

基于 BP 人工神经网络的生化处理水水质预测

RI Son-il^{1,3}, 侯德刚², 张振家¹, 周伟丽¹, 迟莉娜¹, CHOE Won-il³

(1. 上海交通大学环境科学与工程学院, 上海 200240; 2. 吉林燃料乙醇有限公司, 吉林 吉林 132101; 3. 咸兴化工大学机械工程系, 朝鲜 咸兴)

摘要:神经网络具有强大的非线性映射能力和并行处理能力,近年来在水处理领域中被广泛地应用。利用神经网络算法对某污水处理厂的污水处理系统进行了出水水质预测。结果表明,基于 BP 神经网络的水质预测模型拟合效果较好,模拟出来的化学需氧量(COD)、pH、固体悬浮物(SS)及生物需氧量(BOD)的数值范围均较接近于实际值,其平均相对标准差分别为 6.96%、1.31%、12.09%、15.18%。

关键词:神经网络;生化处理;水质;预测

中图分类号:TQ028.8

文献标识码:A

文章编号:0253-4320(2009)12-0066-03

Prediction of water quality in biological wastewater treatment plant using BP artificial neural network

RI Son-il^{1,3}, HOU De-gang², ZHANG Zhen-jia¹, ZHOU Wei-li¹, CHI Li-na¹, CHOE Won-il³

(1. School of Environmental Science and Engineering, Shanghai Jiaotong University, Shanghai 200240, China;

2. Jilin Fuel Alcohol Company Ltd., Jilin 132101, China;

3. Department of Mechanical Engineering, HamHung Chemical University, HamHung, D.P.R. Korea)

Abstract: Artificial Neural Networks (ANN) are widely used in the field of wastewater treatment because of its strong nonlinear mapping and parallel processing ability. The effluent stream quality is predicted at a wastewater treatment plant by using BP ANN model in this paper. The results indicate that the BP ANN model provides the satisfactory fitting effects for the following four variables, in terms of chemical oxygen demand (COD), pH value, suspended solids (SS) and biological oxygen demand (BOD). The simulative results of COD, pH, SS and BOD are very close to the detected values; the average relative standard variation (RSD) are 6.96%, 1.31%, 12.09% and 15.18%, respectively.

Key words: artificial neural network; biochemical treatment; water quality; predict

随着工业的发展、水资源的缺乏、环保及节能的需求,污水循环利用已经变得日益引人注目。污水处理过程的特点是多变量、非线性、时变性与随机性,故建立精确的数学模型比较困难。同时,污水处理系统的控制又属于多目标控制,需要控制几种出水指标,也需要抑制外部环境的变化^[1]。人工神经网络(ANN)的最大优点是可以充分逼近任意复杂的非线性关系,有较强的学习能力和容错性,同时能够处理定量、定性数据,能够利用连接的结构与其他控制方法及人工智能相结合,已成为污水处理过程的研究热点^[1]。

本文旨在采用人工神经网络的 BP 模型对某污水处理厂的污水处理系统进行模拟,以便对出水水质评价提供理论依据。

1 神经网络在水处理中的应用

神经网络方法是建立在现代神经科学研究

成果基础上的一种抽象的数学模型,它反映了大脑功能的若干基本特征,如抽象和模拟。使机器具有人脑那样的感知、学习和推理能力,能够更好地适应环境和系统特性的变化,适合于复杂系统的建模和控制。它具有大规模并行、分布式存储与处理、自组织、自适应与自学习的能力,特别适用于处理需要同时考虑许多因素和条件的、不精确的和模糊的信息处理问题。这使得它在模式识别、控制优化、智能信息处理以及故障诊断等方面都有广泛的应用^[2-3]。

近年来,神经网络在水资源系统、饮用水及污水处理系统、环境治理系统等水处理系统中广泛应用,主要应用于臭氧生物活性炭系统的建模^[4];微滤、纳滤、超滤等膜分离工艺中膜通量、截留率及膜污染预测^[5-9];废水处理中出水水质评价^[10-13]、污水中的金、钡等重金属含量测定预测等领域^[14]。Domier^[15]、Delgrange 等^[16]用神经网络成功预测了膜过滤市政饮用水的膜污染情况。田禹等^[4]利用 BP

人工神经网络模拟了臭氧生物活性炭系统中臭氧投量与进水 COD_{Mn} 、出水 COD_{Mn} 之间的关系,得到了仿真曲线^[1]。

由于在生化水处理中影响因子的复杂性以及各因子之间相互交叉,应用经典的数学模型算法难以精确描述出水水质。而神经网络方法以自身的优势弥补了经典数学模型的不足,有望使水处理控制研究取得突破性进展。

2 BP 人工神经网络模型^[4-5]

BP 人工神经网络通常是指基于误差反向传播算法的多层前向神经网络。BP 网络在某些方面显示出独特的优越性和广泛的推广性,已成为日前研究应用最为广泛的神经网络学习算法,据统计近 90% 的神经网络应用是基于 BP 网络算法的。与感知器和线性神经网络等其他网络不同的是, BP 网络的神经元采用的传递函数通常是 Sigmoid 型可微函数,所以可以实现输入和输出间的任意非线性映射,这使得它在诸如函数逼近、模式识别、数据压缩等领域有着更加广泛的应用。

Matlab 软件提供的 BP 神经元模型中的传递函数通常取如对数 Sigmoid 函数 logsig 、正切 Sigmoid 函数 tansig 和线性函数 purelin 等可微的单调递增函数。

对数 Sigmoid 函数:

$$f(x) = 1/(1 + e^{-x}) \quad (1)$$

正切 Sigmoid 函数:

$$f(x) = \tanh(x) \quad (2)$$

线性函数:

$$f(x) = kx \quad (3)$$

BP 人工神经网络模型的最后 1 层神经元采用 Sigmoid 型函数时,整个网络的输出就被限制在 1 个较小的范围内;如果最后 1 层神经元采用 purelin 型函数,则整个网络输出可以取任意值。BP 网络具有 1 个或多个隐层,其中,隐层神经元一般采用 Sigmoid 型传递函数,而输出层神经元则采用 purelin 型传递函数。当隐层神经元数目足够多时, BP 神经网络可以以任意精度逼近任何 1 个具有有限间断点的非线性函数。

BP 神经网络的训练性能函数采用均方误差函数 mse ,即

$$f(x) = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (x_i - a_i)^2 \quad (4)$$

采用 BP 神经网络时需要尺度标准化,其是指通

过变换处理将网络的输入、输出数据限制在 $[0, 1]$ 或 $[-1, 1]$ 区间内。进行尺度变换的主要原因是网络的各个输入数据常常具有不同的物理意义和不同的量纲,从而使网络训练一开始就给各输入分量以同等重要的地位。常用以下的归一化式。

数据变换区间为 $[0, 1]$:

$$x_i = (x_i - x_{\min}) / (x_{\max} - x_{\min}) \quad (5)$$

数据变换区间为 $[-1, 1]$:

$$x_i = (x_i - x_{\text{mid}}) / [1/2(x_{\max} - x_{\min})] \quad (6)$$

$$x_{\text{mid}} = (x_{\max} + x_{\min}) / 2 \quad (7)$$

式(5)~(7)中, x_i 为输入或输出数据, x_{\max} 为数据变化范围内的最大值, x_{\min} 为数据变化范围内的最小值。

3 生化水处理系统的水质预测

某污水处理厂的水处理工艺中生化处理部分的工艺流程图如图 1 所示。




图 1 生化处理流程图

在生化处理系统中,生化池和中和池 2 个水处理过程的操作参数均影响到出水水质,因此,为了使出水水质达标,需要从目标值反向控制投药量和运行参数。在这种控制过程中,系统的影响因子之间的关系无法用精确简短的数学模型来表达。下面将整个流程看成“黑箱”,利用神经网络算法来表示进出水水质之间的关系。针对上述的生化处理系统建模的 BP 神经网络结构如图 2 所示。




图 2 神经网络的层结构

由图 2 可以看出,输入层的神经元以进水和生化池的向量 COD_{in} 、 pH_{in} 、 SS_{in} 、 BOD_{in} 、 $MLSS_{bio}$ 、污泥回流比、总气水比组成,输出层的神经元由出水的向量 COD_{out} 、 pH_{out} 、 SS_{out} 、 BOD_{out} 组成。首先,在工程运行 1 年的测试数据中分别选取前 50 天的不同数据组成 ANN 的训练样本,利用归一化式(5)将输入数据进行标准化,运用 Matlab 软件提供的 BP 神经网络


算法进行训练。其次,测试数据中分别选取中间 20 天的不同数据作为检验样本,并进行检验样本的模拟值与实验值比较后,误差函数值小于设定的误差时,停止计算。最后,利用 BP 网络建立的水质预测模型模拟了 45 天的出水水质指标 COD_{out} 、 pH_{out} 、 SS_{out} 及 BOD_{out} , 并进行模拟值与实验值的比较。

以上述的模型和样本,分别利用神经网络中的几种训练函数进行反复训练后,分析了其精度(表 1)。由表 1 可见,在几种算法中,trainscg 训练函数的误差较小, COD_{out} 、 pH_{out} 、 SS_{out} 及 BOD_{out} 的平均相对标准差分别为 6.96%、1.31%、12.09%、15.18%。

表 1 几种训练函数的平均相对标准差 %


RSD	traingbr	trainlm	trainrp	traingf	traingb	trainscg	traingp	trainbf
RSD_{COD}	5.62	5.11	8.82	13.46	8.02	6.96	9.96	11.18
RSD_{pH}	0.88	1.82	1.15	1.12	1.10	1.31	1.12	1.28
RSD_{SS}	11.14	17.20	15.22	20.55	18.81	12.09	23.49	11.27
RSD_{BOD}	17.95	14.46	16.98	18.66	19.85	15.18	20.65	16.59

利用训练函数 traingscg 计算的 COD_{out} 、 pH_{out} 、 SS_{out} 及 BOD_{out} 的模拟值与实验值的比较见图 3、图 4。



1— COD_{in} ; 2— SS_{in} ; 3— BOD_{in}
 实验值: □— COD_{out} ; ○— SS_{out} ; △— BOD_{out}
 模拟值: ■— COD_{out} ; ●— SS_{out} ; ▲— BOD_{out}


图 3 COD, SS, BOD 质量浓度的比较



实验值: 1— pH_{in} ; 2— pH_{out}
 模拟值: 3— pH_{out}


图 4 pH 的比较

由图 3、图 4 可见,拟合效果较好,模拟的 4 个变量的数值范围均较接近于实际值,这说明 BP 神经网络算法较好地反映水质评价的实际情况。其次,在进水和生化池的同样的指标中,从可能的最大、最小值范围内选取任意 115 个随机值为样本,利用上述模型对出水水质进行预测。样本的范围分别为 $COD_{in} = 1\ 567 \sim 1\ 992\ mg/L$ 、 $pH_{in} = 9 \sim 13$ 、 $SS_{in} = 313 \sim 977\ mg/L$ 、 $BOD_{in} = 411 \sim 723\ mg/L$ 、 $MLSS_{bio} = 1.9 \sim 4.7\ g/L$ 、生化池的污泥回流比为 90.0% ~ 99.9% 及总气/水比为 12.0% ~ 13.3%。预测的结果如图 5、图 6 所示。



1— COD_{in} ; 2— SS_{in} ; 3— BOD_{in} ; 4— COD_{out} ; 5— SS_{out} ; 6— BOD_{out}

图 5 COD, SS, BOD 质量浓度的预测



1— pH_{in} ; 2— pH_{out}

图 6 pH 的预测

由图 5、图 6 可见,出水的平均水质指标分别为 $COD_{out} = 205.86\ mg/L$ 、 $pH_{out} = 7.97$ 、 $SS_{out} = 59.48\ mg/L$ 、 $BOD_{out} = 11.47\ mg/L$, 均处于实际运行值范围内。这表明,上述的模型能够预测沉淀出水水质。如利用上述的 BP 模型的预测值来反向控制系统的操作,则能够在一定程度上弥补水质超标的现象。

4 结语

人工神经网络能很好地应对污水处理系统之类的多变量、非线性、时变性与随机性高,对建立精确的数学模型比较困难的模糊过程进行建模,并且

(下转第 70 页)




图 1 多级雾化平面丝网超重力旋转床

作用下被高度分散、雾化。则含尘气体在运动中,在颗粒间相互碰撞和呈膜状的液体捕获以及丝网对固体颗粒的过滤作用下,尘粒团聚而变成质量更大的颗粒或被液滴捕获并粘在一起,这样在离心力的作用下,这些颗粒就会被甩向器壁而除去。


2 实验部分

2.1 实验装置

旋转床的主体结构由不锈钢钢管和厚度为 3 mm 的不锈钢板焊接而成,5 层平面支撑结构焊在钢管上,每层平面由 $\phi 5$ mm 的钢筋支撑。转子中央钢管直径 60 mm,钢管上开有等间距的 8 条宽度为 1.5 mm 的缝;丝网材料为不锈钢,丝网孔间距 1.5 mm,厚度 0.7 mm;2 层轴向丝网位置: $\phi = 64$ mm 和

$\phi = 140$ mm;以除雾器平面为基准向下为正,3 层平面丝网高度分别为: $H_1 = 0$ mm, $H_2 = 100$ mm, $H_3 = 200$ mm。

实验流程图如图 2 所示。



1—加粉机;2—风机;3—补偿式压差计;4—U 型压差计;
5—超重力平面丝网旋转床;6—转子流量计;7—水泵;8—水箱;
9—粉尘采样分析仪;10,11—变频器;12—加粉调速仪

图 2 超重力旋转床实验流程图

该实验选择 2 000 目左右的滑石粉模拟工业粉尘,其峰值粒径为 $4.73 \mu\text{m}$ 。气体流量用笛型管和微压差计测量。液体流量由转子流量计计量。旋转床进出口压力降用 U 型管压差计测量。粉尘用型号为 TH-880 的微电脑烟尘平行采样仪采集。

2.2 实验方法

粉尘经烘箱烘干后由小型螺杆挤出到风机的

(上接第 68 页)

能够以很高的精度对系统运行进行预测。这对于实际应用具有较大意义,使得污水处理系统过程有可能实现水质早期预报并反向自动控制以得到理想的目标值。

参考文献

- [1] 黄明智,马懿文,万金泉,等.污水处理中人工神经网络应用研究的探讨[J].环境科学与技术,2008,31(3):131-135.
- [2] 葛哲学,孙志强.神经网络理论与 MATLAB 2007 实现[M].北京:电子工业出版社,2007.
- [3] 许东,吴铮.基于 MATLAB6.X 的系统分析与设计:神经网络[M].2 版.西安:西安电子科技大学出版社,2002:166-238.
- [4] 田禹,王宝贞,周定.人工神经网络对水处理系统建模适应性的研究[J].环境科学学报,1999,19(1):33-36.
- [5] 叶晓,黄小蕊,俞军,等.基于 BP 神经网络建立姬松茸多糖超滤分离模型[J].化学研究与应用,2006,18(9):1120-1123.
- [6] 石宝强,张捍民,杨凤林,等.人工神经网络在膜生物反应器膜污染预测中的应用前景[J].工业水处理,2006,26(12):14-17.
- [7] 孟凡刚,张捍民,李艳松,等.膜生物反应器膜污染数学模型研究进展[J].水处理技术,2005,31(10):1-4.
- [8] 徐茵,李建明,陈文梅.理论研究方法在膜超(微)滤研究中的应

用[J].膜科学与技术,2004,24(2):68-73.

- [9] Grishma R S, Shankaraman C. Predicting membrane fouling during municipal drinking water nanofiltration using artificial neural networks[J]. J Membr Sci, 2003, 217: 69-86.
- [10] 胡志华,万金泉,马懿文,等.基于 ANN 的造纸废水处理智能控制系统研究[J].环境科学与技术,2007,30(3):58-63.
- [11] Mjalli F S, Al-Ashehl S, Alfadala H E. Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance[J]. J Environ Manag, 2007, 83: 329-338.
- [12] Hanbay D, Turkoglu I, Demir Y. Prediction of wastewater treatment plant performance based on wavelet packet decomposition and neural networks[J]. Expert Systems with Applications, 2008, 34: 1038-1043.
- [13] Oliveira-Esquerre K P, Seborg D E, Bruns R E, et al. Application of steady-state and dynamic modeling for the prediction of the BOD of an aerated lagoon at a pulp and paper mill: Part I. Linear approaches[J]. Chem Eng J, 2004, 104: 73-81.
- [14] 郑静,曾嘉,林开利,等.人工神经网络-分光光度法同时测定废水中的金和钡[J].分析实验室,2006,25(12):19-22.
- [15] Dornier M, Decloux M, Trystram G, et al. Dynamic modeling of cross-flow microfiltration using neural networks[J]. J Membr Sci, 1995, 98: 263-273.
- [16] Delgrange N, Cabassud C, Durand-Bourlier L, et al. Neural networks for prediction of ultrafiltration transmembrane pressure-application to drinking water production[J]. J Membr Sci, 1998, 150: 111-123. ■