

赖晓倩, 余镒琦, 梁中耀, 等. 基于差分回归模型和可迁移长短期记忆网络集成的三沙湾水温预测[J]. 海洋学报, 2023, 45(4): 165–178, doi:10.12284/hyxb2023027

Lai Xiaoqian, Yu Yiqi, Liang Zhongyao, et al. Water temperature prediction in the Sansha Bay based on the integration of differential regression model and transportable long short-term memory network[J]. Haiyang Xuebao, 2023, 45(4): 165–178, doi:10.12284/hyxb2023027

基于差分回归模型和可迁移长短期记忆网络集成的三沙湾水温预测

赖晓倩¹, 余镒琦², 梁中耀², 陈火荣³, 陈能汪^{1,2*}

(1. 厦门大学 近海海洋环境科学国家重点实验室, 福建 厦门 361102; 2. 厦门大学 福建省海陆界面生态环境重点实验室, 福建 厦门 361102; 3. 福建省渔业资源监测中心, 福建 福州 350003)

摘要: 水温预测是保障近海渔业生产和环境安全的关键技术。现有的数值模型开发成本大, 业务化应用不足。本文提出了一种集成差分回归 (Differential Regression, DR) 和可迁移长短期记忆网络 (Transferable Long Short-Term Memory, TLSTM) 的水温预测方法。以厦门湾 (源域, 数据多) 和三沙湾 (目标域, 数据少) 水温为研究对象, 根据三沙湾在线监测水温和预报气温数据建立了 DR 模型, 根据厦门湾长时间监测水温数据建立了 TLSTM 模型, 采用变权算法将纯差分回归模型、混差分回归模型和 TLSTM 模型集成为三沙湾 DR-TLSTM 模型, 对模型性能进行了评估, 并与仅根据三沙湾少量监测数据建立的 LSTM 模型效果进行了对比。结果表明: (1) TLSTM 模型的预测精度优于基于目标域少量数据建立的 LSTM 模型; (2) DR-TLSTM 集成模型具有较高的预测精度, 未来 1~7 d 预测的均方根误差为 0.13~0.77℃, 未来 1~3 d 预测的均方根误差小于 0.4℃; (3) DR-TLSTM 集成模型可有效预测水温骤升或骤降趋势, 对水温突变点的预测均方根误差为 0.29~1.09℃。基于本文建立的 DR-TLSTM 集成模型, 实现了三沙湾渔业水域的水温预警预报业务化信息服务。

关键词: 水温预测; 回归模型; LSTM 模型; 迁移学习; 变权集成

中图分类号: P731.11

文献标志码: A

文章编号: 0253-4193(2023)04-0165-14

1 引言

海水养殖场一般选在沿海半封闭的内湾。自 20 世纪 80 年代起, 沿海地区的水产养殖业迅猛发展^[1]。渔业用海是我国最主要的海域使用类型。然而, 很多海湾面临水质恶化和生态退化问题, 危及海水养殖产业的可持续发展^[2-3]。大量的生产实践和科学研究表明, 海洋生物的生长和繁殖都与水温的变化有着密切关系^[4-10]。当水温超过生物的生理极限时将导致生物死亡, 水温过高还会造成饲料的发酵和微生物耗氧, 最后导致养殖生物缺氧死亡^[11]。此外, 极端海温事件

(热浪、寒潮)发生时易造成渔业经济损失。因此, 海湾水温预测是保障渔业生产和环境安全的关键技术。

现有的水温预测主要采用数值模拟方法和数据驱动方法^[12]。数值模拟方法通常需要建立复杂的多维机理模型, 模型参数多且难获取, 开发成本大, 难以支撑业务化应用。数据驱动方法需建立水温和相关影响因子的经验关系, 模型的准确性依赖于大量的监测数据。近年来, 随着水质在线监测技术的发展, 采用数据驱动方法进行水温的精确预测成为可能。长短期记忆网络 (Long Short-Term Memory, LSTM) 模型是一种高级循环神经网络 (Recurrent Neural Network,

收稿日期: 2022-07-06; 修订日期: 2022-09-26。

基金项目: 福建省海洋经济发展补助资金项目 (ZHHY-2019-1); 国家重点研发计划 (2016YFC0502901)。

作者简介: 赖晓倩 (1998—), 女, 福建省龙岩市人, 助理工程师, 主要从事大数据建模研究。E-mail: xiaoqian1_2020@163.com

* 通信作者: 陈能汪 (1976—), 男, 教授, 主要从事海陆界面生态环境研究。E-mail: nwchen@xmu.edu.cn

RNN)模型,能够有效地克服传统RNN训练过程中梯度消失和爆炸的问题^[13-14],在水温预测中展现出良好的效果^[15-19]。例如,Zhang等^[15]采用LSTM模型对海水表面温度进行预测,给出了未来1d和3d的短期预测结果与周和月均值的中长期预测结果。Hou等^[16]提出了一种新的密集扩张卷积LSTM模型来预测海面温度。Yang等^[17]结合时间和空间信息建立了一种端到端的、可训练的LSTM模型来预测海温。张昆^[18]利用多层卷积LSTM模型对不同深度层的海水温度进行预测。Kim等^[19]提出了一种基于LSTM模型的高海温预测方法。需要指出的是,大多数研究采用单一LSTM模型进行预测。然而,海温数据具有非线性和非平稳性的特点^[20],且受到太阳辐射、海洋平流和海气热通量交换等多种扰动因素的影响^[21],单一模型难以准确捕捉海温的变化规律,特别是水温骤升或骤降的趋势。此外,LSTM模型需要大量的训练数据才能获得较高的预测精度^[22],但在很多实际应用场景中并没有足够多的实测数据。迁移学习方法的提出有效地解决了模型训练过程中样本数量不足问题,它将在相似领域/区域(源域)学到的知识用于目标对象(目标域)^[23]。迁移学习已广泛地应用于图像分析和自然语言处理等领域^[24-25],但在海湾渔业水域环境预测的应用未见报道。

据此,本文提出了一种基于差分回归(Differential Regression, DR)和可迁移长短期记忆网络(Transferable LSTM, TLSTM)集成的方法(DR-TLSTM)用于历史监测数据较少的三沙湾的水温预测。首先,采用三沙湾水温数据和气温预报数据构建纯差分回归模型和混差分回归模型;其次,以历史监测数据较多的厦门湾为源域预训练LSTM模型,并将其迁移到三沙湾(冻结模型全部或部分权重参数,并以三沙湾数据进行模型再训练)构建TLSTM模型,获得水温预测结果;最后,采用变权算法将纯差分回归模型、混差分回归模型和TLSTM模型集成为DR-TLSTM模型,并进行三沙湾的水温等级预警预报业务化应用。

2 材料与方法

2.1 研究区域

三沙湾位于福建省东北部沿海,由三都澳、卢门港、白马港、盐田港、东吾洋、官井洋、福鼎洋等组成,水域面积为570 km²,生物资源丰富,是我国珍稀物种中华白海豚的栖息地和我国著名的大黄鱼产卵场,在此大黄鱼网箱养殖规模和产值居全国第一位。三沙湾属于亚热带海洋性气候,年平均降水量约为1631 mm,平均气温约为18.5℃,水温年变化范围为13.0~29.9℃^[26]。

厦门湾位于福建省南部,由九龙江口、西海域、南部海域(外港)、同安湾(包括浔江和东咀港)和东部海域等组成,水域面积为154.18 km²。厦门湾属于南亚热带季风海洋性气候,年平均降水量约为1100 mm,年平均气温约为21℃,水温年变化范围为13.9~29.0℃^[27]。厦门湾与三沙湾同属亚热带海洋性气候^[28],且都受到闽浙沿岸流的影响^[26,29],两者的气候和水文条件较为接近,本文分别选择厦门湾和三沙湾作为源域和目标域进行研究。

2.2 数据收集与数据预处理

本文采用的厦门湾水温数据由厦门大学在厦门湾布放的水质浮标测定,时间范围为2015年1月1日至2018年12月31日;三沙湾水温数据由福建省渔业监测中心在三沙湾布放的水质浮标测定,时间范围为2021年9月17日至2022年3月16日;水温数据的时间频率均为1次/(30 min)。气温预报数据来源于中国天气网(www.weather.com.cn)每日发布的宁德7日天气预报数据,时间范围为2021年9月17日至2022年3月16日,时间频率为1次/d。采用三沙湾2021年12月25日至2022年3月16日的水温数据进行模型的测试评估,其余数据均用于模型构建。

收集到的厦门湾、三沙湾的水温数据和气温预报数据,剔除非数值型数据和重复数据后,用阈值检验、均方差检验和尖峰检验剔除异常值,并用线性插值算法进行缺失值插补。处理完毕后,将数据重采样为日频率数据。

2.3 模型原理与建模流程

本文构建的DR-TLSTM集成模型流程见图1,包括以下4个步骤:(1)采用三沙湾(目标域)水温数据和三沙湾气温预报数据构建差分回归模型(包括纯差分回归模型和混差分回归模型);(2)采用厦门湾(源域)水温数据预训练LSTM模型;(3)采用三沙湾(目标域)水温数据对LSTM模型进行迁移;(4)采用变权算法将纯差分回归模型、混差分回归模型和TLSTM模型集成为DR-TLSTM模型。

2.3.1 LSTM模型

LSTM模型的基本结构单元由遗忘门、输入门、输出门、记忆单元、临时记忆单元、隐藏单元等结构组成,各结构的数学表达式见表1。LSTM结构单元的计算过程包括以下几个步骤:

- (1) 根据 t 时刻的输入数据 x_t 和上一时刻的隐藏单元状态 h_{t-1} ,计算遗忘门状态 f_t ;
- (2) 根据 t 时刻的输入数据 x_t 和上一时刻的隐藏单元状态 h_{t-1} ,计算输入门状态 i_t ;
- (3) 根据 t 时刻的输入数据 x_t 和上一时刻的隐藏

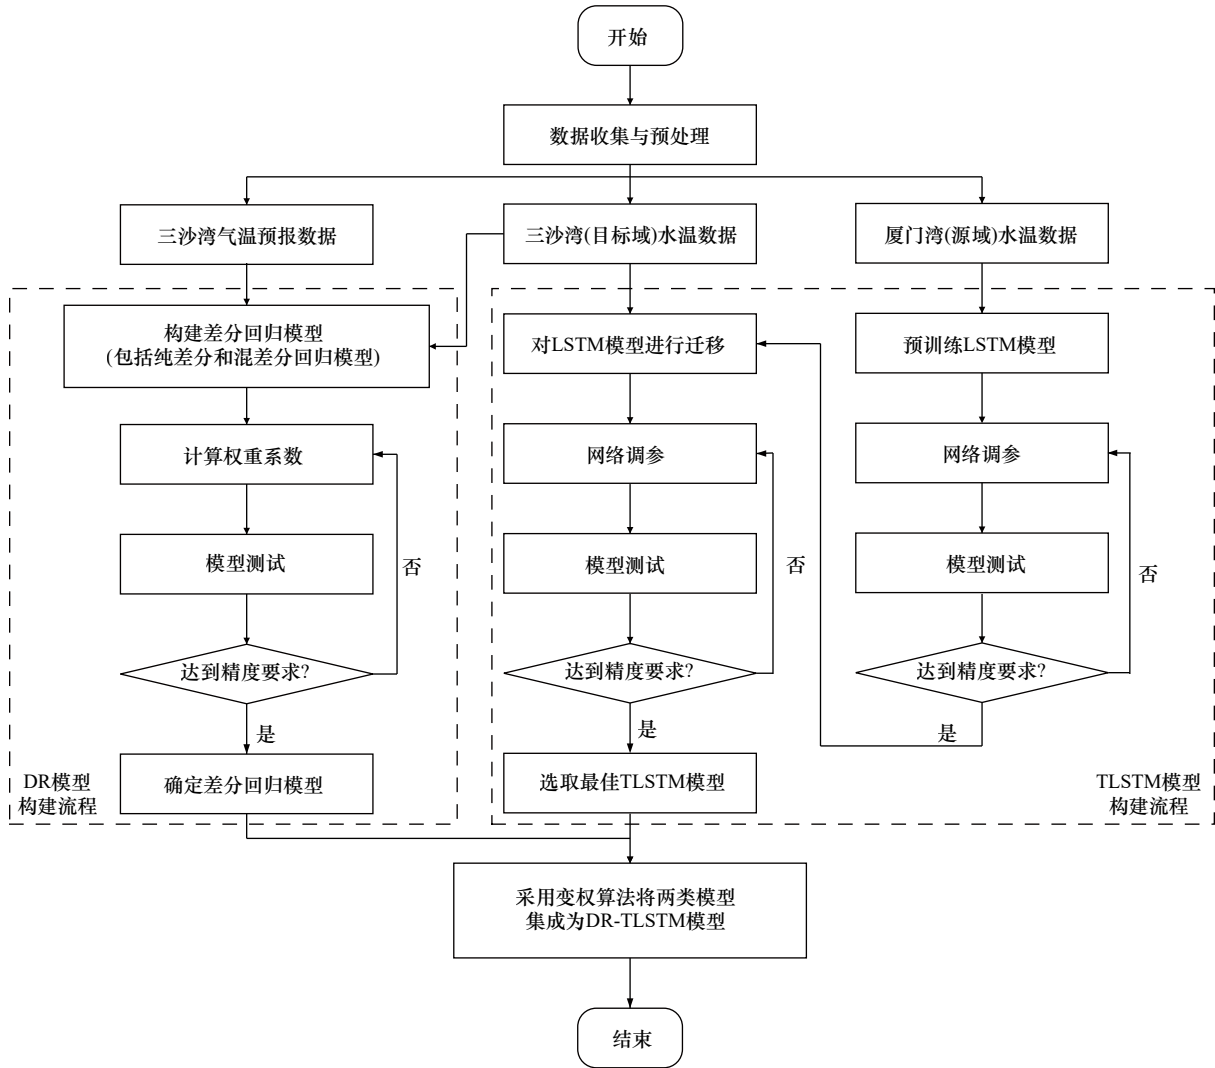


图 1 基于差分回归(DR)与可迁移长短期记忆网络(TLSTM)集成的三沙湾 DR-TLSTM 模型建模流程
 Fig. 1 Modeling process of DR-TLSTM model of Sansha Bay based on differential regression (DR) and transferable long short-term memory (TLSTM)

表 1 长短期记忆网络 (LSTM) 模型结构和数学表达式
 Table 1 Structures and mathematical expressions of long short-term memory (LSTM) model

结构	数学表达式
输入门	$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$
遗忘门	$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$
输出门	$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$
临时记忆单元	$\hat{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$
记忆单元	$C_t = f_t \odot C_{t-1} + i_t \odot \hat{C}_t$
隐藏单元	$h_t = o_t \odot \tanh(C_t)$

注: 式中, i_t 为输入门; f_t 为遗忘门; o_t 为输出门; \hat{C}_t 为 t 时刻临时记忆单元的输出; C_t 为 t 时刻记忆单元的输出; h_t 为 t 时刻隐藏单元的输出; x_t 为 t 时刻的输入数据; σ 为 Sigmoid 激活函数; \tanh 为双曲正切激活函数; W_i 、 W_f 、 W_c 、 W_o 为权重矩阵; b_i 、 b_f 、 b_c 、 b_o 为偏置向量; \odot 为逐元素点积运算。

- 单元状态 h_{t-1} , 计算临时记忆单元状态 \hat{C}_t ;
 - (4) 根据遗忘门状态 f_t 和上一时刻记忆单元状态 C_{t-1} 来确定上一时刻信息的遗忘或保留;
 - (5) 根据输入门状态 i_t 和临时记忆单元状态 \hat{C}_t 来确定当前时刻信息的遗忘或保留;
 - (6) 根据上一时刻信息和当前时刻信息的遗忘或保留情况, 计算当前时刻的记忆单元状态 C_t ;
 - (7) 根据 t 时刻的输入数据 x_t 和上一时刻的隐藏单元状态 h_{t-1} , 计算输出门状态 o_t ;
 - (8) 根据输出门状态 o_t 和当前时刻的记忆单元状态 C_t , 计算当前时刻的隐藏单元状态 h_t , h_t 即为当前时刻 LSTM 结构单元的输出;
 - (9) 将当前时刻的记忆单元状态 C_t 和隐藏单元状态 h_t 输入至下一 LSTM 结构单元, 并重复以上步骤。
- 单层 LSTM 模型提取数据信息的能力是有限的,

可以将多个 LSTM 模型组合成特定架构以提高预测能力。堆叠 LSTM 模型是最常用的组合模型之一。与单层 LSTM 模型相比,堆叠 LSTM 模型的网络结构更加复杂,特征提取能力更强^[30]。因此,本文选用堆叠 LSTM 模型来进行水温预测。

本文用 Z-Score 标准化方法将厦门湾(源域)2015 年 1 月 1 日至 2018 年 12 月 31 日的水温数据转化为平均值为 0、标准差为 1 的数据集,按 4 : 1 的比例将数据集划分为训练集和测试集。经过网络调参和模型测试,根据预测精度选出包含两个 LSTM 网络层的堆叠 LSTM 模型,模型的主要参数和设定值见表 2。

表 2 长短期记忆网络 (LSTM) 模型主要参数和设定值
Table 2 Main parameters and set values of long short-term memory (LSTM) model

主要参数	设定值
LSTM层1神经元个数	48
正则化层1正则化系数	0.2
LSTM层2神经元个数	32
正则化层2正则化系数	0.2
损失函数	MSE
优化器	Adam
批处理大小	32
迭代轮次	150

注: MSE为均方误差, Adam为基于适应性低阶矩估计的一阶梯度优化算法结果。

2.3.2 迁移学习

迁移学习的定义中包含域和任务这两个基本概念。域 D 由输入数据的所有参数组成的参数空间 X 和每一维参数的概率分布 $P(x)$ 构成,其中 $x=\{x_1, x_2, \dots, x_n\} \in X$ 。任务 T 由标签空间 Y 和目标函数 $f(\cdot)$ 构成。对于给定的源域 D_s 和对应的源任务 T_s 、目标域 D_T 和对应的目标任务 T_T ,迁移学习的目标是通过 D_s 和 T_s 中的知识提高 D_T 中目标函数 $f_T(\cdot)$ 的学习效果^[31]。

微调是一种用目标域数据对预训练模型未冻结层的权重参数进行再训练的迁移学习方法。本文采用两种方式对预训练的 LSTM 模型进行迁移:一种是不进行微调,采用全部模型参数,将预训练的 LSTM 模型直接应用于三沙湾(目标域)的水温预测,将其记为 TLSTM 模型(未微调);另一种是进行微调,冻结预训练的 LSTM 模型的首个网络层的参数,用三沙湾 2021 年 9 月 17 日至 12 月 24 日的水温数据对剩余参数进行微调,将其记为 TLSTM 模型。模型微调的主要参数包括损失函数、优化器、批处理大小和迭代轮

次,其设定值分别为 MSE、Adam、32 和 150。

2.3.3 差分回归模型

水温变化和气温变化有明显的相关性,本文根据三沙湾在线监测水温和预报气温数据,构建纯差分回归模型和混差分回归模型。

(1) 构建纯差分回归模型

按式(1)、式(2)构建线性回归方程并计算 w_{p1} 、 w_{p2} 、 w_{p3} 和 w_{p4}^n ($2 \leq n \leq 7$),按式(3)、式(4)构建纯差分回归模型。

$$x_t = x_{t-1} + \sum_{i=1}^3 [w_{pi} \cdot (f_{t+1-i}^1 - f_{t-i}^1)], \quad (1)$$

$$x_t = x_{t+1-n} + w_{p4}^n \cdot (f_t^n - f_t^1), \quad (2)$$

$$p_t^1 = x_{t-1} + \sum_{i=1}^3 [w_{pi} \cdot (f_{t+1-i}^1 - f_{t-i}^1)], \quad (3)$$

$$p_t^n = p_t^1 + w_{p4}^n \cdot (f_t^n - f_t^1), \quad (4)$$

式中, x_t 表示第 t 天的水温实测值; $f_t^1, f_t^2, \dots, f_t^7$ 表示第 t 天发布的未来 1~7 d 气温预报数据; $p_t^1, p_t^2, \dots, p_t^7$ 表示模型在第 t 天的未来 1~7 d 水温预测值; w_{p1} 、 w_{p2} 、 w_{p3} 和 w_{p4}^n ($2 \leq n \leq 7$)为权重系数。

(2) 构建混差分回归模型

按式(5)、式(6)构建线性回归方程并计算 w_{m1} 、 w_{m2} 和 w_{m3}^n ($2 \leq n \leq 7$),按式(7)、式(8)构建混差分回归模型。

$$x_t = x_{t-1} + w_{m1} \cdot (x_{t-1} - x_{t-2}) + w_{m2} \cdot (f_t^1 - f_{t-1}^1), \quad (5)$$

$$x_t = x_{t+1-n} + w_{m3}^n \cdot (f_t^n - f_t^1), \quad (6)$$

$$m_t^1 = x_{t-1} + w_{m1} \cdot (x_{t-1} - x_{t-2}) + w_{m2} \cdot (f_t^1 - f_{t-1}^1), \quad (7)$$

$$m_t^n = m_t^1 + w_{m3}^n \cdot (f_t^n - f_t^1), \quad (8)$$

式中, x_t 表示第 t 天的水温实测值; $f_t^1, f_t^2, \dots, f_t^7$ 表示第 t 天发布的未来 1~7 d 气温预报数据; $m_t^1, m_t^2, \dots, m_t^7$ 表示模型在第 t 天的未来 1~7 d 水温预测值; w_{m1} 、 w_{m2} 和 w_{m3}^n ($2 \leq n \leq 7$)为权重系数。

2.3.4 变权算法

变权算法原理见式(9)至式(12)。

$$R_i(t) = |f_i(t) - T(t)|, \quad (9)$$

$$D_i(t) = \begin{cases} 1, & \text{第1天,} \\ D_i(t-1), & \text{第}t\text{天且}R_i(t) \neq \min\{R_1(t), R_2(t), R_3(t)\}, \\ D_i(t-1)+1, & \text{第}t\text{天且}R_i(t) = \min\{R_1(t), R_2(t), R_3(t)\}, \end{cases} \quad (10)$$

$$W_i(t+1) = \frac{D_i(t)}{D_1(t) + D_2(t) + D_3(t)}, \quad (11)$$

$$Y(t+1) = \sum_{i=1}^3 W_i(t+1) \cdot F_i(t+1), \quad (12)$$

式中, $R_i(t)$ 表示第 i 个模型在第 t 天的预测误差; $f_i(t)$ 表示第 i 个模型在第 t 天的当天水温预测值; $T(t)$ 表示

表 4 迁移学习测试时 100 次重复实验的平均值统计

Table 4 Statistics of the means of 100 replicates in transfer learning test

预测天数	评价指标	目标域LSTM模型		TLSTM模型(未微调)		TLSTM模型	
		最高温	最低温	最高温	最低温	最高温	最低温
第1天	RMSE/°C	5.42	5.69	0.42	0.31	0.38	0.28
	MAE/°C	5.30	5.54	0.36	0.28	0.35	0.25
	R^2	0.823	0.858	0.990	0.994	0.991	0.995
第2天	RMSE/°C	5.57	5.89	0.52	0.39	0.47	0.34
	MAE/°C	5.45	5.72	0.43	0.33	0.43	0.30
	R^2	0.837	0.833	0.968	0.986	0.968	0.987
第3天	RMSE/°C	5.74	6.02	0.62	0.47	0.57	0.43
	MAE/°C	5.61	5.87	0.52	0.40	0.51	0.37
	R^2	0.795	0.812	0.931	0.971	0.931	0.971
第4天	RMSE/°C	5.96	6.17	0.75	0.57	0.68	0.52
	MAE/°C	5.84	6.02	0.61	0.46	0.61	0.44
	R^2	0.740	0.805	0.884	0.950	0.886	0.951
第5天	RMSE/°C	6.22	6.37	0.84	0.64	0.76	0.59
	MAE/°C	6.09	6.22	0.69	0.52	0.68	0.50
	R^2	0.671	0.795	0.834	0.932	0.839	0.933
第6天	RMSE/°C	6.42	6.53	0.91	0.71	0.83	0.65
	MAE/°C	6.30	6.38	0.75	0.58	0.75	0.56
	R^2	0.665	0.760	0.783	0.913	0.794	0.914
第7天	RMSE/°C	6.61	6.70	0.97	0.79	0.88	0.73
	MAE/°C	6.49	6.54	0.80	0.65	0.81	0.64
	R^2	0.653	0.749	0.737	0.882	0.759	0.884

3.2 变权组合测试

选取 TLSTM 模型、纯差分回归模型、混差分回归模型和 DR-TLSTM 集成模型, 进行未来 1~7 d 的日最高水温和日最低水温和的预测, 测试结果见表 5 和图 3。TLSTM 模型未来 1~7 d 水温预测值的 RMSE 为 0.28~0.88°C, MAE 为 0.25~0.81°C, R^2 为 0.759~0.995; 纯差分回归模型未来 1~7 d 水温预测值的 RMSE 为 0.14~0.93°C, MAE 为 0.11~0.77°C, R^2 为 0.775~0.996; 混差分回归模型未来 1~7 d 水温预测值的 RMSE 为 0.15~0.95°C, MAE 为 0.11~0.74°C, R^2 为 0.793~0.995; DR-TLSTM 集成模型未来 1~7 d 水温预测值的 RMSE 为 0.13~0.77°C, MAE 为 0.11~0.71°C, R^2 为 0.791~0.996。

以上结果表明, 相较于 3 种单一模型, DR-TLSTM 集成模型的预测精度最高, 且 100 次测试相关评估指

标的标准差低于 TLSTM 模型。考虑到 TLSTM 模型和回归模型在不同时刻的预测误差不同, 集成模型每日采用变权算法对模型的组合权重进行更新, 赋予最佳单一模型最大权重, 使得预测精度和稳定性均得到有效提升。将 TLSTM 模型和回归模型进行集成应用, 既能保留 LSTM 模型处理非线性数据的优势, 又能发挥回归模型对预报气温数据和水温数据的拟合优势。在刘明等^[34]和康俊锋等^[35]的变权组合测试中, 也发现组合模型的预测效果优于单一模型。

3.3 突变点测试

选取 TLSTM 模型、纯差分回归模型、混差分回归模型和 DR-TLSTM 集成模型, 对水温突变点进行未来 1~7 d 的日最高水温和日最低水温和的预测, 测试结果见表 6 和图 4。TLSTM 模型未来 1~7 d 水温突变点预测值的 RMSE 为 0.29~1.33°C, MAE 为 0.39~




图2 迁移学习对模型预测三沙湾未来1~7 d水温的影响

Fig. 2 The influence of transfer learning on the prediction of water temperature for the next 1–7 days in the Sansha Bay

a, c, e. 最高温 100 次重复测试的均方根误差(RMSE)、平均绝对误差(MAE)、拟合优度(R^2)的平均值和标准差; b, d, f. 最低温 100 次重复测试的均方根误差(RMSE)、平均绝对误差(MAE)、拟合优度(R^2)的平均值和标准差

a, c, e. Means and standard deviations of root mean square error (RMSE), mean absolute error (MAE), goodness of fit (R^2) of 100 replicates at the maximum temperature; b, d, f. means and standard deviations of root mean square error (RMSE), mean absolute error (MAE), goodness of fit (R^2) of 100 replicates at the minimum temperature

表5 变权组合测试时 100 次重复实验的平均值统计

Table 5 Statistics of the means of 100 replicates in variable-weight combination test

预测天数	评价指标	TLSTM模型		纯差分回归模型		混差分回归模型		DR-TLSTM集成模型	
		最高温	最低温	最高温	最低温	最高温	最低温	最高温	最低温
第1天	RMSE/°C	0.38	0.28	0.16	0.14	0.15	0.15	0.13	0.13
	MAE/°C	0.35	0.25	0.12	0.11	0.11	0.11	0.11	0.11
	R^2	0.991	0.995	0.994	0.996	0.995	0.995	0.995	0.996
第2天	RMSE/°C	0.47	0.34	0.30	0.25	0.31	0.25	0.26	0.22
	MAE/°C	0.43	0.30	0.23	0.30	0.22	0.17	0.22	0.18
	R^2	0.968	0.987	0.978	0.989	0.978	0.989	0.978	0.989
第3天	RMSE/°C	0.57	0.43	0.45	0.37	0.48	0.37	0.39	0.33
	MAE/°C	0.51	0.37	0.34	0.29	0.33	0.26	0.33	0.27
	R^2	0.931	0.971	0.946	0.975	0.947	0.975	0.947	0.975
第4天	RMSE/°C	0.68	0.52	0.60	0.48	0.63	0.48	0.51	0.44
	MAE/°C	0.61	0.44	0.46	0.38	0.43	0.35	0.43	0.36
	R^2	0.886	0.951	0.902	0.956	0.906	0.956	0.905	0.956
第5天	RMSE/°C	0.76	0.59	0.71	0.57	0.74	0.57	0.60	0.51
	MAE/°C	0.68	0.50	0.55	0.47	0.53	0.44	0.52	0.43
	R^2	0.839	0.933	0.863	0.939	0.870	0.941	0.867	0.940

续表 5

预测天数	评价指标	TLSTM模型		纯差分回归模型		混差分回归模型		DR-TLSTM集成模型	
		最高温	最低温	最高温	最低温	最高温	最低温	最高温	最低温
第6天	RMSE/°C	0.83	0.65	0.81	0.67	0.83	0.67	0.68	0.59
	MAE/°C	0.75	0.56	0.66	0.58	0.63	0.54	0.62	0.52
	R^2	0.794	0.914	0.822	0.917	0.834	0.922	0.831	0.921
第7天	RMSE/°C	0.88	0.73	0.93	0.79	0.95	0.79	0.77	0.69
	MAE/°C	0.81	0.64	0.77	0.68	0.74	0.65	0.71	0.63
	R^2	0.759	0.884	0.775	0.884	0.793	0.889	0.791	0.890




图 3 变权组合对模型预测三沙湾未来 1~7 d 水温的影响

Fig. 3 Influence of variable-weight combination on the predicted water temperature for the next 1–7 days in the Sansha Bay

a, c, e. 最高温 100 次重复测试的均方根误差 (RMSE)、平均绝对误差 (MAE)、拟合优度 (R^2) 的平均值和标准差; b, d, f. 最低温 100 次重复测试的均方根误差 (RMSE)、平均绝对误差 (MAE)、拟合优度 (R^2) 的平均值和标准差

a, c, e. Means and standard deviations of root mean square error (RMSE), mean absolute error (MAE), goodness of fit (R^2) of 100 replicates at the maximum temperature; b, d, f. means and standard deviations of root mean square error (RMSE), mean absolute error (MAE), goodness of fit (R^2) of 100 replicates at the minimum temperature

表 6 突变点测试时 100 次重复实验的平均值统计

Table 6 Statistics of the means of 100 replicates in sudden change point prediction test

预测天数	评价指标	TLSTM模型		纯差分回归模型		混差分回归模型		DR-TLSTM集成模型	
		最高温	最低温	最高温	最低温	最高温	最低温	最高温	最低温
第1天	RMSE/°C	0.44	0.29	0.42	0.32	0.40	0.34	0.35	0.29
	MAE/°C	0.40	0.39	0.36	0.30	0.33	0.29	0.33	0.29
	R^2	0.992	0.992	0.995	0.993	0.996	0.993	0.996	0.994
第2天	RMSE/°C	0.71	0.61	0.75	0.63	0.78	0.63	0.65	0.57
	MAE/°C	0.66	0.60	0.58	0.60	0.56	0.52	0.57	0.56
	R^2	0.940	0.935	0.954	0.951	0.954	0.951	0.954	0.951

续表 6

预测天数	评价指标	TLSTM模型		纯差分回归模型		混差分回归模型		DR-TLSTM集成模型	
		最高温	最低温	最高温	最低温	最高温	最低温	最高温	最低温
第3天	RMSE/°C	1.07	0.77	1.02	0.67	1.08	0.67	0.89	0.61
	MAE/°C	0.95	0.72	0.80	0.75	0.76	0.69	0.76	0.71
	R^2	0.798	0.705	0.806	0.747	0.808	0.747	0.807	0.747
第4天	RMSE/°C	1.31	0.95	1.01	0.81	1.06	0.81	0.87	0.74
	MAE/°C	1.13	0.95	0.85	0.92	0.80	0.85	0.80	0.87
	R^2	0.729	0.693	0.782	0.780	0.785	0.781	0.784	0.781
第5天	RMSE/°C	1.32	0.95	1.18	0.99	1.23	0.99	1.01	0.90
	MAE/°C	1.04	0.94	0.89	0.95	0.85	0.88	0.84	0.88
	R^2	0.666	0.672	0.788	0.729	0.794	0.731	0.792	0.730
第6天	RMSE/°C	1.33	1.00	1.19	1.07	1.23	1.07	1.01	0.95
	MAE/°C	1.03	1.05	1.00	1.07	0.94	1.00	0.94	0.98
	R^2	0.693	0.691	0.712	0.694	0.722	0.698	0.720	0.698
第7天	RMSE/°C	1.23	1.03	1.31	1.11	1.34	1.12	1.09	0.98
	MAE/°C	1.07	1.06	1.02	1.02	0.97	0.97	0.95	0.95
	R^2	0.630	0.450	0.636	0.526	0.651	0.529	0.649	0.530




图 4 变权组合对模型预测三沙湾未来 1~7 d 水温突变点的影响

Fig. 4 Influence of variable-weight combination on the prediction of water temperature sudden change point for the next 1-7 days in the Sansha Bay

a, c, e. 最高温 100 次重复测试的均方根误差 (RMSE)、平均绝对误差 (MAE)、拟合优度 (R^2) 的平均值和标准差; b, d, f. 最低温 100 次重复测试的均方根误差 (RMSE)、平均绝对误差 (MAE)、拟合优度 (R^2) 的平均值和标准差

a, c, e. Means and standard deviations of root mean square error (RMSE), mean absolute error (MAE), goodness of fit (R^2) of 100 replicates at the maximum temperature; b, d, f. means and standard deviations of root mean square error (RMSE), mean absolute error (MAE), goodness of fit (R^2) of 100 replicates at the minimum temperature

1.13℃, R^2 为 0.450~0.992; 纯差分回归模型未来 1~7 d 水温突变点预测值的 RMSE 为 0.32~1.31℃, MAE 为 0.30~1.07℃, R^2 为 0.526~0.995; 混差分回归模型未来 1~7 d 水温突变点预测值的 RMSE 为 0.34~1.34℃, MAE 为 0.29~1.00℃, R^2 为 0.529~0.996; DR-TLSTM 集成模型未来 1~7 d 水温突变点预测值的 RMSE 为 0.29~1.09℃, MAE 为 0.29~0.98℃, R^2 为 0.530~0.996。

近年来,全球极端海温(如热浪、寒潮)的出现频次和强度均呈上升趋势^[36],受气候变化和区域地理特征等因素的影响^[37],现有的模型方法难以准确预测极端海温。海温突变(骤升和骤降)能较好地指示极端海温事件的出现,对海温突变点进行预测有助于进行海水养殖的应急防范。相较于单一模型,本文构建的 DR-TLSTM 集成模型对水温突变点的预测精度最

高,且 100 次测试相关评估指标的标准差最低,说明该模型能更加稳定有效地预测水温突变趋势,可为极端海温灾害预警提供技术支撑。

3.4 模型预测结果与业务化应用效果

3.4.1 模型预测结果

模型每日得到包括当日在内的未来 1~7 d 水温预测值,以三沙湾 2021 年 12 月 25 日至 2022 年 3 月 10 日水温实测数据为研究对象,与 TLSTM 模型、纯差分回归模型、混差分回归模型和 DR-TLSTM 模型得到的第 1 天至第 7 天预测值进行对比,对比结果见图 5。

与已有的研究报道相比,本文构建的 DR-TLSTM 模型在目标域实测数据量较少的情况下,水温预测精度高于其他基于大量目标域数据构建的 LSTM

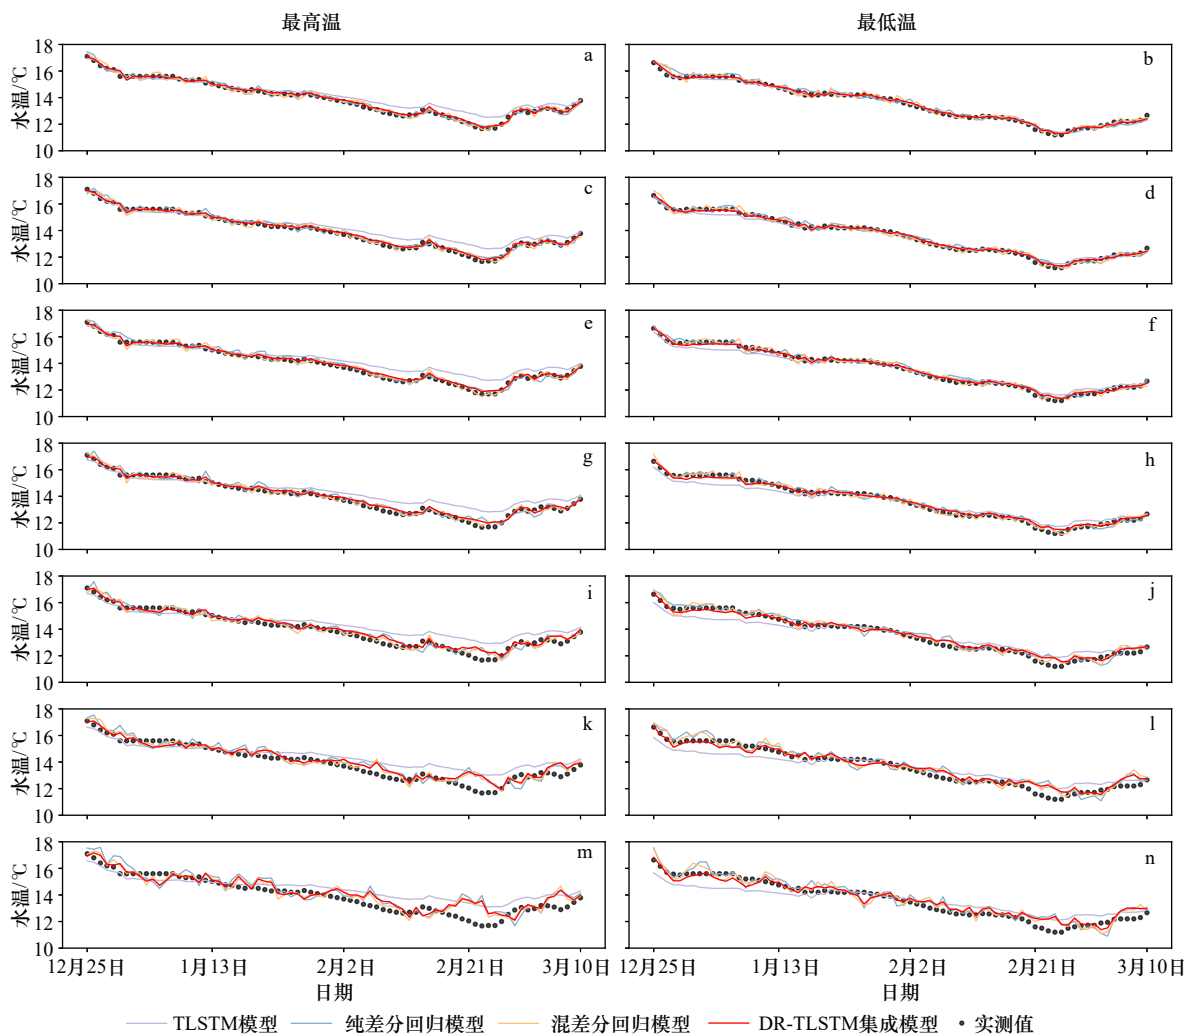


图 5 三沙湾未来 1~7 d 水温实测值和模型预测值对比(2021-2022 年)

Fig. 5 Comparison of observed and predicted water temperature for the next 1-7 days in the Sansha Bay (2021-2022)

a, b. 第 1 天对比结果; c, d. 第 2 天对比结果; e, f. 第 3 天对比结果; g, h. 第 4 天对比结果; i, j. 第 5 天对比结果; k, l. 第 6 天对比结果; m, n. 第 7 天对比结果
a, b. Comparison results on day 1; c, d. comparison results on day 2; e, f. comparison results on day 3; g, h. comparison results on day 4; i, j. comparison results on day 5; k, l. comparison results on day 6; m, n. comparison results on day 7

模型。例如,取各研究模型的第1天预测值的RMSE进行对比,本文构建的DR-TLSTM模型的RMSE可达0.13℃,而Hou等^[16]构建的密集扩张卷积LSTM模型、Yang等^[17]构建的全连接卷积LSTM模型和Kim等^[19]构建的LSTM模型的RMSE分别为0.39℃、0.15℃和0.40℃。因此,DR-TLSTM模型的水温预测性能佳,对于监测资料较少的区域有良好的推广应用潜力。

3.4.2 模型业务化应用效果

模型集成于“福建省智慧渔业水质监测与预警系

统(三沙湾)”,基于湾内3个渔排基在线监测水温数据和天气预报数据进行水温预测,通过GIS可视化提供水温等级预警预报信息服务(图6)。以水温等级预测准确率为评价指标,统计DR-TLSTM模型在2021年12月16日至2022年6月1日每日发布的未来1~7d预警结果。表7表明,模型对未来1~3d的水温等级预测准确率高于91%,未来1~7d水温等级预测准确率高于79%,可为渔业生产和管理用户提供重要的信息参考。



图6 基于差分回归(DR)与可迁移长短期记忆网络(TLSTM)集成的DR-TLSTM模型应用于三沙湾水温预警预报业务化的信息系统界面

Fig. 6 Operational information system interface based on water temperature early warning and forecast in the Sansha Bay by DR-TLSTM model based on differential regression (DR) and transferable long short-term memory (TLSTM)

表7 基于差分回归(DR)与可迁移长短期记忆网络(TLSTM)集成的DR-TLSTM模型对三沙湾水温预警准确率的统计结果

Table 7 Statistical results of DR-TLSTM model based on differential regression (DR) and transferable long short-term memory (TLSTM) for water temperature early warning accuracy in the Sansha Bay

设备编号	第1天	第2天	第3天	第4天	第5天	第6天	第7天
1#渔排基	96.27%	94.03%	91.04%	88.06%	84.33%	82.84%	82.09%
2#渔排基	95.52%	94.03%	91.04%	88.06%	85.82%	83.58%	80.60%
3#渔排基	97.76%	95.52%	91.79%	91.79%	88.06%	87.31%	79.10%

4 结论

本文提出了一种DR-TLSTM集成模型,通过厦门湾源域(数据多)和三沙湾目标域(数据少)之间的迁

移学习,采用变权算法将纯差分回归模型、混差分回归模型和TLSTM模型集成为三沙湾DR-TLSTM模型,有效解决了海湾水温监测数据不足和随机扰动(水温骤升或骤降)预测困难的问题,显著提升了水温

短期预测的效果,具有预测精度高、稳定性强的优点。该模型已集成于“福建省智慧渔业水质监测与预警系统(三沙湾)”,并于2021年9月起开始持续运行,每日提供三沙湾实时水质动态和未来7日的海温

预警预报单,为渔业生产和管理提供技术支撑与信息服务。本文构建的DR-TLSTM集成模型对于缺乏历史监测数据区域的水温预测具有重要的参考价值,也有良好的推广应用潜力。

参考文献:

- [1] 田梓杨, 黄洪辉, 齐占会, 等. 大鹏澳海湾养殖生态环境的化学计量分析[J]. 中国水产科学, 2012, 19(5): 881–888.
Tian Ziyang, Huang Honghui, Qi Zhanhui, et al. Using chemometric methods to study the mariculture eco-environment in Dapeng Cove, China[J]. Journal of Fishery Sciences of China, 2012, 19(5): 881–888.
- [2] 程建新, 肖佳媚, 陈明茹, 等. 兴化湾海湾生态系统退化评价[J]. 厦门大学学报(自然科学版), 2012, 51(5): 944–950.
Cheng Jianxin, Xiao Jiamei, Chen Mingru, et al. Ecosystem degradation assessment of Xinghua Bay[J]. Journal of Xiamen University (Natural Science), 2012, 51(5): 944–950.
- [3] Rabalais N N. Human impacts on fisheries across the land-sea interface[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2015, 112(26): 7892–7893.
- [4] 肖应凯, 刘卫国, 马云麒, 等. 鹿角珊瑚 $\delta^{18}\text{O}$, Sr/Ca和Mg/Ca比值与海水表面温度的相关性研究——不同海水温度下的珊瑚养殖实验[J]. 中国科学: 地球科学, 2014, 57(5): 1048–1060.
Xiao Yingkai, Liu Weiguang, Ma Yunqi, et al. Correlation between $\delta^{18}\text{O}$, Sr/Ca and Mg/Ca of coral *Acropora* and seawater temperature from coral culture experiments[J]. *Science China Earth Sciences*, 2014, 57(5): 1048–1060.
- [5] 胡石建, 李诗翰. 海洋热浪研究进展与展望[J]. 地球科学进展, 2022, 37(1): 51–64.
Hu Shijian, Li Shihan. Progress and prospect of marine heatwave study[J]. *Advances in Earth Science*, 2022, 37(1): 51–64.
- [6] Biswas B K, Svirezhev Y M, Bala B K. A model to predict climate-change impact on fish catch in the world oceans[J]. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 2005, 35(6): 773–783.
- [7] Gianelli I, Ortega L, Marín Y, et al. Evidence of ocean warming in Uruguay's fisheries landings: the mean temperature of the catch approach[J]. *Marine Ecology Progress Series*, 2019, 625: 115–125.
- [8] Wang Wenyu, Zhou Chenghu, Shao Quanqin, et al. Remote sensing of sea surface temperature and chlorophyll-*a*: implications for squid fisheries in the north-west Pacific Ocean[J]. *International Journal of Remote Sensing*, 2010, 31(17/18): 4515–4530.
- [9] Wheeland L J, Morgan M J. Age-specific shifts in Greenland halibut (*Reinhardtius hippoglossoides*) distribution in response to changing ocean climate[J]. *ICES Journal of Marine Science*, 2020, 77(1): 230–240.
- [10] Zisserson B, Cook A. Impact of bottom water temperature change on the southernmost snow crab fishery in the Atlantic Ocean[J]. *Fisheries Research*, 2017, 195: 12–18.
- [11] 卢峰本, 黄滢, 周启强, 等. 海水养殖的气象风险分析及预报[J]. 气象, 2006, 32(11): 113–117.
Lu Fengben, Huang Ying, Zhou Qiqiang, et al. Meteorological risk analysis and forecast to mariculture production[J]. *Meteorological Monthly*, 2006, 32(11): 113–117.
- [12] Xie Jiang, Zhang Jiyuan, Yu Jie, et al. An adaptive scale sea surface temperature predicting method based on deep learning with attention mechanism[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(5): 740–744.
- [13] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735–1780.
- [14] 刘建伟, 宋志妍. 循环神经网络研究综述[J]. 控制与决策, 2022, 37(11): 2753–2768.
Liu Jianwei, Song Zhiyan. Overview of recurrent neural networks[J]. *Control and Decision*, 2022, 37(11): 2753–2768.
- [15] Zhang Qin, Wang Hui, Dong Junyu, et al. Prediction of sea surface temperature using long short-term memory[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(10): 1745–1749.
- [16] Hou Siyun, Li Wen'gen, Liu Tianying, et al. D2CL: a dense dilated convolutional LSTM model for sea surface temperature prediction[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 12514–12523.
- [17] Yang Yuting, Dong Junyu, Sun Xin, et al. A CFCC-LSTM model for sea surface temperature prediction[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(2): 207–211.
- [18] 张昆. 基于深度学习的深海遥感技术研究[D]. 厦门: 厦门大学, 2019.
Zhang Kun. Research on deep-ocean remote sensing by deep learning[D]. Xiamen: Xiamen University, 2019.
- [19] Kim M, Yang H, Kim J. Sea surface temperature and high water temperature occurrence prediction using a long short-term memory model[J]. *Remote Sensing*, 2020, 12(21): 3654.
- [20] 李嘉康, 李其杰, 赵颖, 等. 基于CEEMD-BP神经网络的海温异常预测研究[J]. 数学的实践与认识, 2017, 47(24): 163–171.
Li Jiakang, Li Qijie, Zhao Ying, et al. Sea surface temperature anomaly forecast research based on CEEMD-BP neural network[J]. *Mathematics in Practice and Theory*, 2017, 47(24): 163–171.
- [21] 董璐, 周天军. 20世纪太平洋海温变化中人为因子与自然因子贡献的模拟研究[J]. 海洋学报, 2014, 36(3): 48–60.
Dong Lu, Zhou Tianjun. Contributions of natural and anthropogenic forcings to the twentieth-century Pacific sea surface temperature variability simulated by a climate system model[J]. *Haiyang Xuebao*, 2014, 36(3): 48–60.

- [22] 田远洋, 徐显涛, 彭安帮, 等. 训练数据量对LSTM网络学习性能影响分析[J]. 水文, 2022, 42(1): 29–34, 22.
Tian Yuanyang, Xu Xiantao, Peng Anbang, et al. Effects of training data on the study performance of LSTM network[J]. Journal of China Hydrology, 2022, 42(1): 29–34, 22.
- [23] Zhuang Fuzhen, Qi Zhiyuan, Duan Keyu, et al. A comprehensive survey on transfer learning[J]. *Proceedings of the IEEE*, 2021, 109(1): 43–76.
- [24] 黎英, 宋佩华. 迁移学习在医学图像分类中的研究进展[J]. 中国图象图形学报, 2022, 27(3): 672–686.
Li Ying, Song Peihua. Review of transfer learning in medical image classification[J]. *Journal of Image and Graphics*, 2022, 27(3): 672–686.
- [25] 张晓, 李业刚, 王栋, 等. 基于迁移学习的社交评论命名实体识别[J]. 计算机应用与软件, 2022, 39(1): 143–150.
Zhang Xiao, Li Yegang, Wang Dong, et al. Social comment named entity recognition based on transfer learning[J]. *Computer Applications and Software*, 2022, 39(1): 143–150.
- [26] 王义刚, 宋志尧, 姜翠玲, 等. 福建省海湾数模与环境研究: 三沙湾[M]. 北京: 海洋出版社, 2009.
Wang Yigang, Song Zhiyao, Jiang Cuiling, et al. Numerical Modeling and Environmental Study of Gulf in Fujian Province: Sansha Bay[M]. Beijing: China Ocean Press, 2009.
- [27] 厦门市地方志编纂委员会. 厦门市志[M]. 北京: 方志出版社, 2004.
Xiamen Local Chronicle Compilation Committee. County Annals of Xiamen[M]. Beijing: Local Records Publishing House, 2004.
- [28] 欧阳俊峰. 福建沿海滩涂微型真核生物群落结构及对生物修复的响应[D]. 厦门: 集美大学, 2016.
Ouyang Junfeng. Microeukaryotic community structure and response to bioremediation in intertidal mudflats of Fujian coast[D]. Xiamen: Jimei University, 2016.
- [29] 王翠, 郭晓峰, 方婧, 等. 闽浙沿岸流扩展范围的季节特征及其对典型海湾的影响[J]. 应用海洋学学报, 2018, 37(1): 1–8.
Wang Cui, Guo Xiaofeng, Fang Jing, et al. Characteristics of seasonal spatial expansion of Fujian and Zhejiang Coastal Current and their bay effects[J]. *Journal of Applied Oceanography*, 2018, 37(1): 1–8.
- [30] Yu Yong, Si Xiaosheng, Hu Changhua, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. *Neural Computation*, 2019, 31(7): 1235–1270.
- [31] Pan S J, Yang Qiang. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345–1359.
- [32] 福建省科学技术厅. 大黄鱼养殖[M]. 北京: 海洋出版社, 2004.
Province Department of Science and Technology of Fujian. Breeding and farming of *Pseudosciaena Crocea*[M]. Beijing: China Ocean Press, 2004.
- [33] Yosinski J, Clune J, Bengio Y, et al. How transferable are features in deep neural networks?[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal: MIT Press, 2014.
- [34] 刘明, 王红蕾, 索良泽. 基于变权组合模型的中长期负荷概率密度预测[J]. 电力系统及其自动化学报, 2019, 31(7): 88–94.
Liu Ming, Wang Honglei, Suo Liangze. Medium- and long-term load probability density forecasting based on variable weight combination model[J]. *Proceedings of the CSU-EPSCA*, 2019, 31(7): 88–94.
- [35] 康俊锋, 谭建林, 方雷, 等. XGBoost-LSTM变权组合模型支持下短期PM2.5浓度预测——以上海为例[J]. 中国环境科学, 2021, 41(9): 4016–4025.
Kang Junfeng, Tan Jianlin, Fang Lei, et al. Short-term PM2.5 concentration prediction based on XGBoost and LSTM variable weight combination model: a case study of Shanghai[J]. *China Environmental Science*, 2021, 41(9): 4016–4025.
- [36] Benthuisen J A, Oliver E C J, Feng Ming, et al. Extreme marine warming across tropical Australia during austral summer 2015–2016[J]. *Journal of Geophysical Research: Oceans*, 2018, 123(2): 1301–1326.
- [37] 齐庆华, 蔡榕硕. 中国近海海面温度变化的极端特性及其气候特征研究[J]. 海洋学报, 2019, 41(7): 36–51.
Qi Qinghua, Cai Rongshuo. Analysis on climate characteristics of sea surface temperature extremes in coastal China seas[J]. *Haiyang Xuebao*, 2019, 41(7): 36–51.

Water temperature prediction in the Sansha Bay based on the integration of differential regression model and transportable long short-term memory network

Lai Xiaoqian¹, Yu Yiqi², Liang Zhongyao², Chen Huorong³, Chen Nengwang^{1,2}

(1. State Key Laboratory of Marine Environmental Science, Xiamen University, Xiamen 361102, China; 2. Fujian Provincial Key Laboratory for Coastal Ecology and Environmental Studies, Xiamen University, Xiamen 361102, China; 3. Fishery Resources Monitoring Center of Fujian Province, Fuzhou 350003, China)

Abstract: Water temperature prediction is a key technology to ensure the production of coastal fisheries and environmental safety. The existing numerical models have high development costs with insufficient business applications. This study develops a prediction method of water temperature through integrating differential regression (DR) and transferable long short-term memory (TLSTM). Taking the water temperature of Xiamen Bay (source domain, with a large number of data) and Sansha Bay (target domain, with less data) as the research object, the DR model is established based on the data of monitoring water temperature and forecast temperature in the Sansha Bay, and the TLSTM model is established based on the long-term monitoring data of water temperature in the Xiamen Bay. The pure differential regression model, mixed differential regression model and TLSTM model are integrated into the DR-TLSTM model of Sansha Bay by using variable weight algorithm, and the performance of the model is evaluated, the results are compared with the LSTM model based on only a small amount of monitoring data in the Sansha Bay. The results show that: (1) the prediction accuracy of TLSTM model is better than that of LSTM model based on a small amount of data in the target domain; (2) the DR-TLSTM model has high prediction accuracy, and the root mean square error of prediction in the next 1–7 days is 0.13–0.77°C, and the root mean square error of prediction in the next 1–3 days is less than 0.4°C; (3) the DR-TLSTM model can effectively predict the sudden rise or fall trend of water temperature, and the root mean square error of predicting the sudden change point of water temperature is 0.29–1.09°C. Based on the DR-TLSTM model, the operational information service of water temperature early warning and forecast in the Sansha Bay is realized.

Key words: water temperature prediction; regression model; LSTM model; transfer learning; variable weight integration