



· 综述 ·

神经网络在养殖水质精准预测方面的研究进展

王 骥^{1,2*}, 谢再秘^{2,3*}, 莫春梅^{1,2}

(1. 广东海洋大学电子与信息工程学院, 广东 湛江 524088;

2. 广东海洋大学, 广东省智慧海洋传感网及其装备工程技术研究中心, 广东 湛江 524088;

3. 广东海洋大学数学与计算机学院, 广东 湛江 524088)

摘要: 目前神经网络研究文献成果较多, 虽然在水质精准预测方面起到了一定的参考, 但由于文献缺少科学分类, 使用率不高, 导致学者难以找到研究切入点。针对这一问题, 本文将神经网络方法在养殖区水质精准预测方面的文献按照海水和淡水两大领域进行分类, 主要对每个领域所应用的预测模型从正反馈架构、循环架构和混合架构三个方向对海水时空序列文献进行分类研究和综述, 发现混合架构模型的预测性能优于正反馈模型和循环架构模型, 有利于提升不同深度水质预测模型的精度。另外, 本文对基于神经网络方法的三维水质预测模型进行了初步探讨, 发现学者的研究成果更多地集中在水表层和水中层的不同位置水质参数的变化方面, 而神经网络方法对水表层水质预测精度比水中层和水深层水质预测精度高。

关键词: 养殖水质; 正反馈架构; 循环架构; 混合架构; 神经网络

中图分类号: TP 183; S 959

文献标志码: A

我国水产养殖发展迅速, 养殖产量连续二十多年居世界第一, 占全球产量近七成, 为我国人民提供了 1/3 的优质动物蛋白^[1]。近几年工业污染导致水质变差, 严重影响陆地养殖水产品的数量和质量。在陆地资源不足, 特别是能源紧张的情况下, 人类渔业生产必须依赖于水域环境的自然资源, 特别是海洋渔业, 而渔业养殖水环境成了海洋渔业发展的关键。传统的水质监测方法缺乏智能手段, 虽然能够满足水质参数检测等一般要求, 但不能很好地反映水质的非线性和非平稳性, 检测精度不高。随着神经网络的发展, 研究者为了提升养殖水质预测性能, 将神经网络方法应用于养殖水质预测, 并提出多个混合模型, 如

改进灰色关联分析-长短期记忆模型(CEEMDAN-LZC-GRU)^[2]和多元自适应回归-最小二乘支持向量机(MARS-LSSVM)^[3]等。对神经网络模型应用的相关研究文献与成果较多, 如何合理、规范、快速地使用机器学习, 成为学术界的热点。

1 神经网络方法相关理论

神经网络多层感知机^[4]的神经元之间的连接方式是从输入连接层到隐藏层的神经元或隐藏层的神经元到输出连接层, 层内的神经元是由输入层、隐藏层和输出层所组成, 具体结构如图 1 所示。BP 神经网络^[5]使用反向传播算法来解决参数训练问题。在各层架构基础上演变出的网络包含

收稿日期: 2022-09-17 修回日期: 2022-11-23

资助项目: 国家自然科学基金(51777046); 广东省普通高校重点领域新一代信息技术专项(2020ZDZX3008); 广东省人工智能领域重点专项(2019KZDZX1046)

通信作者: 王骥(照片), 从事无线传感器网络、海洋物联网与人工智能研究, E-mail: 13902576499@163.com; 谢再秘, 从事物联网与人工智能研究, E-mail: 1778037486@qq.com



极限学习机^[6](ELM)和径向基函数神经网络^[7](RBF)等。RBF神经网络与mlp的激活函数区别:前者为自组织映射,而后者不是。RBF神经网络的训练权值是通过聚类算法计算,在速度和计算能力方面表现出了卓越的性能。ELM最大的特点是通过随机选择隐藏节点的方式,使用最小二乘法来确定输出层的权值。




图1 Mlp架构

Fig. 1 Mlp architecture

循环神经网络(RNN)^[8-9]与多层感知机结构相比,层内神经元是相互连接的,不同类型的循环神经网络加以优化来获得较好的信息记忆能力(图2)。长短期记忆神经网络(LSTM)^[10-13]由遗忘门、输出门以及输入门组成,LSTM由循环神经网络进化而来,在循环神经网络的隐藏层中加入记忆细胞来决定某种状态信息是否保留并传到下一层,解决了RNN梯度消失和梯度爆炸问题。门控循环单元神经网络(GRU)^[14-16]是LSTM的变体,与LSTM结构相比,网络由更新门和重置门组成,简化了结构。卷积神经网络(CNN)^[17]能够解决LSTM和GRU在特征提取方面的缺陷,由池化层、卷积层和全连接层组成,卷积层主要提取特征,池化层对输入数据进行采样,全连接层输出结果。

2 神经网络方法在养殖水质预测中的应用

养殖水质分为淡水和海水。国内外学者研究发现,淡水水质参数含量波动小,水域封闭,水流速小,易受污染。与其相比,海水水质受海洋

大气等众多因素的影响,水流速大,波浪大,对海水取样以及监测存在难度。因此,以上环境条件给研究者对海水水质参数分析带来困难。初步统计,近年来国内外研究者对淡水水质的研究较多,而对海水水质预测研究少(表1)^[18-20]。因此,本文重点针对海水水质预测方法的研究。

本文对2019—2022年文献进行梳理,将养殖水质按照淡水和海水两大类来分析。海水预测架构模型分为3种,即正反馈架构模型、循环架构模型和混合架构模型(图3)。

2.1 神经网络方法在淡水领域中的应用

为了能够清晰地了解研究者对淡水预测的研究现状,将淡水预测模型分为一维水质时空序列预测模型和水质三维预测模型进行阐述。

一维水质时空序列预测模型 时空序列是时间序列在空间上的扩展,指在空间上有相关关系的多个时间序列集合,环境监测序列也是属于时空序列的数据之一。国内外学者已对水质时空序列预测方法进行了研究。

构建水质参数预测模型。为了构建水质溶解氧含量精准预测模型,学者提出了EEMD-RELM^[21]、KIG-ELM^[22]、k-medoids-Softplus-ELM^[23]、RBF^[24]和模糊C均值-RBF预测模型^[25],上述预测模型解决了基于数值的物理模型对水质时间序列预测问题,但还存在水质时间序列以及空间序列的特征提取问题。因此,研究者结合深度学习方法,提出了KPCA-RNN^[26]、VMD-DBN^[27]、XGBoost-ISSA-LSTM^[28]、PCA-K-means-GRU^[29]和随机森林-Attention-GRU^[30]预测模型,部分解决了对水质时间序列特征的提取问题,构建了简化的反向理解CNN^[31]和CNN-LSTM^[32-33]预测模型,缓解了对水质空间序列特征提取难的问题。除了神经网络方法应用于水质溶解氧含量预测外,涉及到其他水质参数的应用,如Yan等^[34]构建PSO-DBN-LSSVR预测模型,对总氮浓度的预测性能优于人工神经网络方法^[35]。Ahmadianfar等^[36]构建A-DEPSO与ANFIS集成的预测模型,提高了对电导率的预测准确性。Li等^[37]提出了小波变换方法结合WNN和WNARX集成的预测模型,对不同有毒金属长期序列具有较好的预测准确性。Zhu等^[38]构建极限学习机(ELM)预测模型对水温进行预测。Kisi等^[39]提出了采用连续遗传算法(CGA)等不同智能算法优化自适应神经-模糊推理系统

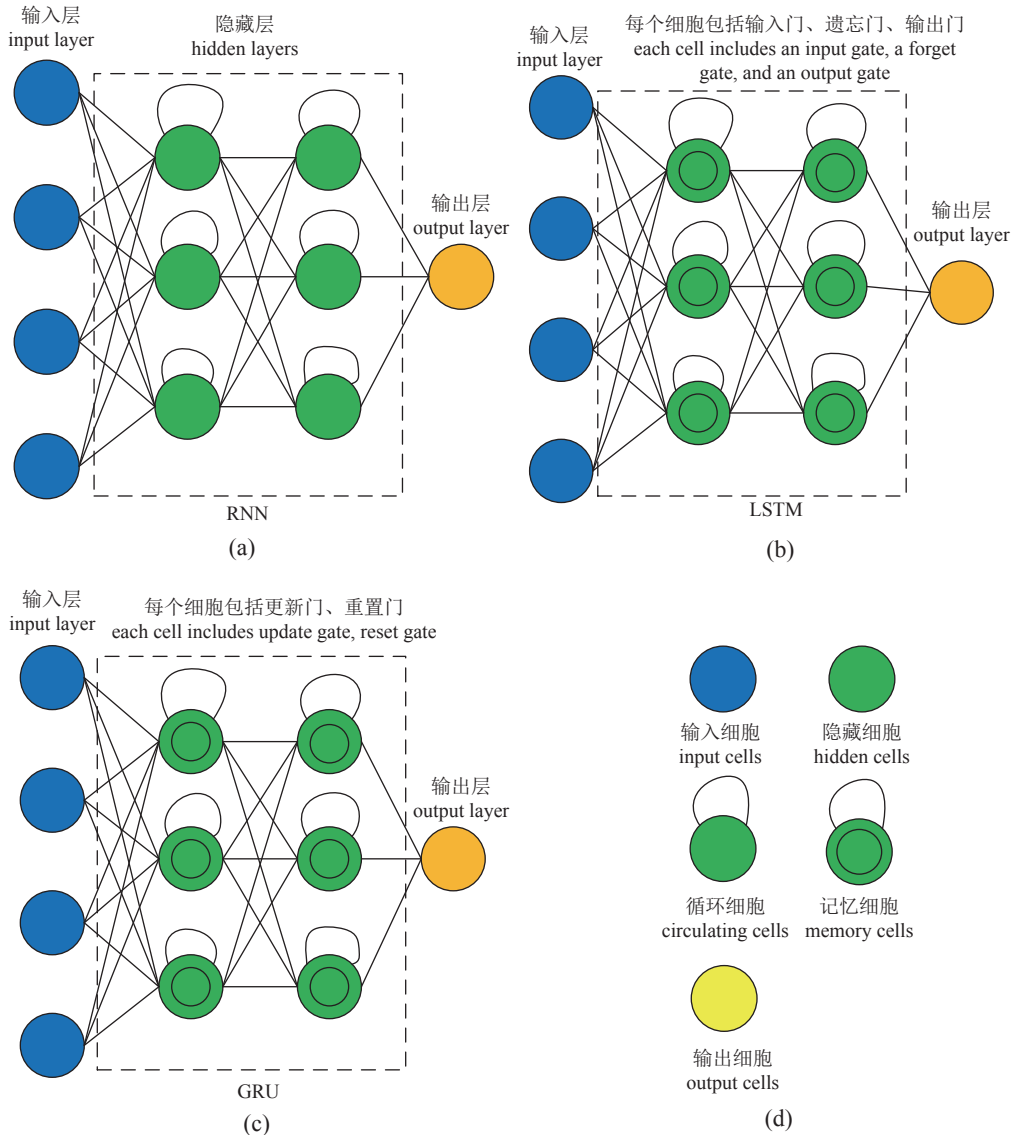


图 2 循环神经网络的两类结构图

(a) RNN, (b) LSTM, (c) GRU, (d) 细胞节点。

Fig. 2 Two types of structure diagram of recurrent neural network

(a) RNN, (b) LSTM, (c) GRU, (d) cell node.

表 1 2019—2022 年综述文献分类与数量

Tab. 1 Classification and number of literature reviewed 2019—2022

应用领域 applications	[18]	[19]	[20]	本文 this article
淡水 fresh water	31	8	19	42
海水 seawater	3	21	2	31

(ANFIS) 的预测模型, 分别对总硬度与电导率进行预测, 验证了 CGA 是优化 ANFIS 预测模型性能的最佳算法。综合上述预测模型分析, 研究者主要从数据预处理、模型的选择和超参数优化等几个方面来提升水质参数的预测精度。

构建水质指数预测和水质评价模型。水质指数预测模型和水质评价模型能够综合评判水质的好坏。Aldhyani 等^[40] 分别构建了非线性自回归神经网络 (NARNET) 和 LSTM 对水质指数进行预测, 结果验证了 NARNET 的预测性能优于 LSTM, 说

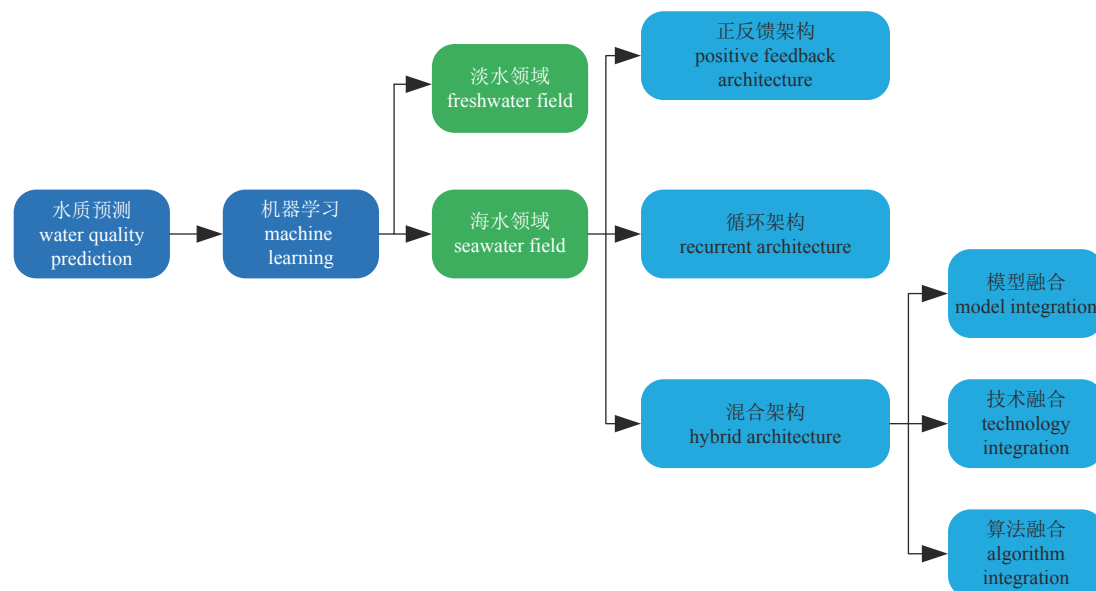


图3 水质预测方法分类图

Fig. 3 Classification chart of water quality prediction methods

明了其在水质时间序列特征提取方面有优势,但对水质指数预测性能不佳。Ebadati 等^[41]验证了多层感知器 (MLP) 对水质评价的准确度,在水质评价上优于 RBF 和回归方法;且为解决传统神经网络方法对水质评价的局限性,探讨了深度学习算法并应用于水质评价。Chen 等^[42]提出了改进卷积神经网络体系架构,用于建立智能光谱模型来评价水体污染水平。Prasad 等^[43]构建 LSTM 预测模型对水质进行二元和多分类评价,精度达 94%。

总之,研究者利用人工智能方法解决一维水质时空序列预测有以下问题,一方面研究一维水质时空特征提取的文献较少;另一方面水质是立体的,所研究的水质参数预测模型和水质评价模型无法了解水质在三维空间的变化。不管是一维水质参数预测模型还是评价模型,研究学者主要从数据预处理、超参数优化和模型的选择等方面入手。涉及输入参数的处理方法有 EEMD、随机森林、K-means、KPCA 和小波变换等;超参数优化方法有 IGA、PSO、DEPSO 和 CGA 等;对于模型的选择,最常用的深度学习方法有 GRU、LSTM 和 CNN 等。

水质三维预测模型 三维水体分为水表层、次表层、水中层和水深层,目前已有研究者对水表层和次表层水质含量进行预测研究。Chen 等^[44-45]使用 K-means-SC-RBF 和 PSO-BP-Kriging 预测模型对次表层溶解氧含量进行预测,结果证明 K-means-SC-RBF 预测模型具有较高的预测精度,运

行时间为 1.028 s,表明该模型在气象因素的影响下仍具有较高的训练效率,完整揭示了次表层不同区域溶解氧含量的变化。Cao 等^[46]构建了 RS-GBRT 预测模型,对次表层溶解氧含量进行了预测,结果显示,该模型的均方误差 (MSE)、平均绝对误差 (MAE) 和均方根误差 (RMSE) 分别为 0.121、0.219 和 0.348,揭示了次表层 20、40 和 60 m 处的溶解氧含量变化,20 m 处的溶解氧含量与气象因素相关,溶解氧含量较高,40 m 处的溶解氧含量与天气和水生植物的光合作用密切相关,60 m 处的溶解氧含量与水生植物光合作用相关。Liu 等^[47]构建三维循环模型,对水表层水温进行三维预测,研究表明,三维循环模型对表层水温的预测精度达到 97%,RMSE 和 MAE 分别为 0.44 和 0.39,对水表以下水温的预测精度达到 90%,RMSE 和 MAE 分别为 0.48 和 0.42。表层水温呈现日变化,由于阳光无法透过深层水层,水表以下 1、2 和 3 m 处水温变化不大。通过对 RMSE 和 MAE 等度量指标进行分析,发现 K-means-SC-RBF 预测模型性能更优,其次为 RS-GBRT、PSO-BP-Kriging 和三维模型,这 4 个模型都将三维坐标作为输入,选择神经网络方法作为水质溶解氧含量的训练模型,考虑了网络中超参数的优化。水质三维预测能够解决传统方法仅限于孤立点的时间序列以及未捕捉点与点(连续点)之间的空间关系,展示了水质参数含量在不同层的变化。通过分析发现,水表层以下的三维预测

模型预测精度有待提高, 建议对水质数据预处理、气象指标等影响水质的其他因素进行优化, 以提升模型的预测精度。

综合分析, 神经网络方法不仅能够满足单点一维淡水水质的准确预测, 而且也能满足三维水质预测, 为研究者对水质参数监测以及水质分布规律提供了参考。然而, 目前研究者在淡水水域所构建的预测模型仅对水表层和次表层进行预测, 在水中层和水深层处的水质预测研究不足。研究者主要通过对水质数据进行预处理、模型中超参数优化、水质时空序列特征的提取等方面来提升模型的预测精度。除了以上几方面, 还考虑了融合不同模型来探索水质空间特征的选择, 提高水质预测精度。目前主要研究难点是淡水水质研究条件相对于海水较简单, 海水较淡水流动大, 水交换频繁, 收集的数据指标波动大, 稳定性弱, 所以海水水质参数的实时收集以及预测准确性较难, 因此本文将神经网络在海水水域中的应用作为重点进行研究。

2.2 神经网络方法在海水水域中的应用

海水水质精准预测一直是业界难题。为了解不同神经网络方法在海水领域中的预测性能, 收集最新应用文献所提出的海水预测模型, 将预测模型分为正反馈架构、循环架构和混合架构来阐述。混合架构再细分为模型、技术和算法三个方面融合方法。表 2 列举了 2019—2022 年的相关文献, 列举了模型的性能表现, 描述了研究方法的分类、结构和优势, 可以清晰地了解神经网络方法应用在海水水域的现状。

一维时空序列预测模型 ① 正反馈架构。

正反馈架构模型较基于数值的物理模型能够对海水水质参数预测表现出良好的性能。Wei 等^[48]和 Er 等^[49]构建 ANN 预测模型, 分别对海温和总大肠杆菌 (*Escherichia coli*) 菌群值进行预测, 预测性能较好。Li 等^[50]构建径向基函数网络 (RBF) 预测模型, 能够很好地学习水质特征, 通过解决 BP (ANN) 网络局部过拟合问题, 提高水质参数预测精度。正反馈架构模型具有超参数少、计算效率高优点, 但将模型的超参数训练到最优时, 预测精度很高, 否则很容易降到最低。由于水质预测呈非线性, 具有时空特性, 所以正反馈架构模型对时空特征的提取存在缺陷, 通过循环架构的模型可以解决上述问题。

② 循环架构。已有研究者将循环架构模型应用于海水水质预测。Wang 等^[51]利用深度联合信息神经网络 (DJINN) 调整树的数量和最大深度优化模型结构的优点, 构建改进 M-DJINN 预测模型, 对水质进行预测, 具有较好的预测性能。Jiang 等^[52]通过实验验证了 DNN 和 RandomForest 预测模型对海水微塑料上弧菌 (*Vibrio*) 的相对丰度的预测性能, 较 SVR、ElasticNet 和 XGBoost 优, 但对时间序列特征的提取方面存在缺陷。Kim 等^[53]构建的 LSTM 神经网络模型能够很好地对水温 and 海表温度进行预测, LSTM 能够学习水温等水质参数的长期时间序列特征, 但会存在预测性能随着预测序列的增加而降低的问题。Han 等^[54]和 Patil 等^[55]分别构建 CNN 预测模型对海温序列特征进行提取, 以提高海温的预测精度, 但相对于 LSTM 来说, 对水质长期序列预测性能差。综合分析, 上述预测模型对水质信息的学习是相互影响的, 或仅学习水质时间序列特征, 或仅学习空间序列特征。为了构建出能够对水质时空序列特征提取的水质预测模型, 可融合 CNN 和 LSTM 集成的混合模型。

③ 混合架构-模型融合。混合架构模型集成了正反馈架构模型与循环架构模型的优点, 即模型融合、技术融合和算法融合深度集成。模型融合采用耦合策略, 融合不同神经网络。Kumar 等^[56]验证了 LSTM 与 RNN 结合的混合模型对海水水质的预测, 其性能表现优于单一的 ANN 和 SVR 正反馈架构模型。为了进一步提高模型的预测精度, 研究者考虑使用 CNN 模型解决水质空间特征提取问题。Liang 等^[57]利用 Inception-v3 优化 CNN 结构的优点, 构建 Inception-v3 与 CNN 集成的模型, 对微生物图像识别进而判断水质。Xiao 等^[58]构建了 CNN 与 LSTM 结合的预测模型 (ConvLSTM) 来捕获水温的时空序列特征, 提高了水质中短期海温序列预测的准确性。本研究团队为了满足 CNN 网络结构原有设计的细化并减少复杂的计算, 提高水质空间特征效率, 对原始的 CNN 结构进行了优化 (图 4)。模型融合主要利用不同模型的优势进行融合, 可改善预测精度, 虽然融合之后的模型参数复杂度很高, 需要处理的水质信息更多, 模型训练耗时较长, 但这项工作非常有意义, 可为将来研究水质精准预测模型提供基础。

④ 混合架构-技术融合。基于技术融合, 采用耦合策略将相关技术与神经网络方法进行融合。

表 2 神经网络方法的分类、结构和优势

Tab. 2 Classification, structure and advantages of neural network methods

类别 categories	网络 networks	结构 structures	优势 advantages	文献 reference
正反馈架构 positive feedback architecture	人工神经网络 artificial neural networks (ANN)	输入层、隐藏层、输出层 input layer, hidden layer, output layer	强大的非线性关系的计算 powerful calculation of nonlinear relationships	[48-49]
	径向基函数神经网络 radial basis function neural network (RBFNNs)	输入层、隐藏层(径向基激活函 数)、输出层 input layer, hidden layer (radial basis activation function), output layer	为了克服局部最小值问题, 消除数据 冗余和错误 to overcome the local minimum problem and eliminate data redundancy and errors	[50]
循环架构 recurrent architecture	深度神经网络 deep neural networks (DNNs)	输入层、隐藏层、输出层 input layer, hidden layer, output layer	解决了前馈网络无法捕获的长期依赖 问题 solving long-term dependency problem that cannot be captured by feed-forward networks	[51-52]
	长短期记忆神经网络 long-term and short-term memory neural networks (LSTMs)	输入门、遗忘门、输出门 input gate, forget gate, output gate	解决RNN梯度消失和梯度爆炸问题 solving the RNN gradient disappearance and gradient explosion problem	[53]
	卷积神经网络(CNN)	输入层、卷积层、池化层、输出 层 input layer, convolutional layer, pooling layer, output layer	能够提取水质特征 ability to extract water quality characteristics	[54-55]
模型融合 model integration	LSTM-RNN	输入层、隐藏层、输入门、遗忘 门、输出门 input layer, hidden layer, input gate, forgetting gate, output gate	提取时间序列特征 extracting time series features	[56]
	inception-v3-CNN	输入层、卷积层、池化层、输出 层 input layer, convolutional layer, pooling layer, output layer	提取空间序列特征 extracting spatial sequence features	[57]
	ConvLSTM	输入层、卷积层、池化层、输入 门、遗忘门 input layer, convolution layer, pooling layer, input gate, forgetting gate	提取水质时空序列特征 extraction of water quality spatial and temporal sequence characteristics	[58]
技术融合 technology integration	EEF-MLP	输入层、隐藏层、输出层 input layer, hidden layer, output layer	提高计算效率 improving computational efficiency	[59]
	Temp Attention-GED	更新门、重置门 update gate, reset gate	专注学习水质时间序列特征 focus on learning water quality time series characteristics	[60]
	Temp-Spa Attention-LSTM	输入门、遗忘门、输出门 input gate, forget gate, output gate	专注学习水质时空序列特征 focus on learning the spatio-temporal sequence characteristics of water quality	[61]
算法融合 algorithm integration	PCA-LSTM、CEEMD-BPNN、 PSO-K-means-Softplus-SELM	算法与神经网络方法结合 algorithms combined with machine learning methods	数据预处理的降维、数据预处理的降 噪、超参数优化 dimensionality reduction of data preprocessing, noise reduction of data preprocessing, hyperparameter optimization	[62-78]

本领域主要将熵集成滤波 (EEF) 和注意力机制两种技术与神经网络方法结合来构建海水预测模型, 前者为减少模型计算量, 后者为了关注水质相关信息, 忽略不相关信息。Foroozand 等^[59]应用 EEF 法结合多元线性回归 (MLR) 集成的模型对海面温度进行预测, 该模型的预测性能和计算效率表现良好。注意力机制分为时间注意力和空间注意力, 能够很好地优化水质预测模型来专注学习海水水质外部属性和时间序列状态。因此, Xie 等^[60]构建时间注意力与门控循环单元编码-解码

(GED) 集成的预测模型对海面温度进行预测, 利用时间注意力机制学习 GED 网络隐藏状态在每个时间窗口中的影响, 提高了模型的预测精度, 但该模型在空间特征的学习专注方面存在不足。Liu 等^[61]提出了时间注意力机制、空间注意力机制与 LSTM 网络集成的预测模型, 能够很好地捕获长短期记忆水质时空序列特征。上述研究应用注意力机制和熵集成滤波等相关技术与神经网络方法相结合, 注意力机制具有专注水质特征信息的选择, 熵集成滤波对水质时空特征信息进行跟踪,

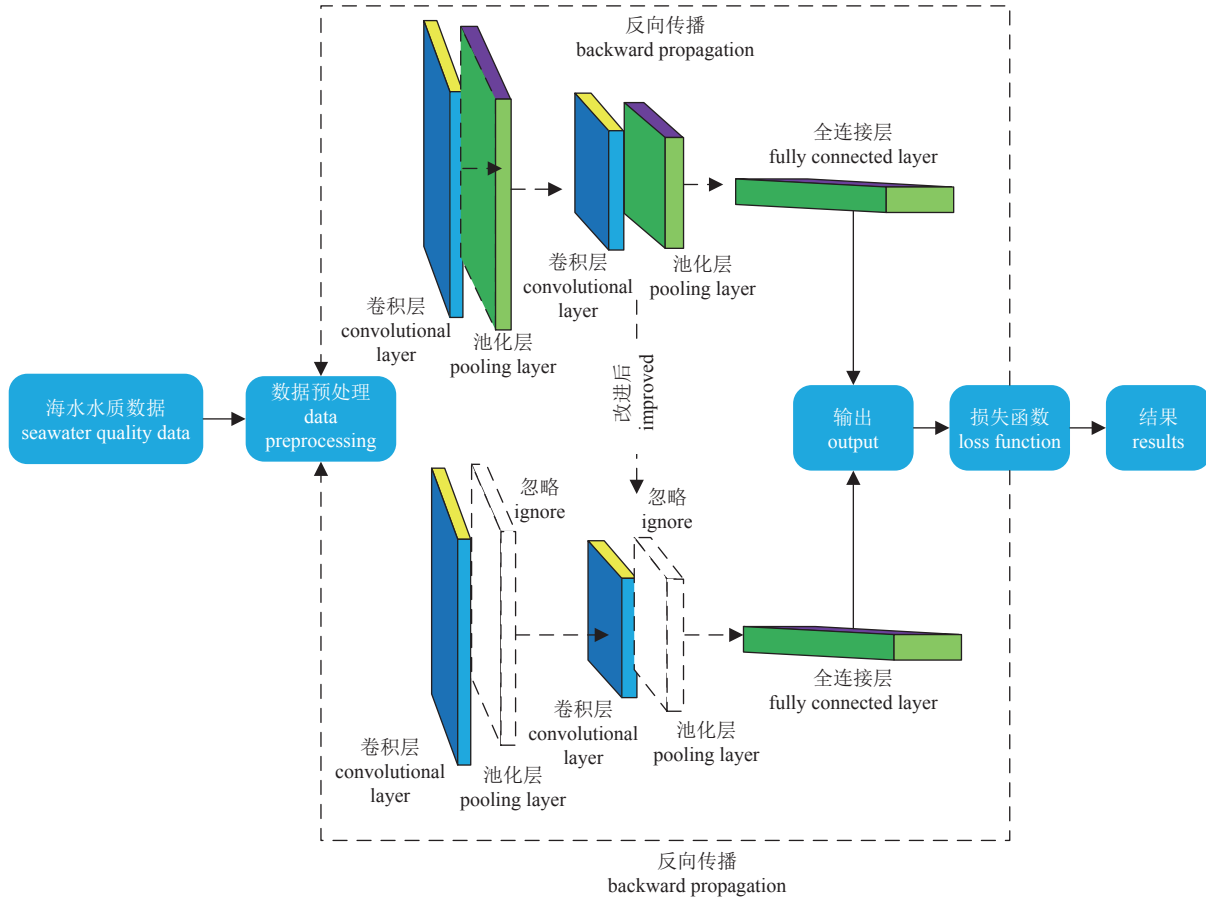


图 4 优化后的 CNN 结构
 Fig. 4 Optimized CNN structure

使神经网络方法在训练中更容易捕获水质特征，提升水质预测精度。

⑤ 混合架构-算法融合。算法融合方法采用耦合策略将不同算法与神经网络方法进行融合。其提高模型的预测精度主要围绕数据处理和网络结构优化等方面 (图 5)。

基于数据处理降维方法的应用。由于获取的原始水质数据维度较高，一方面增加了模型的复杂性，另一方面输入不相关信息到模型中会降低预测准确性。因此，Hu 等^[62]利用 Pearson 相关性系数得到 pH 值和水温等水质参数之间的相关先验 (贝叶斯 Pearson 相关性的先验分布)，提高 LSTM 预测模型对水质的预测精度。PCA 算法被研究者频繁使用来对水质参数进行降维，剔除水质冗余参数，减少模型训练参数。Sun 等^[63]利用 PCA 分析对海水水质因子进行降维，构建了 PCA 算法与关联向量机 (RVM) 结合的预测模型，该模型在预测精度和效率这两个度量指标上优于 RVM 与支持向量机方法。除了 PCA 算法外，还

有独立成分分析算法、线性判别分析算法^[64]和互信息算法^[65-66]等也能对水质特征 (水质参数) 进行简化，再将处理后的数据输入到神经网络中进行训练和学习，提升模型的预测精度。建议可将 PCA 算法和互信息算法结合起来优化海水参数，即对水质参数进行降维，并将每个参数之间的相关性相结合来设计算法。

基于数据处理降噪方法的应用。构建精准预测模型的前提是需要有一个高质量的数据集，由于获取的原始数据存在信号不稳定等噪声，若直接输入到模型，会影响其预测精度。因此，Liu 等^[67]利用小波变换算法对水质数据进行降噪，处理后的数据输入到深度 Bi-S-SRU (双向堆叠简单循环单元) 进行训练和预测，精度上优于 RNN 和 LSTM。Wu 等^[68]采用集成经验模态分解算法 (EEMD) 和互补集成经验分解算法 (CEEMD)，有效解决了 EMD 存在模态混叠的问题，使原始数据的分解信号更加平稳，CEEMD-BPNN 模型在预测精度上优于 EEMD-BPNN 模型。总之，应用于

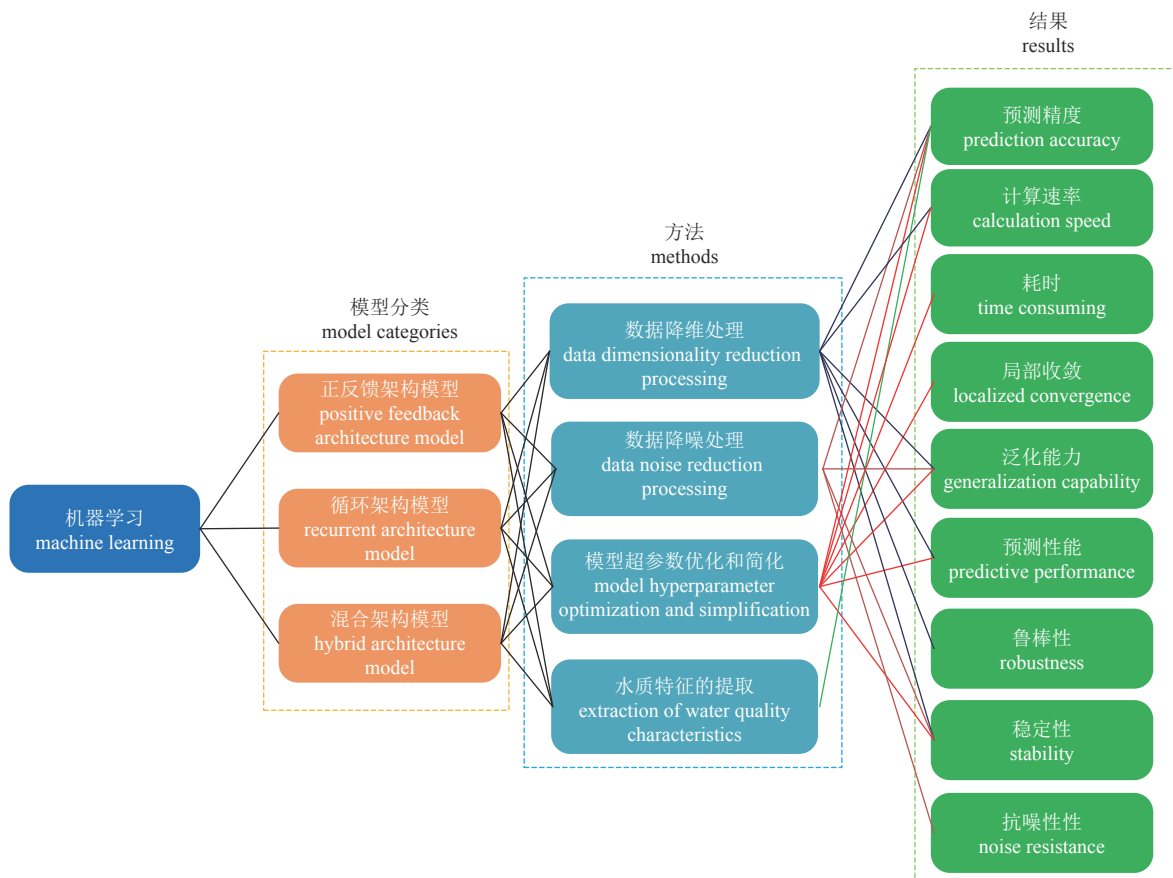


图 5 总优化架构

Fig. 5 Total optimization architecture

水质降噪的算法有小波滤波与 EEMD 等, EEMD 算法需要加入白噪声来剔除信号本身存在的噪声, 小波变换通过设置合适的阈值来降噪, 除了降噪算法外, 还有减法聚类 (SC)^[44]、K-means^[69] 等算法对水质进行降噪, 可有效增强样本信息, 提升神经网络方法的预测精度。

基于模型中超参数优化的应用。Cao 等^[70] 提出了采用粒子群优化算法 (PSO) 优化 K-means 聚类和改进 Softplus 极端学习机 (SELM) 的预测模型, 实验证明该模型具有很好的预测性能和预测精度。除了上述使用的 PSO 算法外, 在线学习算法也能优化模型中的超参数, 该算法根据线上反馈数据, 实时快速地进行模型调整, 使得模型及时反映线上的变化, 提高预测的准确率。Cesa-Bianchi 等^[71] 提出在线学习框架, 所设计的算法能够一次性处理数据, 来提高模型的计算效率并实时调整模型。Chen 等^[72] 为了解决支持向量机存在大规模训练样本中执行时间长、执行效率低的问题, 提出变支持向量机 (VSVM) 在线增量递减学习算法, 解决了随着数据增多导致的过程中训练速度变慢的问

题。Luo 等^[73] 构建的在线学习与极限学习机结合的算法模型 (TORELM) 具有高精度和更好的稳定性。需要说明的是, 除了 PSO 优化算法外, 常用于优化水质预测模型的优化算法还有蚁群算法 (ACO)、差分进化 (DE)、遗传算法 (GA)、改进遗传算法 (IGA) 等智能优化算法^[74]。总之, 在线学习算法具有在线反馈数据来调整模型的超参数的优势, 建议结合神经网络方法构建水质预测模型。模型中的超参数是影响模型预测精度的关键因子, 可以依靠训练水质数据获得超参数最佳值来构建精准预测模型。

基于水质特征的提取。水质特征的提取是模型训练的重要过程, 是影响水质预测精度的一个重要方面。构建一个精准预测模型需要不断地对水质特征参数进行训练和学习, 目前深度学习方法相对于传统神经网络方法在特征提取方面有优势, 在海水应用中的模型主要有 CNN^[75] 和 LSTM^[76-78] 等。在特征提取方面, 目前水质预测领域主要结合 Attention^[79] 等算法对特征选择性地提取, 利用注意力机制捕获水质关键信息, 使模型能够更全

面地学习水质特征, 从而提升模型的预测精度。

对各个海水预测模型进行分类、参数优选、方法比较以及度量指标的描述见表 3。通过各类模型预测性能进行分析和比较得出, 在正反馈架构模型中, 研究者运用 ANN 预测模型对水质参数含量进行预测, 该模型的 RMSE 为 257.42, 精确率为 64%。在循环架构模型中, 研究者构建卷积神经网络预测模型对水质参数含量预测的精度最高达到 97.1%, 最低达到 70%。在混合架构模型中, 预测精度最高的模型为智能算法-LSTM-RNNs 模型, 精度达到 99.72%, 相较于正反馈模型以及循环架构模型, 最高预测精度分别提升了 35.72% 和 2.62%, 预测精度最低的模型为 PCA-ARIMA 模型, 预测精度为 82.1%, 相较于正反馈模型以及循环架构模型的最低预测精度分别提升了 18.1% 和 12.1%, 其次为预测精度为 99.51% 的 RNN-LSTM 模型和精度为 98.97% 的 Pearson 相关系数-LSTM 等预测模型。基于模型融合的预测模型中, 预测性能最好的为 ConvLSTM, 精度达到 98.7%, 基于技术融合的预测模型中, 预测性能最好的为 Attention-GED, 该模型 MSE 和 MAE 分别为 0.1724 和 0.0630, 基于算法融合的预测模型中, 在数据降维处理方面, 预测性能最好的为智能算法-LSTM-RNNs 模型, 该模型的预测精度达到 99.72%, 在数据降噪方面, 预测性能最好的为小波变换-深度 Bi-S-SRU, 该模型 MSE 和 MAE 分别为 0.0026 和 0.0160, 在模型中超参数优化方面, 预测性能最好的为 PSO-SELM-PLS 模型, 该模型的预测精度达到 95.27%。

对出版年份进行分析。通过对 2019—2022 年发表的相关文献 (图 6) 分析得出, 神经网络在海水领域的应用越来越受欢迎, 随着神经网络的发展, 能够解决非线性的海水水质的准确预测问题, 应用于海水养殖水质检测工程, 为养殖户实时掌握水质状况提供指导。2022 年已出版的文献比往年多, 这也表明了海水精准预测模型的研究是一个热点。图 7 反映了研究不同预测变量的文章数量, 大多数研究中使用海温、化学需氧量等作为预测目标, 此外, 研究者还关注了 pH、水温、浑浊度等物理变量和弧菌、总大肠杆菌菌群值等生物变量, 反映了研究者探索海水各参数的精准预测的情况。图 8 反映了不同预测长度的分布, 本文中的预测时长是指提前预测的时间长度, 然

而, 12 篇论文没有提供关于预测长度的细节, 不利于研究者构建海水精准预测模型。利用神经网络方法来捕捉水质短期序列特征之间的关系 (length=1) 似乎是理想的, 因为该过程在 24 篇文献中使用了 6 次, 这些论文提供了关于预测长度的细节, 只有 12 篇论文考虑了长期 (length>1) 预测, 因为水质预测序列的长度不同, 导致所构建预测模型的精度有一定差距。

⑥ 小结。本节概括分析了正反馈架构模型、循环架构模型以及混合架构模型的优缺点及其在海水水质参数预测方面的应用, 得出了 3 种架构模型对海水水质预测准确度提升的程度主要依赖于数据处理、模型参数优化以及特征提取这 3 方面^[80]。综合评价 3 个架构模型, 混合架构模型整体的预测性能较正反馈模型和循环架构模型好, 具有正反馈模型和循环架构模型优势的特点, 在混合架构模型中, 基于算法融合的混合模型预测性能较高, 其次为基于模型融合的混合模型和基于技术融合的混合模型, 而基于算法融合的混合模型中, 在数据降维处理方面的混合模型性能表现最佳, 其次为超参数优化和数据降噪方面的混合模型。

水质三维预测模型 海水不仅具有表面空间特征, 而且还具有多维空间特征和时间序列特征。目前研究者构建的一维时空序列的海水水质预测模型较多, 对三维空间序列预测的相关研究较少。很多研究者只提取某个方向或者某个位置的空间特征, 没有同时考虑不同位置和方向, 因此, Mainali 等^[81] 研究了不同的回归模型, 将以点与点之间距离和方向的水质空间纳入模型。Xu 等^[82] 将轨迹的时空特性对水质的影响加以考虑, 提出 LATL 模型, 该模型不仅采用自适应神经网络对不同位置的水质特征进行学习, 而且在 LSTM 网络中引入时间门和距离门来捕捉连续位置之间的时空关系, 通过实验验证, 该模型对水质预测的性能表现较好。上述研究考虑了不同的位置和方向, 能够为构建三维海水水质预测模型提供基础。Zhang 等^[83] 为了解决传统方法仅限于某些孤立点的时间序列预测以及不同方向空间联系的相关问题, 构建 M-ConvLSTM 预测模型对水表层、次表层和水中层的三维海洋温度进行预测, 实验结果表明, M-ConvLSTM 预测模型对表层海洋温度的预测精度达到 99.94%, 水表层以下海洋温度预测精度达到 84.48%, 上层的水质预测精度优于深层,

表 3 2019—2022 年海水水质研究方法的性能表现

Tab. 3 Performance of seawater quality research methods, 2019—2022

方法 methods	类别 categories	参数 parameters	方法比较 comparison of methods	精度 accuracy	预测长度/d predicted length	文献 reference
ANN	正反馈架构	总大肠杆菌 菌群值	无	RMSE: 257.42; R^2 : 64%		[49]
M-DJINN	循环架构	溶解氧	DJINN, Random Forest, SVR, MLP	R^2 : 96.7%	9, 10, 11, 12	[51]
DNN	循环架构	弧菌的相对 丰度	SVR, XGBoost, ElasticNet, RandomForest	RMSE: 0.1; MAE: 0.05		[52]
RNN-LSTM	混合架构	海面温度	无	R^2 : 99.51%; RMSE: 0.439 9; MAPE: 2.146 5	1, 2, 3, 4, 5, 6, 7	[53]
CNN	循环架构	海面温度	无	MSE: 0.265 9; R^2 : 97.1%		[54]
spatial 2D-CNN	循环架构	海面温度	deep MLP, LSTM	RMSE: 0.75	24	[55]
LSTM-RNN	混合架构	浑浊度	ANN, SVM	R^2 : 88.45%		[56]
ConvLSTM	混合架构	海面温度	Linear SVR, LSTM(1-feature), LSTM(n-features)	R^2 : 98.7%	1, 2, 3, 4, 5, 6, 7, 8, 9, 10	[58]
EEF-BNN	混合架构	海面温度	EEF-NN, EEF-MLR	相关性评价性能	3, 6, 9, 12, 15	[59]
Attention-GED	混合架构	海面温度		MSE: 0.172 4; MAE: 0.063	1, 7, 30	[60]
Attention-RNN	混合架构	溶解氧	SVR-linear, SVR-rbf, MLP, 等	RMSE: 0.264 6, MAPE: 1.024 5, MAE: 0.170 3	1, 2, 8, 24, 48	[61]
皮尔逊相关系数- LSTM	混合架构	pH、水温	RNN	pH: R^2 =98.56%; 水温: R^2 =98.97%		[62]
PCA-RVM	混合架构	pH、溶解氧	单一-RVM, SVM	溶解氧: R^2 =91.1%; pH: R^2 =83.7%		[63]
智能算法 Intelligent algorithms -LSTM - RNNs	混合架构	水质分类	PCA-LSTM-RNNs, ICA- LSTM-RNNs, LDA-LSTM- RNNs	R^2 : 99.72%		[64]
ESRBFNN-EI	混合架构	化学需氧量	MRAN, GAP-RBF, ErrCor- RBF, 等	MSE: 0.017 3		[66]
小波变换-深度Bi-S- SRU	混合架构	pH、水温、溶 解氧	RNN, LSTM	pH: MSE=0.004; MAE=0.003; 水温: MSE=0.002 6; MAE=0.016; 溶解氧: MSE=0.071 4 MAE=0.042 7	3, 4, 5, 6, 7, 8	[67]
CEEMD-BPNN	混合架构	海面温度	EEMD-BPNN	ERR: 0.001 7	1	[68]
K-means-ANN	混合架构	海表参数	MLR, HYCOM	RMSE: 3.793 6, R^2 : 0.666 4		[69]
PSO-SELM-PLS	混合架构	溶解氧	ELM, BP, LSTM, SVM	R^2 : 95.27%		[70]
CNN	循环架构	总溶解固体、 氯化物、钠吸 附比、盐度	DNN, RF, XGBoost	TDS: NSE=0.95, R^2 =0.95, CL: NSE=0.93, R^2 =0.93, PS: NSE=0.96, R^2 =0.96, SAR: NSE=0.67, R^2 =0.70		[75]
STHFM (PCA- ARIMA)	混合架构	有害藻华	线性回归(LR), SVM, 多项 式朴素贝叶斯(MNB)	R^2 : 82.1%	3	[76]
LSTM	循环架构	溶解氧、盐度、 氮离子、水温	无	R^2 : 87%		[77]
AdaBoost-LSTM	混合架构	海面温度	LSTM, AdaBoost	MSE: 0.01, MAE: 0.06	10	[78]
PCA-EEMD-CNN- Attention-GRU- Encoder-Decoder	混合架构	溶解氧、氨氮、 化学需氧量、 总磷、pH	PSO-SELM-PLS, ECA- Adam-RBFNN, 小波变换 深度Bi-S-SRU	RMSE: 0.246, MAPE: 0.307, R^2 : 97.80%	1, 7, 15, 20	[80]




图6 2019—2022年文献数量分布

Fig. 6 Distribution of the number of literature for 2019–2022




图7 不同预测变量的文献数量

1. 海温, 2. 溶解氧, 3. pH, 4. 化学需氧量, 5. 盐度, 6. 氨氮, 7. 水温, 8. 氯化物, 9. 总磷, 10. 弧菌的相对丰度, 11. 总大肠杆菌菌群值, 12. 浊度, 13. 总溶解固体, 14. 钠吸附比。

Fig. 7 Number of literature with different predictor variables

1. sea temperature, 2. dissolved oxygen, 3. pH, 4. chemical oxygen demand, 5. salinity, 6. ammonia nitrogen, 7. water temperature, 8. chloride, 9. total phosphorus, 10. relative abundance of vibrio, 11. total coliform value, 12. turbidity, 13. total dissolved solids, 14. sodium adsorption ratio.

这可能是由于深层的海洋温度变化小于上层。水表层的海洋温度为 5.0~25.0 °C, 次表层的海洋温度为 4.0~12.0 °C, 水中层 1 000 m 处的海洋温度为 3.0~4.5 °C, 2 000 m 处的海洋温度为 1.8~2.2 °C^[83]。Xiao 等^[84] 提出了一维卷积层 (Conv1D) 和两个长短期记忆层集成的预测模型, 对时空序列海洋温度进行三维预测, 实验结果表明, Conv1D-LSTM 预测模型优于持久性模型、AdaBoost 模型和 BP 神经网络模型, 能够更好地模拟各个时间序列的不同空间位置的水温参数, 揭示不同深度和时间序列水温的分布规律。综合以上研究得出, 精准海水三维预测模型能够为养殖户提供养殖水质参数含量的变化趋势, 但目前研究者对海水三维预测的研究偏少, 特别是水中层和水深层的各个时

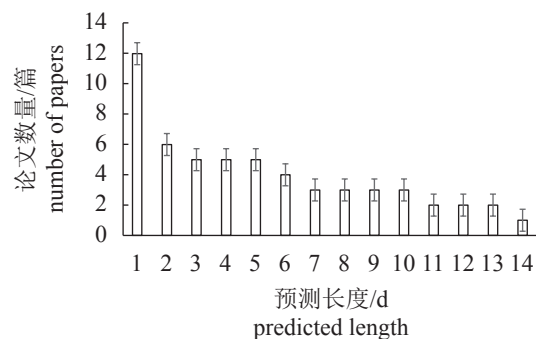


图8 预测长度的分布

1. 无细节, 2. 长度=1, 3. 长度=3, 4. 长度≥20, 5. 长度=7, 6. 长度=6, 7. 长度=4, 8. 长度=5, 9. 长度=9, 10. 长度=10, 11. 长度=8, 12. 长度=12, 13. 长度=15, 14. 长度=11。

Fig. 8 Distribution of predicted lengths

1. no details, 2. length=1, 3. length=3, 4. length≥20, 5. length=7, 6. length=6, 7. length=4, 8. length=5, 9. length=9, 10. length=10, 11. length=8, 12. length=12, 13. length=15, 14. length=11.

间序列的水质参数在三维空间变化中的预测研究。随着水层深度的增加, 海水三维预测模型的预测精度逐渐降低, 未来可考虑模型中超参数优化、空间特征提取以及时空相关性等来提高水质三维预测模型的准确性。

3 结论

近年来, 神经网络方法引起了研究者的广泛关注, 应用于养殖水质精准预测的混合架构方法变体层出不穷, 大大提升了神经网络方法对水质预测的精度, 与正反馈架构方法和循环架构方法相比, 混合架构方法在养殖水质预测研究中有以下优势: ① 强大的特征提取能力。能够自动提取水质时空序列特征。② 专注于信息选择。能够在水质时空序列中动态学习外部属性的信息以及网络隐藏状态在不同时间序列中的变化优势。③ 降噪降维。能够处理水质数据中的噪声, 进而选择对目标变量影响较大的因素输入到模型中。

但目前研究者提出的水质预测方法还存在改进的空间, 需要进一步研究: ① 水质空间特征的选择。该选择涉及模型网络结构搜索, 未来可利用强化学习策略进行自动网络结构搜索, 得到更优的网络结构, 能够很好地选择水质空间特征, 提高水质预测模型精度。② 养殖水质三维预测。目前研究者运用神经网络方法对养殖水质的水表层、次表层和水中层的水质参数进行预测研究, 对水深层水质三维预测的相关研究不足, 除了水表层水质三维预测模型的预测性能较好外, 水表层

层以下水质的预测精度有待提高,特别是水中层和水深层,未来需要对水质三维空间特征和时间序列特征进行提取,并结合在线学习方法加以考虑,以提高三维预测模型的预测精度,继续研究养殖水质各参数在空间上的扩散和在时间序列上的变化情况。③模型的选择。目前很多研究者通过对海水或淡水水域预测中遇到的问题进行探索,结合经验并不断尝试,选择最合适的模型来获得更高的准确率,未来将开发可同时精准预测海水和淡水水域的模型,增强养殖水质预测模型的鲁棒性和准确性。④基于大数据的神经网络方法。随着数据量、预测序列以及三维时空序列维度的增加,基于神经网络的智能模型所面对的工作越来越复杂,模型网络复杂度更高,下一步将基于大数据技术的神经网络方法对三维水质数据进行预测,解决模型任务复杂的问题,提高模型的预测精度。

(作者声明本文无实际或潜在的利益冲突)

参考文献 (References):

- [1] Guo M. 2021 水产养殖行业发展现状及前景分析 [OL]. (2021-09-29)[2022-09-17]. <https://www.chinairn.com/scfx/20210929/160746367.shtml>.
- Guo M. 2021 Aquaculture industry development status and outlook analysis[OL].(2021-09-29)[2022-09-17]. <https://www.chinairn.com/scfx/20210929/160746367.shtml> (in Chinese).
- [2] Huang J D, Liu S Y, Hassan S G, *et al.* A hybrid model for short-term dissolved oxygen content prediction[J]. *Computers and Electronics in Agriculture*, 2021, 186: 106216.
- [3] Najafzadeh M, Ghaemi A. Prediction of the five-day biochemical oxygen demand and chemical oxygen demand in natural streams using machine learning methods[J]. *Environmental Monitoring and Assessment*, 2019, 191(6): 380.
- [4] Yang F, Moayedi H, Mosavi A. Predicting the degree of dissolved oxygen using three types of multi-layer perceptron-based artificial neural networks[J]. *Sustainability*, 2021, 13(17): 9898.
- [5] Zhang Y. Application of BP neural network model based on Simulink in regional water quality prediction[J]. *Fresenius Environmental Bulletin*, 2022, 31(5): 5159-5166.
- [6] Li G Q, Zou J N. Multi-parallel extreme learning machine with excitatory and inhibitory neurons for regression[J]. *Neural Processing Letters*, 2020, 51(2): 1579-1597.
- [7] Egbueri J C, Agbasi J C. Performances of MLR, RBF-NN, and MLP-NN in the evaluation and prediction of water resources quality for irrigation purposes under two modeling scenarios[J]. *Geocarto International*, 2022, 37(26): 14399-14431.
- [8] Lim H, An H, Choi G, *et al.* Prediction of pollution loads in agricultural reservoirs using LSTM algorithm: case study of reservoirs in Nonsan City[J]. *Korean Journal of Agricultural Science*, 2022, 49(2): 193-202.
- [9] Geng J X, Yang C H, Li Y G, *et al.* MPA-RNN: a novel attention-based recurrent neural networks for total nitrogen prediction[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(10): 6516-6525.
- [10] Eze E, Halse S, Ajmal T. Developing a novel water quality prediction model for a South African aquaculture farm[J]. *Water*, 2021, 13(13): 1782.
- [11] Tan W W, Zhang J J, Wu J, *et al.* Application of CNN and long short-term memory network in water quality predicting[J]. *Intelligent Automation & Soft Computing*, 2022, 34(3): 1943-1958.
- [12] Wu J H, Wang Z C. A hybrid model for water quality prediction based on an artificial neural network, wavelet transform, and long short-term memory[J]. *Water*, 2022, 14(4): 610.
- [13] Zhang Y T, Li C L, Jiang Y Q, *et al.* Accurate prediction of water quality in urban drainage network with integrated EMD-LSTM model[J]. *Journal of Cleaner Production*, 2022, 354: 131724.
- [14] Xu J L, Wang K, Lin C, *et al.* FM-GRU: a time series prediction method for water quality based on seq2seq framework[J]. *Water*, 2021, 13(8): 1031.
- [15] Guo J J, Dong J Q, Zhou B, *et al.* A hybrid model for the prediction of dissolved oxygen in seabass farming[J]. *Computers and Electronics in Agriculture*, 2022, 198: 106971.
- [16] Yang H H, Liu S E. Water quality prediction in sea cucumber farming based on a GRU neural network optimized by an improved whale optimization algorithm[J]. *PeerJ Computer Science*, 2022, 8: e1000.
- [17] Sha J, Li X, Zhang M, *et al.* Comparison of forecasting models for real-time monitoring of water quality parameters based on hybrid deep learning neural networks[J]. *Water*, 2021, 13(11): 1547.
- [18] Chen Y Y, Song L H, Liu Y Q, *et al.* A review of the artificial neural network models for water quality prediction[J]. *Applied Sciences*, 2020, 10(17): 5776.

- [19] Gambin A F, Angelats E, Gonzalez J S, *et al.* Sustainable marine ecosystems: Deep learning for water quality assessment and forecasting[J]. *IEEE Access*, 2021, 9: 121344-121365.
- [20] Zhao S L, Zhang S, Liu J C, *et al.* Application of machine learning in intelligent fish aquaculture: a review[J]. *Aquaculture*, 2021, 540: 736724.
- [21] Cao W J, Huan J, Liu C, *et al.* A combined model of dissolved oxygen prediction in the pond based on multiple-factor analysis and multi-scale feature extraction[J]. *Aquacultural Engineering*, 2019, 84: 50-59.
- [22] Kuang L, Shi P, Hua C, *et al.* An enhanced extreme learning machine for dissolved oxygen prediction in wireless sensor networks[J]. *IEEE Access*, 2020, 8: 198730-198739.
- [23] Shi P, Li G H, Yuan Y M, *et al.* Prediction of dissolved oxygen content in aquaculture using clustering-based Softplus extreme learning machine[J]. *Computers and Electronics in Agriculture*, 2019, 157: 329-338.
- [24] Galezan F H, Bayati M R, Safari O, *et al.* Modeling oxygen and organic matter concentration in the intensive rainbow trout (*Oncorhynchus mykiss*) rearing system[J]. *Environmental Monitoring and Assessment*, 2020, 192(4): 223.
- [25] Rozario A P R, Devarajan N. Monitoring the quality of water in shrimp ponds and forecasting of dissolved oxygen using Fuzzy C means clustering based radial basis function neural networks[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2021, 12(5): 4855-4862.
- [26] Zhang Y F, Fitch P, Thorburn P J. Predicting the trend of dissolved oxygen based on the kPCA-RNN model[J]. *Water*, 2020, 12(2): 585.
- [27] Ren Q, Wang X Y, Li W S, *et al.* Research of dissolved oxygen prediction in recirculating aquaculture systems based on deep belief network[J]. *Aquacultural Engineering*, 2020, 90: 102085.
- [28] Wu Y H, Sun L Q, Sun X B, *et al.* A hybrid XGBoost-ISSA-LSTM model for accurate short-term and long-term dissolved oxygen prediction in ponds[J]. *Environmental Science and Pollution Research*, 2022, 29(12): 18142-18159.
- [29] Cao X K, Liu Y R, Wang J P, *et al.* Prediction of dissolved oxygen in pond culture water based on K-means clustering and gated recurrent unit neural network[J]. *Aquacultural Engineering*, 2020, 91: 102122.
- [30] Huan J, Li M B, Xu X G, *et al.* Multi-step prediction of dissolved oxygen in rivers based on random forest missing value imputation and attention mechanism coupled with recurrent neural network[J]. *Water Supply*, 2022, 22(5): 5480-5493.
- [31] Ta X X, Wei Y G. Research on a dissolved oxygen prediction method for recirculating aquaculture systems based on a convolution neural network[J]. *Computers and Electronics in Agriculture*, 2018, 145: 302-310.
- [32] Haq K P R A, Harigovindan V P. Water quality prediction for smart aquaculture using hybrid deep learning models[J]. *IEEE Access*, 2022, 10: 60078-60098.
- [33] Barzegar R, Aalami M T, Adamowski J. Short-term water quality variable prediction using a hybrid CNN-LSTM deep learning model[J]. *Stochastic Environmental Research and Risk Assessment*, 2020, 34(2): 415-433.
- [34] Yan J Z, Gao Y, Yu Y C, *et al.* A prediction model based on deep belief network and least squares SVR applied to cross-section water quality[J]. *Water*, 2020, 12(7): 1929.
- [35] Sinshaw T A, Surbeck C Q, Yasarer H, *et al.* Artificial neural network for prediction of total nitrogen and phosphorus in US lakes[J]. *Journal of Environmental Engineering*, 2019, 145(6): 04019032.
- [36] Ahmadianfar I, Shirvani-Hosseini S, He J X, *et al.* An improved adaptive neuro fuzzy inference system model using conjoined metaheuristic algorithms for electrical conductivity prediction[J]. *Scientific Reports*, 2022, 12(1): 4934.
- [37] Li P F, Hua P, Gui D W, *et al.* A comparative analysis of artificial neural networks and wavelet hybrid approaches to long-term toxic heavy metal prediction[J]. *Scientific Reports*, 2020, 10(1): 13439.
- [38] Zhu S L, Heddam S, Wu S Q, *et al.* Extreme learning machine-based prediction of daily water temperature for rivers[J]. *Environmental Earth Sciences*, 2019, 78(6): 202.
- [39] Kisi O, Azad A, Kashi H, *et al.* Modeling groundwater quality parameters using hybrid neuro-fuzzy methods[J]. *Water Resources Management*, 2019, 33(2): 847-861.
- [40] Aldhyani T H H, Al-Yaari M, Alkahtani H, *et al.* Water quality prediction using artificial intelligence algorithms[J]. *Applied Bionics and Biomechanics*, 2020, 2020: 6659314.
- [41] Ebadati N, Hooshmandzadeh M. Water quality assessment of river using RBF and MLP methods of artificial network analysis (case study: Karoon River Southwest of Iran)[J]. *Environmental Earth Sciences*, 2019, 78(17): 551.
- [42] Chen H Z, Chen A, Xu L L, *et al.* A deep learning CNN architecture applied in smart near-infrared analysis of water pollution for agricultural irrigation resources[J].

- Agricultural Water Management*, 2020, 240: 106303.
- [43] Prasad D V V, Venkataramana L Y, Kumar P S, *et al.* Water quality analysis in a lake using deep learning methodology: prediction and validation[J]. *International Journal of Environmental Analytical Chemistry*, 2022, 102(17): 5641-5656.
- [44] Chen Y Y, Yu H H, Cheng Y J, *et al.* A hybrid intelligent method for three-dimensional short-term prediction of dissolved oxygen content in aquaculture[J]. *PLoS One*, 2018, 13(2): e0192456.
- [45] Chen Y Y, Xu J, Yu H H, *et al.* Three-dimensional short-term prediction model of dissolved oxygen content based on PSO-BPANN algorithm coupled with kriging interpolation[J]. *Mathematical Problems in Engineering*, 2016: 6564202.
- [46] Cao X K, Ren N, Tian G L, *et al.* A three-dimensional prediction method of dissolved oxygen in pond culture based on Attention-GRU-GBRT[J]. *Computers and Electronics in Agriculture*, 2021, 181: 105955.
- [47] Liu W C, Chen W B. Prediction of water temperature in a subtropical subalpine lake using an artificial neural network and three-dimensional circulation models[J]. *Computers & Geosciences*, 2012, 45: 13-25.
- [48] Wei L, Guan L, Qu L Q. Prediction of sea surface temperature in the South China Sea by artificial neural networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(4): 558-562.
- [49] Er B A, Odabas M S, Şenyer N, *et al.* Evaluation of deep sea discharge systems efficiency in the eastern Black Sea using artificial neural network: a case study for Trabzon, Turkey[J]. *Brazilian Archives of Biology and Technology*, 2022, 65: e22210397.
- [50] Li D S, Wang X Y, Sun J J, *et al.* Radial basis function neural network model for dissolved oxygen concentration prediction based on an enhanced clustering algorithm and Adam[J]. *IEEE Access*, 2021, 9: 44521-44533.
- [51] Wang L H, Jiang Y, Qi H. Marine dissolved oxygen prediction with tree tuned deep neural network[J]. *IEEE Access*, 2020, 8: 182431-182440.
- [52] Jiang J W, Zhou H, Zhang T, *et al.* Machine learning to predict dynamic changes of pathogenic *Vibrio* spp. abundance on microplastics in marine environment[J]. *Environmental Pollution*, 2022, 305: 119257.
- [53] 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.
- [54] Han M X, Feng Y, Zhao X L, *et al.* A convolutional neural network using surface data to predict subsurface temperatures in the Pacific Ocean[J]. *IEEE Access*, 2019, 7: 172816-172829.
- [55] Patil K R, Iiyama M. Deep learning models to predict sea surface temperature in Tohoku region[J]. *IEEE Access*, 2022, 10: 40410-40418.
- [56] Kumar L, Afzal M S, Ahmad A. Prediction of water turbidity in a marine environment using machine learning: a case study of Hong Kong[J]. *Regional Studies in Marine Science*, 2022, 52: 102260.
- [57] Liang C M, Lai C C, Wang S H, *et al.* Environmental microorganism classification using optimized deep learning model[J]. *Environmental Science and Pollution Research*, 2021, 28(24): 31920-31932.
- [58] Xiao C J, Chen N C, Hu C L, *et al.* A spatiotemporal deep learning model for sea surface temperature field prediction using time-series satellite data[J]. *Environmental Modelling & Software*, 2019, 120: 104502.
- [59] Foroozand H, Radić V, Weijs S V. Application of entropy ensemble filter in neural network forecasts of tropical Pacific Sea surface temperatures[J]. *Entropy*, 2018, 20(3): 207.
- [60] Xie J, Zhang J Y, Yu J, *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.
- [61] Liu Y Q, Zhang Q, Song L H, *et al.* Attention-based recurrent neural networks for accurate short-term and long-term dissolved oxygen prediction[J]. *Computers and Electronics in Agriculture*, 2019, 165: 104964.
- [62] Hu Z H, Zhang Y R, Zhao Y C, *et al.* A water quality prediction method based on the deep LSTM network considering correlation in smart mariculture[J]. *Sensors*, 2019, 19(6): 1420.
- [63] Sun X C, Wang X, Cai D, *et al.* Multivariate seawater quality prediction based on PCA-RVM supported by edge computing towards smart ocean[J]. *IEEE Access*, 2020, 8: 54506-54513.
- [64] Dilmi S, Ladjal M. A novel approach for water quality classification based on the integration of deep learning and feature extraction techniques[J]. *Chemometrics and Intelligent Laboratory Systems*, 2021, 214: 104329.
- [65] Ma J W, Wang Y K, Niu X X, *et al.* A comparative study of mutual information-based input variable selection strategies for the displacement prediction of seepage-driven landslides using optimized support vector regression[J]. *Stochastic Environmental Research and Risk Assessment*, 2022, 36(10): 3109-3129.
- [66] 李文静, 李萌, 乔俊飞. 基于互信息和自组织RBF神经网络

- 网络的出水BOD软测量方法[J]. *化工学报*, 2019, 70(2): 687-695.
- Li W J, Li M, Qiao J F. Effluent BOD soft measurement based on mutual information and self-organizing RBF neural network[J]. *CIESC Journal*, 2019, 70(2): 687-695 (in Chinese).
- [67] Liu J T, Yu C, Hu Z H, *et al.* Accurate prediction scheme of water quality in smart mariculture with deep Bi-S-SRU learning network[J]. *IEEE Access*, 2020, 8: 24784-24798.
- [68] Wu Z Y, Jiang C B, Conde M, *et al.* Hybrid improved empirical mode decomposition and BP neural network model for the prediction of sea surface temperature[J]. *Ocean Science*, 2019, 15(2): 349-360.
- [69] Gu C, Qi J F, Zhao Y Z, *et al.* Estimation of the mixed layer depth in the Indian ocean from surface parameters: a clustering-neural network method[J]. *Sensors*, 2022, 22(15): 5600.
- [70] Cao S Q, Zhou L X, Zhang Z. Prediction of dissolved oxygen content in aquaculture based on clustering and improved ELM[J]. *IEEE Access*, 2021, 9: 40372-40387.
- [71] Cesa-Bianchi N, Orabona F. Online learning algorithms[J]. *Annual Review of Statistics and its Application*, 2021, 8: 165-190.
- [72] Chen Y T, Xiong J, Xu W H, *et al.* A novel online incremental and decremental learning algorithm based on variable support vector machine[J]. *Cluster Computing*, 2019, 22(3): 7435-7445.
- [73] Luo X, Yang X N, Jiang C W, *et al.* Timeliness online regularized extreme learning machine[J]. *International Journal of Machine Learning and Cybernetics*, 2018, 9(3): 465-476.
- [74] Azad A, Karami H, Farzin S, *et al.* Prediction of water quality parameters using ANFIS optimized by intelligence algorithms (case study: Gorganrood River)[J]. *KSCE Journal of Civil Engineering*, 2018, 22(7): 2206-2213.
- [75] Taşan M, Taşan S, Demir Y. Estimation and uncertainty analysis of groundwater quality parameters in a coastal aquifer under seawater intrusion: a comparative study of deep learning and classic machine learning methods[J]. *Environmental Science and Pollution Research*, 2022, 245: 108569.
- [76] Wen J B, Yang J C, Li Y, *et al.* Harmful algal bloom warning based on machine learning in maritime site monitoring[J]. *Knowledge-Based Systems*, 2022, 245: 108569.
- [77] Rijayanti R, Hwang M. Prediction of sea water condition changes using LSTM algorithm for the fish farm[J]. *Journal of the Korea Institute of Information and Communication Engineering*, 2022, 26(3): 374-380.
- [78] Xiao C J, Chen N C, Hu C L, *et al.* Short and mid-term sea surface temperature prediction using time-series satellite data and LSTM-AdaBoost combination approach[J]. *Remote Sensing of Environment*, 2019, 233: 111358.
- [79] Jia P C, Cao N W, Yang S B. Real-time hourly ozone prediction system for Yangtze River Delta area using attention based on a sequence to sequence model[J]. *Atmospheric Environment*, 2021, 244: 117917.
- [80] Xie Z M, Li Z H, Mo C M, *et al.* A PCA-EEMD-CNN-attention-GRU-encoder-decoder accurate prediction model for key parameters of seawater quality in Zhanjiang Bay[J]. *Materials*, 2022, 15(15): 5200.
- [81] Mainali J, Chang H, Chun Y W. A review of spatial statistical approaches to modeling water quality[J]. *Progress in Physical Geography: Earth and Environment*, 2019, 43(6): 801-826.
- [82] Xu J J, Zhao J, Zhou R, *et al.* Predicting destinations by a deep learning based approach[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2021, 33(2): 651-666.
- [83] Zhang K, Geng X P, Yan X H. Prediction of 3-D ocean temperature by multilayer convolutional LSTM[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(8): 1303-1307.
- [84] Xiao C J, Tong X H, Li D D, *et al.* Prediction of long lead monthly three-dimensional ocean temperature using time series gridded Argo data and a deep learning method[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2022, 112: 102971.

Research progress in accurate prediction of aquaculture water quality by neural network

WANG Ji^{1,2*}, XIE Zaimi^{2,3*}, MO Chunmei^{1,2}

(1. School of Electronics and Information Engineering, Guangdong Ocean University, Zhanjiang 524088, China;

2. Guangdong Smart Ocean Sensor Network and its Equipment Engineering Technology Research Center,

Guangdong Ocean University, Zhanjiang 524088, China;

3. School of Mathematics and Computer Science, Guangdong Ocean University, Zhanjiang 524088, China)

Abstract: China is the world's largest producer and consumer of aquatic products, with aquaculture production ranking first in the world for more than 20 consecutive years, and the demand for aquatic products provides opportunities for the development of the global aquaculture industry. In aquaculture, the aquaculture water environment provides the living environment, food and oxygen for freshwater or seawater. Due to human activities, environmental pollution, agricultural production and other reasons, it may lead to changes in total phosphorus, dissolved oxygen, pH and other indicators in aquaculture waters, which in turn affect the growth of aquatic organisms. Therefore, real-time monitoring and prediction of water quality parameters is an important part of the aquaculture process and is an important measure to determine the quality of aquatic products. Through the analysis of the collected information, there are more neural network research results, which play an important role in accurate water quality prediction, but the lack of scientific classification in the literature and the low usage rate of the literature have made it difficult for scholars to find the research entry point. To address this issue, this paper classified the literature on neural networks methods for accurate prediction of farmed water quality according to two major fields: seawater and freshwater, and mainly studied and analyzed the neural network models applied in each field for prediction of seawater spatio-temporal sequences from three architectures: positive feedback architecture, recurrent architecture and hybrid architecture, and the analysis results showed that the highest prediction performance in the positive feedback architecture model is the ANN prediction model with 64% accuracy, and in the recurrent architecture model, the highest prediction performance is the convolutional neural network prediction model with 97.1% accuracy, and in the hybrid architecture model, the highest prediction accuracy is the intelligent algorithm-LSTM-RNNs model with an accuracy of 99.72%, which is 35.72% and 2.62% higher than the highest accuracy in the positive feedback architecture model and the recurrent architecture model, respectively. The prediction performance of the hybrid architecture model is better than those of the positive feedback model and the recurrent architecture model, which is conducive to improving the prediction accuracy of the different depth water quality prediction models. In addition, this paper had a preliminary discussion on the three-dimensional water quality prediction model based on the neural network method, and the results showed that the research scholars results are more focused on the changes of water quality parameters in different locations of the water surface layer and water intermediate layer, while for neural network prediction model for water surface layer, water quality prediction accuracy was higher than intermediate and deep water layer quality prediction accuracy.

Key words: aquaculture water quality; positive feedback architecture; recurrent architecture; hybrid architecture; neural network

Corresponding authors: WANG Ji. E-mail: 13902576499@163.com;

XIE Zaimi. E-mail: 1778037486@qq.com

Funding projects: National Natural Science Foundation of China (51777046); Special Project on New Generation Information Technology in Key Areas of General Universities in Guangdong Province (2020ZDZX3008); Special Project on Key Areas of Artificial Intelligence in Guangdong Province (2019KZDZX1046)