doi:10.6041/j.issn.1000-1298.2025.11.057

基于 MTL - LSTM - SAT 的养殖鱼类患病及生长预测模型构建与试验

王　朕[1,2]　陈　聪[1]　曹光乔[1,3]　朱　虹[4]　沈启扬[4]　赵　伟[2]
(1. 农业农村部南京农业机械化研究所, 南京 210014; 2. 咸宁市农业科学院, 咸宁 437000;
3. 中国农业科学院研究生院, 北京 100081; 4. 江苏省农机具开发应用中心, 南京 210014)

摘要: 随着集约化鱼类养殖的发展,养殖管理对水质监测与鱼类健康评估提出了更高要求。为了实现基于多模态水质数据的鱼类生长速度与患病比例的联合预测,本文提出一种融合长短记忆神经网络(LSTM)与软注意力机制的多任务学习模型(MTL - LSTM - SAT)。选取湖北省咸宁市养殖基地的集约化养殖红罗非鱼作为试验对象,采集 pH 值、水温、溶解氧质量浓度、氨氮质量浓度、投饲量等环境因子及鱼类体质量、健康状态数据,构建时间序列输入、输出特征。通过引入 LSTM 结构提取水质变化的时序特征,并结合软注意力机制聚焦关键时间步,有效提升了模型对复杂环境动态的建模能力。试验结果表明,本文模型在鱼类生长速度预测中,平均绝对误差(MAE)为 0.074 g/d,均方根误差(RMSE)为 0.092 g/d;在患病比例预测中,MAE 为 0.000 97,RMSE 为 0.001 22,相较于传统 RNN、GRU、BiLSTM、LSTM 与单任务模型均有显著提升。多组对比试验与消融试验验证了本模型在准确性、稳定性与泛化能力方面的优越表现。研究结果为智能化鱼类养殖策略优化提供了理论支撑与算法工具。

关键词: 水产养殖; 多任务学习; 时序记忆; 水质监测; 预测模型
中图分类号: S951.2; TP18.2　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0590-09　　**OSID**:

Construction and Evaluation of Prediction Model for Disease and Growth of Farmed Fish Based on MTL - LSTM - SAT

WANG Zhen[1,2]　CHEN Cong[1]　CAO Guangqiao[1,3]　ZHU Hong[4]　SHEN Qiyang[4]　ZHAO Wei[2]
(1. *Nanjing Institute of Agricultural Mechanization*, *Ministry of Agriculture and Rural Affairs*, *Nanjing* 210014, *China*
2. *Xianning Academy of Agricultural Sciences*, *Xianning* 437000, *China*
3. *Graduate School*, *Chinese Academy of Agricultural Sciences*, *Beijing* 100081, *China*
4. *Jiangsu Provincial Agricultural Machinery Development and Application Center*, *Nanjing* 210014, *China*)

Abstract: With the development of intensive aquaculture, the demand for precise water quality monitoring and fish health assessment has increased significantly. A multi-task learning model was proposed based on long short-term memory networks with a soft attention mechanism (MTL - LSTM - SAT) to jointly predict fish growth rate and disease incidence by using multimodal water quality data. Nile tilapia (*Oreochromis niloticus*) cultured in an aquaculture base in Xianning, Hubei Province, was selected as the experimental subject. Time-series data of environmental factors such as pH value, water temperature, dissolved oxygen, ammonia nitrogen concentration, and feeding amount, as well as fish body weight and health condition, were collected to construct the model input. The LSTM structure captured temporal patterns in water quality dynamics, while the integrated soft attention mechanism enabled the model to focus on critical time steps, enhancing its modeling capability for complex environmental fluctuations. Experimental results showed that the proposed model achieved a mean absolute error (MAE) of 0.074 g/d and root mean square error (RMSE) of 0.092 g/d in growth rate prediction, and a MAE of 0.000 97 and RMSE of 0.001 22 in disease incidence prediction. These results outperformed baseline models, including RNN, GRU, and single-task learning approaches. Multiple comparative and ablation experiments further demonstrated the model's superior accuracy, robustness, and generalization performance. The proposed method offered a promising solution for intelligent fish farming and provided a valuable tool for aquaculture management and decision-making.

Key words: aquaculture; multi-task learning; temporal memory; water quality monitoring; prediction model

收稿日期: 2025-04-29　修回日期: 2025-06-05
基金项目: 江苏省现代农机装备与技术示范推广项目(NJ2023-56)
作者简介: 王朕(1989—),男,博士生,咸宁市农业科学院工程师,主要从事智能化农业装备理论及设计研究,E-mail: wangzhen@xnaas.cn
通信作者: 曹光乔(1978—),男,研究员,博士生导师,主要从事农机化管理工程研究,E-mail: caoguangqiao@126.com

0　引言

人工智能和现代传感器技术发展推动了现代集约化养殖技术进步。水下摄像装置采集鱼类活动数据，机器学习算法采集鱼类健康、生长、养殖密度及数量等指标，现代传感器精准采集溶解氧质量浓度、pH 值、氨氮质量浓度、水温等水质信号。这些监测信息实时提供给养殖者，辅助其决策，提高了养殖效率。比如，氨氮质量浓度过高会使鱼类疾病高发，水温不适会影响鱼类摄食，养殖密度过大则会导致氨氮质量浓度升高等。尽管养殖者获取的信息量大幅增加，但综合分析海量数据仍高度依赖其经验和精力。因此，目前亟需一种能进一步辅助养殖者调整养殖管理策略的智能化方法[1－4]。

近年来，学者研究鱼类生长与养殖环境的关系，并结合智能算法优化养殖条件，提出智能饲养策略。PAUTSINA 等[5]、WEI 等[6]检测鱼类复杂行为，改进综合性鱼类行为及饲养算法，但因硬件易被藻类泥沙污染，应用场景有限。孙龙清等[7]利用监测水质来进行池塘养殖鱼类的精准投饲。SKOIEN 等[8]用水下摄像机采集饲料食用情况并结合算法分析金枪鱼进食行为，误差小，但仅对金枪鱼养殖有参考性。LI 等[9]构建水质环境因子与鱼病关系模型开发鱼病预警系统。陈浩成等[10]通过 BP 网络模型构建以多种条件为输入因子、鱼病种类为输出结果的鱼病诊断模型。随着人工智能、传感器及无线通讯等现代工业技术的发展，越来越多的研究人员对这一领域进行了更深入研究，魏天娇等[11]利用融合的人工智能技术来判断鱼类行为与水质之间的关系。赵建等[12]将图像识别技术用于循环水养殖，对鱼群饥饿状态下的活动特性分级，以此指导投饲设备运行。周超等[13－14]结合计算机视觉、红外光谱及水质环境因子技术研究鱼类摄食行为，解决投喂量不合理导致的水质污染和饲料浪费问题，推动鱼类养殖智能化、现代化。BIAZI 等[15]综合现有成果，提出结合水下摄像系统捕捉鱼类行为特征、传感网络收集水质信息、物联网传输存储数据、大型数据模型支持数据解释决策、自动化设备完成饲养任务的现代饲养策略。

多任务学习（MTL）提出可通过联合学习多个不同但相关任务的模型，提高不同情境下的预测性能。各类水质环境数据与鱼类生长情况强相关，养殖数据是有丰富关系结构的先验数据，为应用 MTL 提供背景。ACHILLE 等[16]解决了多任务学习中的任务表示问题，ZHANG 等[17]研究了用几何推理场景深度和语义优化多任务学习效果。不过，多任务学习模型在学习时对每个任务都用提取到的所有特征，水产养殖中因鱼类生长阶段、季节及天气等因素，训练所得特征可能偏移，需引入长短记忆神经网络算法修正。长短记忆神经网络（LSTM）作为流行的时间序列预测算法，因数据处理能力强，被广泛用于温湿度或天气预测等[18－20]。

本研究基于课题组此前的研究成果[21－22]，利用水下双目摄像头采集鱼类的水下活动图像，并通过改进的视觉识别算法对鱼类的健康状况与生长状态进行识别与分析。

1　数据获取与分析方法

1.1　试验地点

试验于湖北省咸宁市咸安区杨畈高新农业区的水产养殖基地进行，对象为圈养桶内的红罗非鱼。桶直径 4 m，深 2.5 m，由厚 20 mm 的高密度聚乙烯（PE）制成，与外界隔绝性良好。

1.2　数据采集平台

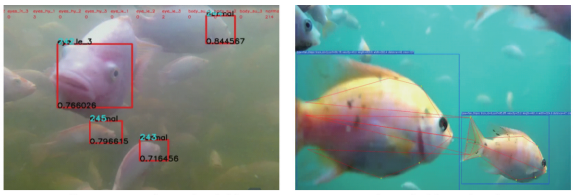
水质数据采集采用定制式的瑞蒙德（REMOND）水质参数在线监测仪，采集水下 1 m 的水质数据，包括盐碱度（pH 值）、水温、氨氮质量浓度、溶解氧质量浓度，鱼类生长情况及健康情况由本团队自主研发的水下自动识别算法进行水下图像采集，每隔 10 min 采集 1 次数据，水下摄像设备为 OAK－D－Pro 型智能广角深度相机，该相机水下摄像后根据鱼类体长、体宽等数据分析体质量及患病情况，并记录每日鱼类投饲量。本文为简化模型，只取每条鱼的体质量平均生长速度；鱼类患病的比例取值范围为 0～1。

表 1 为 7 种数据类型，可控的数据类型为 pH 值、水温、氨氮质量浓度、溶解氧质量浓度、投饲量，被动输出数据类型为患病比例、生长速度。被动输出的两项数据具体获得办法：鱼类疾病识别部分如图 1a 所示，针对患病鱼体表通常出现的异常变化，采用优化后的 YOLO v5 模型对图像中鱼体表的病变特征进行自动识别与分类，进而统计患病个体在整群鱼类中所占比例。鱼类生长状态识别结果如图 1b 所示：

表 1　数据技术参数

Tab.1　Data technical parameters

数据类型	精度	测量范围	测量频率
pH 值	0.01	5.00～9.00	10 min
水温	0.01℃	－50～100℃	10 min
氨氮质量浓度	0.01 mg/L	0.02～150 mg/L	10 min
溶解氧质量浓度	0.01 mg/L	0～15 mg/L	10 min
投饲量	1 g/条	0～1 000 g/条	1 d
生长速度	0.001 g/d	0～1 000 g/d	1 d
患病比例	0.000 1	0～1.0	10 min



(a) 鱼病监测、诊断及统计效果 (b) 鱼类生长情况实时监测

图 1 养殖鱼类情况监测效果

Fig. 1 Monitoring effect of farmed fish conditions

通过识别鱼体关键部位,获取鱼类体长与体宽数据,并据此估算单体体质量,进一步通过对比不同日期的鱼群平均体质量变化,计算单体鱼日均生长速度。将上述两个模型输出的健康与生长数据,与一个完整养殖周期内收集的水质环境数据及每日投喂量数据进行融合,构建融合软注意力机制的长短记忆网络(LSTM)多任务学习框架。该模型旨在实现基于多模态水质数据的鱼类生长速度与健康状态的精准预测,从而为智能化水产养殖管理提供决策支持。

1.3 数据预处理与特征变量选择

在数据预处理阶段,针对水温、pH 值和投喂量等波动较小的指标数据采用 Min - Max 归一化处理,将特征值映射到[0, 1]范围内。而氨氮质量浓度和溶解氧质量浓度等波动较大的指标数据采用 Z -Score 标准化处理,确保模型训练过程中不同特征的权重一致,减少量纲差异对模型性能的影响,即

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{1}$$

式中 x——原始特征值

$x_{\min}$——特征原始特征值最小值

$x_{\max}$——特征原始特征值最大值

x_{norm}——归一化后特征值

$$x_{std} = \frac{x - \mu}{\sigma} \tag{2}$$

式中 μ——该特征值均值

σ——该特征值标准差

x_{std}——标准化后特征值,符合标准正态分布

1.4 相关特征变量

选择皮尔逊相关系数公式对特征变量(pH 值、水温、溶解氧质量浓度、氨氮质量浓度、投喂量)与预测输出值(鱼类患病比例、生长速度)之间的关系进行计算。相关系数(Correlsation coefficient)衡量两个变量之间的线性关系,范围为[-1,1],即

$$\rho_{X,Y} = \frac{\sum (X_i - \overline{X})(Y_i - \overline{Y})}{\sqrt{\sum (X_i - \overline{X})^2 \sum (Y_i - \overline{Y})^2}} \tag{3}$$

式中 X_i——第 i 时刻水温、溶解氧质量浓度、pH 值、氨氮质量浓度或投喂量的输入值

$\rho_{X,Y}$——输入与输出数据的相关系数

Y_i——第 i 时刻体质量增长或患病比例的输出值

$\overline{X}$、$\overline{Y}$——输入、输出数据均值

$\rho_{X,Y}=1$ 完全正相关,$\rho_{X,Y}=-1$ 完全负相关,$\rho_{X,Y}=0$ 无线性关系,当 $\rho_{X,Y}>0$ 时数值越大则正相关性越强,当 $\rho_{X,Y}<0$ 时数值越小则负相关性越强[23-25]。经计算,pH 值、水温、溶解氧质量浓度、氨氮质量浓度、投喂量与鱼类生长速度之间的 $\rho_{X,Y}$ 分别为 0.24、0.78、0.62、-0.86、0.91;pH 值、水温、溶解氧质量浓度、氨氮质量浓度、投喂量与鱼类患病比例之间的 $\rho_{X,Y}$ 分别为 0.21、-0.81、-0.65、0.74、0.59。

2 算法构造与原理

2.1 多任务学习模型构造与工作原理

多任务学习是一种机器学习方法,旨在同时学习多个相关任务。如图 2 所示,利用相关任务中所包含的有用信息,挖掘不同任务之间隐藏的共有数据特征,其通过共享部分网络参数或特征表示,提高各任务的泛化能力,特别适用于数据稀缺或任务间存在关联的情况。应用在鱼类养殖中,可以同时预测鱼类的生长速度(回归任务)和健康状态(分类任务),提高模型的整体性能。输入数据矩阵 $\boldsymbol{X}$,每 1 行代表 1 个时间点观测的水质特征数据,每 1 列代表 1 个具体的特征数值,本文 pH 值、水温、溶解氧质量浓度、氨氮质量浓度、投喂量共 5 列,即

$$\boldsymbol{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1d} \\ x_{21} & x_{22} & \cdots & x_{2d} \\ \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nd} \end{bmatrix} \tag{4}$$

式中 n——样本数量(即行数)

d——特征数量(即列数)

x_{nd}——第 n 个样本的第 d 个特征

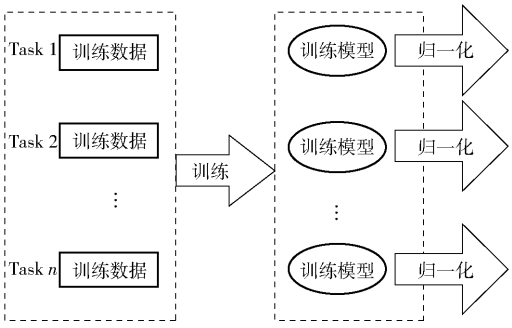


图 2 多任务学习原理结构图

Fig. 2 Schemsatic of multi-task learning

输入数据经过共享层提取通用特征 h

$$h = f_{\text{shared}}(\boldsymbol{X}) = \text{ReLU}(\boldsymbol{W}_{\text{shared}}\boldsymbol{X} + \boldsymbol{b}_{\text{shared}}) \tag{5}$$

式中　f_{shared}——共享层

$\boldsymbol{W}_{\text{shared}}$——共享层权重矩阵

$\boldsymbol{b}_{\text{shared}}$——共享层偏置矩阵

根据不同任务，网络的共享特征会分别传递给不同的任务分支，体质量增长预测值 $\hat{y}_1$ 和患病比例预测值 $\hat{y}_2$ 为

$$\hat{y}_1 = \boldsymbol{W}_1 h + \boldsymbol{b}_1 \tag{6}$$

$$\hat{y}_2 = \sigma(\boldsymbol{W}_2 h + \boldsymbol{b}_2) \tag{7}$$

式中　$\boldsymbol{W}_1$——体质量增长预测权重矩阵

$\boldsymbol{W}_2$——患病比例预测权重矩阵

$\boldsymbol{b}_1$——体质量增长预测偏置矩阵

$\boldsymbol{b}_2$——患病比例预测偏置矩阵

σ——Sigmoid 函数，输出值为 0～1

前向传播计算预测输出后，模型再通过损失函数计算预测值与真实值的差距。在本文的研究方法中，生长速度损失属于回归问题，患病比例虽然是一个分类问题，但是一个连续概率（即模型输出的是 0 到 1 之间的概率值，而不是离散类别），即

$$L = \alpha L_{\text{growth}} + \beta L_{\text{health}} \tag{8}$$

其中

$$L_{\text{growth}} = \frac{1}{N}\sum_{i=1}^{N}(\hat{y}_1^{(i)} - y_1^{(i)})^2 \tag{9}$$

$$L_{\text{health}} = -\frac{1}{N}\sum_{i=1}^{N}[y_2^{(i)}\lg(\hat{y}_2^{(i)}) + (1-y_2^{(i)})\lg(1-\hat{y}_2^{(i)})] \tag{10}$$

式中　L——总损失值

α——控制生长速度损失值权重超参数

β——控制患病比例损失值权重超参数

L_{growth}——生长速度损失值

$y_1^{(i)}$——生长速度真实值

N——总时间节点次数

$\hat{y}_1^{(i)}$——生长速度预测值

L_{health}——患病比例损失值

$y_2^{(i)}$——患病比例真实值

$\hat{y}_2^{(i)}$——患病比例预测值

最终通过反向传播计算损失函数对模型参数的梯度，逐层将误差从输出层传递到输入层，从而更新参数以最小化损失，即

$$w^{(l+1)} = w^{(l)} - \eta\frac{\partial L}{\partial w^{(l)}} \tag{11}$$

式中　$w^{(l)}$、$w^{(l+1)}$——第 l、$l+1$ 层的权重

L——损失函数

η——学习率

$\dfrac{\partial L}{\partial w^{(l)}}$——损失函数对权重的梯度（误差对权重的影响）

其中权重 w 通过沿损失函数的负梯度方向更新，从而减少模型误差。

2.2　长短记忆神经网络模型

LSTM 嵌入于多任务学习架构的输入层和共享层之间，有效捕捉水质时间变化特征，提升鱼类生长速度和健康状态预测能力[26]。LSTM 的网络模型结构如图 3 所示，包含 4 个主要单元：遗忘门 f_t：丢弃无关或过时的水质信息，防止干扰预测；输入门 i_t：写入新信息；候选细胞状态 $\tilde{C}_t$：记忆、累积及更新水质数据；输出门 o_t：传递状态信息，决定预测结果。

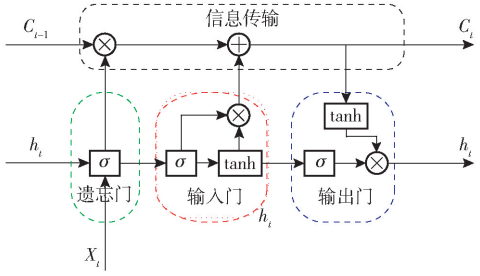


图 3　长短记忆神经网络模型结构图

Fig. 3　Model structure diagram of long and short-term memory neural network

t 时刻外部输入 x_t、$t-1$ 时刻 LSTM 单元输出 h_{t-1}、$t-1$ 时刻细胞状态 C_{t-1}，再经过 LSTM 门控单元处理，输出隐藏状态 h_t 以供多任务学习模型的各分支使用，同时确保细胞状态 C_t 能够防止模型因短期异常而大幅调整预测结果。计算过程为

$$f_t = \sigma(W_f[h_{t-1}, x_t] + \boldsymbol{b}_f) \tag{12}$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + \boldsymbol{b}_i) \tag{13}$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + \boldsymbol{b}_c) \tag{14}$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \tag{15}$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + \boldsymbol{b}_o) \tag{16}$$

$$h_t = o_t \tanh(C_t) \tag{17}$$

式中　W_f——遗忘门权重

W_i——输入门权重

W_c——细胞状态权重

W_o——输出门权重

$\boldsymbol{b}_f$——遗忘门偏置矩阵

$\boldsymbol{b}_i$——输入门偏置矩阵

$\boldsymbol{b}_c$——细胞状态偏置矩阵

$\boldsymbol{b}_o$——输出门偏置矩阵

以上权重和偏置矩阵的初始值为随机设置，而后通过数据训练获取。

2.3　软注意力机制

软注意力机制（Soft attention）是注意力机制的一种，其为一种加权聚合方法，用于动态地关注输入序列中最重要的部分。其在 LSTM 等时间序列模型

中广泛应用,能够有效增强模型对长期依赖的建模能力。能够平滑地分配关注点,不会像硬注意力(Hards attention)那样只关注特定位置,软注意力机制先利用 LSTM 输出隐藏状态向量 $\boldsymbol{h}_t$ 的对注意力分数(能量函数)e_t 进行计算,其后根据 e_t 对注意力权重 a_t 进行计算,最后,得到注意力权重 a_t 后,通过加权求和得到一个上下文向量 $\boldsymbol{z}$,计算方法为

$$e_t = \boldsymbol{v}^{\mathrm{T}} \tanh(\boldsymbol{W}_a h_t + \boldsymbol{b}_a) \tag{18}$$

$$a_t = \frac{\exp(e_t)}{\sum_{i=1}^{T} \exp(e_i)} \tag{19}$$

$$\boldsymbol{z} = \sum_{t=1}^{T} a_t \boldsymbol{h}_t \tag{20}$$

其中 $\sum_{t=1}^{T} a_t = 1 \quad (0 \leqslant a_t \leqslant 1)$

式中 $\boldsymbol{W}_a$——可学习的注意力权重矩阵

$\boldsymbol{v}$——权重向量,将维度映射为标量

$\boldsymbol{b}_a$——偏置矩阵 a_t——注意力权重

$\boldsymbol{h}_t$——LSTM 在时间步 t 的输出向量

T——时间步

2.4 MIL + LSTM + SAT 模型算法

如图 4 所示,采用多任务学习框架,结合软注意力机制和 LSTM 模型,自动提取时间序列的长期趋势和短期波动。通过分析水质与投饲数据对鱼类生长和患病情况的影响,预测鱼类健康状况,以指导养殖策略的调整。LSTM 和软注意力机制作为特征提取工具,能够捕捉水质指标的动态变化和长期依赖性,解决梯度消失问题,并持续监控水质对鱼类健康的影响。注意力机制提升了模型对关键时间点的识别能力,关注对鱼类生长和疾病有显著影响的水质波动。最终,模型通过共享特征层同时进行鱼类患病和生长速度的概率分类,以优化养殖策略。

每层工作描述如下:

(1)输入层:将预处理后的数据转换为适应时间序列特征提取的三维矩阵:类型维度 S、时间维度 T 和特征输入维度 X。

(2)LSTM 层:逐时间步输入数据,LSTM 单元处理时间依赖关系,输出隐藏状态 $\boldsymbol{h}_t$。

(3)软注意力层:依据 LSTM 层输出的隐藏状态 $\boldsymbol{h}_t$ 计算注意力权重 a_t,对长时间序列中的关键时间步进行聚焦,避免重要信息遗忘。

(4)加权求和层:进行加权求和运算生成上下文向量 $\boldsymbol{z}$。

(5)共享特征层:共享特征被分别传递到不同任务的输出层或解码器分支,完成不同目标。

(6)输出层:输出预测结果。

2.5 评价指标

鱼类患病比例、鱼类生长速度预测,采用均方根误差(Root mean squared error,RMSE)和平均绝对误差(Mean absolute error,MAE)进行评价。

3 结果与分析

由于本研究针对的是特定的鱼类养殖环境,其水质特征变量、区域气候条件、数据集规模及数据质量等方面与现有研究存在少许差异,直接将本研究模型的预测效果与前人研究进行对比,可能会因条件差异而导致结论缺乏合理性。因此,为了更系统地验证本研究构建的 MTL - LSTM - SAT 模型鱼类养殖预测任务中的实际效果和适用性,从多个角度开展了模型性能对比分析。分别对比不同深度学习模型(RNN、GRU、LSTM 和 BiLSTM)在时间尺度下,以及不同养殖季节下的 MTL - LSTM - SAT 模型消融试验,综合评估了 MTL - LSTM - SAT 模型与几种常见深度学习模型(RNN、GRU、LSTM 和 BiLSTM)在鱼类生长速度和患病风险预测任务中的表现,重点分析其在时间序列特征提取、预测准确性和泛化能力上的差异。此外,本研究特别探讨了软注意力机制在特定任务中的优势,通过对模型预测数据的可视化分析,进一步验证了其在实际工作中的适应性和鲁棒性。

3.1 模型参数设置

所提出模型(MTL - LSTM - SAT)主要通过采集包括水温、氨氮质量浓度、溶解氧质量浓度、pH 值 4 项水质数据和记录投饲量 1 项投喂数据作为被动输入数据,参照养殖鱼类患病比例和鱼体生长速度两个主动输出数据,通过模型学习输入及输出数据之

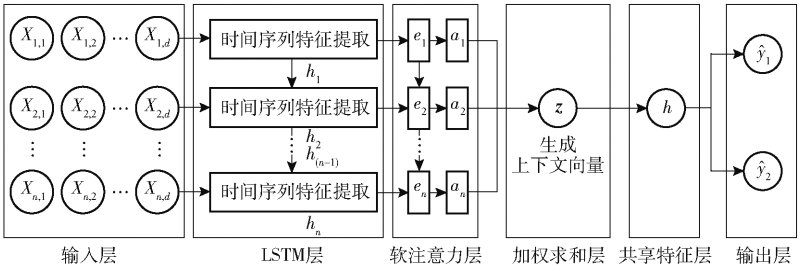


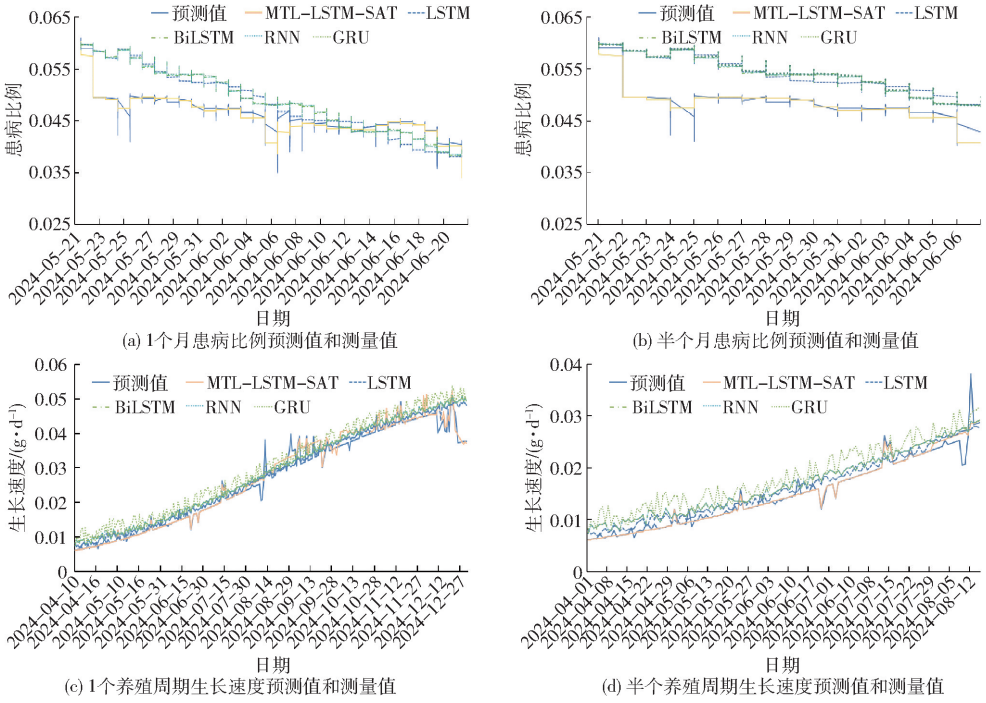
图 4 结合 LSTM 和软注意力机制的多任务学习模型

Fig. 4 Multi-task learning model combining LSTM and soft attention mechanism

间的关系，来预测鱼类患病比例与生长速度，采集时间为2024 年4 月1 日—12 月31 日一个完整养殖周期，水质数据采集时间间隔为 10 min，投饲量采集时间单位 1 d 的投喂总量，鱼类患病比例输出时间间隔为10 min，鱼体平均生长速度时间间隔为 1 d，将所有的数据按照 7∶3分为训练集与测试集，用于模型的训练和检验。模型的最大训练轮数（epoch）设置为 200；每轮训练包含 300 次迭代。输入窗口步长为 24，表示模型使用最近 24 h 的数据作为输入序列。优化器采用 Adam，学习率为 0.001。LSTM 层包含 64 个神经元，用于提取与所有任务相关的高层特征。

3.2　不同模型在不同时间尺度内对比

图 5 为 5 种模型（MTL－LSTM－SAT、RNN、GRU、LSTM 和 BiLSTM）在不同时间尺度下对鱼类患病比例（1 个月和半个月）及鱼类生长速度（1 个养殖周期和半个养殖周期）的预测结果与实际测量值的对比曲线。其中 RNN 为递归神经网络，GRU 为门控循环单元，BiLSTM 为双向长短记忆网络。从图 5 可以看出，5 种模型均能够较准确地捕捉鱼类患病比例及生长情况的变化趋势。然而，相较于其他模型，MTL－LSTM－SAT 在趋势预测方面与实际测量值的吻合度最高，而 RNN、GRU、LSTM 和 BiLSTM 在处理较大幅度波动时预测效果较差。这一差异主要源于 MTL－LSTM－SAT 通过结合输入数据与输出数据的关系进行预测，而其他 4 种模型则主要依赖输出数据本身的模式进行推测。



(a) 1个月患病比例预测值和测量值　(b) 半个月患病比例预测值和测量值

(c) 1个养殖周期生长速度预测值和测量值　(d) 半个养殖周期生长速度预测值和测量值

图 5　不同预测时长预测值与测量值曲线

Fig. 5　Curves of predicted values and measured values at different prediction times

在预测鱼类患病比例方面，MTL－LSTM－SAT 均方根误差（RMSE）和平均绝对误差（MAE）均达到最优。其中，1 个月和半个月时间段均方根误差分别为 0.000 93 和 0.000 81，对应的平均绝对误差分别为 0.000 91 和 0.000 65。对于鱼类生长速度预测，MTL－LSTM－SAT 在 1 个养殖周期和半个养殖周期内均方根误差分别为 0.092、0.122 g/d，平均绝对误差分别为 0.074、0.097 g/d。相比之下，RNN、GRU、LSTM 和 BiLSTM 在 1 个月时间尺度下鱼类患病比例预测均方根误差分别为 0.004 99、0.004 53、0.004 44 和 0.004 5，在半个月时间尺度下均方根误差分别为 0.003 6、0.003 24、0.002 96 和 0.003 11。此外，在鱼类生长速度预测方面，1 个养殖周期时间尺度下均方根误差分别为 1.004、0.853、0.409、0.689 g/d，半个养殖周期尺度下分别为 0.836、0.624、0.396、0.511 g/d。

综合结果，模型预测性能排序为 MTL－LSTM－SAT、LSTM、BiLSTM、GRU、RNN。MTL－LSTM－SAT 在处理非线性复杂时序数据方面表现最佳，而其他模型在数据波动大时预测精度较低。这显示 MTL－LSTM－SAT 在鱼类养殖管理领域具有高应用价值，可提供更可靠的健康监测和生长评估支持。

3.3　不同季节消融试验

水质因子和天气情况对于鱼类的生长及健康有着显著影响，而水质因子和天气受到季节的影响很

大,针对多任务学习框架下结合时间序列预测与软注意力机制的模型,进行了分季节的消融试验。试验的主要目的是探讨该模型在不同季节的数据分布下的适应性,以及时间序列预测、注意力机制、多任务学习 3 个模块在不同气候条件下的贡献度。根据数据时间跨度(2024 年 4—12 月),将整个养殖周期划分为 3 个季节,并分别对模型进行训练和测试。Q1:春季(4—6 月),水温回升,水质较为稳定,育苗期鱼类较脆弱;Q2:夏季(7—9 月),水温较高,水质波动较大,鱼类的新陈代谢较快,饲料投放量较多;Q3:秋季(10—12 月),水温逐渐降低,水质最为稳定,鱼类生长情况较为稳定。

根据表 2、3 可知,MTL - LSTM - SAT 模型在预测鱼类养殖患病比例和生长速度方面表现最佳,误差最低。这表明该模型结合了多任务学习、LSTM 和 SAT 的优势,提高了时序预测的准确性。单独使用 MTL 模型时误差最大,因为其没有考虑水质特征随时间变化的动态性。鱼类生长和健康受水质短期波动和长期趋势影响,MTL 无法有效建模这种时间依赖性。引入 SAT 后,模型在夏季的预测性能提升显著,因为注意力机制能动态捕捉水质特征的瞬时变化,提高模型对高波动环境的适应能力。因此,SAT 对短期剧烈变化的环境敏感,在夏季预测效果最优。

表 2 不同季节患病比例预测消融试验结果

Tab. 2 Prediction of prevalence ratio in different seasons for ablation tests

模型	Q1(4—6 月)		Q2(7—9 月)		Q3(10—12 月)		全养殖周期	
	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
LSTM	0.005 39	0.004 30	0.006 85	0.005 47	0.004 95	0.003 95	0.005 46	0.004 17
MTL	0.010 19	0.008 13	0.022 00	0.017 60	0.009 85	0.007 86	0.020 37	0.018 29
LSTM - SAT	0.005 63	0.004 49	0.006 23	0.004 97	0.004 95	0.003 95	0.005 6	0.004 46
MTL - SAT	0.009 22	0.007 36	0.012 12	0.009 67	0.009 81	0.007 82	0.010 68	0.008 18
MTL - LSTM - SAT	0.001 26	0.000 99	0.001 27	0.001 01	0.001 16	0.000 92	0.001 22	0.000 97

表 3 不同季节生长速度预测消融试验

Tab. 3 Prediction of growth rate in different seasons for ablation test g/d

模型	Q1(4—6 月)		Q2(7—9 月)		Q3(10—12 月)		全养殖周期	
	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
LSTM	0.398	0.318	0.452	0.361	0.359	0.286	0.409	0.326
MTL	1.106	0.888	1.375	1.098	1.211	0.966	1.320	1.053
LSTM - SAT	0.396	0.316	0.389	0.342	0.355	0.283	0.398	0.318
MTL - SAT	1.107	0.883	1.268	1.118	1.102	0.879	1.310	1.081
MTL - LSTM - SAT	0.090	0.071	0.099	0.079	0.082	0.065	0.092	0.074

在 MTL 结构中加入 LSTM 后,模型预测误差显著降低,显示时间依赖性特征对预测精度至关重要。LSTM 通过记忆单元有效模拟水质指标对鱼类长期影响,改善了 MTL 静态特征学习限制。因此,LSTM 显著增强了模型的时间序列建模能力,保持了不同季节的高预测精度。

MTL - LSTM - SAT 模型结合了 MTL、LSTM 和注意力机制的优点,实现了多任务共享学习和长期依赖关系建模,同时利用软注意力机制精确捕捉短期波动,提升了模型在不同时间尺度上的预测能力,达到最优预测效果。

4 讨论

4.1 LSTM 与 SAT 机制在模型中的作用

构建了基于多任务学习(MTL)框架结合长短时记忆网络(LSTM)及软注意力机制(SAT)的预测模型 MTL - LSTM - SAT,对比了不同模型在不同时间尺度鱼类生长速度和患病比例预测任务上的表现。并将消融试验和季节测试相结合,证明该模型在不同时间范围、不同季节的水质环境下均能取得最优的预测效果。由表 2、3 可知,单独使用 MTL 进行预测时,其误差最大,尤其在夏季水质变化剧烈的情况下预测精度较低,且伴随着预测时间范围的增大预测偏差也会显著增大。这主要归因于 MTL 仅能进行静态特征共享,无法充分利用水质的时间序列特征,鱼类养殖是一个长时间的过程,鱼类生长的上一阶段能够显著影响下一阶段,因此难以捕捉长时间的线性关系。因此引入 LSTM 机制,增强模型的时间序列特征,LSTM 能够显著地模拟出水质随时间变化的特征,特别是在春秋季节等水质波动不大、鱼类生长及健康情况稳定的背景下效果明显。但是夏季光照随天气情况变化大,水温升高速度很

快，水质波动较大，需要模型能够捕捉短时间内数据变化，提高短期预测精度，因此，SAT 模块的引入能够使模型根据水质特征在不同时间点的重要性，自动给予其不同权重，从而有效地聚焦于对预测任务影响较大的水质变化。

4.2　与已有研究对比

在水温预测领域，已有多项研究应用深度学习方法取得了显著成果。文献[27－29]采用长短期记忆网络(LSTM)进行温度预测，证明了 LSTM 在捕捉时间序列特征方面的有效性。SONG 等[30]将 LSTM 与 Transformer 相结合，提出了 LSTM－Transformer 混合模型，在降低预测误差和提高决定系数 R^2 表现优异，特别是在春季和秋季。此外，JIANG 等[31]比较了时间卷积网络(TCN)和 LSTM－GRU 混合模型在海洋温度预测中的性能，发现 TCN 在预测精度上更优。QIU 等[32]探讨了使用深度学习中的 LSTM 网络预测河流水温的潜力。结果表明，LSTM 模型在预测河流的每日平均水温方面优于其他方法，能够准确捕捉热力学变化。但上述研究只是使用 LSTM 模型进行水温这一单一水质因子的预测，无法反映出多种水质因子的变化趋势。

在多任务学习与时间序列预测的结合方面，DENG 等[33]提出了多视角多任务学习框架(MVMT)，通过任务级仿射变换和归一化操作，提升了多变量时间序列预测性能。CHOI 等[34]则开发了多任务自监督时间序列表示学习方法，结合上下文、时间和变换一致性，提高了模型在分类、预测和异常检测等下游任务中的表现。然而，上述研究主要关注单一任务或未充分利用多任务学习的潜力。相比之下，本研究的 MTL－LSTM－AT 模型将多任务学习(MTL)、长短期记忆网络(LSTM)和软注意力机制(SAT)相结合，旨在同时预测鱼类的生长速度和健康状况。通过引入软注意力机制，模型能够动态捕捉水质参数的瞬时变化，特别是在夏季水质波动较大的情况下，提升了预测的准确性。试验结果表明，MTL－LSTM－AT 模型在不同季节的预测误差均低于其他模型，验证了其在复杂水质环境下的适应性和优越性。

4.3　不足

本研究的 MTL－LSTM－AT 模型在预测鱼类生长速度和患病比例方面表现出优越性，但存在局限性。主要问题有：①对长期时间依赖的建模能力有限，LSTM 虽擅长时间序列建模，但在跨多个养殖周期的长期预测中可能无法有效捕捉超长期依赖关系。②未充分利用养殖环境的复杂度，当前模型仅考虑了部分环境因子，未全面参考所有关键变量，可能影响预测精度。③模型计算复杂度高，推理速度慢，可能不适用于实时运行，特别是在计算资源有限的边缘设备上，计算开销可能成为瓶颈。

5　结论

(1)为解决鱼类智能化养殖技术瓶颈，明确水质因子、投饲量对鱼类生长及健康的影响，本研究提出 MTL－LSTM－AT 模型，该模型结合多任务学习(MTL)、长短期记忆网络(LSTM)和软注意力机制(AT)，依据水质因子和投喂数据，用鱼类生长速度和健康状况预测模型指导养殖人员决策及自动化投饲设备研发。同时，将其与常用的 LSTM、门控循环单元(GRU)、递归神经网络(RNN)、双向长短记忆网络(BiLSTM)模型预测效果对比。

(2) MTL－LSTM－AT 模型鱼类患病比例和生长速度趋势与测量值基本趋同。鱼类患病比例预测中，全养殖周期均方根误差(RMSE)为 0.001 22，平均绝对误差(MAE)为 0.000 97；鱼类生长速度预测中，全养殖周期 RMSE 为 0.092 g/d，MAE 为 0.074 g/d。

(3) MTL－LSTM－SAT 在鱼类生长速度和患病比例预测上表现最佳，均方根误差和平均绝对误差均优于 RNN、GRU、LSTM 和 BiLSTM。

(4)针对鱼类养殖环境季节性变化开展 MTL－LSTM－SAT 模型消融试验。结果表明，该模型在不同季节表现最优，如 Q2 阶段患病比例预测误差 RMSE 仅 0.001 27，明显优于原始 LSTM 模型的 0.006 85。其中，引入 SAT 机制在夏季提升效果最显著，因其可动态关注关键水质特征；引入 LSTM 能显著降低误差，说明时间依赖性对预测精度很重要，强化了模型时序建模能力。

参　考　文　献

[1]　崔永杰，王明辉. 农业领域自动定向技术研究进展分析[J]. 农业机械学报，2023，54(4)：1－20.
CUI Yongjie，WANG Minghui. Research progress analysis of auto-orientation technologies in agriculture[J]. Transactions of the Chinese Society for Agricultural Machinery，2023，54(4)：1－20.(in Chinese)

[2]　李道亮，刘畅. 人工智能在水产养殖中研究应用分析与未来展望[J]. 智慧农业(中英文)，2020，2(3)：1－20.
LI Daoliang，LIU Chang. Recent advances and future outlook for artificial intelligence in aquaculture[J]. Smart Agriculture，2020，2(3)：1－20.(in Chinese)

[3]　ABDULLAH A F，CHEMAN H，MOHAMMED A，et al. Charting the aquaculture internet of things impact：key applications，

challenges, and future trend[J]. Aquaculture Reports, 2024, 39: 102358.
[4] 何绪刚, 侯杰. 池塘圈养模式研究进展[J]. 华中农业大学学报, 2021, 40(3): 21 - 29.
HE Xugang, HOU Jie. Research progress on pond in-pond raceway system mode[J]. Journal of Huazhong Agricultural University, 2021, 40(3): 21 - 29. (in Chinese)
[5] PAUTSINA A, CISAR P, STYS D, et al. Infrared reflection system for indoor 3D tracking of fish[J]. Aquacultural Engineering, 2015, 69: 7 - 17.
[6] WEI Y, ZHENG D, HU L, et al. Research on intelligent bait casting method based on machine vision technology[J]. Advanced Materials Research, 2015, 1070 - 1072: 1871 - 1874.
[7] 孙龙清, 王泊宁, 王嘉煜, 等. 基于 G - RepVGG 和鱼类运动行为的水质监测方法[J]. 农业机械学报, 2022, 53(增刊 2): 210 - 218.
SUN Longqing, WANG Boning, WANG Jiayu, et al. Water quality monitoring method based on fish movement behavior and G - RepVGG[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(Supp. 2): 210 - 218. (in Chinese)
[8] SKOIEN K R, ALVER M O, ALFREDSEN J A. A computer vision approach for detection and quantification of feed particles in marine fish farms[C]//Proceedings of IEEE International Conference on Image Processing, 2014: 1648 - 1652.
[9] LI N, WANG R M, ZHANG J, et al. Developing a knowledge-based early warning system for fish disease/health via water quality management[J]. Expert Systems with Applications, 2009, 36(3): 6500 - 6511.
[10] 陈浩成, 袁永明, 张红燕, 等. 池塘养殖疾病诊断模型研究[J]. 广东农业科学, 2014, 41(7): 186 - 189.
CHEN Haocheng, YUAN Yongming, ZHANG Hongyan, et al. Study on pond culture disease diagnosis model[J]. Guangdong Agricultural Sciences, 2014, 41(7): 186 - 189. (in Chinese)
[11] 魏天娇,胡祝华,范习禹. 水产养殖中水质与鱼类行为双向映射模型研究[J]. 农业机械学报,2024,55(3):290 - 299.
WEI Tianjiao, HU Zhuhua, FAN Xiyu. Construction of bidirectional mapping model between water quality and fish behavior in aquaculture[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(3):290 - 299. (in Chinese)
[12] 赵建, 鲍伟君, 叶章颖, 等. 基于不同检测方法的养殖鱼类昼夜摄食节律研究进展[J]. 渔业现代化, 2016, 43(2): 17 - 21, 38.
ZHAO Jian, BAO Weijun, YE Zhangying, et al. Different detection methods based research progress on diel feeding rhythms of cultured fishes[J]. Fishery Modernization, 2016, 43(2): 17 - 21, 38. (in Chinese)
[13] 陈彩文, 杜永贵, 周超, 等. 基于图像纹理特征的养殖鱼群摄食活动强度评估[J]. 农业工程学报, 2017, 33(5): 232 - 237.
CHEN Caiwen, DU Yonggui, ZHOU Chao, et al. Intensity assessment of feeding activity of farmed fish based on image texture features[J]. Transactions of the CSAE, 2017, 33(5): 232 - 237. (in Chinese)
[14] 周超, 徐大明, 吝凯, 等. 基于近红外机器视觉的鱼类摄食强度评估方法研究[J]. 智慧农业, 2019, 1(1): 76 - 84.
ZHOU Chao, XU Daming, LIN Kai, et al. Evaluation of fish feeding intensity in aquaculture based on near-infrared machine vision[J]. Smart Agriculture, 2019, 1(1): 76 - 84. (in Chinese)
[15] BIAZI V, MARQUES C. Industry 4.0-based smart systems in aquaculture: a comprehensive review[J]. Aquacultural Engineering, 2023, 103: 102360.
[16] ACHILLE A, LAM M, TEWARI R, et al. Task2Vec: task embedding for meta-learning[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 6430 - 6439.
[17] ZHANG J, SU Q, TANG B, et al. DPSNet: multitask learning using geometry reasoning for scene depth and semantics[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 34(6): 2710 - 2721.
[18] 邝晓飞,万里平,连嘉茜,等. 基于 Transformer 和多序列特征的土壤含水率预测[J]. 农业机械学报,2025,56(8):120 - 127.
KUANG Xiaofei, WAN Liping, LIAN Jiaqian, et al. Prediction of soil moisture content based on Transformer and multi sequence feature[J]. Transactions of the Chinese Society for Agricultural Machinery,2025,56(8):120 - 127. (in Chinese)
[19] 张伟荣,陈学庚,齐江涛,等. 基于农业机器人本体传感信号的旱田平作与垄作类型识别方法[J]. 农业机械学报,2025,56(2):164 - 174.
ZHANG Weirong, CHEN Xuegeng, QI Jiangtao, et al. Recognition method of flat and ridged crop types in dry fields based on propriety sensing signals of agricultural robot[J]. Transactions of the Chinese Society for Agricultural Machinery,2025,56(2):164 - 174. (in Chinese)
[20] 梁正龙,祁少刚,畅青霞,等. 基于 LSTM-SVM 的日光温室环境预测模型[J]. 农业机械学报,2025,56(7):279 - 287.
LIANG Zhenglong, QI Shaogang, CHANG Qingxia, et al. Environmental prediction model of solar greenhouse based on LSTM-SVM[J]. Transactions of the Chinese Society for Agricultural Machinery,2025,56(7):279 - 287. (in Chinese)
[21] WANG Z, LIU H, ZHANG G, et al. Diseased fish detection in the underwater environment using an improved YOLOv5 network for intensive aquaculture[J]. Fishes, 2023, 8(3): 169.
[22] 杨霄,王朕,赵伟,等. 鱼病实时检测系统的研制与试验[J]. 中国农机化学报,2023,44(11):130 - 137.
YANG Xiao, WANG Zhen, ZHAO Wei, et al. Development and testing of real-time detection system for fish diseases[J]. Journal of Chinese Agricultural Mechanization,2023,44(11):130 - 137. (in Chinese)

(下转第 620 页)

with multisource spaceborne remote sensingdata[J]. Journal of Remote Sensing, 2024, 4:01406.
[29] 郑兴明,马明国,赵凯,等. 2017 年 8 月中国东北土壤室内测量反射率数据集[DB/OL]. 中国科学院东北地理与农业生态研究所, 中国科学院寒区旱区环境与工程研究所, 2019. http://doi.org/10.11878/db.202005.000015.000001.
[30] TAGHIZADEH-MEHRJARDI R, SCHMIDT K, EFTEKHARI K, et al. Synthetic resampling strategies and machine learning for digital soil mapping in Iran[J]. European Journal of Soil Science, 2020, 71(3):352 - 368.
[31] HE H B, BAI Y, GARCIA E A, et al. ADASYN: adaptive synthetic sampling approach for imbalanced learning[C]//2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence), 2008:1322 - 1328.
[32] DATTA D, MALLICK P K, REDDY A V N, et al. A hybrid classification of imbalanced hyperspectral images using ADASYN and enhanced deep subsampled multi-grained cascaded forest[J]. Remote Sensing, 2022, 14(19):4853.
[33] TAN K, CHEN L, WANG H, et al. Estimation of the distribution patterns of heavy metal in soil from airborne hyperspectral imagery based on spectral absorption characteristics[J]. Journal of Environmental Management, 2023, 347:119196.
[34] STONER E R, BAUMGARDNER M F. Characteristic variations in reflectance of surface soils[J]. Soil Science Society of America Journal, 1981, 45(6):1161 - 1165.
[35] VISCARRA R R A, WEBSTER R. Discrimination of Australian soil horizons and classes from their visible-near infrared spectra[J]. European Journal of Soil Science, 2011, 62(4):637 - 647.
[36] CHEN L, LAI J, TAN K, et al. Development of a soil heavy metal estimation method based on a spectral index: combining fractional-order derivative pretreatment and the absorption mechanism[J]. Science of the Total Environment, 2022, 813: 151882.
[37] 丁昌伟,王新,陈同俊,等. 贝叶斯优化的 XGBoost 在小断层地震解释中的应用[J]. 煤炭学报, 2023, 48(6):2530 - 2539.
DING Changwei, WANG Xin, CHEN Tongjun, et al. Application of Bayesian optimized XGBoost in seismic in terpretation of small-scale faults[J]. Journal of China Coal Society, 2023, 48(6):2530 - 2539. (in Chinese)
[38] 朱鹤健,陈健飞,陈松林. 土壤地理学[M]. 3 版. 北京: 高等教育出版社,2019.
[39] 刘焕军,张小康,张新乐,等. 面向土壤分类的高光谱反射特征参数模型[J]. 遥感学报, 2017, 21(1):105 - 114.
LIU Huanjun, ZHANG Xiaokang, ZHANG Xinle, et al. Hyperspectral reflectance characteristics paramter extraction for soil classification model[J]. Journal of Remote Sensing, 2017, 21(1):105 - 114. (in Chinese)

(上接第 598 页)

[23] ZHOU X H, WANG J P, CAO X K, et al. Simulation of future dissolved oxygen distribution in pond culture based on sliding window-temporal convolutional network and trend surface analysis[J]. Aquacultural Engineering, 2021, 95: 102200.
[24] DUPUIS A, DADOUCHI C, AGARD B. Performances of a Seq2Seq - LSTM methodology to predict crop rotations in Québec [J]. Smart Agricultural Technology, 2023, 4: 100180.
[25] JOBARTEH B, NEETHIRAJAN S. Leveraging satellite data for greenhouse gas mitigation in Canadian poultry farming[J]. Smart Agricultural Technology, 2025, 10: 100704.
[26] BANDARU L, IRIGIREDDY B C, KOUTILYA P V N R, et al. DeepQC: a deep learning system for automatic quality control of in-situ soil moisture sensor time series data[J]. Smart Agricultural Technology, 2024, 8: 100514.
[27] 张观山, 丁小明, 何芬, 等. 基于 LSTM - AT 的温室空气温度预测模型构建[J]. 农业工程学报, 2024, 40(18): 194 - 201.
ZHANG Guanshan, DING Xiaoming, HE Fen, et al. Predicting greenhouse air temperature using LSTM - AT[J]. Transactions of the CSAE, 2024, 40(18): 194 - 201. (in Chinese)
[28] MISRA I, SHRIVASTAVA A, GUPTA A, et al. Cross-stitch networks for multi-task learning[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2016: 3994 - 4003.
[29] ZHANG Q, WANG H, DONG J, et al. Prediction of sea surface temperature using long short-term memory[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(10): 1745 - 1749.
[30] SONG J, GUO J, CAI Y, et al. Prediction and analysis of sea surface temperature based on LSTM-transformer model[J]. Regional Studies in Marine Science, 2024, 78: 103726.
[31] JIANG Y, ZHAO M, ZHAO W, et al. Prediction of sea temperature using temporal convolutional network and LSTM - GRU network[J]. Complex Engineering Systems, 2021, 1: 6.
[32] QIU R, WANG Y, RHOADS B, et al. River water temperature forecasting using a deep learning method[J]. Journal of Hydrology, 2021, 595: 126016.
[33] DENG J, CHEN X, JIANG R, et al. A multi-view multi-task learning framework for multi-variate time series forecasting[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 35(6): 6099 - 6112.
[34] CHOI H, KANG P. Multi-task self-supervised time-series representation learning[C]//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, 2023: 2613 - 2623.