛芝. 水下声学定位声速改正及定位算法研究[D]. 西安: 长安大学, 2023.
Long Yingzhi. Research on Underwater Acoustic Positioning Sound Velocity Correction and Positioning Algorithm[D]. Xi'an: Chang'an University, 2023.
- [5] 杨玉孔. 惯性与DVL计程仪组合导航技术研究[J]. 光学与光电技术, 2023, 21(5): 125-130.
Yang Yukong. Study on Inertial and DVL High Precision Integrated Navigation Technology[J]. Optics & Optoelectronic Technology, 2023, 21(5): 125-130.
- [6] Miller P A, Farrell J A, Zhao Yuanyuan, et al. Autonomous Underwater Vehicle Navigation[J]. IEEE Journal of Oceanic Engineering, 2010, 35(3): 663-678.
- [7] Itzik Klein, Yeshaya Lipman. Continuous INS/DVL Fusion in Situations of DVL Outages[C]//2020 IEEE/OES Autonomous Underwater Vehicles Symposium (AUV). Piscataway: IEEE, 2020: 1-6.
- [8] Mirabadi A, Mort N, Schmid F. Fault Detection and Isolation in Multisensor Train Navigation Systems[C]//UKACC International Conference on Control'98. Piscataway: IEEE, 1998: 969-974.
- [9] 曾观林, 冯国虎. 水下SINS/DVL组合导航误差抑制综述[J]. 现代防御技术, 2023, 51(4): 25-35.
Zeng Guanlin, Feng Guohu. Review on the Error Suppression of Underwater SINS/DVL Integrated Navigation[J]. Modern Defence Technology, 2023, 51(4): 25-35.
- [10] Ali Karmozdi, Mojtaba Hashemi, Hassan Salarieh, et al. Implementation of Translational Motion Dynamics for INS Data Fusion in DVL Outage in Underwater Navigation[J]. IEEE Sensors Journal, 2021, 21(5): 6652-6659.
- [11] 潘绍华, 徐晓苏, 张亮. 基于卡方检测和相关向量机的DVL异常信息处理机制[J]. 中国惯性技术学报, 2022, 30(4): 461-468.
Pan Shaohua, Xu Xiaosu, Zhang Liang. DVL Exception Information Processing Mechanism Based on Chi-square Test and RVM[J]. Journal of Chinese Inertial Technology, 2022, 30(4): 461-468.
- [12] Jin Kaidi, Chai Hongzhou, Su Chuhan, et al. A Performance-enhanced DVL/SINS Integrated Navigation System Based on Data-driven Approach[J]. Measurement Science and Technology, 2023, 34(9): 095120.
- [13] Zhu Jiupeng, Li An, Qin Fangjun, et al. A Novel Hybrid Method Based on Deep Learning for an Integrated Navigation System during DVL Signal Failure[J]. Electronics, 2022, 11(19): 2980.
- [14] Nadav Cohen, Zeev Yampolsky, Itzik Klein. Set-transformer BeamsNet for AUV Velocity Forecasting in Complete DVL Outage Scenarios[C]//2023 IEEE Underwater Technology (UT). Piscataway: IEEE, 2023: 1-6.
- [15] Nadav Cohen, Itzik Klein. BeamsNet: A Data-driven Approach Enhancing Doppler Velocity Log Measurements for Autonomous Underwater Vehicle Navigation[J]. Engineering Applications of Artificial Intelligence, 2022, 114: 105216.
- [16] Zhou Haoyi, Zhang Shanghang, Peng Jieqi, et al. Informer: Beyond Efficient Transformer for Long Sequence Time-series Forecasting[J]. Proceedings of the

- AAAI Conference on Artificial Intelligence, 2021, 35 (12): 11106-11115.
- [17] Tian Xinyu, Zheng Qinghe, Yu Zhiguo, et al. A Real-time Vehicle Speed Prediction Method Based on a Lightweight Informer Driven by Big Temporal Data[J]. Big Data and Cognitive Computing, 2023, 7(3): 131.
- [18] Wang Di, Xu Xiaosu, Yao Yiqing, et al. A Novel SINS/DVL Tightly Integrated Navigation Method for Complex Environment[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(7): 5183-5196.
- [19] Nadav Cohen, Itzik Klein. LiBeamsNet: AUV Velocity Vector Estimation in Situations of Limited DVL Beam Measurements[C]//OCEANS 2022, Hampton Roads. Piscataway: IEEE, 2022: 1-5.