

6-20-2023

## An Approach to Solving the Incoming Target Based on Uncertain Time Series

Jing Yang

*Navy Submarine College, Qingdao 266041, China; College of System and Engineering, National University of Defence and Technology, Changsha 410073, China*

Minghua Lu

*Navy Submarine College, Qingdao 266041, China*

Xingchen Hu

*College of System and Engineering, National University of Defence and Technology, Changsha 410073, China*

Jinping Wu

*Navy Submarine College, Qingdao 266041, 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 Paper 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.

---

# An Approach to Solving the Incoming Target Based on Uncertain Time Series

## Abstract

The traditional solution method for the incoming attacking target in water lacks the time series characteristics mining on multi-dimensional and uncertain observation data. Aiming at the time series prediction with high complexity and missing data, a method based on adaptive window interpolation and deep variable weight long-term and short-term memory network model for missing time series observation data with multiple sampling frequencies is proposed, which is compared and verified on the simulation data and public test data set. *Aiming at the random missing problem caused by the inconsistency of sampling frequency of multi-source observation information, an adaptive window imputation method is introduced to adaptively adjust the imputation window according to the missing rate of observation information and reduce the error level of traditional imputation methods. The long and short-term memory network model with variable weights is introduced to time series data, and the loss weight of back propagation is adaptively adjusted according to the missing time series observation data at multiple sampling frequencies while being suitable for imputation of missing time series observation data at multiple sampling frequencies.* Experiment results show that the comprehensive use of adaptive window interpolation and variable weight long-term and short-term memory network model can provide a faster and accurate decision-making reference for predicting and defending the incoming targets.

## Keywords

time series data, adaptive window, variable weight LSTM, target solution method

## Recommended Citation

Jing Yang, Minghua Lu, Xingchen Hu, Jinping Wu. An Approach to Solving the Incoming Target Based on Uncertain Time Series[J]. Journal of System Simulation, 2023, 35(6): 1245-1259.

# 基于不确定时间序列的来袭目标解算方法

杨静<sup>1,2</sup>, 陆铭华<sup>1</sup>, 胡星辰<sup>2</sup>, 吴金平<sup>1</sup>

(1. 海军潜艇学院, 山东 青岛 266041; 2. 国防科技大学 系统工程学院, 湖南 长沙 410073)

**摘要:** 传统水中来袭目标解算方法缺乏对多维度、不确定观测数据的时序特征的挖掘。针对此类数据复杂性高、存在缺失的时间序列预测问题, 提出了一种基于自适应窗口插补和深度可变权重长短时记忆网络模型的预测方法, 以适用于多采样频率的缺失时序观测数据, 并在仿真数据和公测数据集上验证。针对多源观测信息采样频率不一致造成的随机缺失问题, 引入自适应窗口插补方法; 根据观测信息的缺失程度自适应调整插补窗口, 降低传统插补方法的误差水平。针对时间序列数据引入可变权重的长短时记忆网络模型, 在适用于多采样频率的缺失时序观测数据插补的同时, 根据观测信息缺失率自适应调整反向传播的损失权重。实验表明: 模型在具备处理不确定数据处理能力的同时, 在区间预测中比传统方法准确率更高, 可以为解算来袭目标提供更有效的决策参考。

**关键词:** 时间序列; 自适应窗口; 可变权重长短时记忆网络; 目标解算方法

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2023)06-1245-15

DOI: 10.16182/j.issn1004731x.joss.22-0123

**引用格式:** 杨静, 陆铭华, 胡星辰, 等. 基于不确定时间序列的来袭目标解算方法[J]. 系统仿真学报, 2023, 35(6): 1245-1259.

**Reference format:** Yang Jing, Lu Minghua, Hu Xingchen, et al. An Approach to Solving the Incoming Target Based on Uncertain Time Series[J]. Journal of System Simulation, 2023, 35(6): 1245-1259.

## An Approach to Solving the Incoming Target Based on Uncertain Time Series

Yang Jing<sup>1,2</sup>, Lu Minghua<sup>1</sup>, Hu Xingchen<sup>2</sup>, Wu Jinping<sup>1</sup>

(1. Navy Submarine College, Qingdao 266041, China;

2. College of System and Engineering, National University of Defence and Technology, Changsha 410073, China)

**Abstract:** The traditional solution method for the incoming attacking target in water lacks the time series characteristics mining on multi-dimensional and uncertain observation data. Aiming at the time series prediction with high complexity and missing data, a method based on adaptive window interpolation and deep variable weight long-term and short-term memory network model for missing time series observation data with multiple sampling frequencies is proposed, which is compared and verified on the simulation data and public test data set. *Aiming at the random missing problem caused by the inconsistency of sampling frequency of multi-source observation information, an adaptive window imputation method is introduced to adaptively adjust the imputation window according to the missing rate of observation information and reduce the error level of traditional imputation methods. The long and short-term memory network model with variable weights is introduced to time series data, and the loss weight of back propagation is adaptively adjusted according to the missing time series observation data at multiple sampling frequencies while being suitable for imputation of missing time series*

收稿日期: 2022-02-23 修回日期: 2022-04-12

基金项目: 国家自然科学基金(71701205)

第一作者: 杨静(1989-), 女, 讲师, 博士生, 研究方向为智能决策技术。E-mail: estella126@126.com

*observation data at multiple sampling frequencies.* Experiment results show that the comprehensive use of adaptive window interpolation and variable weight long-term and short-term memory network model can provide a faster and accurate decision-making reference for predicting and defending the incoming targets.

**Keywords:** time series data; adaptive window; variable weight LSTM; target solution method

## 0 引言

随着近代海战在反潜技术方面的迅速发展, 潜艇防御行动的重要性日益凸显<sup>[1]</sup>。水中防御具有反应时间短、威胁大的特点, 而对于潜艇而言, 对来袭鱼雷弹道的求解是实施有针对性防御策略的一个重要前提条件<sup>[2]</sup>。由于被动声呐探测到的鱼雷报警信号往往只有方位信息是相对准确的, 因此, 对来袭目标散布、解算其运动要素成为了防御问题的一个重要前提<sup>[3]</sup>。然而受水下环境因素和传感器设备的制约, 水下观测具备极高的不确定性, 对来袭目标的判断成为了制约防御决策实时性的主要因素之一<sup>[4]</sup>。

根据目标信息的来源和种类, 解算目标运动要素的方法分为确定性算法和滤波估计法两大类。确定性算法不考虑观测信息的误差, 根据潜艇和目标所构成的几何态势图形, 利用几何原理建立数学模型求解运动要素; 滤波估计法最常用的是最小二乘滤波。文献[5]在改进傅里叶曲线拟合的基础上利用时序轨迹信息来解算目标, 但是其采用数据维度单一, 并没有考虑到多传感器设备的信息融合利用, 也没有将对目标态势识别结果等综合因素应用于对目标的解算。文献[6]综合运用几何法和纯方位法改进最小二乘, 但是无法避免模型对模型参数极为敏感的问题。到目前为止, 水下目标运动要素求解算法主要是将几何法和滤波法相结合<sup>[7-10]</sup>, 以提高纯方位求解的收敛能力, 但是这种仅从算法层面改进, 无法从根本上解决纯方位法模型对于其初值和范围设定敏感的问题。

实际水下目标解算时的考虑是多维度的, 包含对态势的判断分析、多传感器、多平台、多数据链等数据, 是一个存在数据缺失的多变量时间

序列预测问题, 在现实生活中广泛存在<sup>[11-12]</sup>。如何将来源于不同工作频率的观测设备, 甚至于人/智能态势判断的认知维度数据纳入一个统一的表示维度, 通过多方数据“经验”代替人为初值设定, 从数据综合的角度解决传统的初值敏感问题, 并针对不同维度的数据缺失进行有效地插补和表示, 是一个值得关注的问题。

另一个方面, 应当考虑如何提高对观测到的复杂参数的学习和记忆能力, 并利用这种“记忆”来快速仿真求解目标运动要素。现有的解目标运动要素方法几乎都是从观测的先验知识角度引入经验信息<sup>[13-14]</sup>, 缺乏一种对综合态势数据的有效数据, 模型对于经验知识的敏感度高, 缺乏对持续观测数据的有效挖掘。

本文将从水下防御的仿真模型数据集出发, 研究在数据缺失条件下多变量时间序列的自适应插补缺失数据、运用和记忆其时序特性的运动要素解算方法, 并在公测数据集上验证该方法的有效性。

## 1 问题背景

潜艇防御是潜艇作战行动的重要组成部分, 当目标对潜艇构成强威胁时, 潜艇会首先考虑采取防御行动<sup>[14]</sup>。本文考虑强对抗条件下, 基于时序数据的快速解算目标方法。当目标与我方距离较近, 传统的计算需要 1~5 min 才能收敛, 难以满足短时间内对敌跟踪、防御需求, 采用基于时序数据的目标解算方法, 充分挖掘观测多源数据的关联性, 是提高有效性预判, 实现快速决策的重要前提。

由于在构建数据集时更重要的是模拟其数据的高维和不同特征的采样频率不一致, 而不是关注模型逼真度本身, 通过对问题的去繁化简、抽

象描述, 对模型给出以下基本假设。

假设 1: 潜艇发现来袭鱼雷时, 考虑来袭鱼雷为  $0^\circ$  提前角、有利提前角 2 种情况下的仿真。

假设 2: 潜艇通过被动声呐系统持续稳定的目标方位序列信息, 发现来袭鱼雷报警信号, 探测到的方位舷角误差服从的正态分布。

假设 3: 初始仿真以潜艇为坐标原点, 潜艇当前运动方向为  $0^\circ$  航向(以正北方向表示)。

假设 4: 假设来袭鱼雷直航、搜索时均为匀速运动。

图 1 是对 2 种来袭鱼雷情况的决策示意图, 通过对观测目标方位的时序信息  $[B_1, B_2, \dots, B_i]$  进行快速的目标运动要素解算, 然后, 再根据解算参数仿真求解最优决策方案, 最后, 对决策方案与确定条件下的仿真结果进行对比, 从而判定决策的有效性, 并依据确定的仿真结果对决策空间进行改进。

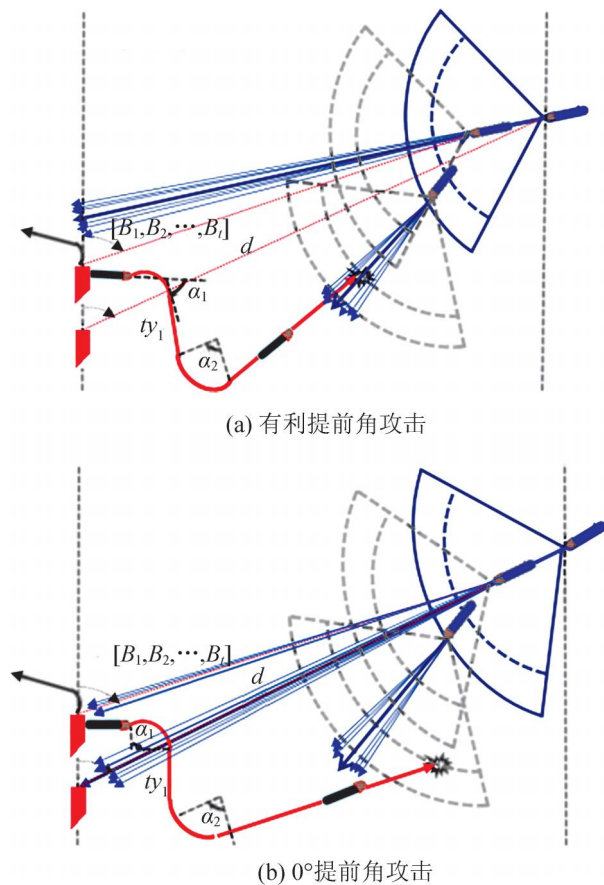


图 1 潜艇防御鱼雷态势图

Fig. 1 Defense situation for submarine defending torpedo

潜艇接到鱼雷报警后, 假设来袭鱼雷处于直航搜索状态,  $t_0$  时刻当我方艇位于  $W_0$  点时, 测得鱼雷方位  $B_0$ ;  $t_i$  时刻当我方艇位于  $W_i$  点时, 测得鱼雷方位  $B_i$ 。该过程中, 潜艇速度记作  $v_w$ , 航向为鱼雷提前角方向, 机动  $T$  个时间步, 获得持续观测的时序角度  $B_1, B_2, \dots, B_i$  信息; 分别利用一速度一距离两方位法、最小二乘估计法求解目标方位、速度和航向, 分别记作  $B_m$ 、 $v_m$  和  $C_m$ ; 依据求解目标运动要素信息, 通过仿真优化算法计算基于最优条件的决策方案。

在上述过程中, 潜艇对目标进行防御, 首先要知道目标的运动要素, 这是进行防御决策的重要前提, 特别是对需要精确制导的防御器材的使用, 确知的运动要素有利于提高使用水声诱饵器材的防御效果。目标运动要素求解是仿真优化的基础, 如果求解不准确, 则仿真优化很难奏效。

## 2 问题现状

### 2.1 基于纯方位解算及存在问题

纯方位法是水下考虑持续观测数据求解的基本方法, 主要原理是基于最小二乘滤波, 可以在只获得目标方位的情况下解算目标运动要素。设连续观测到的目标方位为  $B_1, B_2, \dots, B_i$ , 在  $t$  时刻, 目标的距离和方位分别为  $d, B_t$ , 本艇在  $t_1 \sim t$  时刻观测得到的  $B_1, B_2, \dots, B_i$ , 令初始距离为  $d_0$ , 本艇的航向和航速分别为  $C_w, v_w$ , 需要根据本艇的  $C_w, v_w$  和观测目标方位  $B_1, B_2, \dots, B_i$ , 求解目标(来袭鱼雷)的初始距离  $d_0$ , 目标航向和航速  $C_m, v_m$ 。假设以正东为  $X$  轴, 正北为  $Y$  轴, 则有

$$\int_{t_0}^{t_i} v_w \sin C_w dt + d_i \sin B_i = d_0 \sin B_0 + v_m (t_i - t_0) \sin C_m \quad (1)$$

$$\int_{t_0}^{t_i} v_w \cos C_w dt + d_i \cos B_i = d_0 \cos B_0 + v_m (t_i - t_0) \cos C_m$$

计:



$$\begin{cases} \theta_0 = \sin B_1 \int_{t_0}^{t_i} v_w \cos C_w dt - \cos B_i \int_{t_0}^{t_i} v_w \sin C_w dt \\ \theta_1 = \sin(B_0 - B_i) \\ \theta_2 = (t_i - t_0) \cos B_i \\ \theta_3 = -(t_i - t_0) \sin B_i \end{cases}$$

则有：

$$\theta_1 d_0 + \theta_2 v_m \sin C_m + \theta_3 v_m \cos C_m - \theta_0 = 0 \quad (2)$$

$$\text{设变量 } x_1 = d_0, x_2 = v_m \sin C_m, x_3 = v_m \cos C_m,$$

则假设函数记为

$$h_\theta(x) = \sum_{i=1}^3 \theta_i x_i = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_3 \quad (3)$$

对应损失函数记为

$$J(\theta) = (h_\theta(x) - y)^2 = \left( \sum \theta_i x_i - y \right)^2 \quad (4)$$

这里假设仅一条观测时间序列，即  $x_i \in \mathbf{R}$ ，根据最小二乘原理，平方损失函数分别对  $x_i$  求偏导：

$$\frac{\partial J(\theta)}{\partial x} = 2(h_\theta(x) - y)x_i, \quad i = 1, 2, 3 \quad (5)$$

令偏导数为 0，拟合参数。最终，目标航向和速度为

$$\begin{aligned} C_m &= \arctan(x_2/x_3) \\ v_m &= \sqrt{x_2^2 + x_3^2} \end{aligned} \quad (6)$$

然而最小二乘法为基础的目标运动要素解算方法模型的利用数据单一，仅考虑观测到的方位信息，而忽略外部其他数据的参考价值。

造成这个问题的主要原因是水下信息的获取不稳定，多传感器信号采集质量不一、时钟不一致，数据传输阻隔，情报态势、经验判断等类型数据很难充分挖掘和利用。

更重要的是，以最小二乘为代表的解算方法往往不考虑对时序数据蕴含的方位、距离等信息进行有效再利用，在解算时会抛弃过去信息。

为了对高维数据的时序信息进行有效利用，本文拟采用基于循环神经网络的记忆单元来对时序数据进行拟合，由于传统时序模型很难直接应用于缺失数据，本文首先以滑动时间窗口策略为基础提出了一种动态多维度缺失数据填充方法，再对填充后数据采用基于长短时记忆单元的滑动

窗口预测。将基于时间窗口的多维数据填充与循环神经网络的记忆功能项结合，以防御模型仿真数据样本为例应用该模型，可以提高对目标的解算能力和时效性。

## 2.2 多变量时序数据的处理方法

在现实生活中同样也经常会遇到多变量时序数据处理的问题。不完整的数据会给进一步的建模带来困难，而大多数分类方法无法直接在具有缺失数据的数据集上工作，因此，有很多研究都考虑了对于缺失数据的处理问题<sup>[14-15]</sup>。对缺失数据处理的重点从 2 个方面出发：①忽略并删除缺少属性的数据实例。这种方法的缺陷显而易见，仅在缺失数据较少的情况下起作用，即使这样，删除也会导致样本中丢失有用的信息。②在计算前先将缺失数据采用插补方法用估计值代替<sup>[16]</sup>。丰富的插补技术、有效的插补方法可以明显提高分类的准确性<sup>[17]</sup>。然而，插补误差几乎是不可避免的。特别是当多维数据采样时钟不一致的情况下，应用统一的插补策略会加大数据插补带来的误差，而在存在多维数据输入时，逐一分析多维数据的插补策略是困难的。虽然已经有研究考虑如何处理随分类<sup>[18]</sup>自适应插补的不完整数据，也有一些研究将不确定多元序列与变分贝叶斯共享图神经网络相结合，以构建针对多元序列的分类框架<sup>[19]</sup>，但也仅适用于静态时间序列数据，而难以用于随时间延续而变化的动态时间序列预测任务。

## 2.3 基于循环神经网络的时序数据分类模型

循环神经网络(RNN)是一种可以反应时序数据前后关联的神经网络。通过其隐藏状态，可以捕捉从序列开始，一直到当前时间步序列的历史信息。虽然 RNN 模型的共享参数机制保证了参数的数量不会随着时间步增加而增长，但由于反向传播机制，长时序数据由于其长期的数据依赖关系，在反向求导过程中容易出现梯度消失或者梯度下降的问题。此外，初始框架试图利用来自时

间序列的记忆信息时, 不完整数据无法直接应用于基于循环神经网络的记忆单元。

长短期记忆网络(LSTM)是循环神经网络模型的一种有效改进, 通过引入 3 个门来控制对时序数据的记忆和遗忘, 以及记忆细胞以控制信息传递。LSTM 的 3 个门分别是遗忘门、输入门和输出门。记忆细胞是一种特殊的隐藏状态单元, 用来存储历史时刻的信息, 它采用  $\tanh$  激活函数, 对当前时刻的输入、前一时刻的隐藏状态进行计算, 换句话说, 记忆细胞  $C$  由候选记忆细胞及上一时间步记忆细胞组合得到。输出门控制记忆细胞信息流入隐藏状态。一个 LSTM 单元的结构如图 2 所示。

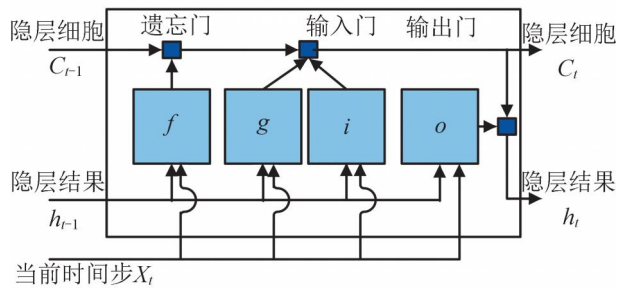


图 2 LSTM 单元  
Fig. 2 LSTM unit

其中:

$$\begin{aligned} i_t &= \delta(W_{ix}X_t + W_{ih}h_{t-1} + b_i) \\ f_t &= \delta(W_{fx}X_t + W_{fh}h_{t-1} + b_f) \\ o_t &= \delta(W_{ox}X_t + W_{oh}h_{t-1} + b_o) \\ g_t &= \tan(W_xX_t + W_{gh}h_{t-1}) \\ h_t &= W_{preh} \tan(i_t; g_t + h_{t-1} \cdot f_t) \cdot o_t \end{aligned} \quad (7)$$

文献[19]提出了基于RNN引入注意力机制和全连接卷积来学习多元时序数据的关系和长期依赖, 但是这些方法都无法直接应用于缺失的数据; 文献[20]通过基于误差分布的可变权重策略以提高集成模型收敛的速度, 但是更适用于静态数据, 还没有在多元时序数据上实现有效应用。

### 3 不完全时序数据预测模型

RNN 模型在保证求解精度的情况下, 主要解决最小二乘法求解的 2 个问题: ①解算目标运动

要素时, 主要以观测方位信息为主要依据, 没有对其他输入信息(我方位置、速度变化等)进行有效利用, 特别是针对有缺失的信息, 只能通过人工经验作为补充判定依据; ②在观测数据的处理过程中, 缺乏对过往信息的有效记忆和再利用。

#### 3.1 多目标运动要素的时序数据表示

对于一个长度为  $L$  的时间序列,  $\mathbf{X} = [x_1, x_2, \dots, x_L]^T \in \mathbf{R}^{L \times M}$ , 本文首先选择一个时间窗长度为  $T$ , 则  $[x_1, x_2, \dots, x_T]^T \in \mathbf{R}^{T \times M}$ , 对于每个时刻, 都存在  $M$  维输入, 并定义  $t$  时刻的输入  $x_t = [x_t^{(1)}, x_t^{(2)}, \dots, x_t^{(M)}] \in \mathbf{R}^M$ ; 对于输出序列, 假设其给定的输出目标序列为  $y_1, y_2, \dots, y_{t-1}$ , 以及给定的输入序列  $[x_1, x_2, \dots, x_T]^T \in \mathbf{R}^{T \times M}$ 。

不同于最小二乘法求解目标运动要素时, 仅考虑到观测方位  $B_1, B_2, \dots, B_t$ , 以及目标和我在  $t$  时刻的航向、速度  $C_t, v_t$ , 多目标运动要素模型还将考虑目标和我的持续速度、航向信息, 以及来自其他观测角度传感器的信号(假设时钟一致)。考虑到真实条件下, 多目标时序数据存在信息不完备的特点, 为了避免因为数据缺失对学习模型造成影响, 多目标数据表示采用均值填充的方法, 对缺失数据进行填补。假设时钟一致, 考虑到真实条件下, 多目标时序数据存在信息不完备的特点, 为了避免因为数据缺失对学习模型造成影响, 多目标数据表示采用均值填充的方法, 对缺失数据进行填补。则在长度为  $T$  的一段时间内观测到的数据为

$$\mathbf{X} = \begin{bmatrix} x_1^{(1)} & x_2^{(1)} & \dots & x_M^{(1)} \\ x_1^{(2)} & \text{NaN} & \dots & x_M^{(2)} \\ \vdots & \vdots & \ddots & \vdots \\ x_1^{(T)} & x_2^{(T)} & \dots & x_M^{(T)} \end{bmatrix}$$

式中: NaN 为缺失数据, 每一行代表一个时刻的输入数据, 每个时刻输入数据特征数目为  $M$ 。

#### 3.2 基于自适应窗口的多变量时序数据补全

时间序列预测的学习算法无法直接应用于缺失数据, 本文首先考虑对缺失数据的补全, 虽然前面已经有一些关于随分类自适应插补的

方法<sup>[9]</sup>，但本文针对的对抗条件下的时序数据仍需充分考虑其特殊的时序特性，例如，方位观测、距离观测等很明显具备非平稳特性，而机动速度、搜索半径等则是相对平稳的时间序列。在一个时间维度内，需要将不同时钟采样频率、不同稳定特性的数据组合成为一个标准化面板数据，而数据缺失可能发生在任意时刻，因此，对于这种总体非均衡的缺失数据，应当依据其每个维度数据的特性作为填充依据，且需要结合传统时间序列的移动平均、差分等策略以改善其非平稳特性。

针对上述这种具有多维度、多频度特征的缺失时间序列数据，在考虑其在时间维度上的特性的同时，采用自适应的滑动平均方法进行填充。具体方法：假设一个时间序列长度为 $N$ ，每个时刻输入数据的维度为 $M$ ，预测的结果标签维度为 $Y$ ，则该时间序列为

$$\mathbf{N}_x = \{x_1, x_2, \dots, x_N\} \in \mathbf{R}^{N \times M}$$

$$\mathbf{N}_y = \{y_1, y_2, \dots, y_N\} \in \mathbf{R}^{N \times Y}$$

式中： $\mathbf{N}_x$ 为输入； $\mathbf{N}_y$ 为其对应的预测结果。对于长度为 $L$ 的一段数据，理论上缺失填充的窗口越小，填充效果越好。然而针对输入特征多维，且缺失的发生不存在规律的问题，缺失窗口太小会导致填充无法正确完成。为了确保动态填充既能够准确，又能够全部填充以适应学习模型，对于每一个特征维度的数据，需要分别维护一个自适应填充窗口，基于当前时间窗口的缺失率来动态调整自适应填充窗口的大小。缺失填充的同时通过 *mask* 记录数据是观测数据还是填充数据，同时根据当前窗口的缺失率动态调整自适应窗口的大小，如图3所示。




图3 多特征缺失的自适应填充方法  
Fig. 3 Multi-feature missing data filling method

自适应窗口填充时，首先初始化采样窗口  $\omega = \{\omega_1, \omega_2, \dots, \omega_m\}$ ，其处理分为3个步骤。

**step 1:** 采样频率检验。多维数据存在采样频率不一致问题，综合数据以最大采样频率作为多维数据样本的综合采样频率。由于采样频率不一致导致的数据缺失，通过前向值填充的方式进行填充。

**step 2:** 非采样频率导致的不同缺失程度的数据缺失，其滑动窗口大小的选择往往会影响到数据填充的效果，在数据输入缺失程度不稳定的情况下，采用自适应窗口的缺失数据处理策略。

具体的思路是，初始化一个记忆窗口  $\omega_g$ ， $\omega_g \ll L$ ， $g = 1, 2, \dots, M$  来记录持续观测的数据信息；在当前记忆窗口长度上检测当前时间窗口的数据缺失程度：

$$\alpha_g^t = \frac{isnan[x_{t-\omega_g}, x_{t-\omega_g+1}, \dots, x_t]}{\omega_g} \quad (8)$$

式中： $isnan()$ 为判断数据缺失数量的函数。如果滑动窗口  $\omega_g$  的当前数据缺失度  $\alpha_g^t$  较高，需要加入先验信息来取滑动平均，增加记忆窗口  $\omega_g$ ；反之，当缺失程度  $\alpha_g^t$  较低时，窗口  $\omega_g$  过大反而会造成当前数据的抖动，因此需要将时间窗口调整到最小(相当于前一个值填充的方式)以降低数据插补造成的影响。

$$\omega_g = \begin{cases} \omega_g + 1, & \alpha_g^t - \alpha_0 > \varepsilon \\ \omega_g - 1, & \alpha_g^t - \alpha_0 < -\varepsilon \\ \omega_g, & |\alpha_g^t - \alpha_0| < \varepsilon \end{cases} \quad (9)$$

**step 3:** 缺失数据填充，确定了窗口  $\omega_g$  后，用式(8)来计算  $\alpha_i$ ，基于非缺失数据加权平均作为缺失数据的填充值，其中  $i \in \{1, 2, \dots, L - \omega_g + 1\}$ 。

$$y_{ij} = \frac{\sum_i^{i+\omega_g} mask \cdot x_{ij}}{(1 - a_g) \omega_g} \quad (10)$$

式中：*mask* 为对观测数据的掩码向量，向量中元素取值为0或者1，代表对应观测数据位置的值是缺失或是存在。滑动平均方法是基于原始序列的非缺失平均值，作为缺失部位的填充。得到的基



于原始序列的滑动平均值可以构成一个新的时间序列, 记为  $Y=[y_1, y_2, \dots, y_{L-\omega_s+1}]$ , 其中, 滑动平均在计算均值时仅考虑非缺失数据, 而不计算填充值, 此外, 该时间序列的掩码还将作为后续模型训练时损失传播的计算数据。

### 3.3 模型的归一化部件

多变量时间序列预测时, 不同特征维度可能会出现数量级、计量方式上的差别。为了避免不同特征在数值量级上产生的影响, 本文在模型输入、LSTM 隐层输出部分分别加入归一化部件, 对一个时间长度为  $L$  的输入序列, 在其每个特征维度上分别进行归一化处理, 将归一化后的输入记为  $x_n$ , 则有

$$x_{nij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^L x_{ij}^2}} \quad (11)$$

待模型学习预测处理后, 再通过其归一化因子对结果进行去归一化, 去归一化因子为

$$\eta_x = \sqrt{\sum_{i=1}^L x_{ij}^2} \quad (12)$$

### 3.4 基于可变权重损失的序列预测模型

针对最小二乘法解算目标仅依据点采样数据, 对数据处置和范围设定敏感, 缺乏对观测到的时序数据的有效利用和充分挖掘。本文提出一种基于 RNN 求解目标运动要素的方法, 在保证模型收敛的情况下, 充分利用时序特征数据, 快速判定求解。

RNN 以 LSTM 为基本记忆单元, 每个 LSTM 的隐层单元采用  $C$  个细胞, 目的是有效利用来自隐藏细胞记忆的时序信息; 考虑到多元序列数据在数值量级方面的差异, 对基于其时间窗的数据进行归一化。

考虑到缺失数据补全与观测数据在精度上具备天然差异, 在预测时应当尽可能减少对填充数据的梯度传播, 因此, 本文在梯度传播时引入一个记录缺失填充情况的向量  $mask$ , 对缺失数据和观测数据进行标注, 在计算梯度时, 减小由于数据填充对

梯度训练造成的影响, 来记录当前值的缺失程度, 因此, 对于反向传播前的损失计算函数改为

$$l_t^k = \frac{\sum_{i=1}^M \beta_t^k (\hat{y} - y)^2}{\sum_{i=1}^M \beta_t^i}, \beta_t^i \in [0, 1] \quad (13)$$

LSTM 层的每个细胞单元在反向传播训练时, 其损失的计算都是带权重的损失, 其中损失权重  $\beta_t^i$  是一个取值范围在  $[0, 1]$  之间的经验值。一方面, 通过共享参数机制持续记忆和运用前序时间数据; 另一方面, 基于自适应窗口的数据填充输入作为当前  $t$  时刻的输入, 目标是持续预测当前时刻的输出分类值, 每次输入的时间序列窗口长度记为  $L$ 。

一个长度为  $L$  的序列经过 LSTM 层后得到  $L$  个隐层输出, 再通过一个全连接层和一个线性回归层, 以实现输入特征的提取和拟合。虽然 LSTM 模型本身可以实现仅通过最后的隐层输出作为归一化的输入, 但是, 考虑到这种做法会导致前序的信息丢失, 不适用于对长时间序列的趋势和信息学习, 因此, 在 LSTM 层后加一个基于位置的注意力机制计算层, 采用点乘注意力的方式, 主要是考虑长时间序列与其位置相关的信息。考虑到真实条件下的输入序列往往是稀疏的, 需要对序列的注意力值  $A$  采用如下方式表达:

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

式中:  $Q$  为一个注意力函数的查询;  $K$  和  $V$  为一对键值对;  $K$  为关键字;  $V$  为输出值; 函数  $\text{softmax}()$  为多分类激活函数。模型的反向传播函数采用 ReLU 激活函数, 方向传播过程描述为

$$F_N(x) = \max(0, xW_1 + b_1)W_2 + b_2 \quad (15)$$

式中:  $x$  为来自上一个 LSTM 的隐层状态; 注意力层的参数  $W$  和偏置  $b$  为需要学习的参数。

模型的 LSTM 隐层和注意力层通过连接一个全连接层, 实现对时间序列  $L$  的特征提取。去归一化处理后的取值就是  $t$  时刻输出的预测值。模型的整体框架如图 4 所示。

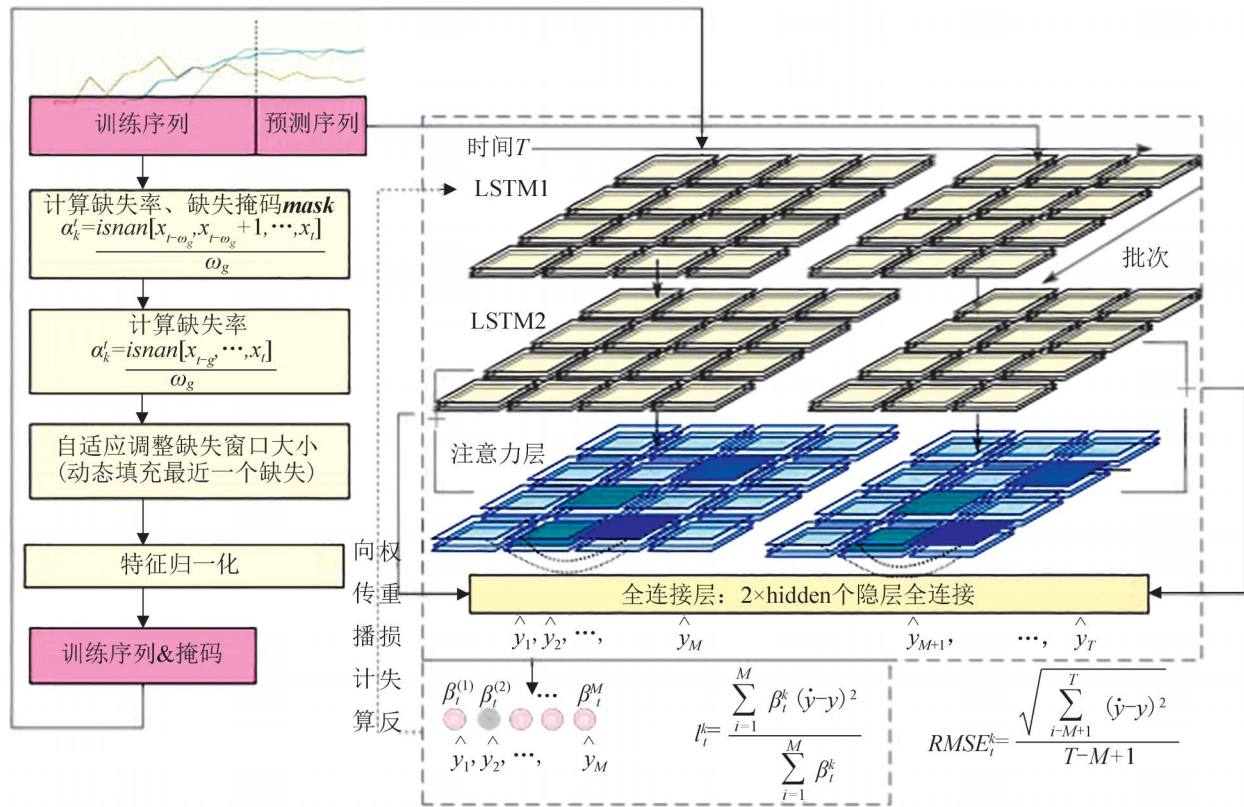


图4 自适应填充与可变权重结合算法框架

Fig. 4 Framework of algorithm combining adaptive filling and variable weights

填充后的输入序列，开始先通过2层LSTM及对应的dropout策略，用隐层状态的编码方式全部联系起来。再根据式(15)计算注意力机制，目的是用动态选择的方式选择性采纳所有的输入，以提高模型对趋势的动态把握能力。预测结果的损失函数计算时采用式(13)的方法对损失函数进行了改进：通过给基于填充数据输入 $X$ 所对应的时间步预测结果 $y$ ，被赋予一个取值为 $[0,1]$ 的损失权重，在反向传播过程中降低对于填充数据的权值更新，在训练时更注重共享观测数据的权值，关于损失权重训练和注意力对模型预测效果的影响将在实验部分阐述。

## 4 模型实验

### 4.1 数据说明

本文采用的仿真数据模拟时长5 min，每隔0.1 s进行一次采样，数据输入为15维，输出数据为2维。

输入数据包括我方位置(横纵坐标)、航向 $C_w$ 、航速 $v_w$ ，部分缺失的观测距离信息 $d$ ，敌我双方的探测半径 $R_{dwm}, R_{dmw}$ ，敌我双方的转向半径 $R_w, R_m$ ，目标剩余航程 $L$ ，对敌我双方状态转换的记录 $S_m, S_w$ ，以及来自3种不同传感器的观测目标方位时序数据 $B_1, B_2, B_3$ ，其中 $B_i = [b_1, b_2, \dots, b_T]$ ,  $i = 1, 2, 3$ ；输出数据是求解得到的目标航向 $C_m$ 和航速 $v_m$ 。不同维度的数据采样频率不一致，本文以最小采样频率对不同特征数据进行了填充和拼接，形成了长度为3 000，输入为 $3\ 000 \times 15$ 维，输出特征为 $3\ 000 \times 2$ 维的仿真数据样本。通过网格化方法初始化不同初始距离 $d = \{2, 2.1, \dots, 3\}$ ，初始方位 $B = [0, 0.1\pi, \dots, 0.9\pi]$ 的组合数据，共计时序数据量为30万条。图5给出了仿真数据集随机截取一次仿真的长度为3 000时序中的600条。

图5(a)是仿真数据模型的状态转换过程，状态转换是指过程仿真模型的有限状态机，过程仿真通过条件触发有限状态机实现交互和模拟的，

其状态转换的含义如表1所示。

图5(b)是通过离散仿真模拟连续物理空间的时间序列观测数据, 观测误差服从正态分布。其中, 数据显示是未经缺失处理的全空间数据, 仍采用随机缺失处理策略对该数据进行处理得到缺失仿真数据样本。




图5 仿真数据集样本部分可视化结果  
Fig. 5 Part of simulation dataset visualization result

表1 仿真数据集状态转换含义  
Table 1 Meaning of finite state machine

状态转换值	潜艇	诱饵	鱼雷
1	直航	准备	直航
2	转向	直航	尾追
3	-	转向	识别诱饵
4	-	失效	丢失目标
5	-	-	失效

同时, 本文还采用 NASDAQ 100 公测数据集, 该数据集是来自 81 个主要的 NASDAQ 100 旗

下公司, 通过时间序列记录其目标序列, 是通过每分钟记录一次收集到的时间序列。从 2016-07-26—12-22, 一共 105 天的数据。每天包括 390 个点, 记录了从开市到闭市。本文采用的是经过编码后的数据<sup>[21]</sup>, 共有 40 560×82 维, 其中前 81 维是输入, 最后 1 维是输出的预测值。

## 4.2 缺失数据填充方式与效果测试

### 4.2.1 自适应窗口与固定窗口填充对比

本文首先以随机缺失处理方式, 对公测数据集、仿真数据集分别进行缺失处理, 得到缺失 20%~60% 的缺失数据。

传统的时间序列预测<sup>[19]</sup>是通过对于一个序列的学习预测最后一个点的数值, 这种预测忽略了模型对于趋势、季节性等的学习能力, 也无法检验随着时间间隔增加, 模型对于后续趋势的预测能力。对于一个长度为  $T$  的时间序列, 按照 70% 长度作为训练集, 30% 长度作为测试集的方式进行划分, 预测后 30% 的时间序列, 采用的评估指标为填补后数据与原始数据相比的平均方差, 即:

$$RMSE = \sqrt{\frac{\sum_{i=1}^L (X_i - \hat{X}_i)^2}{L}} \quad (16)$$

采用固定时间窗口填充策略, 填充效果受数据缺失情况影响较大, 图6是 NASDAQ 数据集和仿真数据集随机选取某特征在不同缺失程度时, 填补效果随固定时间窗口长度  $T$  影响的变化。

可以看出, 固定窗口选取越小, 其出现偏差的可能性越低, 但真实情况下当缺失可能发生在任意时刻时, 固定窗口填充极有可能出现无解情况, 说明采用自适应可变窗口填充解决这一两难问题具备可能性。图7为在公测数据集和仿真数据集上, 不同缺失条件下自适应窗口策略与固定窗口策略填充效果的对比。由于 2 个数据集都具备高维输入特性, 因此, 仅随机选取其中一个特征绘图, 以体现 2 种方法在填充效果上的差距。



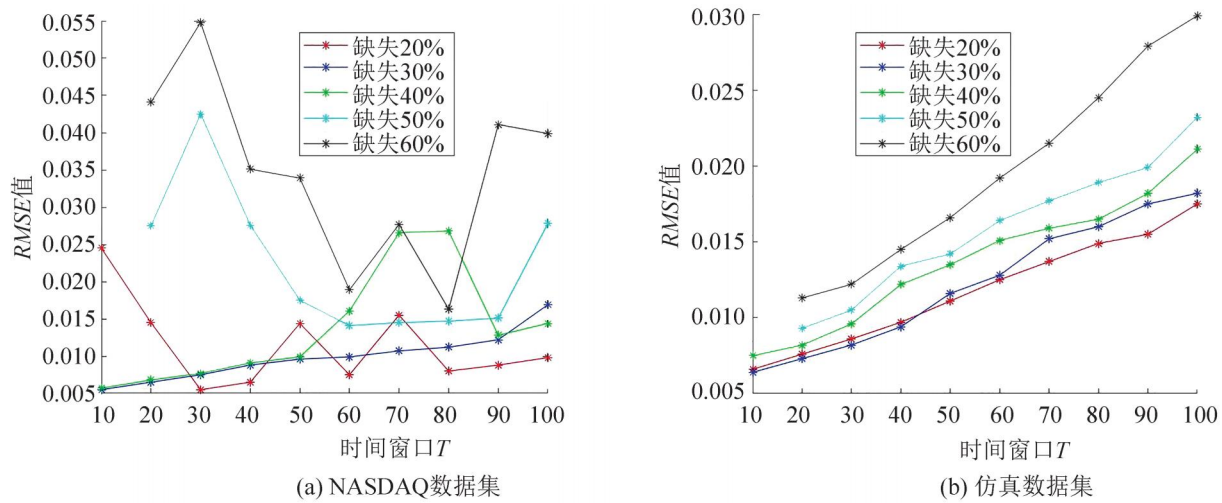


图6 时间窗口对缺失数据填充的影响  
Fig. 6 Influence on filling methods with different time window

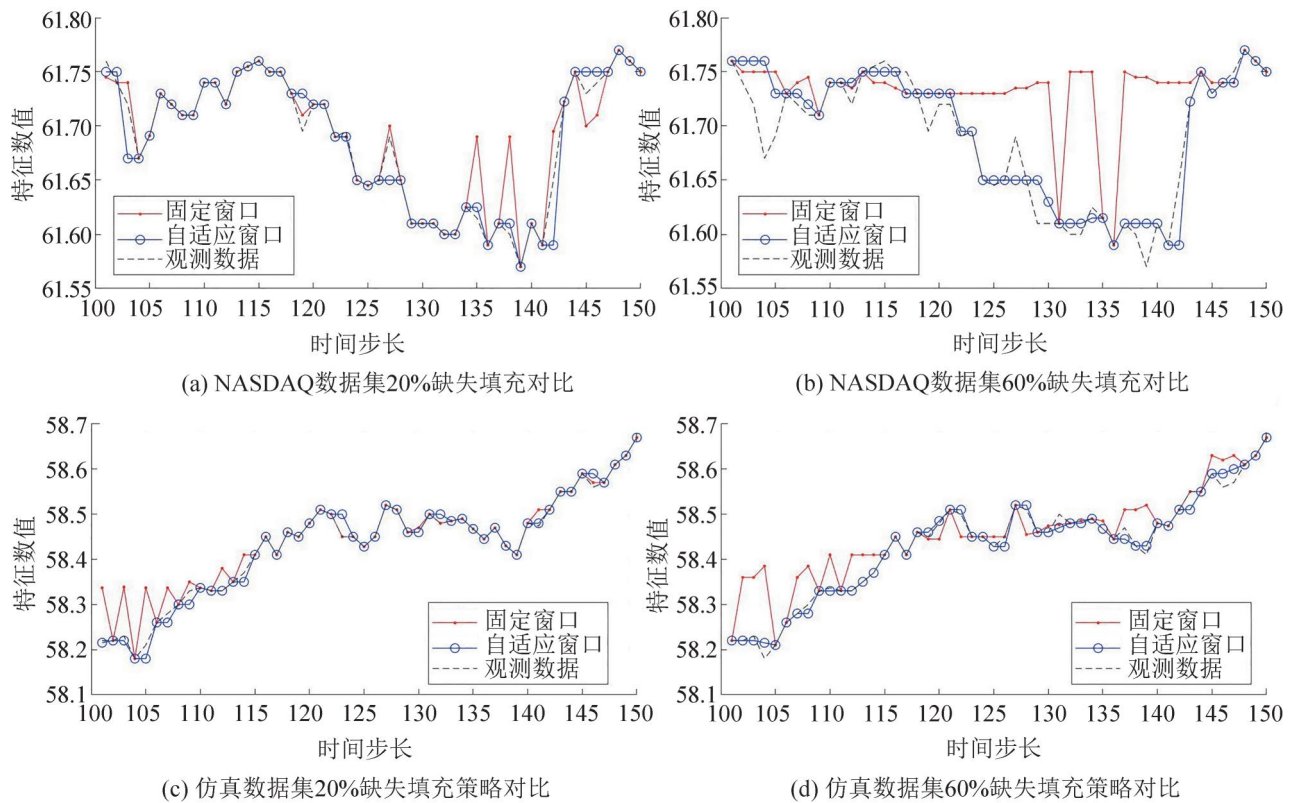


图7 固定时间窗口与自适应窗口填充效果对比  
Fig. 7 Comparison between fixed window and adaptive window

#### 4.2.2 自适应窗口与其他填充策略对比

同时,还测试了在仿真数据集和公测数据集上,使用前向填充插补法(图8)、线性回归插补法(图9)填补缺失数据的效果。

表2是在公测数据集、仿真数据集上,分别选取缺失程度20%~60%时,采用自适应滑动窗口、固定长度滑动窗口( $T=10, T=20$ )、前置值填充、线性插值共4种方式对缺失数据处理。



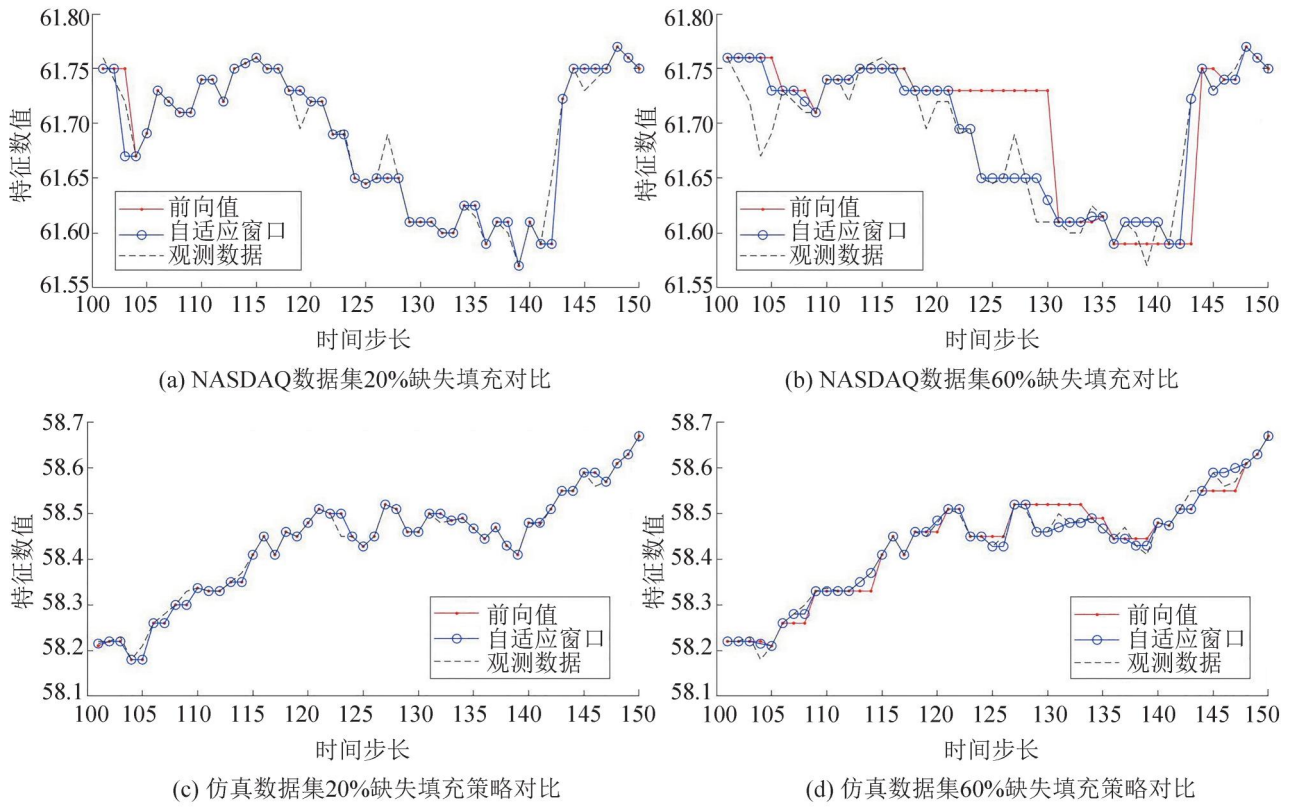


图 8 前向值填充与自适应窗口填充效果对比

Fig. 8 Comparison between previous value and adaptive window

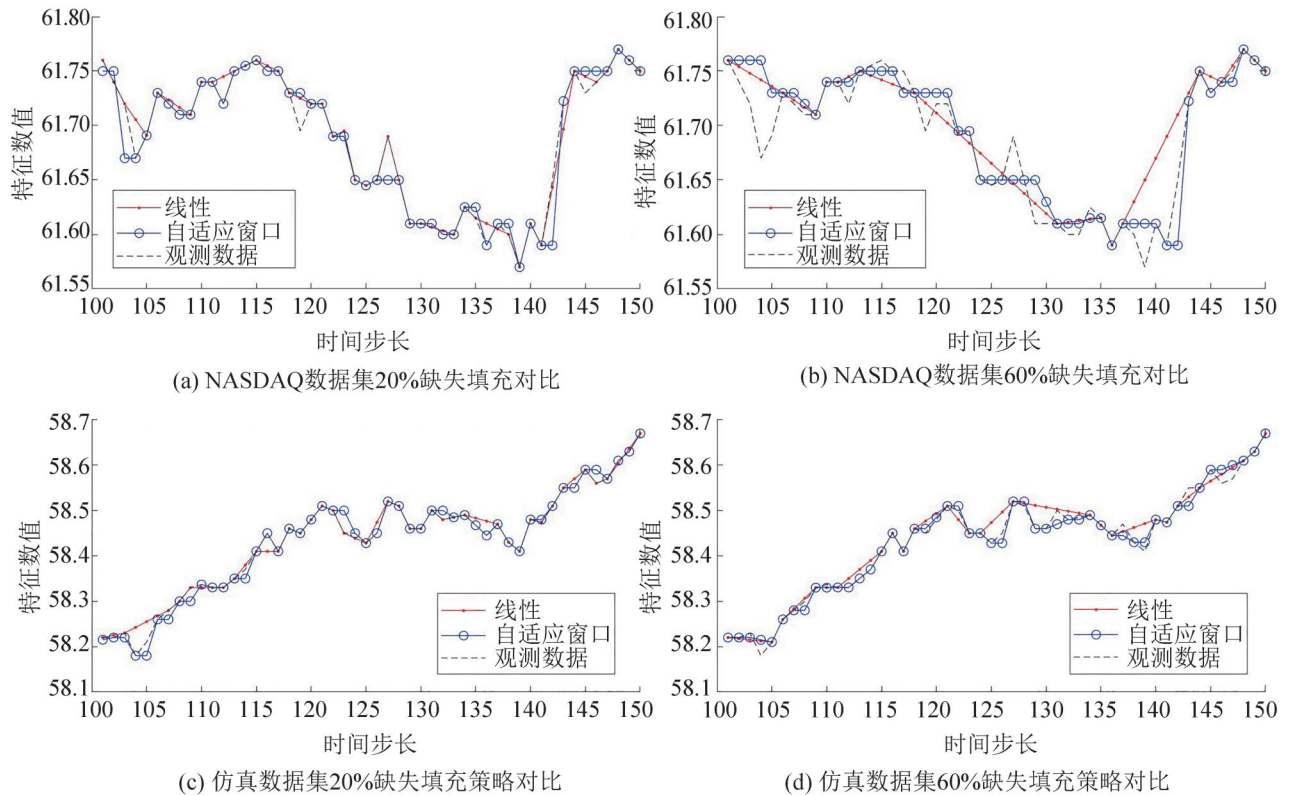


图 9 线性回归法与自适应窗口填充效果对比

Fig. 9 Comparison between linear regression and adaptive window

<http://www.china-simulation.com>

表 2 缺失数据填充策略对比

数据集	缺失/%	自适应	T=10	T=20	前置值	线性插值
公测	20	<b>2.92</b>	3.45	4.19	3.62	3.53
	30	<b>2.45</b>	3.17	3.90	3.79	3.48
	40	<b>3.45</b>	3.96	4.39	NaN	3.27
	50	<b>3.81</b>	NaN	5.33	5.33	4.65
	60	<b>4.27</b>	NaN	5.85	6.16	5.05
仿真	20	<b>1.90</b>	2.12	2.47	3.14	2.27
	30	<b>2.84</b>	3.04	3.44	NaN	3.73
	40	<b>2.77</b>	NaN	3.30	4.16	3.95
	50	<b>3.42</b>	3.83	4.53	NaN	4.19
	60	<b>4.17</b>	NaN	4.76	NaN	4.56

注: NaN代表数据值不存在, 由缺失数据导致的。

实验数据表明基于滑动窗口填充策略填充后的数据可以直接在不同的模型上进行训练。其中, 滑动窗口方式在仿真数据集上的表现远远优于线性插值, 而在公测数据集上两者表现相差不大, 主要原因在于, 可变窗口插补策略更适用于不同特征维度采样频率相差较大的情况; 当数据采样频率基本一致时, 可变滑动窗口插补策略也略优于其他数值插补策略。

### 4.3 模型预测实验与评估指标

#### 4.3.1 模型预测效果对比实验

表 3 是为了进一步证明本文的动态缺失填充和基于损失权重的注意力混合模型的有效性 (2-layer LSTM with attention and variable loss weight, AV2L), 本文分别对带注意力机制无可变权重损失的双层 LSTM 模型(A2L)、无注意力机制的可变权重损失模型(V2L)、无注意力机制和可变权重的双层 LSTM 模型(2L)训练混合模型, 对于一个长度为  $T$  的时间序列, 划分 70% 长度作为训练集, 30% 作为预测区间。评估指标仍然采用  $RMSE$ , 取 30% 预测空间的平均  $RMSE$  作为评估指标, 这种区间预测与模型本身所选取的时间序列长度  $T$  和双层 LSTM 单元的细胞隐层数量  $C$  2 个超参数有关, 固定序列处理窗口  $T=20$ , 细胞隐层数量  $C=128$ , 作为对本文模型比较。

由表 3 可见, 基于注意力和可变权重损失的

双层 LSTM 模混合模型(AV2L)效果最佳。究其原因, 首先构建模型时, 对于具备时间依赖关系的长时间序列采用注意力机制对每个隐层计算注意力分数, 可以有效捕捉来自时间序列的趋势信息。此外, 缺失数据填充的不准确性在训练模型时应当充分纳入考虑, 采用可变权重的损失传播计算方法, 可以降低由于填充不准确造成的梯度传播, 从而提高模型预测的效果。

表 3 不同模型、不同缺失数据对比

数据集	缺失/%	AV2L	A2L	V2L	2L
公测	0	<b>3.519 4</b> ↑	4.375 3	3.534 2	5.292 3
	20	<b>3.584 9</b> ↑	4.891 3	4.143 2	5.693 3
	30	<b>3.618 0</b> ↑	5.012 6	4.285 1	5.942 3
	40	<b>3.724 9</b> ↑	5.283 8	4.933 4	6.278 4
	50	<b>3.987 6</b> ↑	6.023 8	5.342 3	7.023 1
	60	<b>4.034 0</b> ↑	6.561 5	6.468 4	7.542 5
仿真	0	<b>3.339 4</b> ↑	4.363 4	3.632 4	4.867 4
	20	<b>3.512 9</b> ↑	4.356 4	4.142 3	4.953 4
	30	<b>3.567 2</b> ↑	4.743 2	4.324 2	5.124 3
	40	<b>3.653 4</b> ↑	4.990 8	4.678 3	5.132 8
	50	<b>3.817 6</b> ↑	5.954 2	4.834 2	6.943 2
	60	<b>3.935 4</b> ↑	6.195 9	5.942 4	7.104 4

#### 4.3.2 注意力分数效果验证

对注意力分数的可视化如图 10 所示。为了看到预测结果的变化趋势, 在注意力机制可视化时采用时序窗口长度  $T=300$ , 其中, 最后 30 个时间步是预测集。注意力分数的数据维度是  $C \times T$ , 分别代表隐层数量和时间序列长度, 在可视化时由于时间窗口长度较长, 选取隐层细胞数量  $C=256$ , 但由此导致注意力分数纵轴较大, 因此, 可视化的热力图纵轴每行代表的是 10 个隐层细胞的均值, 横轴是预测的时间步  $T$ 。

自注意力分数仅在极少部分数据中存在峰值, 普遍非常稀疏。由于本文更关注的是在动态数据缺失环境下的缺失数据填充和预测框架, 因此, 没有与关注改变计算效率的 SOTA 模型, 如 Informer 等进行执行效率上的对比。通过对注意力分数的热力图分解, 可以看到注意力重点关注存在非平稳趋势时对趋势的分解和学习。

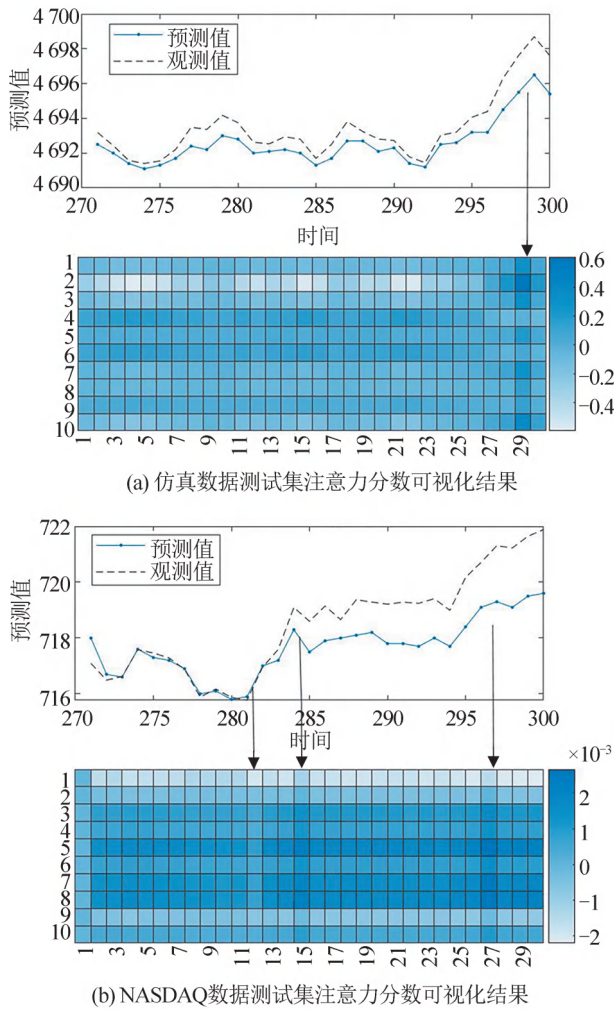


图 10 注意力分数与预测值对比

Fig. 10 Comparison between forecast value and attention score

### 4.3.3 可变权重模型的超参数

模型的时间序列预测过程中, 有 2 个需要寻优的超参数, 即时间窗口长度  $T$  和记忆细胞单元数  $C$ , 通过网格寻优方式对 2 个数据集(仿真数据集选取 3 000 条, 公测数据集选用前 3 000 个时间序列样本)进行测试, 以时间窗口长度  $T = \{8, 16, 20, 32, 40\}$ , 每个 LSTM 单元的细胞数量  $C = \{20, 64, 128, 256, 512\}$ , 其中, 每次反向传播最大迭代次数设置为 500, 训练集训练的迭代次数设置为 300, 对每个长度为  $T$  的数据, 均以前 70% 作为训练集, 后 30% 作为测试集。以  $30\% \times T$  的数据估计结果评估计算效果, 选用指标为  $RMSE$ 。

选取隐层细胞单元  $C=128$ , 图 11 是 2 个数据集在不同时间窗口长度时的  $RMSE$  值。




图 11 模型处理时间序列长度  $T$  与效果关系图

Fig. 11 Relationships between filling widow and RMSE

选择时间窗口  $T=20$ , 图 12 是 2 个数据集在隐层细胞单元数  $C$  不同时的  $RMSE$  值。

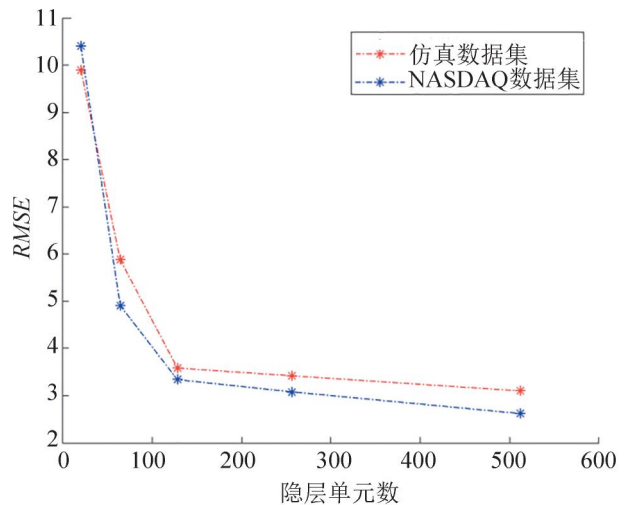


图 12 模型隐层细胞单元数与效果关系图

Fig. 12 Relationships between cell numbers and RMSE

可以看到, 在不同时间数据集上, 随着时间序列长度的增加, 模型性能会先上升, 再下降, 在长度过长的时间序列上反而性能会下降; 而随着细胞隐层的增加, 模型预测效能会变好, 因为隐层细胞数量增加, 可以更好地对学习参数进行拟合。



## 4.4 对比实验

考虑到最小二乘法无法应用于缺失数据, 本文在无缺失仿真数据集上, 测试了基于LSTM的目标解算方法和最小二乘解算方法。其中LSTM采用前1 000条数据作为训练集, 截取最后1 600条数据(中间间隔400条数据), 用训练不充分的LSTM模型做训练和预测; 而最小二乘法采用最后1 600条数据当中13维特征的其中4个特征(观测方位序列 $B$ 、 $v_w$ 、 $C_w$ 、 $v_m$ )用于计算, 模型上下界为真实仿真值20%误差范围(参数具体值)。从运算时间、1 600条数据的预测100个预测点求得的预测速度值 $v_m$ 如图13所示, 其中虚线代表仿真样本对应的真实速度值。

可以看到, 基于LSTM的预测方法收敛速度较快, 且预测的准确度可以达到与传统方法相似; 而最小二乘法在使用时需要很多特殊要求, 比如需要变换方位才能收敛, 不是所有情况下都有解, 不考虑过程中的变化, 对于初值的准确性和给定范围非常敏感。图中橙色线是初值范围相对准确条件下最小二乘法的实验结果, 可以看到, 该方法在1 min时才逐渐收敛; 图中红色线是基于LSTM的速度预测结果, 可以看到, 相比于最小二乘法, 所提方法的收敛速度更快。针对水下对抗这种演化速度极快的问题, 快速收敛具备极高的现实意义, 可以作为后续工程应用的技术雏形。




图13 最小二乘法与自适应权重模型的预测结果  
Fig. 13 Comparison between least square multiply and adaptive window models

## 5 结论

数据缺失情况下, 传统的算法很难直接应用, 采用基于自适应滑动窗口的插补策略, 并结合具有记忆功能的时序数据学习模型, 可以很好地实现在存在缺失信息的高维输入条件下模型的预测和目标解算。实验证明: 提升目标求解能力, 一方面需要对缺失数据进行多粒度的填充, 另一方面, 也需要模型训练时能够更好地将先验知识、历史数据进行有效运用。后续, 还将讨论如何更为自然、直观地为缺失数据预测提供一种统一的表示框架, 以提高模型的自适应能力。

### 参考文献:

- [1] 吴金平, 毛俊超, 丁文强. 潜艇鱼雷射击过程仿真建模[J]. 系统仿真学报, 2018, 30(3): 873-879.  
Wu Jinping, Mao Junchao, Ding Wenqiang. Modeling of Submarine Torpedo-Launching Simulation[J]. Journal of System Simulation, 2018, 30(3): 873-879.
- [2] 林彬, 宋晨晨, 张雅静, 等. 面向e-引航的近海边缘计算网络优化与仿真[J]. 系统仿真学报, 2020, 32(10): 1989-1996.  
Lin Bin, Song Chenchen, Zhang Yajing, et al. Optimization and Simulation of Offshore Edge Computing Network for e-Pilotage[J]. Journal of System Simulation, 2020, 32(10): 1989-1996.
- [3] 姚庆锴, 柳少军, 贺筱媛, 等. 基于深度学习的空中任务识别方法研究[J]. 系统仿真学报, 2017, 29(9): 2227-2231.  
Yao Qingkai, Liu Shaojun, He Xiaoyuan, et al. Research of Air Mission Recognition Method Based on Deep Learning[J]. Journal of System Simulation, 2017, 29(9): 2227-2231.
- [4] 李慧, 陈红倩, 杨倩玉, 等. 一种针对日志数据流的实时可视化方法[J]. 系统仿真学报, 2016, 28(9): 2133-2138.  
Li Hui, Chen Hongqian, Yang Qianyu, et al. Real-time Visualization Method for Log Data Stream[J]. Journal of System Simulation, 2016, 28(9): 2133-2138.
- [5] 邓新文, 刘兆才, 李帅. 基于傅里叶曲线拟合的水下目标运动要素解算方法[J]. 舰船电子工程, 2020, 40(8): 155-157.  
Deng Xinwen, Liu Zhaocai, Li Shuai. Solution Method of Underwater Target Motion Elements Based on Fourier Curve Fitting[J]. Ship Electronic Engineering, 2020, 40(8): 155-157.



- [6] 赵健昕, 笄良龙. 基于异方差伪线性模型的纯方位目标要素估计[J]. 探测与控制学报, 2017, 39(2): 7-12.  
Zhao Jianxin, Da Lianglong. Target Bearings-only Elements Estimation Based on Heteroscedastic Pseudolinear Model[J]. Journal of detection and control, 2017, 39(2): 7-12.
- [7] 赵健昕. 纯方位目标定位与跟踪航路优化模型[J]. 火力与指挥控制, 2010, 45(11): 106-108, 112.  
Zhao Jianxin. The Optimal Model of Fairway on Bearings-only Locating and Tracking[J]. Fire Control & Command Control, 2010, 45(11): 106-108, 112.
- [8] 刘浩, 毛宏霞, 肖志河, 等. 基于动态时间规整的火箭尾喷焰识别仿真[J]. 系统仿真学报, 2022, 34(1): 126-133.  
Liu Hao, Mao Hongxia, Xiao Zhihe, et al. Simulation of Rocket Exhaust Plumes Recognition Based on Dynamic Time Warping[J]. Journal of System Simulation, 2022, 34(1): 126-133.
- [9] 孙鑫, 李振华, 董军宇, 等. 面向海洋数据的复杂网络建模及可视化分析[J]. 系统仿真学报, 2018, 30(7): 2445-2452.  
Sun Xin, Li Zhenhua, Dong Junyu, et al. Complex Network Modeling and Visualization Analysis for Ocean Observation Data[J]. Journal of System Simulation, 2018, 30(7): 2445-2452.
- [10] 李训浩, 许任洲, 杜栓平. 利用会聚区隐蔽解算目标运动要素的方法[J]. 火力与指挥控制, 2006, 31(8): 36-40.  
Li Xungao, Xu Renzhou, Du Shuanping. Method of Calculating Hiddenly Target Motion Factors by Using Convergence Zone[J]. Fire Control & Command Control, 2006, 31(8): 36-40.
- [11] 李长文, 赵建昕. 声速有限条件下的纯方位方法[J]. 指挥控制与仿真, 2012, 34(5): 94-98.  
Li Changwen, Zhao Jianxin. Bearing-only Method Conditioned on Finite Sound Velocity[J]. Command Control and Simulation, 2012, 34(5): 94-98.
- [12] 李长文, 初磊. 理想声自导鱼雷运动要素的距离方位观测解算方法[J]. 弹道学报, 2016, 28(3): 43-58.  
Li Changwen, Chu Lei. Method of Solving Motion Factors of Ideal Acoustic Homing Torpedo by Distance and Bearing[J]. Journal of Ballistics, 2016, 28(3): 43-58.
- [13] 黄文斌, 宋健锋. 一种基于灰关联的目标运动要素解算方法[J]. 鱼雷技术, 2008, 16(2): 57-60.  
Huang Wenbin, Song Jianfeng. A Calculation Method of Target Motion Factors Based on Grey Relational Analysis [J]. Torpedo Technology, 2008, 16(2): 57-60.
- [14] 毛文涛, 蒋梦雪, 李源, 等. 基于异常序列剔除的多变量时间序列结构化预测[J]. 自动化学报, 2018, 44(4): 619-634.  
Mao Wentao, Jiang Mengxue, Li Yuan, et al. Structural Prediction of Multivariate Time Series Through Outlier Elimination[J]. Acta Automatica Sinica, 2018, 44(4): 619-634.
- [15] Choudhury S J, Pal N R. Imputation of Missing Data with Neural Networks for Classification[J]. Knowledge-Based Systems, 2019, 182: 104838.
- [16] García S, Luengo J, Herrera F. Tutorial on Practical Tips of the Most Influential Data Preprocessing Algorithms in Data Mining[J]. Knowledge-Based Systems, 2016, 98: 1-29.
- [17] Huang Hekai, Wang Hongzhi, Sun Ming. Incomplete Data Classification with View-Based Decision Tree[J]. Applied Soft Computing, 2020, 94: 106437.
- [18] Liu Zhunga, Pan Quan, Dezert Jean, et al. Adaptive Imputation of Missing Values for Incomplete Pattern Classification[J]. Pattern Recognit, 2016, 52: 85-95.
- [19] 鹿天柱, 钱晓超, 何舒, 等. 一种基于深度学习的时间序列预测方法[J]. 控制与决策, 2021, 36(3): 645-652.  
Lu Tianzhu, Qian Xiaochao, He Shu, et al. A Time Series Prediction Method Based on Deep Learning[J]. Control and Decision, 2021, 36(3): 645-652.
- [20] Liu Zhining, Cao Wei, Gao Zhifeng, et al. Self-paced Ensemble for Highly Imbalanced Massive Data Classification[C]//2020 IEEE 36th International Conference on Data Engineering(ICDE). Dallas, TX, USA: IEEE, 2020: 841-852. DOI: 10.1109/ICDE48307.2020.00078.
- [21] Qin Yao, Song Dongjin, Cheng Haifeng, et al. A Dual-Stage Attention-Based Recurrent Neural Network for Time Series Prediction[C]//International Joint Conference on Artificial Intelligence(IJCAI). Melbourne, Australia: AAAI, 2017: 2627-2633.