

徐大明,杜永贵,孙传恒,等. 基于改进粒子群优化极限学习机的养殖氨态氮含量预测模型[J]. 江苏农业科学,2017,45(4):183-186.
doi:10.15889/j.issn.1002-1302.2017.04.057

基于改进粒子群优化极限学习机的 养殖氨态氮含量预测模型

徐大明^{1,2,3,4}, 杜永贵¹, 孙传恒^{2,3,4}, 周超^{2,3,4}

(1. 太原理工大学信息工程学院,山西太原 030000; 2. 国家农业信息化工程技术研究中心,北京 100097;

3. 农业部农业信息技术重点实验室,北京 100097; 4. 北京市农业物联网工程技术研究中心,北京 100097)

摘要:针对养殖水体氨态氮含量预测准确性低的问题,提出了一种基于改进粒子群算法优化极限学习机的水产养殖氨态氮含量预测模型。引入自适应变异算子改进粒子群算法的搜索性能,利用改进粒子群算法优化极限学习机的初始权值和阈值,最后训练极限学习机预测模型求得最优解。将该预测模型应用在小汤山水产品养殖系统进行有效性验证,通过试验发现,与 PSO-ELM 和普通 BP 神经网络相比,IPSO-ELM 预测氨态氮含量模型有更高的精度和更好的拟合能力。结果表明,基于改进粒子群优化的极限学习机氨态氮含量预测模型简单易懂、预测精度高、易于实现,具有较好的预测性能。

关键词:氨态氮预测;粒子群算法;变异算子;极限学习机

中图分类号:TP181;S934

文献标志码:A

文章编号:1002-1302(2017)04-0183-04

养殖水质参数预测已经成为水产品集约化、精准化养殖的基础性工作,及时准确的水质预测对预防水质恶化及水产品疾病暴有着十分重要的现实意义和经济价值^[1]。氨态氮($\text{NH}_3\text{-N}$)含量过高是造成水体富营养化的重要因素之一,氨态氮常常以游离氨(NH_3)和铵态氮(NH_4^+)的形式存在于养殖水体之中,若含量过高,将导致水产品抵抗力下降,呼吸困难,严重时甚至造成水产品大范围死亡^[2]。虽然水体中氨态氮的含量可以在线监测,但由于养殖水体是一个大时滞的系统,存在着明显的时间延迟,氨态氮含量的变化通常滞后于鱼的生理变化^[3]。因此,为了满足集约化养殖的实际需求,对氨态氮含量进行预测是很有必要的。

目前的水质参数预测在自然水体中应用得较多,养殖水质预测方面的研究较少。常用的水质预测方法有水质模拟法、专家评估法、历史平均法、回归分析法等^[4-6],由于养殖水质参数之间的高耦合关系,这些方法对于模糊不确定性的养殖水质的预测精度效果不甚理想。人工神经网络^[7-9]具有非常强的自适应学习能力和对非线性函数的逼近能力,可以作为构建水质预测模型的有力工具,但同时常见的前馈神经网络又存在着收敛慢、过学习、易陷入局部最优解的缺点。极限学习机^[10]是一种简单易用、有效的单隐层前馈神经网络学习算法,具有学习速度快且泛化性能好的优点,很好地克服了上

述缺陷。但是由于极限学习机初始权值和阈值的随机性,得到的结果通常不是最优解。本研究利用改进粒子群算法对极限学习机初始权值和阈值进行优化,构建养殖水质参数 pH 值、溶氧量、Mn 含量、氨态氮含量和未来某时刻的氨态氮含量之间的非线性关系预测模型,并将该模型运用到小汤山国家精准农业示范基地水产养殖池塘,测试模型的预测精度。

1 试验区域概况与数据来源

1.1 试验区域概况

本试验区域是小汤山国家精准农业示范基地水产养殖池塘,该区域每个池塘约 200 m²,配备 YSI6600 多参数水质检测仪、增氧泵、水泵、物联网水质监控系统。物联网水质监控系统已经稳定、有效地运行了 3 年并且记录了大量的水质数据。

1.2 数据的获取

该系统采集的水质参数有 pH 值、溶氧量、Mn 含量、氨态氮含量。本研究使用的数据来自于 2015 年 6 月 7—12 日,共 6 d。系统的采样周期是 5 min,鉴于每个周期内的数据变化不大,因此本研究选择每 15 min 的数据为有效值,样本总数为 576 组。将这些数据分成 2 个部分:前 456 组水质数据作为学习样本,供 PSO-BNPP 水质预测模型建模训练;后 120 组水质数据作为测试数据,用来检测水质预测模型的性能,原始数据如图 1 所示。

1.3 数据的预处理

高密度水产养殖溶解氧受外界影响因素较大,若直接使用原始数据对预测模型的参数组合进行优化训练,不仅训练时间较长,同时影响所建立模型的准确性和鲁棒性,因此有必要对原始数据进行归一化操作,将所有的数据归一化到区间 [0.02, 0.98] 中。

收稿日期:2015-12-17

基金项目:国家科技支撑计划(编号:2014BAD08B09-02);国家“863”计划(编号:2012AA101905-02);北京市自然科学基金(编号:6152009)。

作者简介:徐大明(1991—),男,江苏盐城人,硕士,研究方向为智能算法。E-mail:xudaming@vip.qq.com。

通信作者:孙传恒,博士,研究员,研究方向为农业信息化。E-mail:sunch@nercita.org.cn。




图1 试验样本原始数据

$$x' = 0.02 + 0.96 \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中: x 表示原始数据; x_{\max} 和 x_{\min} 分别为数据集的最大值和最小值; x' 为归一化之后的数据。

2 改进粒子群算法优化极限学习机的软测量模型

2.1 极限学习机

南洋理工大学黄广斌教授等在 2004 年提出一种简单易用、有效的单隐层前馈神经网络学习算法, 即极限学习机^[11-13] (extreme learning machine, ELM)。在 ELM 中, 初始权值和阈值是随机设定的, 只须要设置网络的隐层节点个数, 算法执行过程中不须要对网络的输入权值以及隐元的阈值进行调整, 产生唯一最优解。相比于其他前馈神经网络, ELM 具有学习速度快、泛化性好等优点。

对于单隐层神经网络, 若有 n 个任意的样本 (X_i, Y_i) , 其中 $X_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$, $Y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in R^m$, 一个具有 k 个隐层节点的单隐层前馈神经网络可以表示为:

$$F_k(x) = \sum_{i=1}^k \beta_i G(A_i \cdot X_j + B_i), j=1, \dots, n_0 \quad (2)$$

式中: $A_i = [a_{i1}, a_{i2}, \dots, a_{in}]^T$ 为输入权值, β_i 为连接第 i 个隐层节点的输出权值, B_i 为第 i 个隐层节点的阈值, $A_i \cdot X_j$ 表示向量 A_i 和 X_j 的内积, $G(x)$ 为激活函数。

若此包含 k 个隐含层的神经网络输出 t_j 逼近这 n 个样本, 使得输出误差最小, 则存在 A_i, B_i, β_i , 使得:

$$t_j = \sum_{i=1}^k \beta_i G(A_i \cdot X_j + B_i), j=1, \dots, n_0 \quad (3)$$

简化得到

$$H\beta = T \quad (4)$$

式中: H 为隐含节点的输出, β 为输出权重, T 为期望输出。在 ELM 中, 由于输入权重和隐含层阈值随即给定, 因此隐含层的输出矩阵 H 是固定的。训练单隐层神经网络可以转化成求解线性系统 $H\beta = T$, β 可以由式(5)确定:

$$\hat{\beta} = H^+ T \quad (5)$$

式中: H^+ 称为隐含层输出矩阵 H 的 Moore - penrose 的广义逆, $\hat{\beta}$ 表示系统的最小二乘解。

2.2 基本粒子群算法

粒子群算法^[14-17] (particle swarm optimization, PSO) 是由 Eberhart 和 Kennedy 在 1995 年提出, 该算法是一种源于模拟鸟群觅食过程中群聚、迁徙行为的智能全局随机搜索算法。在 PSO 中, 每一个优化问题的候选解都被记作搜索空间上的 1 个“粒子”, 每一个粒子都有 1 个被目标函数决定的适应值, 以及 1 个决定它们搜索方向和搜索距离的速度。粒子根据自身的位置和当前最优粒子的位置在搜索空间中智能调整, 直至满足要求为止。

由 n 个粒子组成的群体对 S 维 (每个粒子的维数) 空间进行搜索, 其中第 i 个粒子表示为 $X_i = (X_{i1}, X_{i2}, \dots, X_{is})$, 代表第 i 个粒子在 S 维空间的位置, 即问题的潜在解。每个粒子对应的速度可以表示为 $V_i = (V_{i1}, V_{i2}, \dots, V_{is})$, 每个粒子在搜索时要考虑 2 个“极值”来更新自己, 一个是本身的历史最优值 $P_i = (P_{i1}, P_{i2}, \dots, P_{is})$, $i=1, 2, \dots, n$; 另一个是全部粒子的最优值 $P_g = (P_{g1}, P_{g2}, \dots, P_{gs})$, $i=1, 2, \dots, n$ 。

在迭代过程中, 粒子的速度和位置在迭代中的更新:

$$V_{is}^{k+1} = \omega V_{is}^k + c_1 \xi (P_{is}^k - X_{is}^k) + c_2 \eta (P_{gs}^k - X_{is}^k); \quad (6)$$

$$X_{is}^{k+1} = X_{is}^k + r V_{is}^{k+1} \quad (7)$$

式中: ω 称作惯性权重, 系保持原来速度的系数; c_1 和 c_2 分别为粒子跟踪自己和整个群体最优值的权重系数; ξ 和 η 为均匀分布在区间 $[0, 1]$ 内的随机数; r 为约束因子。

2.3 改进粒子群算法

粒子在快速向自身历史最佳位置和群体历史最佳位置的聚集过程中形成快速趋同效应, 容易出现陷入局部极值、早熟收敛或者停滞的现象^[18-20]。为了克服上述缺陷, 本研究参照遗传算法中的算子变异思维, 将 PSO 算法中的某些参数以一

定的概率初始化。变异操作可以在扩大迭代中不断地缩小搜索范围,跳出搜索到的最佳位置,再次进行搜索,极大地降低了陷入局部极值的可能性,提高了搜索到全局最优解的概率。

2.4 改进粒子群优化极限学习机预测算法

由于 ELM 的输入权值和隐含层的阈值是随机给定的,存在输入权值和隐含层阈值为 0 的情况,导致部分隐含层节点可能失效,因此在实际应用中,常常须要设置大量的隐含层节点数才能满足精度要求。同时由于 ELM 的初始权值、阈值都是随机生成的,因此每次训练学习结果都不一样,有时差距较大。

针对上述问题,本研究提出改进粒子群优化极限学习机预测算法(IPSO-ELM),具体步骤如下:Step 1,初始化 PSO 的相关参数,包括种群数量、惯性权重、学习因子、最大迭代次数以及位置和速度的取值范围。其中,粒子的初始速度和初始位置随机赋值。

Step 2,根据输入输出信号的个数确定 ELM 的拓扑结构,并随机生成一组粒子群 $W_i = [w_{i1}, w_{i2}, \dots, w_{is}]^T, i = 1, 2, \dots, n$ 初始化 ELM 的权值和阈值,其中

$$S = S_1 S_2 + S_2 S_3 + S_2 + S_3. \quad (8)$$

式中: S_1, S_2, S_3 分别为 ELM 的输入层节点数、隐含层节点数和输出层节点数。

Step 3,选择 ELM 激活函数,根据 Step 2 中得到的粒子 W_i 对 ELM 权值阈值进行赋值。输入学习样本运用 ELM 对网络进行寻优迭代,计算每组粒子的适应度,根据初始粒子适应度值确定个体极值和群体极值,并将每个粒子的最好位置作为其历史最佳位置。

Step 4,根据公式(6)和公式(7),更新粒子的速度和位置,引入变异算子,在粒子更新之前有一定的概率初始化粒子速度和位置,计算适应度值,更新粒子的个体极值和群体极值。

Step 5,判断是否满足结束条件,如果适应度值达到预设的精度,或者误差满足条件,或者达到最大迭代次数,则停止寻优迭代。将其解码后作为 ELM 的权值、阈值,经过模型训练后输出最优解;如果不满足结束条件,回到 Step 4。流程图如图 2 所示。




图2 IPSO-ELM 算法流程图

3 算法实现与试验结果分析

基于 IPSO-ELM 氨态氮含量预测模型的开发环境为:酷睿 i5 3210M 2.49 GHz, 2 GB 内存, Windows XP 系统, Matlab R2012a 试验仿真环境。粒子群算法部分初始化:种群大小个数为 35, 权重系数 $c_1 = c_2 = 1.49445$, 约束因子 $r = 0.729$, 算子变异概率 $P = 0.05$, 迭代次数设置为 50, 惯性权重最大值 $\omega_{\max} = 1.2$, 最小值 $\omega_{\min} = 0.4$, 粒子的最大速度 $V_{\max} = 5$, 最小速度 $V_{\min} = -1$ 。适应度函数采用 ELM 的预测值和真实值之间的均方根误差(RMSE), ELM 的激活函数选择 Sigmoid。

3.1 基于 IPSO-ELM 的养殖氨态氮含量预测模型

根据高密度养殖氨态氮含量预测的需要,选择每 15 min 的养殖水质参数数据:pH 值(pH_i)、溶氧量(DO_i)、高锰酸盐($CODMn_i$)、氨态氮含量(N_i)作为模型输入值,将下一个时间点的氨态氮含量(N_{i+1})作为模型输出值,进行建模学习。然后将得到的预测结果与实际值进行比较分析。

为了综合比较 IPSO-ELM 的水质预测模型的性能,本研究采取多种评价指标:均方根误差(RMSE)、相对均方差均值(MSRE)、平均绝对误差(MAE)和决定系数(R^2)作为判断模型性能的准则。各项评价指标的计算公式如下:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}; \quad (9)$$

$$MSRE = \frac{1}{n} \sum_{i=1}^n \frac{(y_i - \hat{y}_i)^2}{y_i^2}; \quad (10)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|; \quad (11)$$

$$R^2 = \frac{[\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})]^2}{\sum_{i=1}^n (y_i - \bar{y})^2 \cdot \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}. \quad (12)$$

式中: \hat{y}_i 为模型预测值; y_i 为实际值; \bar{y} 为真实值序列平均值; $\bar{\hat{y}}$ 为预测值序列平均值; n 为样本的数量。

3.2 预测结果分析

为了检验 IPSO-ELM 氨态氮含量预测模型的实际应用效果,选取 PSO-ELM 和传统 BP 神经网络进行对比。PSO-ELM 的初始参数和 IPSO-ELM 的初始参数一样,BP 神经网络采用 4 输入节点-4 隐含节点-1 输出节点的拓扑结构,学习率为 0.086,激活函数为 Sigmoid,训练次数为 500 次,训练目标为 0.000 1。预测的结果拟合曲线对比如图 3 所示;表 1 列出了相同前提下各模型的预测误差指标分析。




图3 IPSO-ELM、PSO-ELM、BP 神经网络预测结果对比

由图 3 和表 1 可见,3 种氨态氮含量预测模型的预测结果都能很好地反映氨态氮含量随时间的变化而变化趋势和规律,这说明 3 种预测模型都能较好地满足时间序列上的氨态氮含量预测要求。同时可以看出,改进粒子群优化极限学习机氨态氮含量预测模型预测精度明显高于其他 2 种预测模型。

表 1 3 种预测模型结果分析

预测模型	RMSE	MSRE	MAE	R ²	训练时间 (s)
BP 神经网络模型	0.350 3	0.978 5	0.267 4	0.711 0	14.367 2
PSO-ELM 模型	0.219 2	0.370 9	0.170 7	0.885 3	8.092 3
IPSO-ELM 模型	0.121 9	0.059 0	0.092 7	0.968 4	8.209 0

在前提条件相同的情况下,IPSO-ELM 模型和传统 BP 神经网络相比,评价指标 RMSE、MSRE、MAE、运行时间分别降低了 65.2%、94.0%、65.3%、6.158 2 s, R² 提高了 36.2%; IPSO-ELM 模型和 PSO-ELM 相比,评价指标 RMSE、MSRE、MAE 分别降低了 44.4%、84.1%、45.7%, R² 提高了 9.4%,但是在运行时间这方面 IPSO-ELM 模型由于引入变异算子,因此略高于 PSO-ELM 预测模型 0.116 7 s(表 1)。由表 2 可知,当训练样本为 200 组时,由于粒子群算法的快速趋同效应,算法陷入局部极值,因此出现预测精度低于传统 BP 神经网络的现象。本试验采取了变异算子的 IPSO-ELM 算法,由于避免了快速趋同效应,预测精度全部高于另外 2 种算法。

表 2 3 种预测模型不同训练样本的预测误差

训练样 本数(组)	预测样 本数(组)	RMSE		
		BP 神经网络	PSO-ELM	IPSO-ELM
456	20	0.281 3	0.197 2	0.131 3
400	20	0.272 0	0.198 2	0.130 1
300	20	0.362 3	0.287 4	0.162 1
200	20	0.368 7	0.456 5	0.207 2
100	20	0.390 2	0.389 0	0.230 6

基于上述分析,对于所有评价指标,本研究提出的 IPSO-ELM 氨态氮含量预测模型比传统 BP 神经网络和 PSO-ELM 模型具有更高的预测精度和较少的运行时间,可以满足高密度养殖条件下氨态氮含量预测的需求;训练样本越少,IPSO-ELM 模型的预测精度比 PSO-ELM 模型和 BP 模型提高得越多,这对实现小样本预测具有重要意义。

4 结论

通过对养殖水体氨态氮含量的预测,可以及时掌握氨态氮的含量以及变化趋势,为开展生态养殖环境评价、及时准确的水质预警提供基础法。本研究介绍了一种基于改进粒子群优化的极限学习机水质预测模型,引入变异算子,改善了 PSO 算法快速趋同效应。将其应用在时间序列上氨态氮含量预测,并同 PSO-ELM 模型和普通 BP 神经网络进行对比。试验结果表明,IPSO-ELM 预测模型对非线性时间序列上的养殖氨态氮含量预测是可行的,相比其他 2 种模型有更高的精度和更好的拟合能力。在 IPSO-ELM 模型的训练过程中,粒子群的参数决定着预测模型的精度和性能,然而目前参数的

选择还是依靠经验和拼凑法,今后须在研究中进一步探讨如何获得粒子群算法的最佳参数组合,实现自适应调整。

参考文献:

[1]Huang G H,Xia J. Barriers to sustainable water quality management [J]. Journal of Environmental Management,2001,61(1):1-23.

[2]何力,徐忠法,周瑞琼. 内陆渔业水质环境相关标准的应用和分析[J]. 水利渔业,2004,24(1):39-40.

[3]刘双印. 基于计算智能的水产养殖水质预测预警方法研究[D]. 北京:中国农业大学,2014:13-18.

[4]李如忠. 水质预测模式理论研究进展与趋势分析[J]. 合肥工业大学学报(自然科学版),2006,29(1):26-30.

[5]刘双印,徐龙琴,李振波,等. 基于 PCA-MCAFA-LSSVM 的养殖水质 pH 值预测模型[J]. 农业机械学报,2014,45(5):239-246.

[6]Liu S Y,Tai H J,Ding Q S,et al. A hybrid approach of support vector regression with genetic algorithm optimization for aquaculture water quality prediction[J]. Mathematical and Computer Modelling,2013,58:458-465.

[7]梁毅,刘世洪. 基于遗传算法优化的 BP 神经网络的组合预测模型方法研究[J]. 中国农业科学,2012,45(23):4924-4930.

[8]朱建良,闻彦,李国辉. 基于灰色理论与 BP 神经网络的电力负荷预报[J]. 电机与控制学报,2006,10(4):440-442.

[9]祁金秀,陈晶. 基于粒子群算法优化的径向基函数水质预测模型[J]. 甘肃水利水电技术,2014,50(5):1-4.

[10]Huang G B,Zhu Q Y,Siew C K. Extreme learning machine: theory and applications [J]. Neurocomputing,2006,70(1/2/3):489-501.

[11]王杰,毕浩洋. 一种基于粒子群优化的极限学习机[J]. 郑州大学学报,2013,45(1):100-104.

[12]Zong W W,Huang G B. Face recognition based on extreme learning machine[J]. Neurocomputing,2011,74(16):2541-2551.

[13]张翌晖,王贺,胡志坚,等. 基于集合经验模态分解和改进极限学习机的短期风速组合预测研究[J]. 电力系统保护与控制,2014,42(10):29-34.

[14]Ren C,An N,Wang J Z,et al. Optimal parameters selection for BP neural network based on particle swarm optimization: a case study of wind speed forecasting[J]. Knowledge-Based Systems,2014,56:226-239.

[15]粒子群算法研究[EB/OL]. [2015-04-18]. <http://blog.csdn.net/niuyongjie/article/details/1569671>.

[16]李珊. 基于粒子群算法的 BP 神经网络漏钢预测模型[D]. 秦皇岛:燕山大学,2014:23-31.

[17]倪剑剑,邢汉承,张志政,等. 粒子群优化算法研究进展[J]. 模式识别与人工智能,2007,20(3):349-357.

[18]黄树运. 改进的粒子群算法训练 BP 神经网络的研究[D]. 南宁:广西大学,2013:11-19.

[19]李松,刘力军,翟曼. 改进粒子群算法优化 BP 神经网络的短时交通流预测[J]. 系统工程理论与实践,2012,32(9):2045-2049.

[20]何勇,李妍琰. 改进粒子群优化 BP 神经网络的洪水智能预测模型研究[J]. 西南师范大学学报(自然科学版),2014,39(5):75-80.