

基于随机配置网络的海水养殖氨氮浓度软测量模型

王魏^{1,2} 郭戈^{1,3}

(1. 大连海事大学船舶电气工程学院, 大连 116026; 2. 大连海洋大学信息工程学院, 大连 116023;

3. 东北大学秦皇岛分校控制工程学院, 秦皇岛 066004)

摘要: 氨氮浓度是水产养殖过程的重要监控指标,水中氨氮浓度过高,会产生较强的神经毒素,导致水生物大面积死亡,因此,需实时准确监测水产养殖过程中水的氨氮浓度。然而,由于影响海水水质因素较多,各因素之间关系复杂、相互影响,目前未能实现海水氨氮浓度的实时监测。通过分析海水养殖水体中氨氮的生成和硝化过程,选取水体中与氨氮浓度相关且易测的水质参数(温度、电导率、pH值、溶解氧质量浓度)为辅助变量,采用收敛速度快且泛化能力较强的随机配置网络建立了氨氮浓度软测量模型。为验证方法的有效性,设计了实验室海水养殖循环水系统,通过试验系统的实测数据,将该方法与其他几种神经网络建模方法进行了比较。结果表明,氨氮浓度随机配置网络模型具有更高的精度和更快的运行速度。基于模型设计了水产养殖水质监控系统,并将此方法嵌入上位机WinCC软件,实现了氨氮浓度的在线监测。

关键词: 海水养殖; 氨氮浓度; 软测量; 随机配置网络

中图分类号: S96; TP2 文献标识码: A 文章编号: 1000-1298(2020)01-0214-07

OSID:



Soft Measurement Model for Ammonia Nitrogen Concentration in Marine Aquaculture Based on Stochastic Configuration Networks

WANG Wei^{1,2} GUO Ge^{1,3}

(1. College of Marine Electrical Engineering, Dalian Maritime University, Dalian 116026, China

2. College of Information Engineering, Dalian Ocean University, Dalian 116023, China

3. School of Control Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China)

Abstract: The concentration of ammonia nitrogen is one of the key indexes in the process of marine aquaculture. Excessive levels of ammonia nitrogen in the water produce strong neurotoxins, leading to large-scale death of aquatic organisms. Therefore, it is very important to monitor the concentration of ammonia nitrogen in water in real time and accurately. Due to many factors affecting seawater quality, and the complex factors often affect each other, there is no instrument to realize the real-time detection of seawater ammonia nitrogen concentration at present. Firstly, the current research status of ammonia nitrogen monitoring in water of aquaculture was reviewed. Then, the formation and nitrification process of ammonia nitrogen in marine aquaculture water was analyzed, and the parameters (temperature, conductivity, pH value and dissolved oxygen concentration) related to ammonia nitrogen concentration were selected as auxiliary variables. A soft measurement model of ammonia nitrogen concentration was established by using a stochastic configuration networks with high convergence speed and strong generalization ability. In order to verify the effectiveness, the proposed method was compared with other neural network modeling methods by using the measured data of the turbot intensive marine aquaculture system independently established by the laboratory. The results showed that the proposed method had higher generalization ability, higher prediction accuracy and faster running speed. Finally, the aquaculture water quality monitoring system was developed, and this method was embedded in the upper computer WinCC software to realize online monitoring of ammonia nitrogen concentration.

Key words: marine aquaculture; ammonia nitrogen concentration; soft measurement; stochastic configuration networks

收稿日期: 2019-05-16 修回日期: 2019-09-04

基金项目: 国家自然科学基金项目(61503054)、大连市科技之星项目(2017RQ143)和辽宁省教育厅青年科技人才“育苗”项目(QL201912)

作者简介: 王魏(1982—),女,博士后,大连海洋大学副教授,主要从事海洋渔业水质监测等研究,E-mail: ww_wangwei@dliou.edu.cn

通信作者: 郭戈(1972—),男,教授,博士生导师,主要从事信息物理系统优化决策理论及应用研究,E-mail: geguo@yeah.net

0 引言

养殖水质常受残留饵料、养殖对象粪便、化学药物等因素影响,致使水中氮、磷、有机质等不断增加,产生氨氮、亚硝酸盐等有毒物质,严重危及养殖对象的健康,甚至导致其大批量死亡,造成不可挽回的经济损失^[1]。集约化水产养殖利用循环海水进行高密度精养,需密切关注养殖水环境的各个指标,尤其是氨氮浓度,实时监测其变化并加以调控,不仅关系到养殖水产品的质量和收益,而且还影响到食用者的健康。

目前,已有水质监测方法大致可分为 3 种^[2]:人工采样试验检测、传感器检测和软测量方法。国外对集约化水产养殖的研究较早,拥有比较完善的水质监测仪器,包括美国的 YSI6820/6920 型多参数水质分析仪,德国 WTW 公司的 Mnlti350i 型手提式多参数测定仪、IQ Sensor Net 型在线多参数分析仪等。这些设备都存在造价高、维护成本高、监测费用高等问题^[3-4],难以在我国养殖企业普及和推广。

随着我国集约化循环海水养殖模式的逐渐兴起,国内学者也在养殖水体氨氮浓度监测方面做了一些研究。有基于 BP 神经网络预测氨氮浓度的方法^[5-6],该方法选择水温、pH 值和非离子氨浓度等输入进行变量预测。也有基于 RBF 神经网络预测出水氨氮浓度的方法,该方法采用温度、pH 值、溶解氧浓度、总氮浓度作为输入变量^[7]。这些方法虽然预测结果较好,但无法在实际中推广应用,输入变量参数也存在不能实时测量的问题,仅局限于实验室研究。文献[8]总结了近年来各种氨氮测定方法,比如纳氏试剂法、次溴酸盐氧化法、靛酚蓝分光光度法、氨气敏电极法等,给出了各种方法的适用范围、优缺点及试验运用条件,但这些方法大都属于离线测量。基于上述研究现状,本文借鉴其他学者将神经网络用于水产养殖溶解氧浓度预测^[9-10]、污水处理过程中氨氮浓度检测^[11-12]等相关研究,选择养殖生产过程较易得到的温度、电导率、pH 值、溶解氧质量浓度作为辅助变量,利用文献[13]提出的随机配置网络对氨氮浓度进行软测量建模。为将软测量模型应用于实际,设计实验室集约化循环海水养殖系统,通过仿真试验验证方法的有效性。

1 氨氮浓度随机配置网络软测量模型建立

1.1 随机配置神经网络

为了克服传统梯度类算法本身所固有的收敛速度慢、易陷入局部极小等问题,随机算法被用于神经网络学习,且具有快速特性^[14]。文献[13]提出一种

新型随机神经网络,称为随机配置网络(Stochastic configuration networks, SCN)。与目前应用较广泛的随机权值功能连接网络^[15](Random vector functional link network, RVFL)相比,它的特点是在人为很少干预的情况下,从一个小型网络开始,在一定的约束条件下随机配置输入权值和阈值,逐渐增加隐含层节点的数量并利用最小二乘法求出输出权值和偏置,直到网络的训练精度满足终止条件。这种给定约束条件的方法能够保证网络的全局逼近性,因此本文选择 SCN 对氨氮浓度进行软测量,网络构建主要步骤如下:

给定目标函数 $f: R^d \rightarrow R^m$, 假设一个随机配置网络模型已有 $L-1$ 个隐含层节点,即

$$\begin{cases} f_0 = 0 \\ f_{L-1} = \sum_{i=1}^{L-1} \beta_i \varphi_i(\mathbf{w}_i^T \mathbf{x} + b_i) \quad (L = 2, 3, \dots) \end{cases} \quad (1)$$

其中 $\beta_i = [\beta_{i,1} \quad \beta_{i,2} \quad \dots \quad \beta_{i,m}]^T$
 式中 β_i ——第 i 个隐含层节点的输出权值
 $\varphi_i(\cdot)$ ——第 i 个隐含层节点的激活函数
 \mathbf{w}_i ——第 i 个隐含层节点的随机输入权值
 \mathbf{x} ——输入变量
 b_i ——第 i 个隐含层节点的阈值
 f_0 ——初始目标函数

定义残差

$$\mathbf{e}_{L-1}^* = \mathbf{f} - \mathbf{f}_{L-1} = [e_{L-1,1}^* \quad e_{L-1,2}^* \quad \dots \quad e_{L-1,m}^*] \quad (2)$$

上角 * 表示最小残差值,且

$$[\beta_1^* \quad \beta_2^* \quad \dots \quad \beta_{L-1}^*] = \arg \min_{\beta} \left\| \mathbf{f} - \sum_{i=1}^{L-1} \beta_i \varphi_i \right\|$$

假设 Γ 是 L_2 (所有勒贝格可测量函数的空间) 中的稀疏空间,对于任意 $\varphi \in \Gamma, 0 < \|\varphi\| < b_\varphi, b_\varphi \in \mathbf{R}^+$ 。给定 $0 < r < 1$ 和一个非负实值序列 $\{\mu_L\}$, $\lim_{L \rightarrow +\infty} \mu_L = 0$ 满足 $\mu_L \leq 1 - r (L = 1, 2, \dots)$, 定义 $\delta_L^* = \sum_{q=1}^m \delta_{L,q}^*$, 而

$$\delta_{L,q}^* = (1 - r - \mu_L) \|e_{L-1,q}^*\|^2 \quad (q = 1, 2, \dots, m) \quad (3)$$

如果随机基函数 ϕ_L 满足

$$\langle e_{L-1,q}^*, \phi_L \rangle^2 \geq b_\varphi^2 \delta_{L,q}^* \quad (4)$$

输出权值则可计算为

$$[\beta_1^* \quad \beta_2^* \quad \dots \quad \beta_L^*] = \arg \min_{\beta} \left\| \mathbf{f} - \sum_{i=1}^L \beta_i \varphi_i \right\| \quad (5)$$


有 $\lim_{L \rightarrow \infty} \|\mathbf{f} - \mathbf{f}_L\| = 0$, 其中

$$f_L^* = \sum_{l=1}^L \beta_l^* \varphi_l \quad (6)$$

其中 $\beta_l^* = [\beta_{l,1}^* \ \beta_{l,2}^* \ \cdots \ \beta_{l,m}^*]^T$

1.2 辅助变量选择

水中氨氮在硝化和反硝化作用下会与亚硝酸氮互相转化,二者均有毒害性,亚硝酸氮作为中间产物最终会转换为无毒无害的硝酸氮,作为氮肥被水生植物吸收。因此,水体中主要危害来自于氨氮的影响。氨氮在水中以离子态氨(NH_4^+)和非离子态氨(NH_3)2种形式存在。 NH_4^+ 与水易发生水解反应



NH_3 比 NH_4^+ 对养殖对象危害大, NH_4^+ 呈弱碱性,两者之间受水中pH值影响相互转换维持动态平衡。

水中 NH_3 与氨氮($\text{NH}_3\text{-N}$)存在一定的解离平衡关系,水中 NH_3 在相对条件下的质量浓度计算公式为^[16]

$$c_{\text{NH}_3} = 1.4 \times 10^{-4} c_{\text{NH}_3\text{-N}} f_p \quad (8)$$

其中 $f_p = 100 / (10^{pK_a - c_{\text{pH}}} + 1)$

$$pK_a = 9.245 + 0.002949S + 0.0324(298 - T)$$

式中 c_{NH_3} ——在一定水体温度、盐度和pH值下的水体中非离子氨的质量浓度,mg/L

$c_{\text{NH}_3\text{-N}}$ ——水体中氨氮质量浓度,mg/L

f_p ——水体中非离子氨所占的百分比,%

T ——海水温度,K

S ——海水盐度

K_a ——温度 T 、盐度 S 情况下,海水中 NH_4^+ 的解离平衡常数

c_{pH} ——水体的pH值

p 表示取负对数。根据上述分析可知,pH值会影响氨氮的动态平衡,盐度(可由电导率计算)可以体现养殖水环境中离子态氨的量。另外,水中有机物进行生物氧化分解时需消耗溶解氧,溶解氧浓度则关系到3种氮之间的转化效果。水体温度不仅会影响反应速率,还会影响溶解氧的最大溶解率。除此之外,目前可测的水质因素还有氧化还原电位、浊度、光照强度等,不可测的有硝酸盐、亚硝酸盐、总磷、化学需氧量、生物需氧量等。本次试验结合查阅的文献,且考虑到传感器及试验成本问题,选择对氨氮浓度影响较大的水体温度、电导率、溶解氧质量浓度、水体pH值这4个变量为集约化循环海水养殖水环境中氨氮浓度软测量模型的辅助变量。

1.3 氨氮浓度软测量模型构建

根据上述3种氮之间的转换规律及影响因素分析,将水体温度、电导率、溶解氧质量浓度、pH值作

为输入变量,建立氨氮浓度软测量模型

$$c_{\text{NH}_3\text{-N}} = f_x(t_T, c_{\text{pH}}, d, c_{\text{DO}}) \quad (9)$$

式中 $f_x(\cdot)$ ——未知非线性函数

t_T ——水体温度, $^{\circ}\text{C}$

d ——电导率,mS/cm

c_{DO} ——水中溶解氧的质量浓度,mg/L

建立氨氮浓度随机配置网络模型的具体过程如下:给定 N 组训练集 $\{(\mathbf{x}_n, \mathbf{y}_n) \mid n=1, 2, \dots, N\}$,其中 $\mathbf{x}_n \in \mathbf{R}^4$ 和 $\mathbf{y}_n \in \mathbf{R}$ 。令 $\mathbf{X} \in \mathbf{R}^{N \times 4}$ 、 $\mathbf{Y} \in \mathbf{R}^{N \times 1}$ 表示输入输出数据矩阵; $\mathbf{e}_{L-1}(\mathbf{X}) \in \mathbf{R}^{N \times 1}$ 是残差数据矩阵,其中每列 $\mathbf{e}_{L-1,q}(\mathbf{X}) = [e_{L-1,q}(\mathbf{x}_1) \ e_{L-1,q}(\mathbf{x}_2) \ \cdots \ e_{L-1,q}(\mathbf{x}_N)]^T \in \mathbf{R}^N$, $q=1$ 。定义第 L 个隐含层节点的输出向量为

$$\mathbf{h}_L(\mathbf{X}) = (\varphi_L(\mathbf{w}_L^T \mathbf{x}_1 + b_L), \varphi_L(\mathbf{w}_L^T \mathbf{x}_2 + b_L), \dots, \varphi_L(\mathbf{w}_L^T \mathbf{x}_N + b_L))^T \quad (10)$$

因此,隐含层的输出矩阵 \mathbf{f}_L 可以表示为 $\mathbf{H}_L = [h_1 \ h_2 \ \cdots \ h_L]$ 。定义

$$\xi_{L,q} = \frac{(\mathbf{e}_{L-1,q}^T(\mathbf{X}) \mathbf{h}_L(\mathbf{X}))^2}{\mathbf{h}_L^T(\mathbf{X}) \mathbf{h}_L(\mathbf{X})} -$$

$$(1 - r - \mu_L) \mathbf{e}_{L-1,q}^T(\mathbf{X}) \mathbf{e}_{L-1,q}(\mathbf{X}) \quad (q=1) \quad (11)$$

根据文献[13]中提出的随机配置算法,首先在不同的间隔产生较大范围的候选节点 T_{max} ,命名为 $\{\varphi_L^{(1)}, \varphi_L^{(2)}, \dots, \varphi_L^{(T_{\text{max}})}\}$,在候选节点中选择结果为正值的最小集合 $\{\xi_{L,1}, \xi_{L,2}\}$ 。然后,候选节点 φ_L^* 带有最大值 $\xi_L = \sum_{q=1}^2 \xi_{L,q}$,将被分配为第 L 个隐藏节点 f_L 。因此,随机配置网络的输出权值矩阵 $\beta = [\beta_1 \ \beta_2 \ \cdots \ \beta_L]^T \in \mathbf{R}^{L \times 2}$ 可以通过标准最小二乘来计算,即

$$\beta^* = \arg \min_{\beta} \|\mathbf{H}_L \beta - \mathbf{Y}\|_F^2 = \mathbf{H}_L^+ \mathbf{Y} \quad (12)$$

式中 \mathbf{H}_L^+ ——矩阵 \mathbf{H}_L 的Moore-Penrose广义逆矩阵

$\|\cdot\|_F$ ——Frobenius范数

β^* ——残差最小时的输出权值矩阵

\mathbf{Y} ——输出数据矩阵

2 氨氮浓度随机配置网络软测量模型实现

2.1 试验系统设计

为实现本文提出的氨氮浓度随机配置网络软测量建模方法,设计实验室集约化海水养殖系统如图1所示。

2.1.1 循环水养殖区

循环水养殖区包括5个水箱,结构如图2所示。蓄水箱存放纯净海水,有独立的排水系统,主要用于补充系统日常海水消耗,通过水泵与上位水箱单向连通。上位水箱最低点高于其他水箱,




图 1 实验室集约化循环海水养殖系统结构图

Fig. 1 Structure diagram of intensive circulating mariculture system

1. 上位机系统 2. PLC 系统 3. 循环水养殖区 4. 传感器模块

分别与过滤水箱、养殖水箱、沉降水箱相连。当 PLC(可编程控制器)控制上位水箱送水通道电磁




图 2 水循环系统

Fig. 2 Water circulation system

阀打开,上位水箱中的水即在重力作用下分别注入过滤水箱、养殖水箱和沉降水箱,减少使用水泵,具有节约能源、降低检查维护成本以及降低故障率的作用。

2.1.2 传感器模块

本次试验选用的温度、溶解氧质量浓度、pH 值、电导率传感器输入电压标准值均为 24 V DC,输出信号:4 ~ 20 mA DC,具体技术参数如表 1 所示。

表 1 传感器技术参数

Tab. 1 Technical parameters of sensors

变量	传感器类型	测量量程	测量精度/适用温度
温度	PT100 型铂电阻接触式	-5 ~ 60℃	±0.5%
溶解氧质量浓度	德国 WTW 公司 FDO 700 IQ 型,荧光法	0 ~ 20.0 mg/L	±0.01 mg/L
pH 值	德国 WTW 公司 SensoLyt 700 IQ SEA 型	2.00 ~ 14.00	0 ~ 80℃
电导率	德国 WTW 公司 TetraCon700 IQ 型	0.1 ~ 500 mS/cm	0 ~ 60℃

2.1.3 PLC 及上位机控制系统

控制系统由 Siemens S7-300 型 PLC 构成,对养殖区进行控制,实现温度调节、增氧泵的启停等,并将传感器采集的数据传到上位机,在上位机完成氨氮浓度模型的建立与计算。

2.2 数据采集

2.2.1 试验准备

本次试验场地选在实验室内,养殖水箱尺寸为 0.58 m × 0.44 m × 0.58 m,采用集约化循环海水养殖模式,试验养殖对象为大菱鲆。正式试验前先在养殖池内饱食驯养 14 d,挑选健康活跃的鱼苗,根据大菱鲆最优养殖密度,按 9 kg/m²放养,投喂膨化颗粒海鱼饲料。海水取自大连黑石礁近海海域,经粗砂、pp 棉过滤,活性炭吸附后使用。

试验时间为 2017 年 4—6 月,为期 60 d,遮光循环水养殖。每天投饵两次(09:00 和 16:00)。采取饱食投喂方式,即投饵时,逐粒投饵直到水箱底大菱鲆不再跃起索饵、争食时停止投放。每次投饵前,先清理缸底未被过滤的部分排泄物,投饵结束后,再清理缸底残余的饵料,以降低过滤系统压力,增加滤材使用寿命。试验过程中根据液位变化调节新鲜海水流量。

2.2.2 试验数据

养殖水体中的温度、溶解氧质量浓度、pH 值、电导率以及养殖池内液面高度通过传感器实时测量,

经由 PLC 传输至上位机数据库。

养殖水体氨氮的测量采用纳氏试剂法。此方法反应速度较快,操作方法简单,易于学习,灵敏度高,被广泛应用于各种研究领域和实际生产过程,是目前国际上最常用的氨氮测量方法。

试验过程中,从 08:00 到 18:00,每隔 2 h 取一次样,测量养殖水体氨氮质量浓度,并进行记录。与传感器测量数据共同存储在 Excel 表进行统计。将采集到的数据经过中位值滤波及 3σ 准则去除掉异常值后,共收集 236 组数据,部分试验数据如表 2 所示。

表 2 部分试验数据

Tab. 2 Partial experimental data

时刻	温度/ ℃	溶解氧质量浓 度/(mg·L ⁻¹)	pH 值	电导率/ (mS·cm ⁻¹)	氨氮质量浓度/ (mg·L ⁻¹)
08:00	14.9	8.20	7.85	41.1	0.1859
10:00	14.7	8.26	7.85	41.1	0.2161
⋮	⋮	⋮	⋮	⋮	⋮
16:00	14.1	8.38	7.90	41.3	0.3417
18:00	13.5	8.63	7.90	39.9	0.3417

2.3 模型实现

采用均方根误差(Root mean squared error, RMSE)作为衡量精度的指标,用于比较不同建模方法的预测效果。

采用提出的基于随机配置网络的氨氮浓度软测

量建模方法,依托实验室采集的数据,50%用于训练,50%用于预测,得到氨氮质量浓度训练过程均方根误差变化曲线如图3所示。




图3 随机配置网络训练过程均方根误差

Fig. 3 RMSE of stochastic configuration network training

隐含层节点个数为19,模型训练和预测结果如图4、5所示。从图中可以看出,氨氮质量浓度模型计算值大部分能够跟随真值的变化趋势,说明本文采用的随机配置网络模型是有效的。




图4 基于SCN神经网络的氨氮质量浓度模型训练结果

Fig. 4 Training results of ammonia nitrogen concentration model based on SCN




图5 基于SCN神经网络的氨氮质量浓度模型预测结果

Fig. 5 Prediction results of ammonia nitrogen concentration model based on SCN

基于西门子PLC控制,采用WinCC组态软件设计了集约化水产养殖监控系统,将建立好的氨氮浓度软测量模型用于试验系统,实现了氨氮浓度的实时监测。

2.4 结果分析与讨论

为验证本文提出方法的有效性,采用其它不同网络,如BP、RBF和RVFL神经网络进行建模试验,预测结果如图6~8所示。

采用相同个数的隐含层节点,对比各种方法的运行时间以及训练和预测精度,如表3所示。

从比较结果来看,BP网络有较好的训练精度,均方根误差为0.040 mg/L,但预测精度稍差,均方根误差为0.066 mg/L,说明其泛化能力有限。RBF网络与BP网络相比,训练精度和预测精度都稍差,




图6 基于BP神经网络的氨氮浓度模型预测结果

Fig. 6 Prediction results of ammonia nitrogen concentration model based on BP




图7 基于RBF神经网络的氨氮浓度模型预测结果

Fig. 7 Prediction results of ammonia nitrogen concentration model based on RBF




图8 基于RVFL神经网络的氨氮浓度模型预测结果

Fig. 8 Prediction results of ammonia nitrogen concentration model based on RVFL

表3 不同算法结果比较

Tab. 3 Comparison of results of different algorithms

算法	均方根误差/(mg·L ⁻¹)		运行时间/s	隐含层节点个数
	训练	预测		
BP神经网络	0.040	0.066	12.36	19
RBF神经网络	0.057	0.069	3.13	19
RVFL神经网络	0.057	0.067	1.40	19
SCN神经网络	0.051	0.064	1.32	19

均方根误差分别为0.057 mg/L和0.069 mg/L,但是运行时间为3.13 s,运算速度比BP网络的12.36 s快。从隐含层节点个数来看,对于相同的隐含层节点个数,BP网络运行速度最慢,如果数据量增加,继续加大节点个数,运行时间会更长,RBF网络也有同样的问题。基于随机算法的两种网络RVFL和SCN,运行速度较快,分别为1.40 s和1.32 s,显示了随机算法的速度优势,与BP和RBF算法相比,二者的精度也较高,训练过程均方根误差分别为0.057 mg/L和0.051 mg/L,预测过程均方根误差分别为0.067 mg/L和0.064 mg/L,说明两种随机算法

的泛化能力也较强,且 SCN 算法比 RVFL 算法有更高的精度和更快的运行速度。

为进一步提高氨氮预测精度,分析目前模型误差产生的原因。一是影响氨氮浓度的因素很多,本试验忽略其它因素的影响,只用 4 个较易获得的变量作为辅助变量,存在一定的误差。二是本试验没有考虑过程动态,水产养殖水质参数的变化是连续动态的,氨氮浓度与前一时刻的水质情况密切相关。

随着水产养殖大数据技术的发展,基于数据的建模技术必然成为水产养殖大数据分析的趋势^[17]。课题未来的工作需要考虑辅助变量的添加与约简,比如采用主元分析或粗糙集等方法,也要考虑模型参数的优化^[18]。此外,现场采集数据包括噪声和离群点等情况,还需选择适当的鲁棒^[19]和集成^[20]数据建模方法。更重要的是,还应考虑养殖过程动态特性以及水质因素之间的时间序列关联,建立水质

因素动态软测量模型。

3 结束语

在集约化水产养殖过程中,氨氮浓度的高精度实时检测对鱼类生长和健康至关重要。本文首先通过查阅国内外相关领域文献,分析了用软测量方法实现集约化水产养殖水质氨氮浓度的可行性。然后通过氨氮转化机理分析,找出易测且对氨氮浓度影响较大的 4 个因素作为软测量模型的辅助变量,并采用近年提出的随机配置网络建立氨氮浓度软测量模型。随机配置网络在建模方面人工干预少,参数范围可随机自适应选择,具有学习快速和泛化能力强等优点。建立实验室集约化海水养殖软硬件系统,进行了数据采集和建模试验,结果表明本文提出的软测量模型比其他传统方法更适合水产养殖过程氨氮浓度的在线监测。

参 考 文 献

- [1] 尹宝全,曹闪闪,傅泽田,等. 水产养殖水质监测与控制技术研究进展分析[J/OL]. 农业机械学报, 2019, 50(2): 1-13. YIN Baoquan, CAO Shanshan, FU Zetian, et al. Review and trend analysis of water quality monitoring and control technology in aquaculture[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(2): 1-13. http://www.jcsam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190201&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2019.02.001. (in Chinese)
- [2] 何群华. 水体中氨氮测定方法的研究进展[J]. 广东化工, 2013, 40(14): 154-155, 160. HE Qunhua. Advances on the analysis methods of ammonia nitrogen in water[J]. Guangdong Chemical Industry, 2013, 40(14): 154-155, 160. (in Chinese)
- [3] 罗澍, 严少红, 黄远峰, 等. 四种氨氮自动监测仪与实验室国标方法测定氨氮的比较分析[J]. 中国环境监测, 2010, 3(26): 32-35. LUO Shu, YAN Shaohong, HUANG Yuanfeng, et al. Comparison between four automatic on-line monitoring instrument and laboratorial national standard method to determine ammonia-nitrogen in water[J]. Environmental Monitoring in China, 2010, 3(26): 32-35. (in Chinese)
- [4] 陈静, 徐滋秋, 付万年, 等. 电导法氨氮自动连续监测仪的设计与研究[J]. 仪表技术, 2010(12): 39-41. CHEN Jing, XU Ziqiu, FU Wannian, et al. Design and study on conductometry ammonia on-line and continuous monitoring detector[J]. Instrumentation Technology, 2010(12): 39-41. (in Chinese)
- [5] 高艳萍, 周敏, 姜凤娇. 基于 BP 网络养殖水体氨氮预测模型及实现[J]. 农机化研究, 2008, 30(7): 48-50. GAO Yanping, ZHOU Min, JIANG Fengjiao. Prediction model and implementation of ammonia nitrogen in aquaculture water based on BP network[J]. Journal of Agricultural Mechanization Research, 2008, 30(7): 48-50. (in Chinese)
- [6] 杨争光, 范良忠. 基于 MEC-BP 神经网络在水产养殖水质预测中的应用[J]. 计算机与现代化, 2015(6): 32-36. YANG Zhengguang, FAN Liangzhong. Application of water quality prediction based on MEC-BP neural network in aquaculture[J]. Computer and Modernization, 2015(6): 32-36. (in Chinese)
- [7] DENG Changhui, KONG Deyan, SONG Yanhong, et al. A soft-sensing approach to on-line predicting ammonia nitrogen based on RBF neural networks[C]//International Conferences on Embedded Software and Systems, 2009: 454-458.
- [8] 王文萍, 郭周芳, 尚伟伟, 等. 水中氨氮的测定方法[J]. 水科学与工程技术, 2012(3): 26-28. WANG Wenping, GUO Zhoufang, SHANG Weiwei, et al. Determination methods summary of ammonia nitrogen in water[J]. Water Sciences and Engineering Technology, 2012(3): 26-28. (in Chinese)
- [9] 宦娟, 刘星桥. 基于 K-means 聚类 and ELM 神经网络的养殖水质溶解氧预测[J]. 农业工程学报, 2016, 32(17): 174-181. HUAN Juan, LIU Xingqiao. Dissolved oxygen prediction in water based on K-means clustering and ELM neural network for aquaculture[J]. Transactions of the CSAE, 2016, 32(17): 174-181. (in Chinese)
- [10] 陈英义, 程倩倩, 方晓敏, 等. 主成分分析和长短时记忆神经网络预测水产养殖水体溶解氧[J]. 农业工程学报, 2018, 34(17): 183-191. CHEN Yingyi, CHENG Qianqian, FANG Xiaomin, et al. Principal component analysis and long short-term memory neural network for predicting dissolved oxygen in water for aquaculture[J]. Transactions of the CSAE, 2018, 34(17): 183-191.

(in Chinese)

- [11] 乔俊飞, 马士杰, 许进超. 基于递归 RBF 神经网络的出水氨氮预测研究[J]. 计算机与应用化学, 2017, 34(2): 145 - 151.
QIAO Junfei, MA Shijie, XU Jinchao. Prediction of ammonia nitrogen based on recurrent RBF neural network[J]. Computers and Applied Chemistry, 2017, 34(2): 145 - 151. (in Chinese)
- [12] 韩红桂, 陈治远, 乔俊飞, 等. 基于区间二型模糊神经网络的出水氨氮软测量[J]. 化工学报, 2017, 68(3): 1032 - 1040.
HAN Honggui, CHEN Zhiyuan, QIAO Junfei, et al. Soft-sensor method for effluent ammonia nitrogen based on interval type-2 fuzzy neural networks[J]. CIESC Journal, 2017, 68(3): 1032 - 1040. (in Chinese)
- [13] SCARDAPANE S, WANG D. Randomness in neural networks: an overview [J]. WIREs Data Mining and Knowledge Discovery, 2017, 7(2): 1 - 18.
- [14] WANG Dianhui, LI Ming. Stochastic configuration networks: fundamentals and algorithms[J]. IEEE Trans. on Cybernetics, 2017, 47(10): 3466 - 3479.
- [15] PAO Y, PARK G, SOBAJIC D. Learning and generalization characteristics of the random vector functional-link net [J]. Neurocomputing, 1994, 6(2): 163 - 180.
- [16] KOOIJMAN S A L M. A safety factor for LC values allowing for differences in sensitivity among species[J]. Water Research, 1987, 21(3): 269 - 276.
- [17] 段青玲, 刘怡然, 张璐, 等. 水产养殖大数据技术研究进展与发展趋势分析[J/OL]. 农业机械学报, 2018, 49(6): 1 - 16.
DUAN Qingling, LIU Yiran, ZHANG Lu, et al. State-of-the-art review for application of big data technology in aquaculture[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(6): 1 - 16. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180601&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2018.06.001. (in Chinese)
- [18] 朱成云, 刘星桥, 李慧, 等. 工厂化水产养殖溶解氧预测模型优化[J/OL]. 农业机械学报, 2016, 47(1): 273 - 278.
ZHU Chengyun, LIU Xingqiao, LI Hui, et al. Optimization of prediction model of dissolved oxygen in industrial aquaculture [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(1): 273 - 278. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20160137&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2016.01.037. (in Chinese)
- [19] WANG Dianhui, LI Ming. Robust stochastic configuration networks with kernel density estimation for uncertain data regression [J]. Information Sciences, 2017, 412 - 413: 210 - 222.
- [20] WANG Dianhui, CUI Caihao. Stochastic configuration networks ensemble with heterogeneous features for large-scale data analytics[J]. Information Science, 2017, 417: 55 - 71.