

一种改进型离散 Hopfield 学习算法

李 荣^{1,2}, 乔俊飞¹, 韩红桂¹

(1. 北京工业大学 电子信息与控制工程学院, 北京 100124; 2. 北京农业职业学院 水利与建筑工程系, 北京 102442)

摘 要: 针对离散 Hopfield 神经网络(DHNN)的权值设计问题, 提出一种改进型学习算法, 并在 DHNN 动力学分析的基础上设计该学习算法. 利用矩阵分解的方法(MD)得到正交矩阵, 并采用得到的正交矩阵直接计算 DHNN 的权值矩阵. 通过该学习算法得到的权值矩阵, 可以很好地存储训练样本的信息, 使测试样本收敛到稳定点. 该学习算法不需要进行分块计算, 减少了计算步骤和计算量, 降低了网络的迭代次数, 从而提高了网络运行速度. 最后, 将该学习算法应用于水质评价, 验证了其有效性和可行性.

关键词: 离散 Hopfield 神经网络; 权值矩阵; 矩阵分解; 水质评价

中图分类号: TP273

文献标志码: A

An improved learning algorithm for discrete Hopfield

LI Rong^{1,2}, QIAO Jun-fei¹, HAN Hong-gui¹

(1. School of Electric Information and Control Engineering, Beijing University of Technology, Beijing 100124, China;

2. Department of Water Conservancy and Architectural Engineering, Beijing Vocational College of Agriculture, Beijing 102442, China. Correspondent: LI Rong, E-mail: lirong0602@sina.com)

Abstract: According to the weight design problem of discrete Hopfield neural network(DHNN), an improved learning algorithm for weight design is proposed. On the basis of the dynamic analysis for DHNN, the learning algorithm is designed. The orthogonal matrix is got by using the method of matrix decomposition(MD), and the orthogonal matrix is used to get the weight matrix of DHNN directly. The weight matrix which is obtained by the learning algorithm can store information well, so that the testing sample can converge to a stable point. The learning algorithm does not need block calculation. The calculation steps, the amount of calculation and the number of iterations are reduced, so the operating speed of the network is improved. Finally, the algorithm is applied to water quality evaluation to prove its effectiveness and feasibility.

Key words: discrete Hopfield neural network; weight matrix; matrix decomposition; water quality evaluation

0 引 言

离散 Hopfield 神经网络(DHNN)^[1-2]是一种全连接的递归神经网络, 对于复杂的非线性系统, 它具有丰富的动力学行为. DHNN 已经广泛地应用于不同的领域, 如模式识别^[3-4]、图像处理^[5]和信号检测^[6]等方面.

DHNN 是通过学习算法得到网络的连接权值, 并将平衡点存储在其中, 当给定一组初始值时, DHNN 向能量递减的方向变化, 并最终收敛到某个平衡点. 通过改变神经元间的连接权值可以改变网络平衡点的位置, 因此, DHNN 的连接权值决定着整个网络的性能. 国内外已有学者对 DHNN 的连接权值进行了研

究, 文献[7]研究了动态突触型的 DHNN 连接权值, 使网络的连接权值进行动态更新. Somesh 等^[8]针对有噪声英文字母的识别问题, 采用遗传算法与 Hebb 规则相结合的方法得到最优的 DHNN 连接权值. 其中, Hebb 规则^[9]是一种常用的学习算法, 具有收敛速度快、算法简便的优点, 对于正交的样本可以收敛到其稳定点; 但是 Hebb 规则存在样本移动和交叉干扰的问题, 对于非正交的样本, 难以保证精确的记忆. 文献[10]采用外积法计算网络的连接权值, 解决了信息的存储和检索问题. 外积法^[11]是使用 Hebb 规则进行调整的方法, 是一种有效的计算 DHNN 连接权值的学习算法, 易于实现, 但在样本关联性很强的情况下, 记

收稿日期: 2012-10-15; 修回日期: 2013-01-23.

基金项目: 国家自然科学基金重点项目(61034008); 国家自然科学基金项目(61203099); 北京市自然科学基金项目(4122006); 教育部博士点新教师基金项目(20121103120020).

作者简介: 李荣(1981-), 女, 博士生, 从事神经网络结构设计、智能信息处理的研究; 乔俊飞(1968-), 男, 教授, 博士生导师, 从事智能控制、智能信息处理等研究.

忆效果不理想. Srivastava 等^[12]采用正交法来解释生物信息的存储过程, 该方法可以去除生物信息从输入到存储过程中的干扰. 正交法^[13]能够克服 Hebb 规则法的一些限制, 如交叉干扰等问题, 该方法得到的连接权值能够保证 DHNN 收敛到稳定点, 所以其应用较广; 但是该算法计算过程比较复杂, 计算量相对较大, 运行过程中迭代次数较多, 耗时较长.

鉴于以上问题, 本文提出了基于矩阵分解 (MD) 的学习算法. 该方法克服了前述学习算法存在的问题, 避免了权值移动和交叉干扰问题, 简化了计算过程, 缩短了计算时间, 使整个网络的运行速度得到提高. 最后, 该学习算法的有效性和可行性在水质评价中得到了验证.

1 DHNN 模型

DHNN 是一种单层的全反馈网络, 网络中的每个神经元将当前的输出通过连接权值反馈给所有的神经元, 得到的结果作为下一时刻网络的输入. 任意的两个神经元之间形成制约关系, 从而控制其他神经元的输出. 假设无外部输入, DHNN 的结构如图 1 所示.

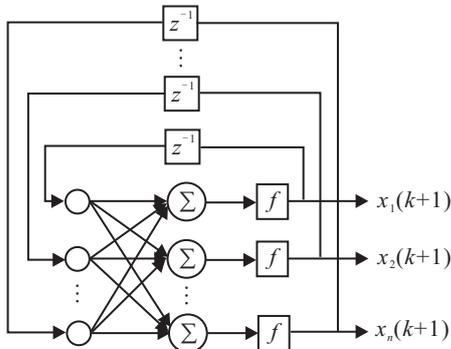


图 1 DHNN 的结构

对于共有 n 个神经元的 DHNN, 每个神经元的状态为 $+1$ 或者 -1 . 第 i 个神经元在 k 时刻的状态为 $x_i(k) \in \{+1, -1\}$, 其中 $i = 1, 2, \dots, n$. DHNN 的网络状态是所有神经元状态的集合, 设整个网络在 k 时刻的状态为 $X(k)$, 则 $X(k)$ 可以表示为

$$X(k) = [x_1(k), x_2(k), \dots, x_n(k)]. \quad (1)$$

通过 DHNN 的反馈连接, 网络经过单位延迟 z^{-1} 得到第 i 个神经元在 $k+1$ 时刻的状态为

$$x_i(k+1) = f\left(\sum_{j=1}^n w_{ij}x_j(k)\right). \quad (2)$$

其中: w_{ij} 为第 i 个神经元与第 j 个神经元之间的连接权值; 符号函数

$$f(a) = \begin{cases} 1, & a \geq 0; \\ -1, & a < 0. \end{cases} \quad (3)$$

整个网络在 $k+1$ 时刻的输出状态为 $X(k+1)$, 则 $X(k+1)$ 可以表示为

$$X(k+1) = [x_1(k+1), x_2(k+1), \dots, x_n(k+1)]. \quad (4)$$

$X(k+1)$ 的矩阵形式可以表示如下:

$$X(k+1) = f(WX(k)), \quad (5)$$

其中 W 为 DHNN 的权值矩阵.

2 学习算法设计

DHNN 具有良好的动力学特性, 可以很好地解决非线性问题. 首先, 对 DHNN 进行动力学分析, 得到 DHNN 的学习算法需要满足的条件; 然后, 在此基础上进行学习算法的设计实现.

2.1 动力学分析

假设 $R(k) = [r_1(k), r_2(k), \dots, r_n(k)]$ 为 DHNN 需要存储的向量. 设计合适的连接权值, 使得 DHNN 满足:

- 1) $\Delta E \leq 0$, 即能量函数 E 随着时间单调下降;
- 2) $R(k)$ 为网络的平衡点, 并且是能量函数的局部极小值, 即 $R(k)$ 能收敛到自身.

在 DHNN 中, 能量函数的变量 ΔE 表示为

$$\Delta E = -\left(\sum_{j=1}^n w_{ij}r_j(k)\right)\Delta r_i, \quad (6)$$

其中 $\Delta r_i = r_i(k+1) - r_i(k)$, $i = 1, 2, \dots, n$.

1) 若 $r_i(k) \neq r_i(k+1)$, $i = 1, 2, \dots, n$, 则由式 (2) 和 (6) 可知 $\Delta E < 0$, 满足条件 $\Delta E \leq 0$; 但 $R(k+1) \neq R(k)$, 所以 $R(k)$ 无法收敛到自身.

2) 若 $r_i(k) = r_i(k+1)$, $i = 1, 2, \dots, n$, 则由式 (2) 和 (6) 可知 $\Delta E = 0$, 满足条件 $\Delta E \leq 0$; 并且 $R(k+1) = R(k)$, 所以 $R(k)$ 可以收敛到自身, 即 $R(k)$ 为网络的平衡点.

对此, 需要通过学习算法设计合适的 DHNN 连接权值, 当输入初始值时, 能使 DHNN 最终达到某个稳定的状态 (即网络的平衡点), 实现信息的存储. 所以, 提出了一种改进型的学习算法, 可以快速有效地计算出 DHNN 的连接权值.

2.2 学习算法实现

DHNN 通过权值设计将信息存储到网络中, 使网络从初始状态收敛到某一个稳定点. DHNN 连接权值的设计需要学习算法来实现, 学习算法的设计实现主要从两个方面考虑: 1) 满足 DHNN 的动力学特性; 2) 学习算法有效可行. 对此提出一种 MD 学习算法来计算 DHNN 的连接权值.

DHNN 需要将最初的信息存储到网络中, 作为网络的平衡点. 将 m 个需要存储的信息 S_1, S_2, \dots, S_m 作为网络的训练样本, 并将其存储在矩阵 P 中, 令

$$P = [S_1^T, S_2^T, \dots, S_m^T]. \quad (7)$$

两两正交的训练样本更易于存储,而且可以成为DHNN的稳定点.但是由于训练样本的多样性,训练样本不一定两两正交,可采用MD方法得到正交的训练样本,对式(7)进行奇异值分解,令

$$P = UHV^T. \quad (8)$$

其中: U, V 为两个正交的矩阵; H 为伪对角矩阵.

通过奇异值分解得到正交矩阵 U , 并将相应的信息存储在 U 中, 通过它来计算网络的连接权值.

Hebb 规则对于非正交样本, 难以准确记忆, 所以, 采用 MD 方法可以保证样本准确存储, 成为 DHNN 的稳定点.

为了保证 DHNN 的稳定性, 需要其权值对称, 所以, 基于文献 [3] 设置对角矩阵 Z , 令

$$Z = \text{diag}[z_1, z_2, \dots, z_n]. \quad (9)$$

其中

$$\begin{cases} z_1 = a_1, a_1 \in [1, 10]; \\ z_i = a_2, a_2 \in [0, 1), i = 2, 3, \dots, n. \end{cases}$$

得到网络的权值矩阵为

$$W = UZU^T. \quad (10)$$

改进型的学习算法采用 MD 方法, 避免了 Hebb 规则存在的样本移动和交叉干扰问题; 同时, 与广泛应用的正交法相比, 该算法简化了计算过程, 缩短了运行时间.

3 实验与分析

为了证明本文提出的基于 MD 方法的改进型学习算法的有效性和可行性, 下面采用水质评价的实验对其进行验证.

水环境问题是我国当前的一个重要问题, 对于水环境的保护和治理是业界非常关注的研究话题. 在文献 [14-15] 中已经提出了水环境治理的重要性和相应的污水处理的神经网络方法, 并取得了很好的效果. 在水环境治理中, 水质评价是水环境质量管理及相关措施实施的重要依据, 并且 DHNN 已经广泛地用于各类水质评价中. 所以, 本文以水质评价为例对改进型学习算法的 DHNN 进行验证, 并将改进算法与常用方法在水质评价结果、迭代次数、运行时间等方面进行对比, 以验证改进型学习算法的有效性和可行性.

在此选取溶解氧、BOD₅、COD、非离子氨、大肠菌群、挥发酚、氟化物、铬(六价)8项指标作为水质评价标准, 将水质分为 I、II、III、IV、V 五类, 如表 1 所示. DHNN 存储的信息是 5 种分类标准. 这 5 类分类标准可以用 S_1, S_2, S_3, S_4, S_5 来表示. 以综合水质评价标准的第 I 类为例进行说明, 达到第 I 类分类标准的用 +1 表示, 未达到第 I 类分类标准的用 -1 表示,

因此, S_1 的矩阵形式可以表示如下:

$$S_1 = \begin{bmatrix} 1 & -1 & -1 & -1 & -1 \\ 1 & -1 & -1 & -1 & -1 \\ 1 & -1 & -1 & -1 & -1 \\ 1 & -1 & -1 & -1 & -1 \\ 1 & -1 & -1 & -1 & -1 \\ 1 & -1 & -1 & -1 & -1 \\ 1 & -1 & -1 & -1 & -1 \\ 1 & -1 & -1 & -1 & -1 \end{bmatrix}. \quad (11)$$

表 1 水质评价的标准

指标	I	II	III	IV	V
溶解氧/(mg/l)	7.5	6	5	3	2
BOD ₅ /(mg/l)	小于 3	3	4	6	10
COD/(mg/l)	2	4	8	10	15
非离子氨/(mg/l)	0.02	0.02	0.02	0.2	0.2
大肠菌群/(个/l)	200	1000	2000	5000	10000
挥发酚/(mg/l)	0.002	0.002	0.005	0.01	0.1
氟化物/(mg/l)	小于 1.0	1.0	1.0	1.5	1.5
铬(六价)/(mg/l)	0.01	0.05	0.05	0.05	0.1

将第 I 类分类标准 S_1 的矩阵形式转化为分类形式, 可以如图 2 表示, ● 表示达到第 I 类分类标准, ○ 表示未达到第 I 类分类标准.

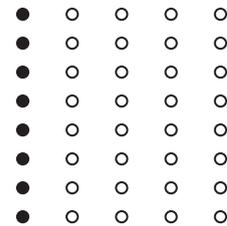


图 2 第 I 类评价标准

以此类推, 综合水质的 5 类评价标准的分类形式可以如图 3 表示, ● 表示达到相应的分类标准, ○ 表示未达到相应的分类标准.

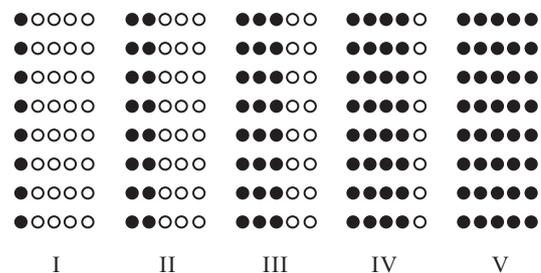


图 3 综合水质评价标准

将表 1 中的 5 类水质评价标准所对应的矩阵 S_1, S_2, S_3, S_4, S_5 作为训练样本存储到矩阵 P 中, 即 $P = [S_1^T, S_2^T, S_3^T, S_4^T, S_5^T]$. 设置 DHNN 的网络参数 $n = 5, m = 5, a_1 = 5, a_2 = 0.2$. 将网络参数代入式 (8), 进行奇异值分解, 得到正交矩阵 U . 将网络参数代入式 (9), 得到对角矩阵 Z . 再将 U, Z 代入式 (10), 得到 DHNN 的权值矩阵 W . 将水质评价标准作为平衡点存储在矩阵 W 中.

表 2 实测数据

指 标	1	2	3	4	5	6	7	8	9	10
溶解氧/(mg/l)	8.9	5.0	3.5	6.2	9.7	10.4	7.5	4.9	6.9	4.0
BOD ₅ /(mg/l)	0.6	2.8	6.0	4.4	1.4	1.2	0.7	6.3	1.6	3.0
COD/(mg/l)	1.2	4.6	8.1	5.4	3.1	1.2	0.7	6.5	3.3	1.2
非离子氨/(mg/l)	0.0132	0.023	0.05	0.188	0.0004	0.0005	0.0005	0.0005	0.0613	0.02
大肠菌群/(个/l)	2390	12000	5000	3000	2000	2380	2000	5000	2380	2380
挥发酚/(mg/l)	0.001	0.001	0.005	0.003	0.001	0.001	0.001	0.038	0.001	0.003
氟化物/(mg/l)	0.138	4.399	1.0	0.979	0.313	0.054	0.109	0.130	0.926	1.0
铬(六价)/(mg/l)	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.04

以某监测点的实测数据为例进行测试,如表2所示.共有10组实测数据作为测试样本,根据表1中的5类水质评价标准将表2中的每组测试样本分别转化为相应的矩阵形式.以第1组测试样本为例,根据表1可以转换为矩阵形式并得到其相应的水质模式,如图4所示,●表示达到相应的分类标准,○表示未达到相应的分类标准.

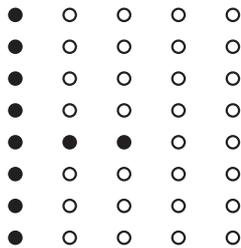


图 4 第 1 组测试样本的水质模式

将第1组测试样本输入到网络中进行测试,可以得到其水质评价结果,如图5所示.同样,将其他的测试样本转化为矩阵形式,并分别输入到DHNN中进行评价,得到相应的水质评价结果,如图5所示,●表示达到相应的分类标准,○表示未达到相应的分类标准.在这里测试样本不需要进行矩阵分解,直接输入到已经训练好的DHNN中,通过网络演化达到平衡点.由图5可以看到,基于MD方法的改进型学习算法可以将测试数据进行很好地分类.

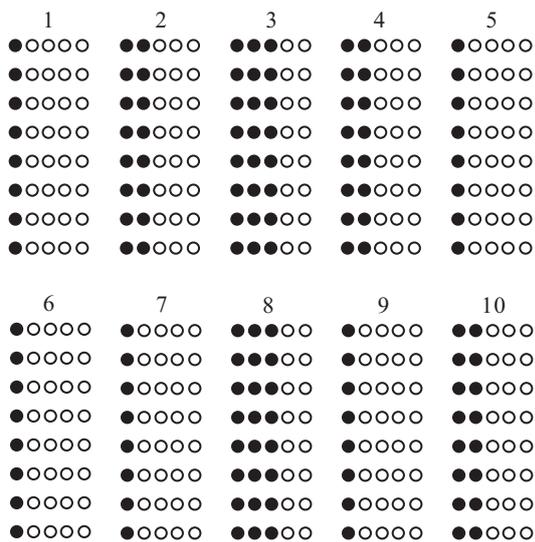


图 5 水质评价结果

将改进型学习算法得到的水质评价结果与其他的进行学习算法进行对比,结果如表3所示.由表3可以看出,由于Hebb规则自身的局限性,导致其评价结果存在误差,第8个测试数据未能正确地评价.由表3同样可以发现,改进型学习算法的评价结果与广泛应用的正交法得到的结果一致,其正确率达到100%,说明采用基于MD方法的改进型学习算法是可行的,其克服了Hebb规则存在的样本移动和交叉干扰的问题.

表 3 评价结果对比

方法	1	2	3	4	5	6	7	8	9	10
正交法	I	II	III	II	I	I	I	III	I	II
Hebb 规则	I	II	III	II	I	I	I	II	I	II
改进算法	I	II	III	II	I	I	I	III	I	II

各学习算法的迭代次数的对比如表4所示.正交法的迭代次数较多,需要经过多步迭代才能完成分类.Hebb规则采用较少的迭代次数即可完成分类,改进型学习算法同样可以采用较少的迭代步数.由此可见,改进型的学习算法可以较快地完成信息的存储和分类.

表 4 迭代次数对比

方法	1	2	3	4	5	6	7	8	9	10
正交法	3	10	10	10	5	3	5	10	10	5
Hebb 规则	1	1	1	1	1	1	1	1	1	1
改进算法	1	1	1	1	1	1	1	1	1	1

下面对各算法的运行时间进行对比,如表5所示.由表5可以看到:在3种学习算法中,正交法的运行时间最长,Hebb规则的运行时间最短,改进型学习算法介于两者之间;改进型的学习算法运行时间上的优势不及Hebb规则,但是优于正交法.由此可见,改进型的学习算法在一定程度上缩短了DHNN的运行时间,提高了网络的运行速度.

由上述可知,改进型学习算法可以很好地进行水质评价,与Hebb规则相比,克服了Hebb的样本移动和交叉干扰的问题,可以进行正确的水质评价;与广泛应用的正交法相比,可以得到一致的评价结果,并且运行过程中迭代次数较少,简化了计算过程和计算步骤,缩短了运行时间.由此可见,采用改进型学习算法具有可行性.

表5 运行时间对比

方法	1	2	3	4	5	6	7	8	9	10
正交法	0.564 534	0.571 130	0.573 629	0.571 633	0.570 762	0.562 918	0.572 051	0.577 752	0.568 531	0.566 575
Hebb规则	0.000 336	0.000 347	0.000 306	0.000 387	0.000 339	0.000 321	0.000 413	0.000 308	0.000 305	0.000 292
改进算法	0.009 410	0.008 269	0.008 349	0.007 627	0.006 855	0.004 957	0.005 837	0.003 855	0.003 746	0.002 022

4 结 论

本文提出了一种DHNN权值设计的改进型学习算法,有效地解决了现有的学习算法存在的问题.在动力学分析的基础上,通过MD方法设计实现该学习算法,并以水质评价为例对该学习算法进行了验证,表明了其有效性和可行性.通过与其他学习算法的对比,得到以下结论:

1) 采用MD方法,可以对信息进行准确地存储,避免了Hebb规则的样本移动和交叉干扰的问题,保证了学习算法具有较好的评价结果;

2) 与广泛应用的正交法相比,该学习算法不需要矩阵的分块计算,简化了计算过程,减少了计算步骤,并且迭代次数较少,缩短了运行时间,提高了DHNN的运行速度.

参考文献(References)

- [1] Hopfield J J. Neural networks and physical systems with emergent collective computational abilities[J]. Proc of the National Academy of Sciences, 1982, 79(8): 2554-2558.
- [2] Hopfield J J. Neurons with graded response have collective computational properties like those of two-state neurons[J]. Proc of the National Academy of Sciences, 1984, 81(10): 3088-3092.
- [3] Zheng Pengsheng, Tang Wansheng, Zhang Jianxiong. A simple method for designing efficient small-world neural networks[J]. Neural Networks, 2010, 23(2): 155-159.
- [4] Lee Donq-Liang. Pattern sequence recognition using a time-varying Hopfield network[J]. IEEE Trans on Neural Network, 2002, 13(2): 330-342.
- [5] Gonzalo Pajares, María Guijarro, Angela Ribeiro. A Hopfield neural network for combining classifiers applied to textured images[J]. Neural Networks, 2010, 23(1): 144-153.
- [6] Toru Aonishi, Yasunao Komatsu, Koji Kurata. Self-consistent signal-to-noise analysis of Hopfield model with unit replacement[J]. Neural Networks, 2010, 23(10): 1180-1186.
- [7] 王直杰, 范宏, 严晨. 动态突触型 Hopfield 神经网络的动态特性研究[J]. 控制与决策, 2006, 21(7): 771-775. (Wang Z J, Fan H, Yan C. Dynamics of Hopfield neural networks with dynamic synapses[J]. Control and Decision, 2006, 21(7): 771-775.)
- [8] Somesh Kumar, Manu Pratap Singh. Study of Hopfield neural network with sub-optimal and random GA for pattern recalling of English characters[J]. Applied Soft Computing, 2012, 12(8): 2593-2600.
- [9] Sompolinsky H. The theory of neural networks: The Hebb rule and beyond[J]. Lecture Notes in Physics, 1987, 275: 485-527.
- [10] Rogerio Martins Gomes, Antonio Padua Braga, Henrique Elias Borges. Information storage and retrieval analysis of hierarchically coupled associative memories[J]. Information Sciences, 2012, 195: 175-189.
- [11] Wei Yan, Chun-Hsien Chen, Wunching Chang. An investigation into sustainable product conceptualization using a design knowledge hierarchy and Hopfield network[J]. Computers and Industrial Engineering, 2009, 56(4): 1617-1626.
- [12] Vipin Srivastava, Parker D J, Edwards S F. The nervous system might 'orthogonalize' to discriminate[J]. J of Theoretical Biology, 2008, 253(3): 514-517.
- [13] Amr A Adly, Salwa K Abd-El-Hafiz. Efficient modeling of vector hysteresis using a novel Hopfield neural network implementation of Stoner-Wohlfarth-like operators[J]. J of Advanced Research, 2013: 4(4): 403-409.
- [14] Han Honggui, Chen Qili, Qiao Junfei. Research on an online self-organizing radial basis function neural network[J]. Neural Computer & Application, 2010, 19(5): 667-676.
- [15] Han Honggui, Qiao Junfei. A self-organizing fuzzy neural network based on a growing-and-pruning algorithm[J]. IEEE Trans on Neural Network, 2010, 18(6): 1129-1143.

(责任编辑: 孙艺红)