Prediction Model for Water Dissolved Oxygen Based on VMD and an Improved Mamba Model*

FU Xuanyu[1], SHI Pei[2,3*]

(1.School of Computer Science, Nanjing University of Information Science and Technology, Nanjing Jiangsu 210044, China;
2.School of Internet of Things Engineering, Wuxi University, Wuxi Jiangsu 214105, China;
3.Jiangsu Engineering Research Center of Internet of Things Device Super Convergence and Security, Wuxi Jiangsu 214105, China)

Abstract: Dissolved oxygen forecasting holds significant importance in water quality prediction and aquaculture management. Accurate dissolved oxygen predictions can effectively mitigate aquaculture risks and enhance farming efficiency. To improve the accuracy and stability of dissolved oxygen forecasting, a deep learning model is proposed, which combines variational mode decomposition (VMD) with a multi-layer stacked Mamba architecture. First, VMD is employed to pre-process the dissolved oxygen time series, leveraging its robust decomposition capability to extract multi-scale features and reduce high-frequency noise interference. Subsequently, a multi-head attention mechanism is introduced to enhance the model's ability to capture long-range dependencies within the time-series data. This leads to the construction of the VMD-SAMamba prediction model. Through its multi-layer stacked Mamba architecture, this model better captures complex temporal patterns and non-linear features. Finally, the model is evaluated on a dataset collected from a riverine aquaculture base in Anqing City, Anhui Province. The results indicate that the proposed model achieves MAE, RMSE, and R^2 values of 0.050 7, 0.083 1, and 0.994 9, respectively, demonstrating significant advantages over other mainstream models. This study provides an effective approach for dissolved oxygen prediction, offering theoretical support for precision management in aquaculture.

Key words: aquaculture; dissolved oxygen prediction; VMD; multi-head attention mechanism; Mamba
EEACC: 7220 **doi**: 10.3969/j.issn.1004-1699.2026.09.011

基于变分模态分解与改进 Mamba 的水体溶解氧预测模型*

付玄宇[1], 施 珮[2,3*]

(1.南京信息工程大学计算机学院, 江苏 南京 210044; 2.无锡学院物联网工程学院, 江苏 无锡 214105;
3.江苏省物联网设备超融合与安全工程研究中心, 江苏 无锡 214105)

摘 要: 溶解氧预测在水质预测与养殖管理中具有重要意义, 精准的溶解氧预测可有效降低养殖风险, 提高养殖效率。为了提升溶解氧预测的准确性和稳定性, 提出了一种变分模态分解(Variational Mode Decomposition, VMD)与多层堆叠式 Mamba 结构相结合的深度学习预测模型。首先, 通过 VMD 对溶解氧时间序列进行预处理, 利用其强大的信号分解能力有效提取时间序列中的多尺度特征, 间接减少高频噪声的干扰。其次, 引入多头注意力机制增强模型对时序数据中长程依赖关系的捕捉能力, 从而构建 VMD-SAMamba 溶解氧预测模型。该模型通过多层堆叠 Mamba 结构, 能够更好地捕捉复杂的时序模式和非线性特征, 最后在安徽省安庆市的河道水产养殖基地采集的数据集上进行了预测测试。结果表明, 所提模型在 MAE、RMSE 和 R^2 上分别达到了 0.050 7、0.083 1 和 0.994 9, 较其他主流模型表现出显著优势。为溶解氧预测提供了一种有效方法, 可为水产养殖的精细化管理提供理论支持。

关键词: 水产养殖; 溶解氧预测; 变分模态分解; 多头注意力机制; Mamba
中图分类号: TP183; TP391.41; X832 **文献标识码**: A **文章编号**: 1004-1699(2026)09-2005-09

溶解氧(Dissolved Oxygen, DO)是水产养殖中的重要水质指标[1-2], 其不仅反映水体产氧与耗氧过程的动态平衡, 还直接影响养殖对象的生长、免疫与存活状态。过低会导致缺氧死亡, 过高则可能诱发气泡病[3-5]。然而, 溶解氧水平易受气象条件、水体理化特性及人类活动等多重因素的共同作用而波动[6], 使得溶解氧呈现出显著的非线性和时变特征, 增加其预测与调控的难度。因此, 溶解氧的准确预测, 对实现水质精确调控[7]、降低养殖风险[8]具有重要的科学与应用价值。

在水产养殖领域, 溶解氧浓度预测一直是国内外学者关注的重点问题。长短期记忆(Long Short-

项目来源: 江苏省高校自然科学研究面上项目(21KJB520020); 国家自然科学基金项目(62602474); 无锡市"太湖之光"科技攻关项目(K20221044); 江苏高校"青蓝工程"资助项目; 无锡市"锡山英才"创新领军人才项目(2022xsyc002); 2023 年度江苏省高校优秀科技创新团队项目
收稿日期: 2025-10-10 **修改日期**: 2025-11-20

Term Memory, LSTM)网络与门控循环单元(Gated Recurrent Unit, GRU)因其在缓解梯度消失与捕捉非线性动态方面的优势,被广泛应用于水质预测与溶解氧建模任务中[9-10]。然而,单一循环结构在处理长序列依赖时仍存在信息衰减与记忆能力不足的问题,其对复杂水环境中多尺度、非平稳信号的建模能力有限。为进一步提升预测性能,部分研究尝试GRU与双向循环网络(Bidirectional Long Short-Term Memory, BiLSTM)相结合,以利用GRU对时序依赖关系的高效建模能力,并借助双向结构增强对上下文依赖的捕捉。石庆兰等[11]从双向特征提取与网络融合的角度提出了BiLSTM与GRU的融合预测模型,通过双向结构增强特征捕获能力并利用GRU简化计算,有效提升稻虾养殖溶解氧含量的预测精度与效率。胡龙元等[12]通过智能优化算法解决超参数敏感与局部最优问题,提出了一种混合预测模型(IWOA-GRUC+),用于提升长江流域溶解氧预测精度。然而,这些方法在处理强噪声与非平稳水质信号时存在适应性不足的问题。

事实上,溶解氧序列存在典型的噪声干扰和非平稳特性,很多国内外学者尝试引入多种信号分解与预处理技术以降低噪声信息的干扰。现有研究广泛采用信号分解的方法解决这些特性带来的问题。Xu等[13]提出了一种基于小波变换与双阶段注意力机制的长短期记忆网络(WT-DSE-LSTM)水质预测模型,实现了溶解氧浓度的多步预测。白雯睿等[14]基于小波分解与序列到序列机制构建了WD-Seq2Seq预测模型,通过多尺度分解提取时序特征并建模输出依赖关系,显著提升了河道溶解氧的多步预测性能。曹文治等[15]构建了EEMD-LSTM-SVR三阶段水质预测模型,通过模态分解、LSTM预测与SVR非线性重构,有效降低了误差累积,提升了湘江流域河道断面溶解氧与氨氮浓度的预测精度。施珮等[16]提出了CEEMDAN-CPELM溶解氧预测模型,通过模态分解与模糊熵聚类重构数据,并采用偏最小二乘优化极限学习机,有效提升了南美白对虾养殖池塘的溶解氧预测精度。这些研究在噪声抑制与特征提取方面已经取得了一定进展,但在应对溶解氧序列的多尺度特征及异常波动时预测能力仍显不足。

因此,本文提出了一种融合信号分解与深度建模的新型预测模型。首先,引入变分模态分解[17](Variational Mode Decomposition, VMD)对溶解氧目标序列进行预处理,实现多尺度模态分解,将高频成分与低频成分进行区分,进而减少噪声干扰,提升时序建模的稳定性。其次,在Mamba模块中融合多头注意力机制,以突破传统方法在远程依赖建模方面的局限,实现对全局时序关系的高效捕捉。最后,构建多层堆叠式Mamba模型,以增强层次化特征抽取与非线性动态建模能力,从而更好适应溶解氧浓度的复杂时序特征。

1 数据获取与预处理

1.1 研究区域与数据源

本研究所用数据采集自安徽省安庆市迎江区新洲乡康宁村八河套的河道水产养殖基地(东经117°213 1,北纬30°484 5)。该养殖河道部署的物联网感知监测系统包括多种水质传感器和自动气象站。水质传感器能够实时采集水体中的溶解氧、pH和水温参数信息,各传感器一般部署在水下0.7 m处,各传感器参数信息如表1所示。自动气象站采集多种气象数据,包括气温、湿度、大气压强、风速、风向、总辐射、PM2.5、PM10和降雨量。水质和气象传感器采集的数据通过GPRS网络传输至服务器端,支持电脑和手机多终端实时访问,图1为该河道养殖的系统架构图。

表1 水质传感器参数

传感器名称	量程范围	精确度	型号
水温传感器	-20 ℃~50 ℃	0.02 ℃	RDO PRO-X
溶解氧传感器	0~40 mg/L	±0.001 mg/L	RDO PRO-X
pH传感器	0~14	±0.01	PHS485-01

本研究选取的数据采集时间为2023年8月15日00:00至2023年12月19日00:00,采样频率为30 min/次。部分设备因断电原因存在数据缺失,共获得6041条数据,缺失8条数据。

1.2 数据预处理

在物联网水质监测系统的在线数据采集过程中,因设备断电、极端天气等不可控因素,常导致监测序列出现数据缺失与异常,影响后续分析的可靠性。因此,本研究首先采用线性插值法[18]对缺失数据进行初步填补,以保持时间序列的连续性,如式(1)所示:

$$y=y_0+\frac{y_1-y_0}{x_1-x_0}(x-x_0) \tag{1}$$

式中:y_0和y_1分别为时间点x_0和x_1对应的观测值,x为缺失时间点,y为插值结果。

针对监测序列中的异常观测值,引入基于密度的局部离群因子(LOF)算法[19],对它们进行识别与剔除。在此基础上,对于因异常值剔除而产生的新缺失点,再次采用线性插值法进行补全。最后,利用SG(Savitzky-Golay)滤波对处理后的时序数据进行

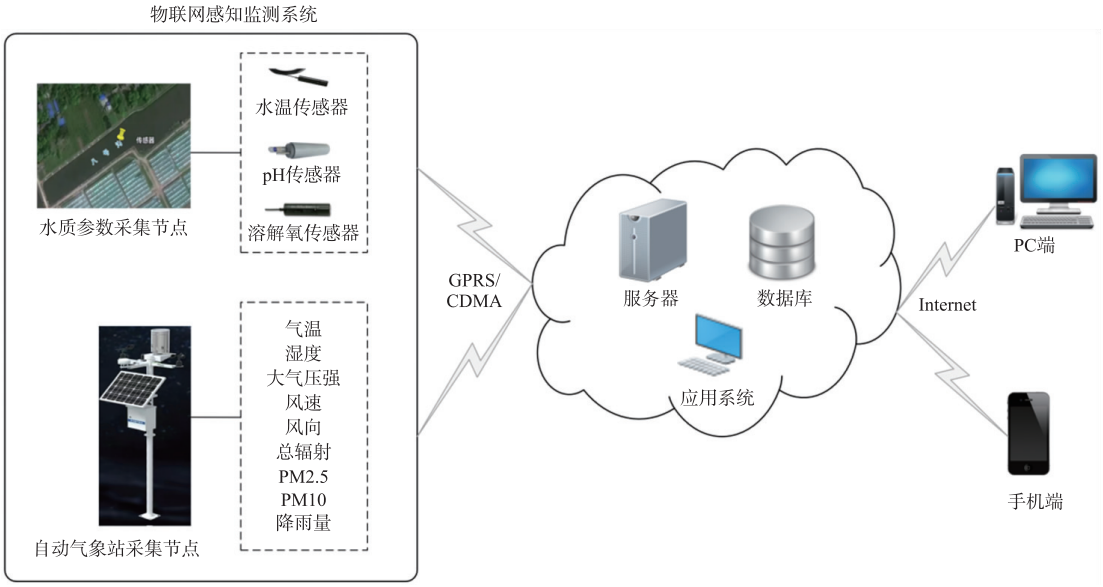

图 1　河道养殖监测系统架构

去噪,从而构建“干净”的数据集。

由于水质参数的量纲和量级差异,直接使用原始数据可能导致模型训练不稳定。因此,本文采用最小-最大归一化方法[20]标准化数据,消除量纲差异,确保各特征在同一尺度下,从而提高训练效率并加速收敛。

2　预测模型的构建

2.1　特征选择

为确保输入变量对溶解氧预测的有效贡献,本研究在数据预处理阶段采用皮尔逊相关系数[21]对候选特征与溶解氧浓度的相关性进行定量分析,并按照相关性强弱排序,具体算式如下:

$$r=\frac{\sum_{i=1}^{n}(X_i-\bar{X})(Y_i-\bar{Y})}{\sqrt{\sum_{i=1}^{n}(X_i-\bar{X})^2}\sqrt{\sum_{i=1}^{n}(Y_i-\bar{Y})^2}} \tag{2}$$

式中:r 为皮尔逊相关系数,X_i 和 Y_i 为第 i 个数据点的 X 和 Y 的观测值,$\bar{X}$ 和 $\bar{Y}$ 为 X 和 Y 的样本均值。

2.2　VMD 分解

在构建完整水质数据集后,为进一步提取序列特征并削弱噪声干扰,本研究引入 VMD 对溶解氧进行处理。VMD 由 Dragomiretskiy[22]提出,是一种基于自适应信号分解的技术,旨在将非平稳信号分解为若干个具有不同频率特征的内禀模态函数(Intrinsic Mode Functions,IMF)。与传统的经验模态分解(Empirical Mode Decomposition,EMD)相比,VMD 通过引入变分问题的形式,能够有效地避免模态混叠问题,并且具有较好的自适应性和稳健性。因此,本研究将 VMD 引入溶解氧预测,以提升模型对复杂时序特征的表征能力,从而增强预测精度。

VMD 约束变分模型如式(3)所示:

$$\begin{cases}\min\limits_{\{u_k,w_k\}}\left(\sum\limits_{k}\left\|\partial_t\left\{\left[\delta(t)+\dfrac{\mathrm{j}}{\pi t}\right]u_k(t)\right\}\mathrm{e}^{-\mathrm{j}w_k t}\right\|_2^2\right)\\ \text{s.t.}\ \sum\limits_{k}u_k(t)=f\end{cases} \tag{3}$$

式中:u_k 为各模态函数,w_k 为各模态中心频率,$\delta(t)$ 是狄拉克函数,f 为需要被分解的原始序列。针对上述约束变分模型,VMD 通过引入增广拉格朗日函数将其转化为无约束优化问题,并采用交替方向乘子法进行高效求解。该算法在频域内交替执行以下核心步骤:首先,通过维纳滤波与频谱重心估计,同步更新所有模态分量及其中心频率;其次,依据当前重构误差对拉格朗日乘子进行双重上升更新。此迭代过程持续直至满足收敛条件,从而自适应地实现信号的分解。

2.3　Mamba 基础架构

Mamba[23]是一种基于结构化状态空间模型(Structured State Space,SSM)的新型序列建模架构。它通过引入选择性机制(Selective Mechanism),不仅成功解决了传统 SSM 模型在内容感知推理上的短板,还保持了比 Transformer 更低的线性计算复杂度增长。

传统 SSM 模型中,状态转移参数 $\boldsymbol{A}$、$\boldsymbol{B}$、$\boldsymbol{C}$ 通常保持固定,难以适应时序数据的动态变化;而 Mamba 则摒弃了这一静态设定,使参数在时间维度上可变,从而增强了模型对非平稳序列的建模能力。模型在时刻 t 的状态更新与输出计算可表示为:

$$\begin{aligned}\boldsymbol{h}_t&=A\boldsymbol{h}_{t-1}+B\boldsymbol{x}_t\\ \boldsymbol{y}_t&=C\boldsymbol{h}_t\end{aligned} \tag{4}$$

式中：$\boldsymbol{h}_t$ 为隐状态向量，$\boldsymbol{x}_t$ 为输入向量，$\boldsymbol{y}_t$ 为输出向量，$\boldsymbol{A}$、$\boldsymbol{B}$ 和 $\boldsymbol{C}$ 为可学习参数矩阵。随后，Mamba 采用零阶保持（Zero-Order Hold，ZOH）方法对连续时间系统进行离散化，其核心离散化公式为：

$$\begin{aligned}\overline{\boldsymbol{A}}&=\exp(\Delta\boldsymbol{A})\\ \overline{\boldsymbol{B}}&=(\Delta\boldsymbol{A})^{-1}(\mathrm{e}^{\Delta\boldsymbol{A}}-\boldsymbol{I})\times\Delta\boldsymbol{B}\end{aligned}\tag{5}$$

式中：$\overline{\boldsymbol{A}}$ 和 $\overline{\boldsymbol{B}}$ 为离散化后的模型参数。该方法通过矩阵指数运算将连续系统的状态保持为常数，直到下一个输入到来，实现了从连续域到离散域的平滑转换。最终，模型的离散形式可表示为：

$$\begin{aligned}\boldsymbol{h}_t&=\overline{\boldsymbol{A}}\boldsymbol{h}_{t-1}+\overline{\boldsymbol{B}}\boldsymbol{x}_t\\ \boldsymbol{y}_t&=\boldsymbol{C}\boldsymbol{h}_t\end{aligned}\tag{6}$$

这种离散化处理使得模型能够有效地处理实际应用中的离散时间序列数据。

尽管选择性机制导致传统卷积模式的效率降低，但 Mamba 通过硬件感知的并行扫描算法有效克服了这一挑战。该算法将计算过程融合，并在 GPU 高速缓存中执行，从而显著减少内存访问开销，实现了高效的线性计算复杂度。这使 Mamba 特别适用于处理水产养殖中长时间跨度的溶解氧浓度序列数据，Mamba 块子模型结构如图 2 所示。

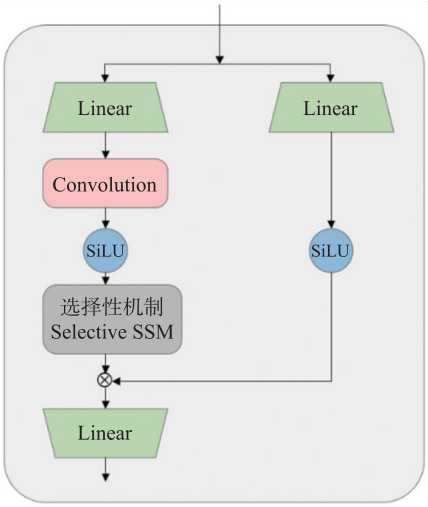

图 2 mamba 块子模型

2.4 多头注意力机制

在溶解氧预测任务中，长时间依赖建模往往面临信息衰减与特征提取不足的问题。为此，本研究在模型中引入多头注意力机制[24]（Multi-Head Attention，MHA），以增强模型对关键时序特征的捕捉能力。

给定输入序列 X，注意力机制首先通过线性变换得到查询 $\boldsymbol{Q}$、键 $\boldsymbol{K}$ 与值 $\boldsymbol{V}$：

$$\boldsymbol{Q}=X\boldsymbol{W}^{Q},\boldsymbol{K}=X\boldsymbol{W}^{K},\boldsymbol{V}=X\boldsymbol{W}^{V}\tag{7}$$

式中：$\boldsymbol{W}^{Q}$，$\boldsymbol{W}^{K}$，$\boldsymbol{W}^{V}$ 为可训练的参数矩阵，用于实现不同特征子空间的映射。单头注意力的计算公式为：

$$\mathrm{Attention}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=\mathrm{Softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_k}}\right)\boldsymbol{V}\tag{8}$$

式中：$\boldsymbol{Q}$ 为查询矩阵、$\boldsymbol{K}$ 为键矩阵，$\boldsymbol{V}$ 为值矩阵，d_k 为向量维度，Softmax 表示归一化操作。

在此基础上，多头注意力机制通过并行执行多个独立的注意力头，并在最后进行拼接与线性映射，从而提升模型的特征表达能力：

$$\mathrm{MultiHead}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=\mathrm{Concat}(\mathrm{head}_1,\cdots,\mathrm{head}_h)\boldsymbol{W}^{O}\tag{9}$$

式中：$\mathrm{head}_i=\mathrm{Attention}(\boldsymbol{Q}\boldsymbol{W}_i^{Q},\boldsymbol{K}\boldsymbol{W}_i^{K},\boldsymbol{V}\boldsymbol{W}_i^{V})$，$\boldsymbol{W}^{O}$ 为输出映射参数。

通过多头机制，模型能够在不同子空间并行学习时间序列的多尺度依赖关系，从而更有效地捕捉溶解氧浓度变化中潜在的时序模式与关键特征。

2.5 SAMamba 框架

为解决溶解氧浓度的时序预测问题，本文提出了一种深度序列建模网络 SAMamba（Stacked Attention Mamba）。该模型首先通过线性映射将输入特征投影到固定维度，以确保与后续模块的一致性。SAMamba 通过多层堆叠的 Mamba 模块，每层独立学习不同尺度的序列特征，并通过层间传递逐步抽象复杂的动态模式。每层 Mamba 模块内的卷积层捕捉局部模式，状态空间建模捕获全局信息，多头注意力机制调节时间步间的依赖关系，从而有效建模远程依赖。最终，模型提取最后时间步的特征向量，经过线性映射生成预测值，实现溶解氧浓度的回归预测。整体结构充分融合了局部卷积特征、全局序列演化和长程依赖建模的优势，为复杂时序预测任务提供了一种高效且可扩展的解决方案，SA-Mamba 模型结构如图 3 所示。

2.6 预测模型 VMD-SAMamba

养殖过程中水体溶解氧含量的变化受多个复杂因素影响，且在时间维度上呈现强非线性与非平稳特性，在预测过程中需同时兼顾多源环境参数（如水温、pH 值等）间的耦合关系与时序动态依赖。因此，本研究构建了 VMD-SAMamba 溶解氧预测模型。首先，采用 VMD 对原始溶解氧序列进行多尺度模态分解，将高频噪声与低频趋势成分有效分离，从而提高数据质量与模型稳定性。其次，引入与多头注意力机制相结合的 Mamba 模块，在保持长序列并行化计算效率的同时，增强对全局时序关系与重要时间节点的感知能力。为进一步提升特征提取的层次性与非线性拟合能力，模型采用多层堆叠式设计，以保障训练稳定性与泛化性能。整体预测流程如图 4 所示。

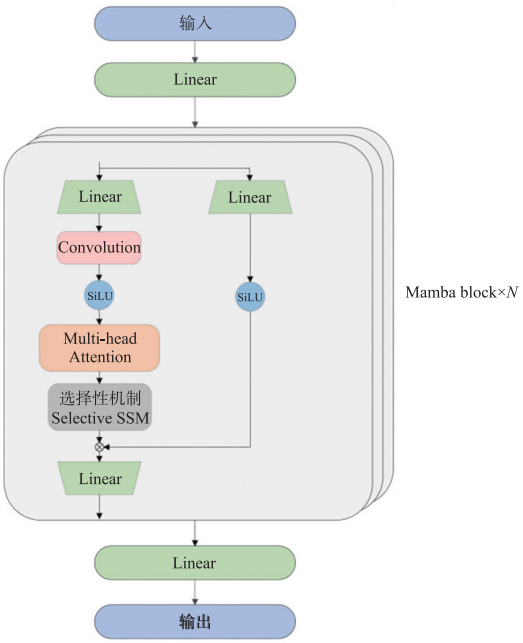

图 3　SAMamba 模型结构

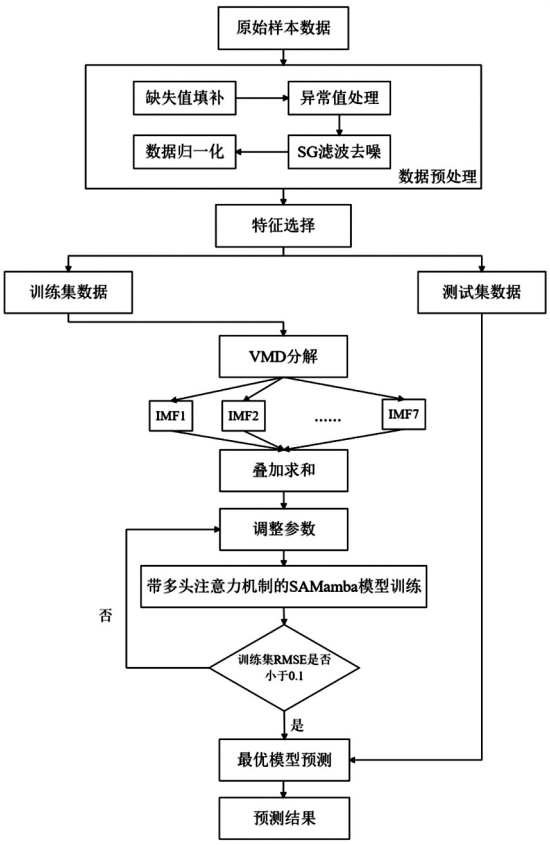

图 4　VMD-SAMamba 模型流程

本研究模型对溶解氧预测的步骤如下:

①对采集的水质数据进行预处理,主要包括缺失值填补、异常值处理、SG 滤波去噪与归一化等操作,并按照 8∶2 的比例将数据划分为训练集和测试集。

②使用皮尔逊相关系数对数据集进行关联系数计算,判断影响溶解氧变化的关键指标,构建预测体系,并对训练集和测试集进行预测构建和训练。

③在构建的 VMD-SAMamba 模型中,采用 VMD 对目标溶解氧进行分解,并将多个分解量叠加重构为新的溶解氧目标序列。以重构后的溶解氧序列作为训练目标,输入 SAMamba 模型进行训练,直至训练效果达到最佳或达到预定训练次数。

④在测试集中进行 VMD-SAMamba 预测模型测试,并将其与当前主流预测模型的预测结果进行对比,分析其预测性能,最终输出溶解氧预测结果。

2.7　模型性能评估指标

为了全面评估模型性能,本研究采用平均绝对误差(Mean Absolute Error,MAE)、均方根误差(Root Mean Squared Error,RMSE)以及决定系数(Coefficient of Determination,R^2)作为评价指标,其计算公式为:

$$\mathrm{MAE}=\frac{1}{n}\sum_{i=1}^{n}|y_i-\hat{y}_i| \tag{10}$$

$$\mathrm{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i-\hat{y}_i)^2} \tag{11}$$

$$R^2=1-\frac{\sum_{i=1}^{n}(y_i-\hat{y}_i)^2}{\sum_{i=1}^{n}(y_i-\bar{y})^2} \tag{12}$$

式中:y_i 表示第 i 个样本的实际值,$\hat{y}_i$ 表示第 i 样本的预测值,$\bar{y}$ 是实际值 y 的均值,n 是样本数量。

3　结果与分析

3.1　试验设置

本研究的所有模型均基于 PyTorch 2.0.0 框架,在 Ubuntu 20.04 操作系统下运行,Python 版本为 3.8。实验硬件环境为 Intel Xeon Platinum 8474C CPU(15 核)、NVIDIA RTX 4090D GPU(24 GB),并基于 CUDA 11.8 提供计算支持。

3.2　特征选择

表 2 所示为溶解氧与各指标的皮尔逊相关系数的结果,综合考虑特征的贡献度与冗余性,最终选取溶解氧、水温、气温等 5 或 6 个特征作为模型输入变量。

表 2　溶解氧与各指标的相关系数

水温	气温	大气压力	风速	PM2.5	PM10	PH	湿度	风向
−0.941 5	−0.822 5	0.805 7	0.434 9	−0.362 9	−0.361 5	0.341 2	0.248 0	−0.197 8

3.3 VMD 分解

为了更好地提取溶解氧时间序列的多尺度特征,本文采用了 VMD 对溶解氧信号进行了处理。获得 7 个 IMF,每个 IMF 代表信号的不同频率成分。通过这种分解,信号的低频成分通常包含了主要的趋势和周期性,而高频成分则可能包含噪声,图 5 展示了 VMD 分解的结果。

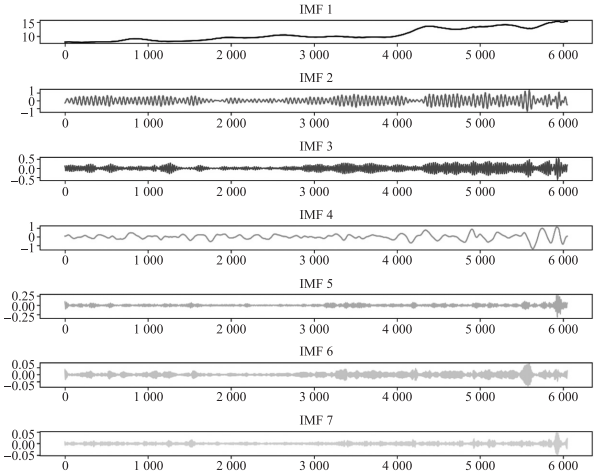

图 5 各 IMF 分量

3.4 不同溶解氧模型预测性能比较

为了全面评估 VMD-SAMamba 模型的预测性能,本文将其与 LSTM[25]、GRU[26]、DA-CNN-BiLSTM[27]、CNN-BiGRU[28]、CNN-BiLSTM[29]等模型对比。

表 3 为不同溶解氧模型预测性能对比结果。

表 3 不同溶解氧模型预测性能对比

模型	MAE	RMSE	R^2
LSTM	0.165 7	0.231 7	0.960 7
GRU	0.143 9	0.195 1	0.972 2
DA-CNN-BiLSTM	0.117 1	0.177 4	0.977 1
CNN-BiGRU	0.154 0	0.240 7	0.957 8
CNN-BiLSTM	0.144 7	0.212 2	0.967 3
EMD-SAMamba	0.075 1	0.103 7	0.992 1
VMD-SAMamba	**0.050 7**	**0.083 1**	**0.994 9**

相比基线模型 LSTM 和 GRU,VMD-SAMamba 各项预测指标均最佳,在 MAE、RMSE 和 R^2 上分别取得了大幅度的提升,MAE 降低了 69.40%、64.77%,RMSE 降低了 64.13%、57.41%,R^2 提升了 0.034 2、0.022 7。DA-CNN-BiLSTM、CNN-BiGRU 和 CNN-BiLSTM 模型在预测精度上也显示了较好的表现,但与 VMD-SAMamba 相比,仍存在一定的差距。具体而言,VMD-SAMamba 的 RMSE 相较于上述三者分别降低了 53.16%、65.48%和 60.84%,其 MAE 分别降低了 56.70%、67.08%和 64.96%。与 EMD-SAMamba 相比,MAE、RMSE 上分别降低了 32.49%、19.87%,R^2 提升了 0.002 8。由此,表明本文提出的模型在溶解氧预测性能上具有较明显的优势。

如图 6 所示,从整体趋势来看,溶解氧浓度随时间呈现出明显的昼夜周期性变化特征,白昼时段因光合作用增强导致溶解氧升高,夜间则因光合作用停止导致溶解氧水平下降。本研究提出的 VMD-SAMamba 模型在溶解氧预测任务中表现最为优越,预测曲线与真实值的拟合效果最为接近,尤其在溶解氧波动较大及峰值处,能够相对准确跟踪真实值的变化趋势。其余模型的预测曲线与真实曲线之间的差距较为明显,GRU 和 LSTM 模型的预测精度较差,尤其在溶解氧的波动较大时,预测结果与真实值之间的偏差较为明显。

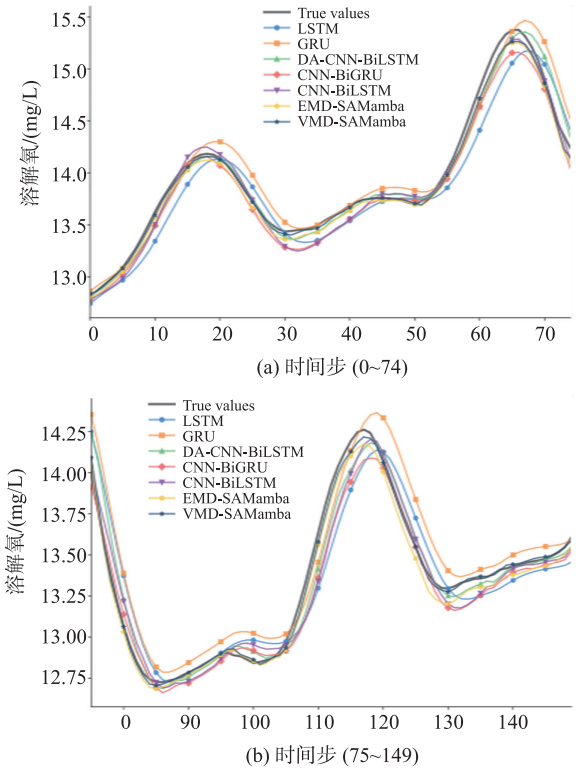

图 6 不同模型预测溶解氧的预测性能对比

3.5 预测有效性分析

为进一步验证所提方法在误差稳定性与统计显著性方面的优势,对各模型预测结果的误差分布进行了可视化比较。

图 7 展示了不同模型在测试集上的预测误差分布情况。从整体上看,传统序列模型(如 LSTM、GRU、CNN-BiGRU、CNN-BiLSTM、DA-CNN-BiLSTM)均存在较大的波动范围和明显的离群点,表明其在拟合复杂溶解氧序列时稳定性不足。相比之下,EMD-SAMamba 在中位数附近表现出更小的波动,但其误差分布仍然较宽。本文提出的 VMD-SAMamba 模型的误差箱体最为紧凑,分布区间显著

缩小,充分说明该模型不仅能够有效降低预测偏差,还显著提升了预测结果的稳定性与鲁棒性。

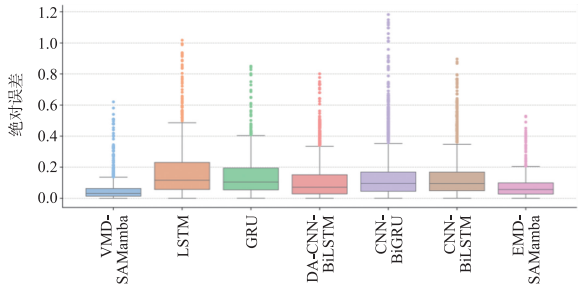

图 7　溶解氧预测绝对误差分布

图 8 展示了 7 种模型的对溶解氧预测性能的泰勒图,越靠近圆点代表模型预测性能越好。从图中可以看出,VMD-SAMamba 模型在综合预测性能上表现最佳,其相关系数最接近 1,标准差和 RMSE 均表现出较小的误差。GRU 模型虽然标准差接近观测值,但其相关性较低,导致预测精度相对较差。其他模型,如 LSTM、DA-CNN-BiLSTM、CNN-BiGRU 和 CNN-BiLSTM,均在相关性和预测误差方面逊色于 VMD-SAMamba,尤其是在误差(RMSE)上表现出明显的劣势。与 EMD-SAMamba 相比,VMD-SAMamba 在标准差和相关系数方面表现更优,其 RMSE 由 0.103 7 降至 0.083 1。结果表明,VMD 方法因其能有效克服 EMD 的模态混叠问题,生成了更稳定的子序列,为预测模型提供了质量更高的输入,提升了溶解氧的预测精度。

综上,VMD-SAMamba 模型在预测精度、稳定性和鲁棒性方面均表现最佳,特别是在捕捉溶解氧浓度的动态变化和波动时。

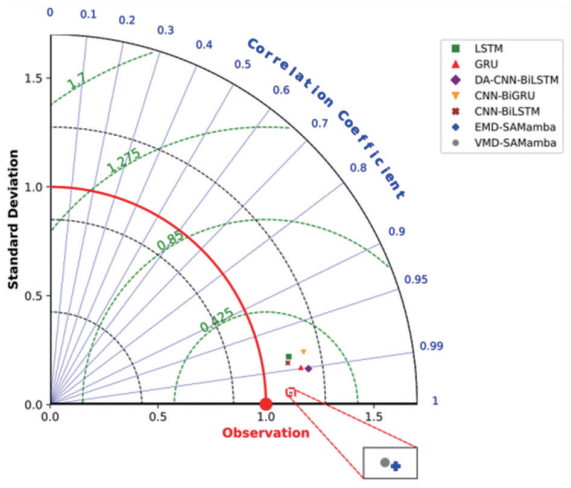

图 8　不同模型对溶解氧预测性能的泰勒图

3.6　消融实验

为验证各改进的模块对溶解氧预测模型性能上的影响,本研究设计了系列消融实验,分别构造如下 4 个消融对比模型。

本研究提出四种模型进行溶解氧预测:基线模型 Mamba、VMD-Mamba(引入 VMD 分解方法)、VMD-Mamba-Att(在 VMD-Mamba 基础上加入多头注意力机制以强化时序依赖建模)以及 VMD-SA-Mamba(采用多层堆叠式 Mamba 提升预测精度),实验结果如表 4 所示。

表 4　消融实验的溶解氧预测性能对比

模型	MAE	RMSE	R^2
Mamba	0.103 1	0.136 4	0.986 4
VMD-Mamba	0.080 3	0.090 6	0.994 0
VMD-Mamba-Att	0.066 8	0.088 9	0.994 2
VMD-SAMamba	**0.050 7**	**0.083 1**	**0.994 9**

从表 4 所示的消融实验结果可以看出,Mamba 作为基线模型,其 RMSE 为 0.136 4,MAE 为 0.103 1,表明能够有效预测溶解氧序列。在引入 VMD 预处理后,VMD-Mamba 模型的 MAE 和 RMSE 分别降至 0.080 3 和 0.090 6,R^2 提升至 0.9940,显著提升了性能,表明 VMD 在序列分解中的起到重要作用。进一步引入多头注意力机制,构建 VMD-Mamba-Att,MAE 和 RMSE 分别降至 0.066 8 和 0.088 9,提升了模型对关键依赖关系的捕捉能力。VMD-SAMamba 通过多层堆叠式 Mamba 结构,达到了最佳性能,MAE、RMSE 和 R^2 分别为 0.050 7、0.083 1 和 0.994 9,表明深层时序建模能够有效捕捉复杂模式和长程依赖。

图 9 展示了消融实验中不同模型在溶解氧预测

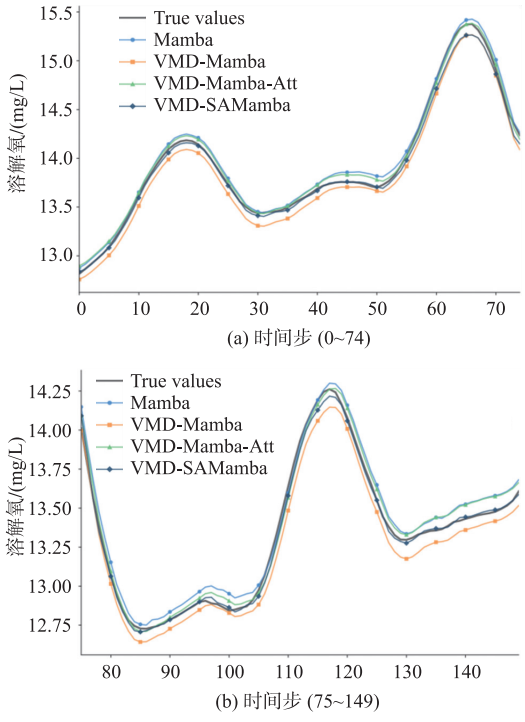

图 9　消融实验的溶解氧预测效果对比

任务中的表现。Mamba 作为基线模型,虽然能够较为稳定地预测溶解氧,但在波动较大的区域,预测值与真实值之间存在明显差异。引入 VMD 预处理后的 VMD-Mamba 模型,预测曲线在波动部分有所改善,拟合效果较基线模型更加接近真实值,尤其在溶解氧变化较大的时段,表现出更高的稳定性。对引入多头注意力机制的 VMD-Mamba-Att 模型,尽管与 VMD-Mamba 相比,改进幅度较小,但在捕捉时序数据中的关键依赖关系仍有所提升。VMD-SAMamba 模型通过深层堆叠的 Mamba 结构,展现了最佳的预测精度,证明了深层时序建模和多层结构的引入在捕捉复杂时序模式和长程依赖方面的显著优势。

4 结论

本文提出了一种融合信号分解与深度学习方法的创新预测框架 VMD-SAMamba。主要结论如下:①通过引入 VMD 对溶解氧序列进行多尺度分解,有效降低了噪声对预测过程的影响,提升了模型的稳定性和鲁棒性。②构建了结合多头注意力机制与 Mamba 结构的多层堆叠模型,增强了模型对溶解氧浓度中长期依赖关系的捕捉能力,提升了全局时序模式的学习效果。③对所提出的 VMD-SAMamba 模型进行了充分验证,结果表明其在多项性能指标上均优于主流模型,相较于 CNN-BiGRU 模型,MAE 与 RMSE 分别降低了 67.08%和 65.48%,同时显著优于 LSTM、GRU、CNN-BiLSTM 等方法,展现出优异的预测性能与应用潜力。

本文提出的河道水体溶解氧预测模型 VMD-SAMamba 具有较高的预测性能,对智慧渔业与水质智能调控具有重要参考价值。未来研究将进一步探索多变量耦合预测与轻量化模型部署,以推动其在实际应用场景中的落地。

参考文献:

[1] 李无言,王志强,蒋永年,等. 基于优化回声状态网络的溶解氧预测建模[J]. 控制工程,2023,30(3):520-528.

[2] 李雯,施珮. 融合特征信息和改进 BiGRU 的池塘养殖溶解氧预测模型[J]. 农业工程学报,2025,41(19):218-226.

[3] 张铮,高森,张泽扬. 基于特征构造预处理与 TCN-BiGRU 的池塘溶解氧预测模型[J]. 上海海洋大学学报,2023,32(5):943-952.

[4] 陈英义,方晓敏,梅思远,等. 基于 WT-CNN-LSTM 的溶解氧含量预测模型[J]. 农业机械学报,2020,51(10):284-291.

[5] 姚启,缪新颖. 基于主成分分析及 GA-LM 的水产养殖环境溶解氧和氨氮含量预测[J]. 大连海洋大学学报,2021,36(5):851-858.

[6] 曹守启,周礼馨,张铮. 采用改进长短时记忆神经网络的水产养殖溶解氧预测模型[J]. 农业工程学报,2021,37(14):235-242.

[7] 谢雨茜,李路,朱明,等. 基于 EMD 与 *K*-Means 的 ILSTM 模型在池塘溶解氧预测中的应用[J]. 华中农业大学学报(自然科学版),2022,41(3):200-210.

[8] 张铮,贾香港,张泽扬,等. 融合 IDA-GRU 和 IIDW 的水产养殖溶解氧时空预测模型[J]. 农业工程学报,2023,39(21):161-171.

[9] Putpuek N, Putpuek A, Sungthong A. A Comparative Study of LSTM,GRU,BiLSTM and BiGRU to Predict Dissolved Oxygen[C]//2023 20th International Joint Conference on Computer Science and Software Engineering(JCSSE),Phitsanulok,Thailand,IEEE,2023:67-72.

[10] Bi J,Lin Y Z,Dong Q X,et al. An Improved Attention-Based LSTM for Multi-Step Dissolved Oxygen Prediction in Water Environment[C]//2020 IEEE International Conference on Networking,Sensing and Control(ICNSC),Nanjing,China,IEEE,2020:1-6.

[11] 石庆兰,束金阳,李道亮,等. 基于 BiLSTM-GRU 融合网络的稻虾养殖溶解氧含量预测[J]. 农业机械学报,2023,54(10):364-370.

[12] 胡龙元,刘黎志. 基于改进鲸鱼算法优化 GRU-CNN 的溶解氧预测[J]. 环境工程学报,2024,18(10):2957-2964.

[13] Xu X,Guo C,Fan J,et al. A Multi-Step Prediction Model Based on Wavelet Transform and Deep Learning Techniques for Predicting Dissolved Oxygen Concentration[C]//2024 8th Asian Conference on Artificial Intelligence,Fuzhou,China,2024:146-152.

[14] 白雯睿,杨毅强,李强. 引入小波分解的 Seq2Seq 水质多步预测模型研究[J]. 现代电子技术,2022,45(17):100-105.

[15] 曹文治,苏雅,曾阳艳,等. 基于 EEMD-LSTM-SVR 的水质预测模型[J]. 系统工程,2023,41(4):1-12.

[16] 施珮,匡亮,王泉,等. 一种基于 CEEMDAN-CPELM 的池塘溶解氧预测模型研究[J]. 传感技术学报,2024,37(1):89-97.

[17] 胡家铭,曾庆军,韩春伟,等. 基于自适应 VMD 的 sEMG 信号识别研究[J]. 电子器件,2025,48(1):25-30.

[18] 陈静,李海洋. 基于 GRA-GRU 的淮河流域水质预测研究[J]. 安全与环境学报,2024,24(1):376-387.

[19] Breunig M M, Kriegel H P, Ng R T, et al. LOF: Identifying Density-Based Local Outliers[J]. ACM SIGMOD Record,2000,29(2):93-104.

[20] 陶志勇,胡启振,任晓奎. 基于二层分解技术和改进神

经网络的河流溶解氧预测研究[J]. 云南大学学报(自然科学版),2022,44(2):262-270.

[21] 赵朔,桂峰兰,柳后起. 基于三种机器学习模型的太湖总氮浓度预测[J]. 中国农村水利水电,2022(6):24-28,39.

[22] Dragomiretskiy K,Zosso D. Variational Mode Decomposition [J]. IEEE Transactions on Signal Processing,2014,62(3):531-544.

[23] 白晓磊,张雪元,王智永,等. 基于 Mamba 模型的区域电价预测方法[J]. 计算机应用,2025,45(S2):137-142.

[24] 高广尚. 深度学习推荐模型中的注意力机制研究综述[J]. 计算机工程与应用,2022,58(9):9-18.

[25] Huan J, Li H, Li M B, et al. Prediction of Dissolved Oxygen in Aquaculture Based on Gradient Boosting Decision Tree and Long Short-Term Memory Network:A Study of Chang Zhou Fishery Demonstration Base, China[J]. Computers and Electronics in Agriculture, 2020, 175:105530.

[26] Li W Y, Wu H, Zhu N Y, et al. Prediction of Dissolved Oxygen in a Fishery Pond Based on Gated Recurrent Unit (GRU)[J]. Information Processing in Agriculture,2021,8(1):185-193.

[27] 谢小良,吴琳琳. 基于 DA-CNN-BiLSTM 的河流溶解氧浓度预测[J]. 人民黄河,2024,46(7):92-97,111.

[28] 黄宇,顾智勇,李永玲,等. 基于时间模式注意力机制的 CNN-BiGRU 短期负荷预测[J]. 华北电力大学学报(自然科学版),2023,50(6):11-20.

[29] Wang X, Tang X, Zhu M, et al. Predicting Abrupt Depletion of Dissolved Oxygen in Chaohu Lake Using CNN-BiLSTM with Improved Attention Mechanism[J]. Water Research,2024,261:122027.

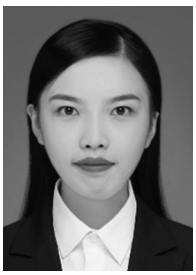

付玄宇(2002—),女,硕士研究生,研究方向为水质预测,fxy3037@163.com;

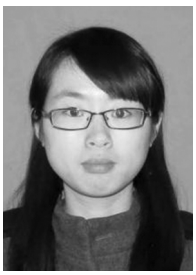

施　珮(1988—),女,导师,通讯作者,博士,硕士生导师,副教授。研究方向为无线传感网络、农业物联网和大数据分析方向,ship@cwxu.edu.cn。