

文章编号:1000 - 0615(2006)02 - 0225 - 05

基于模糊神经网络的池塘溶解氧预测模型

郭连喜, 邓长辉

(大连水产学院信息工程学院, 辽宁 大连 116023)

摘要: 在分析了池塘溶解氧影响因素的基础上,利用模糊神经网络良好的非线性逼近能力建立了池塘溶解氧的模糊神经网络预测模型。神经网络模型如采用常规的 BP 或其它梯度算法,常导致训练时间较长且易陷入局部极小点,本实验采用快速的粒子群优化算法对模糊神经网络进行训练,收敛速度明显加快。实验结果表明采用该方法预报溶解氧的预测精度较常规 BP 递推算法的预测精度明显提高,所采用的模型能对溶解氧进行可靠的预测,该方法为研制开发智能水质检测仪以及工厂化养殖工作奠定了基础,对实际生产具有一定的指导意义。

关键词: 溶解氧;模糊神经网络;粒子群优化算法;预测模型

中图分类号: S967.4; TP183 **文献标识码:** A

Prediction model for dissolved oxygen in fish pond based on fuzzy neural network

GUO Lian-xi, DENG Chang-hui

(School of Information Engineering, Dalian Fisheries University, Dalian 116023, China)

Abstract: Dissolved oxygen (DO) is an important water quality parameter in fishery water. Dissolved oxygen condition has great influence on water quality and growth of cultured organisms. With rapid development of pond cultivation, the dissolved oxygen concentration in pond is gradually attached importance to as factor of water environment. At present we mainly adopt timing and fixed point measurement for dissolved oxygen in pond, so the accurate predication of DO in fishpond has been the key to aquatic breeding. The factor which influences dissolved oxygen in pond is complicated. For a certain pond, the dissolved oxygen is relative to different seasons, measuring time, the position, the depth of measuring point, wind speed, the depth and surface area of the pond. The prediction for dissolved oxygen in pond is a problem of multi-variable, non-linearity and long-time lag. Due to complexity and non-linearity of influence factor of dissolved oxygen, it is difficult to use precise mathematics model to describe dissolved oxygen quantitatively. The artificial neural network is a nonlinear optimization tool. By its good characteristics of high nonlinear mapping, self-organization, the ability of high parallel processing, the artificial neural network connects various affected factors. After synthetically analyzing and considering the measurability of all variables, we selected water temperature, nitrite, ammonia value ($\text{NO}_2\text{-N}$), and total nitrogen value in the pond as input variable of the neural network, and dissolved oxygen in pond as output variables of the neural network. This paper applied fuzzy neural networks to predict dissolved oxygen in pond. Fuzzy neural network not only possesses the advantages of the fuzzy system and artificial neural network, but also offsets disadvantages caused by their individual modeling. It collects learning, associating, self-adaptive and fuzzy information processing as a whole. On the basis of this, the project selected fuzzy neural network technology as modeling method of prediction for dissolved oxygen in the pond. Fuzzy neural networks have nice approximation ability. However, the training of NNs by conventional back-propagation method, i. e. the BP

收稿日期:2005-11-14

资助项目:国家自然科学基金(30200212);农业部海洋水产增养殖学与生物技术重点开放实验室开放课题(K2004012)

作者简介:郭连喜(1957-),男,辽宁丹东人,副教授,硕士,主要从事渔业信息处理及控制。Tel:0411-84762728, E-mail:glx@dlfu.

edu.cn

NNs, has intrinsic vulnerable weakness in slow convergence and local minima. Thus it becomes one of the research directions in fuzzy neural network to adopt global searching algorithms to optimize the parameters of fuzzy neural network. A great deal of bibliography adopt genetic algorithm to optimize fuzzy neural network. In this research we adopted the easier global optimization algorithm (particle swarm optimization algorithm) to optimize fuzzy neural network. Particle swarm optimization (PSO) is an evolutionary computation technique developed by Kennedy and Eberhart in 1995 and successfully used for nonlinear function optimization and neural network training. It is easy to be achieved and need not adjust lots of parameters and has characteristics of rapid convergence. In this work, PSO algorithm was applied to training of fuzzy neural network and then compared with BP algorithm, showing faster convergence rate. The experimental results show that the proposed method is effective and more accurate than BP-NNs and the real-world application is potential. The method proposed lays foundation for developing intelligent measuring instrument and applying industrialized mariculture.

Key words: dissolved oxygen (DO); fuzzy neural network; particle swarm optimization (PSO); prediction model

溶解氧是渔业水体的一项十分重要的水质指标,溶氧状况对水质和养殖生物的生长均有重要影响^[1]。随着池塘养殖的迅速发展,池塘溶解氧作为养殖水域必控的水环境因子越来越受到重视。目前对池塘溶解氧多数采用定时、定点测量,对溶解氧动态变化的辨识,主要基于养殖管理人员对池塘内养殖生物活动变化的观察来识别的。这种事后控制的方式常常会造成对养殖生物生长发育的不良影响。因此,及时掌握池塘水域溶解氧的动态变化规律,在池塘缺氧之前进行池塘溶解氧的事前预测是水产养殖生产中迫切需要解决的问题。

池塘溶解氧的预测是多变量、非线性、大时滞问题,应用人工神经网络对其进行预测是很好的解决方案。国外有关于应用人工神经网络进行水产养殖预测的研究^[2],国内也有人曾应用神经网络对池塘溶解氧进行预测^[3]。本文应用模糊神经网络对池塘溶解氧进行预测。模糊神经网络具有良好的非线性逼近能力,但用梯度下降法进行优化效率较低,我们引入快速的粒子群优化算法^[4]对模糊神经网络进行优化,能够较好地解决这个问题。该模型为池塘溶解氧的快速预测提供了一种新方法,为我们正在开发研制的智能型水质检测仪及工厂化养殖工作提供了新思路。

1 基于模糊神经网络的池塘溶解氧预测模型

1.1 影响池塘溶解氧的因素分析

影响池塘溶解氧的因素非常复杂,它包括了物理、生物以及化学等多方面原因,主要因素有:池塘水体温度、水体含氮量和空气中氧气组成的分压力等^[1,5-7]。另外,还取决于该池塘中氧气

的来源与消耗、氧气的溶解与溢出速率等。对于某一具体池塘来说,溶解氧与不同季节、测量时间、测量点的位置和深度、风速以及池塘的深度和表面积有关。

由于溶解氧影响因素的复杂性和非线性,很难采用精确的数学模型对其进行定量描述,而人工神经网络这一非线性优化工具以其高度的非线性映射、自组织结构、高度并行处理将影响溶解氧的诸多因素通过一定方式连接起来,对网络进行学习与联想记忆,能很好地实现溶解氧的预测。

上述影响溶解氧的某些因素在一定条件下对某一具体池塘和测量点在分析时可以认为是不变的。我们综合分析并考虑各变量的可测性选取池塘水体温度、亚硝酸盐、氨氮值以及总氮值 4 个变量作为神经网络模型的输入变量,神经网络模型的输出变量为池塘溶解氧。

1.2 模糊神经网络模型

模糊神经网络的结构 模糊系统、人工神经网络技术以及它们相互结合所组成的模糊神经网络(也称神经模糊系统)是近年来计算智能领域研究的重要内容^[8,9]。模糊神经网络不仅继承了模糊系统与人工神经网络各自的优点,也弥补了它们单独建模所固有的不足,集学习、联想、自适应及模糊信息处理于一体,可提高整个系统的学习能力和表达能力;基于此,本课题选择模糊神经网络技术作为池塘溶解氧预测模型的建模方法。

图 1 为采用 4 层神经网络来实现模糊推理的网络结构,这 4 层分别为输入层、隶属度生成层、推理层和输出层。为了表达清晰,在图 1 中,假设模糊系统有 2 个输入变量 x_1 、 x_2 ,一个输出变量 y ,并且每个输入变量在其论域上划分为两个模糊子集。




图 1 模糊神经网络结构

Fig.1 Architecture of fuzzy neural network

令 $X = (x_1, x_2)^T$, $U, y \in V$ 分别表示系统输入和输出,它们分别与模糊规则的前提和结论相对应;则系统中第 j 条规则的形式可表示为:

$$R_j: \text{if } x_1 = X_{1j}, \text{ and } x_2 = X_{2j}, \text{ then } y = Y_j \quad (1)$$

其中, Y_j 为第 j 条规则的结论; $X_{ij} (i = 1, 2)$ 为输入变量的模糊子集,本文采用高斯型函数来描述输入 x_i 满足前提 X_{ij} 的程度,即隶属度

$$\mu_{X_{ij}}(x_i) = \exp\left[-\frac{(x_i - m_{ij})^2}{2\sigma_{ij}^2}\right] \quad (2)$$

其中, m_{ij} 为高斯型函数的均值, σ_{ij} 为标准偏差;所以,输入空间的一个模糊子集完全由参数 m_{ij} 和 σ_{ij} 确定。

模糊推理 对于一个输入 $X = (x_1, x_2)^T \in U$,模糊推理的主要过程如下:

(1) 规则前提对输入 X 适应度的计算

根据模糊理论,规则前提对输入 X 的适应度就是 X 相对于前提模糊子集的隶属度,在本研究第 j 条规则对 X 的适应度可写为:

$$\mu_j = \mu_{X_{1j}}(x_1) \cdot \mu_{X_{2j}}(x_2) = \exp\left[-\sum_{i=1}^2 \frac{(x_i - m_{ij})^2}{2\sigma_{ij}^2}\right] \quad (3)$$

上式的作用相当于输入层与规则层的连接权值。

(2) 模糊决策方法

各条规则对输入 X 的适应度反映了各条规则对最后模糊决策的贡献程度。假设系统中共有 m 条规则,本文采用加权平均法进行去模糊化处理,可得到模糊系统的输出为:

$$y = \frac{\sum_{j=1}^m w_j \mu_j}{\sum_{j=1}^m \mu_j} \quad (4)$$

其中, w_j 为推理层与输出层之间的连接权重。

在该网络模型中,如果已知输入变量数 (N) 及其模糊子集的个数 (Y),则模糊推理层节点数(即规则数) $m = Y^N$,即表示系统最多有 Y^N 条规则。需要确定的参数只有各规则前提隶属度参数 (m_{ij}, σ_{ij}) 以及权重 w_j 。

模糊神经网络的学习算法通常采用梯度下降法,计算量较大,容易陷入局部极小,且学习效率很低,因而采用全局搜索算法优化模糊神经网络的参数就成为模糊神经网络研究的方向之一。大量文献采用遗传算法来优化模糊神经网络。在本课题研究中,我们尝试用一种更为简单的全局优化算法——粒子群优化算法,来优化模糊神经网络。

1.3 粒子群优化算法

美国的 Kennedy 和 Eberhar 受鸟群觅食行为的启发,于 1995 年提出了粒子群优化算法 (particle swarm optimization, PSO)。最初的设想是仿真简单的社会系统,研究并解释复杂的社会行为,后来发现粒子群优化算法可以用于复杂优化问题的求解^[10,11]。

算法采用速度位置搜索模型。假设在一个 D 维的目标搜索空间中,有 m 个粒子组成一个群落,其中第 i 个粒子表示为一个 D 维的向量 $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})$, $i = 1, 2, \dots, m$,即第 i 个粒子在 D 维的搜索空间中的位置是 x_i 。换言之,每个粒子的位置就是一个潜在的解。将 x_i 代入一个目标函数就可以计算出其适应值,根据适应值的大小衡量 x_i 的优劣。第 i 个粒子的速度也是一个 D 维的向量,记为 $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ 。第 i 个粒子迄今为止搜索到的最优位置为 $p_i = (p_{i1}, p_{i2}, \dots, p_{iD})$,整个粒子群迄今为止搜索到的最优位置为 $p_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 。粒子根据以下公式来更新其速度和位置^[11]:

$$\begin{aligned} v_{id} &= v_{id} + c_1 \cdot \text{rand}() \cdot (p_{id} - x_{id}) + c_2 \cdot \text{rand}() \cdot (p_{gd} - x_{id}) \\ x_{id} &= x_{id} + v_{id} \end{aligned} \quad (5)$$

其中, $\text{rand}()$ 是均匀分布在 $(0, 1)$ 区间的随机数。学习因子 c_1, c_2 一般取 $c_1 = c_2 = 2^{[12]}$ 。极值与全局极值进行搜索,直到达到规定的迭代次数或满足规定的误差标准为止。粒子在每一维飞行的速度不能超过算法设定的最大速度 v_{\max} 。设置较大的 v_{\max} 可以保证粒子种群的全局搜索能力, v_{\max} 较小则粒子种群的局部搜索能力加强。 $v_{id} (-$

v_{\max} , $+v_{\max}$), v_{\max} 是常数, 由用户决定。

Shi 和 Eberhart 对最早提出的 PSO 算法进行了惯性权重修正^[13,14], 由于公式(5)中的 v_{id} 具有随机性且其本身缺乏记忆能力, 有扩大搜索空间, 探索新的搜索区域的趋势。因此, 具有全局优化的能力。在考虑实际优化问题时, 往往希望先采用全局搜索, 使搜索空间快速收敛于某一区域, 然后采用局部精细搜索以获得高精度的解。因此, 在公式(5)的 v_{id} 前乘以惯性权重 w , w 为非负数, w 较大算法具有较强的全局搜索能力, w 较小则算法倾向于局部搜索。一般的做法是将 w 初始值为 0.9 并使其随迭代次数的增加线性递减至 0.4, 以达到上述期望的优化目的。改进后的算法表示如下:

$$v_{id} = wv_{id} + c_1 \cdot \text{rand}() \cdot (p_{id} - x_{id}) + c_2 \cdot \text{rand}() \cdot (p_{gd} - x_{id})$$

$$x_{id} = x_{id} + v_{id} \quad (6)$$

迭代中止条件根据具体问题一般选为最大迭代次数或粒子群迄今为止搜索到的最优位置满足预订最小适应阈值。

粒子群优化算法是基于群体智能理论的优化

算法通过群体中粒子间的合作与竞争产生的群体智能指导优化搜索。与进化算法比较, PSO 保留了基于种群的全局搜索策略, 但是其采用的速度-位移模型操作简单, 避免了复杂的遗传操作。它特有的记忆使其可以动态跟踪当前的搜索情况调整其搜索策略。与进化算法比较, 粒子群优化算法是一种更高效的并行搜索算法。

2 预测模型的检验与分析

以大连地区某养殖池塘为研究对象, 因为池塘溶解氧与季节有关, 我们搜集了该池塘近 3 年同一季节的接近 300 组数据, 根据实际情况选取了 260 组覆盖面较大的数据作为建模数据。我们取 240 组数据训练网络, 另 20 组数据对网络模型检验。网络模型的输入变量 (x_1, x_2, x_3, x_4) 为温度、亚硝酸盐、氨氮值以及总氮值 4 个变量, 网络模型的输出变量 (y) 为池塘溶解氧。每个输入变量分为 3 个模糊子集, 模糊子集的隶属度函数参数是随机产生的。首先进行模型输入、输出项的预处理, 然后用这些数据对网络进行训练, 得出网络模型, 再用 20 组数据进行模型的测试, 测试样本数据及模型计算值如表 1 所示。

表 1 测试样本及模型输出值

Tab. 1 Testing samples and the predicted values

| 样本号 no. | 温度() temperature | 总氮(mg L ⁻¹) total nitrogen | 亚硝酸盐(mg L ⁻¹) NO ₂ -N | 氨氮(mg L ⁻¹) NH ₄ ⁺ -N | 溶解氧(mg L ⁻¹) DO | 模型计算溶解氧(mg L ⁻¹) DO |
|------------|----------------------|---|---|--|--------------------------------|------------------------------------|
| 1 | 19.3 | 0.090 | 0.023 | 0.067 | 6.35 | 6.30 |
| 2 | 19.2 | 0.107 | 0.023 | 0.084 | 5.60 | 5.70 |
| 3 | 19.8 | 0.084 | 0.008 | 0.076 | 6.15 | 6.30 |
| 4 | 19.6 | 0.080 | 0.009 | 0.071 | 5.90 | 5.60 |
| 5 | 19.0 | 0.105 | 0.041 | 0.064 | 5.80 | 5.02 |
| 6 | 18.5 | 0.111 | 0.035 | 0.076 | 5.00 | 5.40 |
| 7 | 19.0 | 0.137 | 0.043 | 0.094 | 5.35 | 4.98 |
| 8 | 18.8 | 0.126 | 0.034 | 0.092 | 5.22 | 5.47 |
| 9 | 18.6 | 0.136 | 0.024 | 0.112 | 6.35 | 6.08 |
| 10 | 18.0 | 0.074 | 0.016 | 0.058 | 5.15 | 5.14 |
| 11 | 19.0 | 0.091 | 0.020 | 0.071 | 6.90 | 6.39 |
| 12 | 18.5 | 0.110 | 0.028 | 0.082 | 5.65 | 5.72 |
| 13 | 19.2 | 0.143 | 0.028 | 0.115 | 5.95 | 5.65 |
| 14 | 17.9 | 0.058 | 0.008 | 0.050 | 5.25 | 5.00 |
| 15 | 18.4 | 0.113 | 0.026 | 0.087 | 5.80 | 6.03 |
| 16 | 18.6 | 0.070 | 0.014 | 0.056 | 5.15 | 5.24 |
| 17 | 18.4 | 0.084 | 0.012 | 0.072 | 6.08 | 6.19 |
| 18 | 18.6 | 0.112 | 0.040 | 0.072 | 6.23 | 6.25 |
| 19 | 19.3 | 0.086 | 0.009 | 0.077 | 6.00 | 5.90 |
| 20 | 19.5 | 0.115 | 0.036 | 0.079 | 6.34 | 6.37 |

根据表 1 测试结果比较表明,进行测试的 20 组数据中,预测溶解氧与实际测量溶解氧之差在 $|\Delta| < 0.3 \text{ mg} \cdot \text{L}^{-1}$ 之内的为 17 组,占 85%;预报溶解氧与实际测量溶解氧之差在 $|\Delta| < 0.5 \text{ mg} \cdot \text{L}^{-1}$ 之内的为 18 组,占 90%,大于 $0.5 \text{ mg} \cdot \text{L}^{-1}$ 的仅有 2 组,最大误差为 $0.78 \text{ mg} \cdot \text{L}^{-1}$ 。

本文所采用的训练样本和测试样本的均方根误差 (RSME) 分别为 0.2881 和 0.2879,训练样本和测试样本的平均绝对百分误差 (MAPE) 分别为 3.814% 和 3.806%。这些指标表明,经上述样本训练后得到的神经网络模型不仅对训练样本具有较好的拟合能力,而且对测试样本也具有很高的拟合能力,说明该神经网络的泛化能力很强。由此可见本文运用模糊神经网络预测池塘溶解氧的方法是可行的,所建立的模型具有较高的预测精度,能够取得良好的效果。

3 结束语

溶解氧是海水池塘养殖非常关键的一个参数,能够精确地预报池塘溶解氧,对水产养殖具有重要意义。本文在分析溶解氧影响因素的复杂性和非线性的基础上,利用 PSO 算法建立神经网络预测模型,较文献[3]所采用的 BP 递推算法的预测精度明显提高,MAPE 由 5.5% 降至 3.806%。建模研究结果表明,所采用的模型能对溶解氧进行可靠的预测,该方法为本课题组正在研制开发的智能水质检测仪以及工厂化养殖工作奠定了基础,对实际生产具有一定的指导意义。

参考文献:

- [1] 雷衍之. 养殖水环境化学 [M]. 北京:中国农业出版社, 2004. 63 - 89.
- [2] 楼文高. 神经网络在水产科学中的应用 [J]. 上海水产大学学报, 2001, 10 (4): 347 - 352.
- [3] 王红英, 樊增绪, 薛松堂. 一种新的池塘溶解氧预测模型 [J]. 农业工程学报, 1997, 12 (4): 145 - 147.
- [4] Eberhart R C, Shi Y. Particle swarm optimization: developments, applications and resources [A]. Proceedings of the IEEE Congress on Evolutionary Computation [C]. Piscataway, NJ: IEEE Service Center, 2001, 81 - 86.
- [5] 徐宁, 李德尚, 董双林. 海水养殖池塘溶解氧平衡的实验研究 [J]. 中国水产科学, 1996, 6 (1): 69 - 74.
- [6] 臧维玲, 戴习林, 朱正国, 等. 中国对虾池溶解氧的收支平衡状态 [J]. 海洋通报, 1995, 17 (4): 137 - 141.
- [7] 方志山, 杨圣云, 许振祖. 杏林虾池综合养殖系统主要环境因子的变化 [J]. 台湾海峡, 2001, 20 (4): 496 - 501.
- [8] 王振雷. 模糊神经网络理论及其在复杂系统中的应用研究 [D]. 辽宁: 东北大学学位论文, 2002.
- [9] Jang J, Sun C. Neuro fuzzy modeling and control [J]. Proceedings of the IEEE, 1995.
- [10] Kennedy J. The particle swarm: social adaptation of knowledge [A]. Proceedings of IEEE International Conference on Evolutionary Computation [C], Indianapolis, Indiana, 1997.
- [11] Eberhart R C, Kennedy J. A new optimizer using particle swarm theory [A]. Proceedings of Sixth International Symposium Micro Machine and Human Science [C], Nagoya, Japan, 1995.
- [12] Shi Y H, Eberhart R C. Parameter selection in particle swarm optimization [A]. Annual, Conference on Evolutionary Programming [C], San Diego, March 1998.
- [13] Shi Y H, Eberhart R C. A modified particle swarm optimizer [A]. IEEE International Conference on Evolutionary Computation [R], Anchorage, Alaska, 1998.
- [14] Shi Y H, Eberhart R C. Empirical study of particle swarm optimization [A]. Proceedings of the IEEE Congress on Evolutionary Computation [R], 1999.