

文章编号:1000-582X(2012)08-072-08

污水处理过程的 QSOM 出水水质预报

李鹏华^a, 柴毅^a, 熊庆宇^a, 柴华^b

(重庆大学 a. 自动化学院; b. 城市建设与环境工程学院, 重庆 400000)

摘要:针对活性污泥污水处理过程中微生物活动的不确定性、生化反应的复杂性及工艺参数的强耦合和大滞后等特性,提出一种量子自组织特征映射神经网络(QSOM)方法来进行出水水质预报。该方法将出水水质在异常情况下所对应的进水数据样本转换成量子态形式提交给网络输入层,通过计算量子输入与相应权值的相关系数作为网络的最佳输入匹配,学习规则中采用量子门更新网络权值。最后通过某污水处理厂生化处理过程中的实际运行数据的实验表明所提预报方法是有效的。

关键词:量子自组织特征映射神经网络;量子神经元;污水处理;水质预报

中图分类号:TP273

文献标志码:A

Prognoses of inlet water quality via QSOM in wastewater treatment processes

LI Penghua^a, CHAI Yi^a, XIONG Qingyu^a, CHAI Hua^b

(a. College of Automation; b. College of Urban Construction and Environmental Engineering, Chongqing University, Chongqing 400000, P. R. China)

Abstract: A quantum self-organizing feature map neural network (QSOM) method is introduced for water quality prediction in activated sludge wastewater treatment processes which includes uncertainty of microbial activity and complexity of biochemical reactions and strong lagging of parameters. This approach quantizes the inlet water quality data corresponding outlet water in abnormal state and makes the quantized data sample as the input of QSOM. The correlation coefficient of the quantum inputs and its weights are calculated as the best inputs matching of network by using quantum gates to update the weights in learning the rules. The experiments illustrate the efficiency of this prediction approach by using operational data of Chongqing Jiguanshi wastewater treatment plant.

Key words: quantum self-organizing feature map neural network; quantum neuron; wastewater treatment; water quality prediction

作为国内大多数污水处理厂所通用一种污水处理方法,活性污泥工艺是通过活性污泥在污水中的凝聚、吸附、氧化、分解和沉淀等作用以去除其中的有机污染物。由于微生物活动的未知性、生化反应的复杂性及工艺参数的时变性,通过对工艺流程建

立精确的机理模型来分析和预报关键水质指标是比较困难的。例如国际水协会(IWA)所提出的ASM(activated sludge model)活性污泥系列模型因其参数众多并不利于模型的准确辨识^[1],难于对关键水质指标进行有效的实时控制。污水处理系统所具有

收稿日期:2012-03-12

基金项目:国家自然科学基金资助项目(60974090);教育部博士点基金资助项目(200806110021);中央高校基本科研业务费资助项目(CDJXS10170005)

作者简介:李鹏华(1984-),男,重庆大学博士生,主要从事量子神经网络的研究,(Tel)023-65106464;(E-mail)lipenghua@cqu.edu.cn.

的不稳定性和不确定性以及对几种出水指标的控制属于多目标控制^[2],而人工神经网络(ANN)具有任意逼近非线性关系和很强的自学习、自适应能力,可将其引入到污水处理邻域,实现相关水质指标的分析 and 预报。

鉴于污水处理流程中由进水到出水大致需要 24 h 的停留,因此通过进水指标对出水指标进行预报属于长时预报,只需对出水指标在异常情况下所对应的进水指标进行分类评价,即可实现对出水指标的预报。由 Kohonen 提出的自组织特征映射(self-organizing feature map, SOM)网络是一种非监督的、竞争学习的聚类网络,能够学习未知的外界环境特征并将其自动聚类^[3]。相比于 BP 神经网络^[4-7]等方法,其更适用于对污水处理系统进行分析 and 预报^[8-9]。然而,P-SOM 依然存在着跟其他神经网络类似的缺陷^[10-12],通过将量子计算(quantum computing)引入到 ANN 中而产生的量子神经网络(quantum neural networks, QNN),在结合二者优势的基础上克服了 ANN 的内在缺陷^[13-15],并在分类方面要明显优于常规 ANN^[16-18]。

为此,提出一种量子自组织特征映射神经网络方法来进行出水水质预报。通过建立量子神经元及量子自组织特征映射神经网络模型,在给出相应学习规则的基础上,分别采用基于 PCA 的 SOM^[9]和基于有监督和无监督相结合的 QSOM^[18]以及所提的 QSOM 对重庆市某污水处理厂的 actual 生产报表进行数据实验来证明算法的有效性。

1 量子 SOM 网络

量子自组织特征映射神经网络的核心思想就是先量子化 SOM 的网络输入,然后将普通的 SOM 神经元替换为量子神经元以完成相应的自组织拓扑映射,最后调整相应的学习规则,采用量子门更新量子神经元的权值。QSOM 的自组织映射结构及量子神经元的拓扑结构如图 1 所示。其中 $\frac{\pi}{2}U$ 用于产生控制量子比特的相位; $2\pi f_{bs}(\sigma)$ 代表神经元内部状态的相位, σ 是相位的调节参数; \hat{F} 为求模算符,用于将量子神经元的输入映射为实数。

1.1 网络输入的量子化描述

图 1 中以实向量表示的网络输入 $\mathbf{X}=[x_1, x_2 \dots x_n]^T$ 可通过如下定义实现量子化

$$|\mathbf{X}_i\rangle = [|\mathbf{X}_i\rangle, |\mathbf{X}_i\rangle \dots |\mathbf{X}_i\rangle]^T, \quad (1)$$

对于第 $i(i=1, 2 \dots n)$ 个量子输入 $|\mathbf{X}_i\rangle$ 可表示为

$$|\mathbf{X}_i\rangle = \cos[2\pi f_{bs}(x_i)]|\mathbf{X}_i\rangle + \sin[2\pi f_{bs}(x_i)]|\mathbf{X}_i\rangle$$

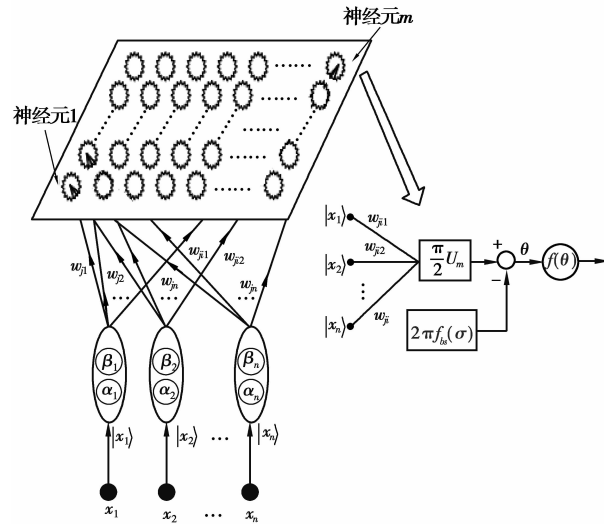


图 1 QSOM 及其量子神经元拓扑结构

$$= [\alpha_i, \beta_i]^T, \quad (2)$$

此处, $f_{bs}(x_i) = \frac{1}{(1 + e^{-x_i})}$, $\alpha_i = \cos[2\pi f_{bs}(x_i)]$, $\beta_i = \sin[2\pi f_{bs}(x_i)]$ 。

1.2 学习规则

二维输出阵列中与第 $j(j=1, 2 \dots m)$ 个神经元相连的网络突触权值为

$$\mathbf{W}_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T, \quad (3)$$

这里, w_{ji} 为一个 2×2 的矩阵, 即 $w_{ji} = \begin{bmatrix} w_{ji1} & w_{ji2} \\ w_{ji3} & w_{ji4} \end{bmatrix}$,

而 w_{ji} 作用于 $|\mathbf{X}_i\rangle$ 可表示为

$$w_{ji} |\mathbf{X}_i\rangle = \begin{bmatrix} w_{ji1} & w_{ji2} \\ w_{ji3} & w_{ji4} \end{bmatrix} \begin{bmatrix} \alpha_i \\ \beta_i \end{bmatrix} = \begin{bmatrix} w_{ji1}\alpha_i + w_{ji2}\beta_i \\ w_{ji3}\alpha_i + w_{ji4}\beta_i \end{bmatrix}. \quad (4)$$

则可定义网络输入 $|\mathbf{X}_i\rangle$ 与其在竞争层中所对应神经元 j 相连接的权值 w_{ji} 的相似系数为

$$\rho_{i,j} = \frac{\|w_{ji} |\mathbf{X}_i\rangle\|_2}{\|w_{ji}\|_2 \| |\mathbf{X}_i\rangle \|_2}, \quad (5)$$

其中,

$$\|w_{ji} |\mathbf{X}_i\rangle\|_2 = \sqrt{|w_{ji1}\alpha_i + w_{ji2}\beta_i|^2 + |w_{ji3}\alpha_i + w_{ji4}\beta_i|^2}, \quad (6)$$

$$\| |\mathbf{X}_i\rangle \|_2 = \sqrt{[x_i | \mathbf{X}_i]}, \quad (7)$$

$$\|w_{ji}\|_2 = \sqrt{\lambda_{\max}}, \quad (8)$$

此处, λ_{\max} 为 $w_{ji}^+ w_{ji}$ 的最大特征值。则输入向量 $|\mathbf{X}_i\rangle$ 与突触权值 w_{ji} 的最佳匹配可由式(9)确定

$$q(|\mathbf{X}_i\rangle) = \max_{\substack{i \in \{1, 2, \dots, n\} \\ j \in \{1, 2, \dots, m\}}} \{\rho_{i,j}\}, \quad (9)$$

其中, $q(|\mathbf{X}_i\rangle)$ 为输出神经元阵列的索引, 特别指定

为获胜神经元,它可以用量子 Grover^[19-20]算法查询出。由此,可以得到 QSOM 的学习规则为

$$\mathbf{W}_j(k+1) = \begin{cases} [U_{j1}w_{j1}, U_{j2}w_{j2}, \dots, U_{jn}w_{jn}]^T, & j \in N_q(k), \\ \mathbf{W}_j(k), & j \notin N_q(k), \end{cases} \quad (10)$$

这里

$$U_{ji} = \begin{bmatrix} \cos \theta_{ji} & -\sin \theta_{ji} \\ \sin \theta_{ji} & \cos \theta_{ji} \end{bmatrix}, \quad (11)$$

$$\theta_{ji} = -f_{bs}(\det(A)) \arccos(\rho_{i,j}), \quad (12)$$

$$A = \begin{bmatrix} \alpha_{w_{j1}} & \alpha_{w_{j2}} \\ \beta_{w_{j3}} & \beta_{w_{j4}} \end{bmatrix}, \quad (13)$$

$\alpha_{w_{ji}}$ 与 $\beta_{w_{ji}}$ 代表 w_{ji} 中元素所对应概率幅值, $N_q(k)$ 代表以获胜神经元 q 为中心, 以 $R_{j,q} = r_0 \exp\left(-\frac{\|r_j - r_q\|^2}{\sigma^2(k)}\right)$ 为选定半径的邻域集合, r_j 和 r_q 分别代表神经元 j 和 q 的坐标。根据式(10)中的学习规则, 可将与获胜神经元相关的权值 \mathbf{W}_q 拖向 $|\mathbf{X}_i\rangle$, 同时也把那些最接近单元的 \mathbf{W}_j 随 \mathbf{W}_q 一起拖动。

2 数值实验

为验证所提算法的有效性, 下面分别采用基于 PCA 的 SOM 和基于有监督和无监督相结合的 QSOM 以及所提的 QSOM 进行数据实验, 并从网络参数、训练时间、分类正确率及预报正确率等方面进行了比较。

2.1 数据介绍

实验所用数据来源于重庆市某污水处理厂 2006 年 6 月至 2007 年 6 月间的生产报表, 将其中的出水水质在异常情况下所对应的 45 组进水数据和出水水质在正常情况下所对应的 3 组进水数据作为训练样本(如图 3 所示), 并从生产报表中另选 5 组进水数据作为测试样本, 以期实现对出水水质的预报。水质评价指标为: 混合液悬浮固体浓度(mixed liquor suspended solids, MLSS)、污泥容积指数(sludge volume index, SVI)、化学需氧量(chemical oxygen demand, COD)、悬浮固体浓度(suspend solid, SS)、总氮(total nitrogen, TN)、总磷(total phosphorus, TP)以及水温 T 和水质酸碱度 PH。

图 2 中的 x 坐标为样本数; y 坐标为水质评价指标种类, 其中 $y_1 \sim y_8$ 依次为: PH、COD(mg/L)、 $T(^{\circ}\text{C})$ 、SS(mg/L)、TP(mg/L)、TN(mg/L)、MLSS(mg/L)、SVI(mL/g); z 坐标为各个指标的数值。关于水质异常种类与样本之间的对应关系如表 1 所示。




图 2 出水水质异常所对应的进水数据

2.2 基于 PCA 的 SOM 的水质预报

1) 网络训练

根据文献 9 中所述步骤, 完成训练后的 P-SOM 临近神经元之间的距离以及神经元分类结果如图 3~5 所示。




图 3 P-SOM 的临近神经元距离




图 4 P-SOM 的各个神经元分类




图 5 P-SOM 的激活神经元分布

在图 3 中,蓝色的六角形代表神经元,红线为各神经元之间的连接线,而包含红线的菱形表示各神经元之间距离的远近,从黄色到黑色,随着颜色加深距离越远。从图中可看出竞争层含有 16 个神经元,

各个神经元彼此相互连接,其中每一个神经元代表出水水质的异常,除 1~3,6~10 号神经元的距离较近之外,其余神经元都彼此隔离(神经元编号从左下角开始(0,0)为 1 号神经元右下角(0,3)为 4 号神经元,第 2 行第 4 列(1,3.5)为 5 号神经元,第 3 行第 1 列(1.75,0)为 6 号神经元,依次类推,右上角(2.5,3.5)为 16 号神经元)。图 4 显示了训练数据与各个神经元的匹配情况,从该图可看出输入数据的总体分布较均匀,每个神经元都有数据输入,即每个神经元都得到了训练。其中上半部和右下部输入的数据较多,而图 3 所示的这部分神经元又都是彼此隔离的,因此,P-SOM 网络训练是成功的。图 5 是图 4 在数据输入维度中的补充解释,它显示了各组输入数据对获胜神经元的激活情况。结合图 3~图 5 可得到 P-SOM 网络中输入数据与各个神经元匹配及各个神经元所代表的异常种类(见表 1)。

表 1 水质异常种类及网络训练情况

异常种类	进水样本		训练样本编号			获胜神经元编号		
	异常原因	图 2 对应的样本编号	P-SOM	QOSM	I-QSOM	P-SOM	QSOM	I-QOSM
1	COD	1~2,17,19	1~2, 17,19,35	1~2, 17,19	1~2,17,19	12	10	8
2	SS	3,10~11	3,10~11,45	3,10~11	3,10~11	16	1	5
3	TN	26~28,35~36	4,26~28,36	26~28,35~37	26~28,35~36	4	3	1
4	TP	21,30~31	5,21,30~31	30~31	21,30~31	1	14	3
5	COD/TN	4~6	6	4~6	4~6	7	2	7
6	COD/TP	7,42	7,42	7,42	7,42	8	9	2
7	SS/TN	8~9	8~9,24	8~9,24~25	8~9	11	12	6
8	SS/TP	12~13,34,43	12,34,43	12,34,43	12~13,34,43	14	6	14
9	TN/TP	18,40,44	13,18,40,44	18,40,44	18,40,44	13	15	10
10	COD/SS	14,47	14,47	14,47	14,47	10	16	9
11	COD/SS/TN	15~16,32~33	15~16,32~33	15~16,32~33	15~16,32~33	9	8	4
12	COD/SS/TP	20,38	20,38	20~21,38	20,37	5	5	16
13	COD/TN/TP	22,37	22,37	22	22,38	6	7	11
14	SS/TN/TP	23~25,29	23,25,29	23,29	23~25,29	3	13	15
15	COD/SS/TN/TP	41,45~46,48	41,46,48	41,45~46,48	41,45~46,48	15	11	13
16	指标正常	39	39	39	39	2	4	12

2)网络测试

为验证 P-SOM 网络的泛化性能和预报准确性,从生产报表中另选 5 组进水数据作为测试样本(详

情见表 2),经归一化后提交到上述训练好的网络中进行测试,测试结果如图 6~图 9 所示。从图 6 可看出预报的水质异常种类共有 4 种,竞争层获胜神经




图 6 P-SOM 的预报结果

元的编号依次为 1、3、8、16，查表 1 可知对应的水质异常种类依次为 TP 超标，SS、TN、TP 三者同时超标，COD、TP 同时超标，SS 超标。而表 2 所示的水质异常状况只有 TP 超标，SS 超标，COD、TP 同时超标三种类型。结合图 7 可知，编号为 1~4 的

输入数据样本(如表 2)的预报是准确的，而第 5 个样本的预报出现了错误，即将正常的水质预报成了 SS、TN、TP 三者同时超标。出错的原因可以从图 3 中看出：第 3 号神经元与第 2 号神经元的距离太近，导致分类不明显，以至将水质正常的情况归属于 SS、TN、TP 同时超标的情况。




图 7 P-SOM 预报中的获胜神经元分布

表 2 测试数据样本

异常种类	PH	COD	T	SS	TP	TN	MLSS	SVI
TP	0.215 686	-0.957 32	0.159 091	-1	0.436 364	-0.423 66	0.054 383	0.833 333
SS	1	1	-1	1	0.072 727	1	1	1
	0.960 784	0.015 244	0.613 636	-0.326 32	-1	0.660 263	-0.502 86	0.333 333
COD/TP	-1	-0.829 27	0.727 273	-0.326 32	1	-0.445 9	-1	-0.666 67
正常	-1	-1	1	-0.613 16	0.236 364	-1	-0.335 49	-1

2.3 基于 QSOM 的水质预报

1) 网络训练

研究所提的 QSOM 的网络训练大致可按以下步骤进行：

①将 8×48 的进水数据样本归一化到 $-1 \sim 1$ 之间，根据式(2)将其转化为量子态描述；

②随机初始化权值矩阵

$$w_{ji} = \begin{bmatrix} \cos\varphi & \cos\phi \\ \sin\varphi & \sin\phi \end{bmatrix},$$

其中 φ, ϕ 均为 $[0, 2\pi]$ 之间的随机数，设置学习率参数初值 $\mu_0 = 0.9$ ，邻域半径初值 $r_0 = 5$ ，离散时间下标 $k = 0$ ，总学习次数 $N = 500$ ；

③将总学习次数为停止条件，检查停止条件，如果失败，则继续，如果成功，则退出；

④对于每个训练样本 $|\mathbf{X}_i\rangle$ ，执行步骤⑤~⑧；

⑤按照式(5)~(8)计算出竞争层获胜神经元

编号；

⑥以获胜神经元 q 为中心，以 $R_{j,q}$ 为选定半径作为邻域集合，在竞争层中根据式(10)~(13)进行权值更新。

⑦依据式(14)调整学习率参数 $\mu(k)$ ；

$$\mu(k) = \frac{\mu_0}{\|\mathbf{X}_i\|_2} \quad (14)$$

⑧根据式(15)适当缩减拓扑邻域 $N_q(k)$ ；

$$R_{j,q} = r_0 \exp\left(\frac{-\|\mathbf{r}_j - \mathbf{r}_q\|^2}{\sigma^2(k)}\right) \quad (15)$$

⑨设置 $k \leftarrow k + 1$ ，然后转到步骤③。

根据上述步骤，完成训练后的 QSOM 网络临近神经元之间的距离以及神经元分类结果如图 8~9 所示。

2) 网络测试

为将 QSOM 网络的泛化性能和预报准确性与




图 8 QSOM 的神经元权值分布




图 10 QSOM 预报中的获胜神经元分布




图 9 SOM 竞争层获胜神经元分布

P-SOM 进行比较,依然采用表 2 中所示数据作为测试样本,在将其量子化处理后输入到已训练好的 QSOM 网络中进行测试,测试结果如图 10 所示。

由图 10 可知,第 1 个测试样本激活的神经元为 14 号神经元,第 2 和第 3 个测试样本激活了 1 号神经元,而第 4 与第 5 个测试样本所对应的获胜神经元分别为 9 号神经元和 4 号神经元。查表 1 可知,这 4 个神经元所代表的物理意义依次为:TP 超标、SS 超标、COD 和 TP 同时超标、水质正常。这与表 2 中 5 个测试样本的各自的物理意义相同,因此利用 QSOM 进行预报是成功的。

2.4 基于无监督和有监督相结合的 QSOM 的水质预报

文献[18]所提出的 SOM 网络(以下简称 I-QSOM)与所提 SOM 网络主要存在以下区别:

①I-QSOM 网络中权值仅考虑了向量的形式,而实际上将权值量子化后,对于单量子比特门,权值

应该是一个矩阵的形式;

②I-QSOM 网络中相似系数中分母定义为权值与输入的内积,当输入为多维向量(即输入数据为矩阵)时是不能直接做出内积,因此本文将其定义为输入矩阵与权值矩阵范数的乘积;

③由①和②区别,最终导致 I-QSOM 网络在无监督部分的学习规则与所提学习规则不同;

④出于算法复杂度的考虑,在网络训练方面仅考虑了无监督的过程。

按照文献 I-QSOM^[18] 中的训练方式,完成训练后的 QSOM 网络临近神经元之间的距离以及神经元分类结果如图 11~图 12 所示,网络的测试结果如图 13 所示。




图 11 I-QSOM 的神经元权值分布

由图 13 可知,第 1 个测试样本激活的神经元为 3 号神经元,第 2 和第 3 个测试样本激活了 5 号神经元,而第 4 与第 5 个测试样本所对应的获胜神经元分别为 2 号神经元和 12 号神经元。查表 1 可知,这 4 个神经元所代表的物理意义依次为:TP 超标、SS




图 12 I-QSOM 竞争层获胜神经元分布




图 13 I-QSOM 预报中的获胜神经元分布

超标、COD 和 TP 同时超标、水质正常。这与表 2 中 5 个测试样本的各自的物理意义相同,因此利用

I-QSOM 进行预报是成功的。

2.5 三种网络的总体比较

为了验证所提算法的有效性,下面将从网络参数、训练时间、分类正确率和预报正确率 4 个方面对 QSOM 和 P-SOM 进行一个全面的比较(见表 3)。其中网络参数可分别从前面得出,而利用 SOM 进行训练的时间为 18 s, QSOM 所需时间为 16.28 s, 而 I-QSOM 则为 17.53 s,这是因为 I-QSOM 中增加了有监督的学习过程。

关于分类正确率和预报正确率可根据表 1 及预报结果得出。从表 1 可以看出, P-SOM 将原本为 TN 超标的第 35 个测试样本错误地分类到 COD 超标中,这就造成 TN 超标的样本集对第 35 号测试样本的缺失,因此分类错误的样本个数为 2。类似情况还有第 45 号样本被误分到 SS 超标中,第 4、第 5、第 13 号样本依次错误地归属到 TN 超标、TP 超标、TP 和 TN 同时超标的异常类型。所以, P-SOM 训练中正确的分类样本数为 $48 - 5 \times 2 = 38$ 。而在 QSOM 的训练中,第 21、第 25、第 37 号样本依次被误归到 COD/SS/TP、SS/TP、TN 超标之中,因而 QSOM 分类正确的样本数为 $48 - 3 \times 2 = 42$ 。同理, I-QSOM 的分类正确数为 $48 - 2 \times 2 = 44$ 。尽管 I-QSOM 的分类正确率为 91.67% 要高于 QSOM 的 87.50%,但二者的预报正确率却是一致的,且 QSOM 所需时间要低于 I-QSOM。

表 3 P-SOM、QSOM 及 I-QSOM 的比较情况

算法	网络训练				网络测试			
	网络参数			运行时间/s	分类正确数	分类正确率/%	预报正确数	预报正确率/%
	迭代次数	学习率	邻域半径					
P-SOM	500	0.9	4	18	38	79.17	4	80
QSOM	500	0.9	5	16.28	42	87.50	5	100
I-QSOM	500	0.9	5	17.23	44	91.67	5	100

4 结论

基于活性污泥法的污水处理过程是一个存在强耦合、大滞后的过程,且利用机理模型对其关键水质指标进行分析和预报的难度很大,因此可以使用 SOM 网络通过对出水水质在异常情况下所对应的进水样本进行分类,提取出异常特征,进而实现对出水水质的预报。考虑到量子神经网络的分类能力要强于普通的 ANN,提出了一种量子自组织特征映射神经网络方法来进行出水水质预报。

通过建立量子神经元及量子自组织特征映射神经网络模型,在给出相应学习规则的基础上,以重庆市某污水处理厂生化脱氮除磷过程中的实际运行数据为样本进行了数值实验。实验研究表明,所提算法在学习时间、预报正确率等方面要明显优于 P-SOM,尽管 QSOM 的分类正确率要低于 I-QSOM,但预报的结果与 I-QSOM 相同,且所需时间也要少于 I-QSOM。并对解决具有超大滞后、强耦合的复杂工业系统中的关键工艺参数的预报问题具有重要意义。

参考文献:

- [1] 丛秋梅, 柴天佑, 余文. 污水处理过程的递阶神经网络建模[J]. 控制理论与应用, 2009, 26(1): 8-14.
CONG Qiumei, CHAI Tianyou, Yu Wen. Modeling wastewater treatment plant via hierarchical neural networks[J]. Control Theory & Applications, 2009, 26(1): 8-14.
- [2] 黄明智, 马崑文, 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.
HUANG Mingzhi, MA Yongwen, WAN Jinquan, et al. An approach to artificial neural network and its application to wastewater treatment[J]. Environmental Science & Technology, 2008, 31(3): 131-135.
- [3] Kohonen T. Self-organized formation of topologically correct feature maps[J]. Biological Cybernetics, 1982, 43(1): 59-69.
- [4] Yetilmezsoy K, Sapci-zengin Z. Stochastic modeling applications for the prediction of COD removal efficiency of UASB reactors treating diluted real cotton textile wastewater [J]. Stochastic Environmental Research and Risk Assessment, 2009, 23(1): 13-26.
- [5] Fan L P, Boshnakov K. Neural-network-based water quality monitoring for wastewater treatment processes [C]// Proceedings of the 6th International Conference on Natural Computation, Aug. 10-12, 2010, Yantai, Shandong, China. [S. l.]: IEEE Press, 2010, 4: 1746-1748.
- [6] Xue J F, Ma Y T, Huang Z M. Research on the process of solid-liquid separation of piggery wastewater simulated by BP network[C]// Proceedings of the 2nd International Conference on Modelling and Simulation, May 21-22, 2009, Manchester, England, UK. [S. l.]: IEEE Press, 2009: 366-371.
- [7] 王晓萍, 孙继洋, 金鑫. 基于 BP 神经网络的钱塘江水质指标的预测[J]. 浙江大学学报: 工学版, 2007, 41(2): 361-364.
WANG Xiaoping, SUN Jiyang, JIN Xin. Prediction of water quality index in Qiantang River based on BP neural network model [J]. Journal of Zhejiang University: Engineering Science, 2007, 41(2): 361-364.
- [8] Qiao J F, Han H G, Jia Y M. An adaptive self-organizing fuzzy neural network[C]// Proceedings of the 2007 International Conference on Wavelet Analysis and Pattern Recognition, Nov. 2-4, 2007, Beijing, China. [S. l.]: IEEE Press, 2008, 2: 711-715.
- [9] 雷璐宁, 石为人, 范敏. 基于改进的 SOM 神经网络在水质评价分析中的应用[J]. 仪器仪表学报, 2009, 30(11): 2379-2383.
Lei Luning, Shi Weiren, Fan Min. Water quality evaluation analysis based on improved SOM neural network[J]. Chinese Journal of Scientific Instrument, 2009, 30(11): 2379-2383.
- [10] Luitel B, Venayagamoorthy G K. Quantum inspired PSO for the optimization of simultaneous recurrent neural networks as MIMO learning systems[J]. Neural Networks, 2010, 23(5): 583-586.
- [11] Zhang L L, Merényi E. Learning multiple latent variables with self-organizing maps[C]// Proceedings of the 2010 IEEE International Conference on Granular Computing, Aug. 14-16, 2010, San Jose, CA, USA: IEEE, 2010: 609-614.
- [12] Van heerden W S, Engelbrecht A P. A comparison of map neuron labeling approaches for unsupervised self-organizing feature maps[C]// Proceedings of the IEEE International Joint Conference on Neural Networks, June 1-8, 2008. Hongkong, China: IEEE, 2008: 2139-2146.
- [13] Furtuna R, Curteanu S, Cazacu M. Optimization methodology applied to feed-forward artificial neural network parameters [J]. International Journal of Quantum Chemistry, 2010, 111(3): 539-553.
- [14] Rigatos G G. Stochastic processes and neuronal modelling: quantum harmonic oscillator dynamics in neural structures[J]. Neural Processing Letters, 2010, 32(2): 167-199.
- [15] Kasabov N. Future directions for intelligent systems and information sciences [M]. Heidelberg: Springer-Verlag, 2000: 213-234.
- [16] Menneer T. Quantum artificial neural networks [D]. Exeter: The University of Exeter, 1998.
- [17] Li W G. A study of parallel self-organizing map[J]. Transactions of Nonferrous Metals Society of China English Edition, 1998, 9(1): 27-35.
- [18] 李盼池, 李士勇. 一种量子自组织特征映射网络模型及聚类算法[J]. 量子电子学报, 2007, 24(4): 465-468.
LI Panchi, LI Shiyong. A quantum self- organization feature mapping networks and clustering algorithm[J]. Chinese Journal of Quantum Electronics, 2007, 24(4): 465-468.
- [19] Hao L, Li J L, Long G L. Eavesdropping in a quantum secret sharing protocol based on Grover algorithm and its solution[J]. Science China: Physics, Mechanics and Astronomy, 2010, 53(3): 491-495.
- [20] Vallone G, De martini F, Mataloni P. Quantum algorithms in one-way quantum computation[J]. Optics and Spectroscopy, 2010, 108(2): 282-287.