

李志刚¹ 刘宇杰¹ 韩国峰² 程尚¹ 付多民¹ 李莹琦¹

基于 R-OSELM 的海洋环境数据在线预测

摘要

为及时辨识海洋环境的变化趋势和降低长期累积的海洋环境数据对预测模型的影响,提出一种基于循环在线顺序极限学习机(Recurrent Online Sequential Extreme Learning Machine R-OSELM)的海洋环境数据在线预测模型.采用完全在线的方法初始化海洋环境数据训练集,通过在线顺序极限学习机算法对已有的海洋环境数据进行逐块输入,利用极限学习机的自动编码技术与一种归一化方法对输入权重循环处理,实现预测模型的在线更新,最后完成对海洋环境数据的在线预测.使用该模型对溶解氧、叶绿素 a、浊度、蓝绿藻进行预测,结果表明 R-OSELM 模型的预测精度高于对比模型,确定其具备海洋环境数据在线预测能力,可为海洋水域水体富营养化与海洋环境污染预警提供参考.

关键词

海洋环境数据;时间序列预测;在线预测;在线顺序极限学习机;循环神经网络

中图分类号 TP311.13;P714

文献标志码 A

收稿日期 2022-02-09

资助项目 国家重点研发计划(2017YFE0135700);河北省高等学校科学技术研究项目(ZD2021088);唐山市科技计划(19150230E)

作者简介

李志刚,男,博士,教授,研究方向为数据挖掘.lizhigang@ncst.edu.cn

李莹琦(通信作者),女,讲师,研究方向为机器学习理论与应用研究.liyingqi@ncst.edu.cn

1 华北理工大学 人工智能学院/河北省工业智能感知重点实验室,唐山,063210

2 唐山市就业服务中心,唐山,063000

0 引言

随着人类活动的加剧,海洋海域的自然生态环境遭到了严重的破坏^[1].随着信息技术的发展,海洋环境数据的获取已经成为可能.通过分析^[2]的手段,来对海洋环境数据实施监控是可行的.为保护海洋生态系统,对海洋环境污染提供预警,许多学者利用神经网络模型预测海洋环境数据.在海洋水质预测方面,现有的预测模型在训练方式上使用批量学习算法^[3-5],即每当收到新数据时,批量学习过去的数据和新的数据来重新训练模型.在海洋环境工程应用中,当监测站采集到的海洋环境训练样本发生变化或者有新的海洋环境训练样本加入时必须对全部海洋环境训练样本重新进行训练,这将浪费额外的计算资源.在离线预测中,数据被输入到一个固定的公式或训练好的模型中,忽略对模型的更新,从而导致其学习效率低下,难以满足模型在线预测的要求.所以,将在线预测方法应用于海洋环境数据预测具有重要意义.

近年来,已提出许多在线预测模型和方法,如滑动时间窗方法、在线顺序极限学习机等.滑动时间窗方法是将数据以等量样本选择的方式进行在线预测,但预测模型本身没有随时间序列在线更新和动态学习的能力,导致预测精度不优秀.海洋环境数据在线预测是逐个或逐块学习已有的海洋环境数据,并对未来的海洋环境数据进行预测,从而对海洋环境实现污染监测和动态维护.在海洋环境预报中,海洋环境数据的生成是连续的,为提高学习效率,模型更新是不可避免的.但在新数据不断到来的情况下,频繁地更新模型计算成本高昂.在线顺序极限学习机(Online Sequential Extreme Learning Machine, OS-ELM)^[6-8]会在新数据到达时以较低的成本自动更新(然后可以丢弃新数据)模型方程,通过使用递归最小二乘法随机初始化输入权重和更新输出权重,使网络能够逐个或逐块学习数据.同时,通过应用递归最小二乘法的遗忘因子,OS-ELM 可以快速适应新的输入模式,基于后续数据和随机选择隐藏节点参数更新权重使该方法快速准确.但是 OS-ELM 是针对单层前馈神经网络的,并且其输入权重无法调整,而循环神经网络(Recurrent Neural Network, RNN)^[9-11]则具有记忆过去事件的能力.RNN 在连续序列数据建模方面不仅考虑当前的输入,而且还使用它以前学到的东西.但是 RNN 在学习过程中存在训练集长度过大导致的梯度消失或爆炸问题.因此,需要探索能够面对长期累

积的海洋环境数据保证预测精度的在线预测方法.

面对长期累积的海洋环境数据,现有的在线预测模型自身没有随时间序列在线更新和动态学习的能力,导致模型预测精度下降.在 OS-ELM 的基础上,以“调整输入权重反馈更新”为原则,本文提出了基于循环在线顺序极限学习机(Recurrent Online Sequential Extreme Learning Machine, R-OSELM)的海洋环境在线预测模型.以海洋环境时间序列为例进行建模和在线预测实验验证,结果表明,R-OSELM 与其他在线预测模型相比对海洋环境数据在线预测精度较好,可以满足海洋大数据观测监测服务平台对海洋环境数据在线预测的更高需求.

1 R-OSELM 模型

1.1 模型结构

R-OSELM 是一种改进的 OS-ELM,它将两种新的方法应用于传统的 OS-ELM:具有归一化的自动编码技术和 RNN 结构的反馈更新输入权重,如图 1 所示.R-OSELM 模型的构造:在 RNN 框架中,其 n 维输入层通过输入权重 W 连接到 L 维隐藏层,隐藏层通过输出权重 β 连接到 m 维输出层,隐藏层通过隐藏权重 V 也连接到自身.

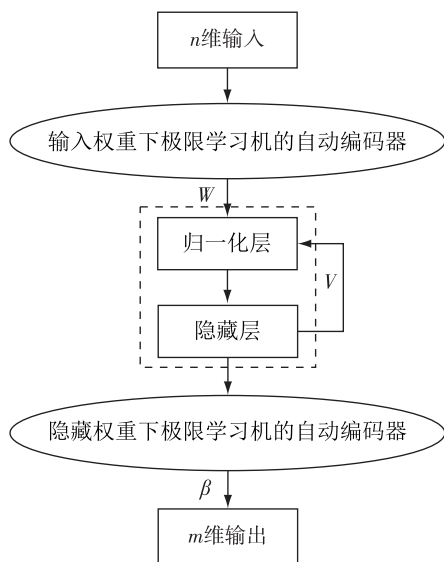


图 1 R-OSELM 模型框架

Fig. 1 The proposed R-OSELM model frame

R-OSELM 模型还定义了两个辅助 ELM-AE(Extreme Learning Machine-Auto Encoder)网络,两个辅助 ELM-AE 网络的工作原理是通过调整隐藏层的节点数,将输入特征压缩,一个用于更新输入权重称为

输入权重下极限学习机自动编码器,另一个用于更新隐藏权重称为隐藏权重下极限学习机自动编码器(图 2).在输入权重下极限学习机自动编码器中,其输入层通过输入权重连接到隐藏层,隐藏层通过输出权重连接到输出层.输入权重下极限学习机自动编码器的输入层维数和输出层维数与 R-OSELM 的输入层维数相同,输入权重下极限学习机自动编码器的隐藏层维数与 R-OSELM 的隐藏层维数相同.隐藏权重下极限学习机自动编码器的结构同理,它的输入层、输出层和隐藏层的维数与 R-OSELM 的隐藏层维数相同.

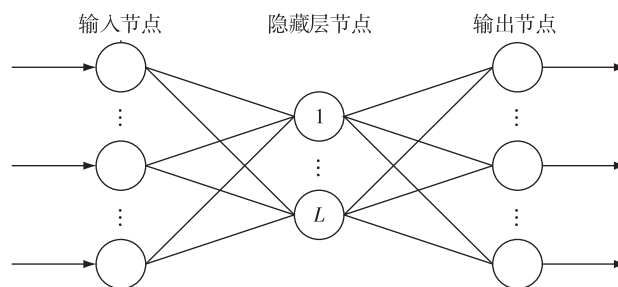


图 2 极限学习机自动编码器

Fig. 2 Extreme learning machine autoencoder

每当新的海洋环境数据输入时,采用递归最小二乘法随机初始化输入权重与隐藏权重下极限学习机自动编码器.极限学习机的自动编码技术(ELM-AE)^[12]调整隐藏节点数将输入特征压缩,然后通过应用递归最小二乘法的遗忘因子,使其可以快速适应新的输入模式.在 OS-ELM 的非线性激活层的之前加入一个归一层,通过减去特征的平均值,再除以特征的方差,简单地归一化输入特征.连接隐藏层的隐藏权重也会在新输入到达时更新,使用与更新输入权重相同的技术,这样可使模型持续更新输入与输出权重.将这种在线学习方法用于学习 RNN,最后可得模型的预测输出.应用极限学习机的自动编码器和归一化方法来调整输入权重的 R-OSELM 模型,使预测模型随时间序列的更新能够动态调整,有利于提高海洋环境数据预测精度.R-OSELM 的结构特点决定了其训练方式的特殊性.

1.2 模型算法

R-OSELM 模型组成包括两个阶段:初始化阶段和在线顺序学习阶段.

1.2.1 初始化阶段

对 R-OSELM 使用一种全在线初始化方法,不需要初始数据集.公式如下:

$$\beta_0 = 0, \quad P_0 = \left(\frac{I}{C} \right)^{-1}. \quad (1)$$

利用式(1)设定其初始输出权重 β_0 和初始辅助矩阵 P_0 . 其隐藏层输出的初始值 H_0 是随机生成的, 输入权重下极限学习机自动编码器的输入权重 W^i 和隐藏权重下极限学习机自动编码器的输入权重 W^h 也随机赋值. 用式(1)对它们的输出权重 β_0^i, β_0^h 和相应的辅助矩阵 P_0^i, P_0^h 初始化.

当有一个新的海洋环境训练样本为 N^{k+1} 的输入数据块到达时, 其中 $k+1$ 表示第 $k+1$ 个海洋环境训练样本输入数据块, k 从 0 开始递增时, 进行下面的学习过程. 为了数学上的简单性, 将海洋环境数据训练样本 N^{k+1} 的大小设置为 1.

1.2.2 在线顺序学习阶段

1) 更新输入权重. 首先使用输入权重下极限学习机自动编码器更新 R-OSELM 的输入权重. 输入权重下极限学习机自动编码器将第 $k+1$ 个输入样本 $x(k+1)$ 传送到隐藏层. 输入权重下极限学习机自动编码器隐藏层的输出矩阵 H_{k+1}^i 计算公式如下:

$$H_{k+1}^i = g(\text{norm}(W_{k+1}^i x(k+1))), \quad (2)$$

$$\text{norm}(x) = \frac{x - \mu^i}{\sqrt{\sigma^i + \varepsilon}}, \quad (3)$$

$$\mu^i = \frac{1}{L} \sum_{j=1}^L x_j, \quad (4)$$

$$\sigma^i = \frac{1}{L} \sum_{j=1}^L (x_j - \mu^i)^2, \quad (5)$$

式(5)中, x_j 表示训练样本, 具有 L 个隐藏节点的输出. 在非线性激活层的前面加入 norm 函数作为归一化层, 然后使用递归最小二乘法计算输入权重下极限学习机自动编码器的输出权重 β_{k+1}^i :

$$\beta_{k+1}^i = \beta_k^i + P_{k+1}^i H_{k+1}^{i T} (x(k+1) - H_{k+1}^i \beta_k^i), \quad (6)$$

$$P_{k+1}^i = \frac{1}{\lambda} P_k^i - P_k^i H_{k+1}^{i T} (\lambda^2 + \lambda H_{k+1}^i P_k^i H_{k+1}^{i T})^{-1} H_{k+1}^i P_k^i, \quad (7)$$

式(7)中 λ 为常数遗忘因子. 用 T_{k+1} 代替 $x(k+1)$ 执行无监督自动编码^[13], 公式如下:

$$\beta_{k+1}^i = \beta_k^i + P_{k+1}^i H_{k+1}^{i T} (T_{k+1} - H_{k+1}^i \beta_k^i). \quad (8)$$

将 β_{k+1}^i 的转置作为 R-OSELM 模型的输入权重 W_{k+1}^i :

$$W_{k+1}^i = \beta_{k+1}^{i T}. \quad (9)$$

2) 更新隐藏权重. 同样, 使用隐藏权重下极限学习机自动编码器更新 R-OSELM 的隐藏权重. 隐藏权重下极限学习机自动编码器将 R-OSELM 的第 k 个

隐藏层输出 H_k 传送到隐藏层, 隐藏权重下极限学习机自动编码器隐藏层的输出矩阵 H_{k+1}^h 计算公式如下:

$$H_{k+1}^h = g(\text{norm}(W_{k+1}^h H_k)). \quad (10)$$

执行无监督自动编码^[13], 使用递归最小二乘法计算隐藏权重下极限学习机自动编码器的输出权重 β_{k+1}^h :

$$\beta_{k+1}^h = \beta_k^h + P_{k+1}^h H_{k+1}^{h T} (H_k - H_{k+1}^h \beta_k^h), \quad (11)$$

$$P_{k+1}^h = \frac{1}{\lambda} P_k^h - P_k^h H_{k+1}^{h T} (\lambda^2 + \lambda H_{k+1}^h P_k^h H_{k+1}^{h T})^{-1} H_{k+1}^h P_k^h, \quad (12)$$

把 β_{k+1}^h 的转置当作 R-OSELM 的隐藏权重 V_{k+1} :

$$V_{k+1} = \beta_{k+1}^{h T}. \quad (13)$$

3) 前馈传播. 用第 $k+1$ 个输入样本 $x(k+1)$ 来计算 R-OSELM 的隐藏层输出矩阵 H_{k+1} , 公式如下:

$$H_{k+1} = g(\text{norm}(W_{k+1} x(k+1) + V_{k+1} H_k)). \quad (14)$$

4) 更新输出权重. 利用式(8)和式(15)更新 R-OSELM 的输出权重 β_{k+1} :

$$P_{k+1} = P_k - P_k H_{k+1}^T (I + H_{k+1} P_k H_{k+1}^T)^{-1} H_{k+1} P_k. \quad (15)$$

本文提出的 R-OSELM 不限于单个隐藏层, 而是可以有 m 个隐藏层, 此时 R-OSELM 有 m 个输入权重下极限学习机自动编码器, m 个隐藏权重下极限学习机自动编码器. 在此更深层次的结构中, 可以学习更复杂的海洋环境数据特征.

1.3 算法流程(见下页)

2 仿真实验与性能评估

2.1 实验数据集

本文使用中国北部海湾海域某定点浮标的实测数据验证 R-OSELM 模型性能. 数据样本选择中国某海域的海洋环境数据, 样本选择周期为 5 min, 涵盖气象参数和水质参数两种类型. 在线监控的样本特征属性由溶解氧、叶绿素 a、浊度和蓝绿藻组成. 选取 4 种因素各 8 000 个海洋环境数据实验样本. 监测的海洋生态环境原始数据变化曲线如图 3 所示.

2.2 在线预测模型性能分析

为使模型在在线训练阶段效果更佳, 将模型输入维数设置为 100. 在模型参数选择上, 将遗忘因子 $\lambda=0.915$, 隐节点数设置为 21, 采用 sigmoid 作为激活函数. 本文选用标准均方根误差 (NRMSE)、平均绝对百分比误差 (MAPE) 和决定系数 (R^2) 作为模型预测性能的度量标准.

R-OSELM 算法流程

步骤 1(初始化阶段):

1) 设置隐藏节点数目 L , 随机生成隐藏层输出的初始值 H_0 , 输入权重下极限学习机自动编码器的输入权重 W^i , 隐藏权重下极限学习机自动编码器的输入权重 W^h 和隐藏层偏置 $\sigma^i(i = 1, 2, \dots, L)$.

2) 使 $\beta_0^i = \beta_0^h = 0, P_0^i = P_0^h = (I/C)^{-1}$.

步骤 2(在线顺序学习阶段):

For $k = 1, 2, \dots$

① 获得第 $(k + 1)$ 个海洋环境数据训练样本块 $\left\{ (x_i, t_i) \right\}_{i=(\sum_{j=0}^k N_j)+1}^{\sum_{j=0}^{k+1} N_j}$, 其中 N_j 表示第 j 个海洋环境数据训练样本块的数目;

② 由式(2) 计算 H_{k+1}^i , 由式(7) 和式(8) 计算 P_{k+1}^i 和 β_{k+1}^i ;

③ 由式(10) 计算 H_{k+1}^h , 由式(12) 和式(11) 计算 P_{k+1}^h 和 β_{k+1}^h ;

④ 把 β_{k+1}^i 和 β_{k+1}^h 转置分别得出 W_{k+1} 和 V_{k+1} ;

⑤ 将 W_{k+1} 和 V_{k+1} 代入式(14) 计算出 H_{k+1} ;

⑥ 由式(8) 和式(15) 更新 R-OSELM 的输出权重 β_{k+1} .

重复步骤 2 直到没有新数据到达.

End

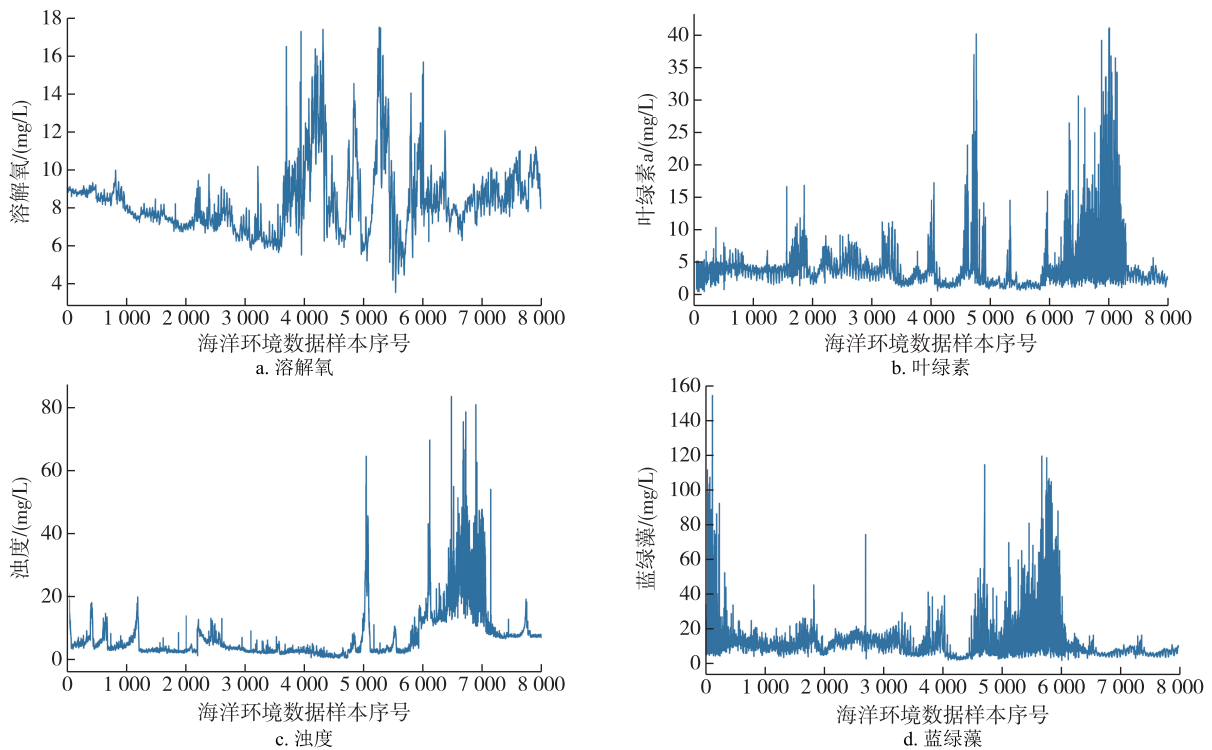


图 3 原始海洋环境数据变化曲线

Fig. 3 Change curves of original marine environment parameters

$$NRMSE = \sqrt{\frac{\sum_{t=1}^N (y_r(t) - y_p(t))^2}{N\sigma^2}}, \quad (16)$$

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{y_r(t) - y_p(t)}{y_p(t)} \right| \times 100\%, \quad (17)$$

$$R^2 = 1 - \frac{\sum_{t=1}^N (y_r(t) - y_p(t))^2}{\sum_{t=1}^N (y_r(t) - \bar{y}_r(t))^2}, \quad (18)$$

式中, N 为海洋数据集的长度, $y_r(t)$ 为 t 时刻的实际数据, $\bar{y}_r(t)$ 为实际数据的平均值, $y_p(t)$ 为模型在 t 时刻的预测数据, σ^2 为预测值的方差

OS-ELM 仅使用 ELM-AE 更新输入权重, 虽可获得更好的隐藏层特征, 但 OS-ELM 的性能会下降. 本实验首先验证 R-OSELM 在不加入归一化层前, ELM-AE 对 OS-ELM 的影响, 将 OS-ELM 与 OS-ELM-AE 的隐藏节点数分别设置为 5、15、20、25, 以 NRMSE 为度量标准. 实验结果表明, OS-ELM 在仅使

用 ELM-AE 后,随着隐藏节点数量的增加,模型的性能变得更差,如图 4 所示.所以,需要对 OS-ELM-AE 再使用一种归一化方法提升模型的性能.




图 4 OS-ELM 与 OS-ELM-AE 的 NRMSE 对比
Fig. 4 Comparison of NRMSE between OS-ELM and OS-ELM-AE

海洋环境数据的预测和实际对比如图 5 所示,可知 4 种海洋环境因素的预测曲线基本能拟合实际数据的变化情况,能够准确地反映出未来海洋环境的变化趋势,验证了 R-OSELM 在海洋环境数据在线预测任务中的可行性.

4 种海洋环境数据预测结果如表 1 所示.其中: NRMSE 的值均小于 0.1; MAPE 的值均小于 10%,尤其是溶解氧与浊度的 MAPE 值小于 1%; R^2 均大于 0.99.结果表明 R-OSELM 模型拟合效果优秀.

表 1 R-OSELM 模型的海洋环境数据预测结果

Table 1 Marine environment data predicted by R-OSELM model

| 海洋环境因素 | NRMSE/(mg/L) | MAPE/% | R^2 |
|--------|--------------|-----------|-----------|
| 溶解氧 | 0.069 542 | 0.911 783 | 0.995 200 |
| 叶绿素 a | 0.081 768 | 4.543 197 | 0.993 400 |
| 浊度 | 0.063 357 | 0.910 172 | 0.996 000 |
| 蓝绿藻 | 0.089 847 | 4.373 204 | 0.992 000 |

2.3 与对比模型的性能比较

挑选处理在线预测任务的 3 种传统模型: OS-ELM、在线 LSTM^[14] 和在线 SVR^[15] 为对比模型,对溶解氧、叶绿素 a、浊度和蓝绿藻 4 种海洋环境数据进行在线预测实验,验证 R-OSELM 在海洋环境数据在线预测任务中的可行性.为保证实验的可对比性,对比模型的输入层尺寸和输出层尺寸与 R-OSELM 相同.

图 6 给出了 R-OSELM 与其他 3 种模型对溶解氧、叶绿素 a、浊度和蓝绿藻数据的 NRMSE 对比,可以看出 R-OSELM 明显优于其他 3 种对比模型,其 NRMSE 值均在 0.1 以下.由图 6 可知,在线 LSTM 与在线 SVR 预测能力明显不如 R-OSELM 和 OS-ELM,这可能是由于 OS-ELM 拥有对模型在线更新的能力,而前 2 种在线方法只是在于对样本输入的处理上. R-OSELM 在加入提出的归一化方法对输入权重不断更新后,效果优于 OS-ELM,能使其性能进一步提高.

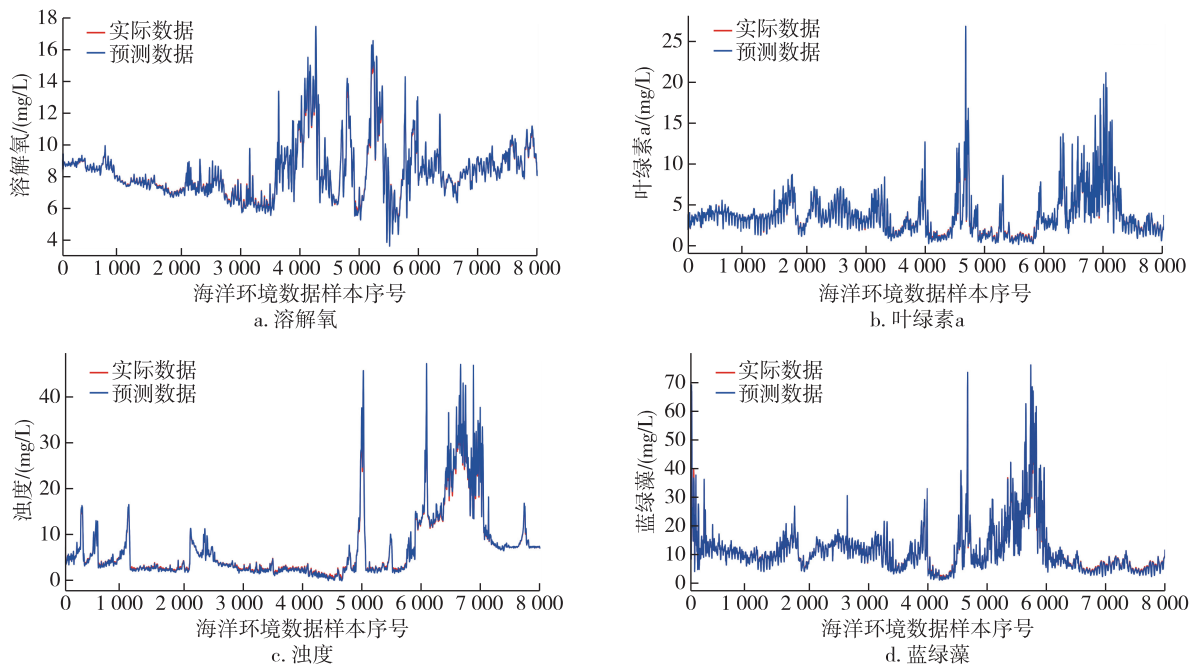


图 5 R-OSELM 模型预测数据与实际数据对比

Fig. 5 Comparison between actual data and predicted data from R-OSELM model

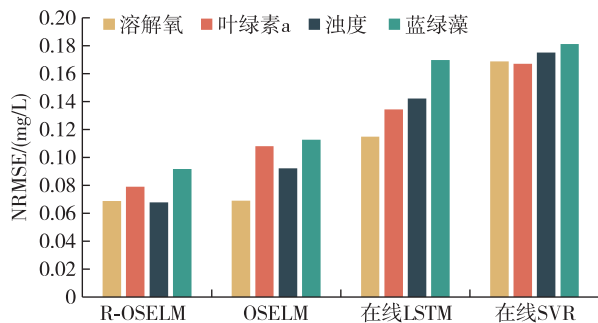


图6 R-OSELM模型与三个传统模型的NRMSE对比

Fig. 6 Comparison of NRMSE between R-OSELM model and three traditional models

总体来说,R-OSELM 在海洋环境数据在线预测任务中表现稳定,能有效实现对海洋环境数据的在线预测,提升预测的准确性。

3 结语

本文提出一种 R-OSELM 的海洋环境数据在线预测模型,对长期累积的海洋环境数据,随海洋环境时间序列在线更新,动态调整在线预测模型提升预测精度.该模型使用 ELM-AE 用于提取更好的输入特征,之后使用归一化处理并对隐藏权重进行循环输入,使其能够很好地训练循环神经网络.实验结果表明 R-OSELM 应用于海洋环境数据在线预测任务,预测精度有显著提升.R-OSELM 的特殊结构不仅在初始学习阶段能够快速学习输入模式,而且比其他在线预测方法更能快速适应输入模式的变化,可以高效完成海洋环境数据在线预测任务,满足对海洋水质环境在线预测的需求。

参考文献

References

[1] 王利明,马蕾,杨晓飞,等.渤海环境污染的治理与保护对策[J].中国资源综合利用,2020,38(3):109-111
WANG Liming, MA Lei, YANG Xiaofei, et al. The countermeasures for the pollution control and protection in the Bohai Sea [J]. China Resources Comprehensive Utilization, 2020, 38(3): 109-111

[2] Babak V P, Babak S V, Myslovyeh M V, et al. Methods and models for information data analysis [M] // Diagnostic Systems for Energy Equipments. Cham: Springer International Publishing, 2020: 23-70

[3] 豆荆辉,夏瑞,张凯,等.非参数模型在河湖富营养化研究领域应用进展[J].环境科学研究,2021,34(8):1928-1940
DOU Jinghui, XIA Rui, ZHANG Kai, et al. Application progress of non-parametric models in the field of river

and lake eutrophication research [J]. Research of Environmental Sciences, 2021, 34(8): 1928-1940

[4] 张雪薇,韩震.基于 Conv GRU 深度学习网络模型的海表面温度预测[J].大连海洋大学学报,2022,37(3):531-538
ZHANG Xuewei, HAN Zhen. Sea surface temperature prediction based on ConvGRU deep learning network model [J]. Journal of Dalian Ocean University, 2022, 37(3): 531-538

[5] 孙龙清,吴雨寒,孙希蓓,等.基于 IBAS 和 LSTM 网络的池塘水溶解氧含量预测[J].农业机械学报,2021,52(增刊1):252-260
SUN Longqing, WU Yuhuan, SUN Xibei, et al. Dissolved oxygen prediction model in ponds based on improved beetle antennae search and LSTM network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(sup1): 252-260

[6] Cao W P, Ming Z, Xu Z W, et al. Online sequential extreme learning machine with dynamic forgetting factor [J]. IEEE Access, 2019, 7: 179746-179757

[7] Cao W W, Yang Q M. Online sequential extreme learning machine based adaptive control for wastewater treatment plant [J]. Neurocomputing, 2020, 408: 169-175

[8] Al-Dhief F T, Baki M M, Latiff N M A, et al. Voice pathology detection and classification by adopting online sequential extreme learning machine [J]. IEEE Access, 2021, 9: 77293-77306

[9] 杨丽,吴雨茜,王俊丽,等.循环神经网络研究综述[J].计算机应用,2018,38(增刊2):1-6,26
YANG Li, WU Yuxi, WANG Junli, et al. Research on recurrent neural network [J]. Journal of Computer Applications, 2018, 38(sup2): 1-6, 26

[10] Li L, Jiang P, Xu H, et al. Water quality prediction based on recurrent neural network and improved evidence theory: a case study of Qiantang River, China [J]. Environmental Science and Pollution Research, 2019, 26(19): 19879-19896

[11] Ye Q Q, Yang X Q, Chen C B, et al. River water quality parameters prediction method based on LSTM-RNN model [C] // 2019 Chinese Control and Decision Conference (CCDC). June 3-5, 2019, Nanchang, China. IEEE, 2019: 3024-3028

[12] Ding S F, Zhang N, Zhang J, et al. Unsupervised extreme learning machine with representational features [J]. International Journal of Machine Learning and Cybernetics, 2017, 8(2): 587-595

[13] Liu Z, Huang S L, Jin W, et al. Broad learning system for semi-supervised learning [J]. Neurocomputing, 2021, 444: 38-47

[14] Bakhshwain N, University K F, Sagheer A, et al. Online tuning of hyperparameters in deep LSTM for time series applications [J]. International Journal of Intelligent Engineering and Systems, 2021, 14(1): 212-220

[15] Hu Z G, Kang H, Zheng M G. Stream data load prediction for resource scaling using online support vector regression [J]. Algorithms, 2019, 12(2): 37

Online prediction of marine environment data based on R-OSELM

LI Zhigang¹ LIU Yujie¹ HAN Guofeng² CHENG Shang¹ FU Duomin¹ LI Yingqi¹

1 College of Artificial Intelligence/Hebei Key Laboratory of Industrial Intelligent Perception,
North China University of Science and Technology, Tangshan 063210

2 Tangshan Employment Service Center, Tangshan 063000

Abstract In order to timely identify the changing trend of marine environment and reduce the influence of long-term accumulated marine environment data on prediction model, an online prediction model of marine environment data based on recurrent online sequential extreme learning machine (R-OSELM) is proposed. The marine environment data training set is initialized by an online method, the existing marine environment data is input block by block via online sequential extreme learning machine algorithm, and the input weight is cyclically processed by automatic coding technology of extreme learning machine and a normalized method, which realize the online update of the prediction model. Finally, online prediction of marine environment data is completed. The model is then used to predict dissolved oxygen, chlorophyll A, turbidity, and blue-green algae. The results show that the prediction accuracy of R-OSELM model is better than that of the comparison model. It is verified that the proposed R-OSELM model is capable of online prediction of marine environment data, which can provide support for early warning of marine eutrophication and other marine environmental pollution.

Key words marine environment data; time series prediction; online prediction; online sequential extreme learning machine; recurrent neural network