

滑动窗与修剪技术的动态模糊神经网络方法研究*

马莉¹, 张德丰¹, 马子龙²

(1. 佛山科学技术学院计算机系, 广东佛山 528000;
2. 哈尔滨工业大学电子工程系, 黑龙江哈尔滨 150001)

摘要: 提出了一种新型的动态模糊神经网络算法, 该动态模糊神经网络的结构基于扩展的径向基网络。其算法的最主要特点是: 使用滑动窗技术保持固定长度的数据来调整参数, 避免了数据饱和; 使用了修剪技术, 使得网络结构不会持续增长, 避免了过拟合及过训练现象, 因而确保了系统的泛化能力。最后通过对血压的控制来验证动态模糊神经网络的逼近能力及所提控制方案的有效性。由仿真结果表明使用滑动窗与修剪技术的 D-FNN 控制器具有良好的性能。

关键词: 动态模糊神经网络; 模糊规则; 修剪技术; 血压

中图分类号: TP183 **文献标志码:** A **文章编号:** 0529-6579 (2010) 01-0048-05

Dynamic Fuzzy Neural Network Method Research of the Glide Window and Pruning Technology

MA Li¹, ZHANG Defeng¹, MA Zilong²

(1. Department of Computer Science, Foshan University, Foshan 528000, China;

2. Department of Electrical Engineering, Harbin Institute of Technology, Harbin 150001, China)

Abstract: Based on expansion radial basis function network, one kind of new dynamic fuzzy neural network algorithm was proposed. The algorithm's main feature is to maintain the fixed length of data by using glide window technology and avoid the data being saturated. The Pruning technology was used to make the network architecture unsustained growth, and avoid the fitting and the training phenomenon, thus, it has guaranteed system's pan-ability. Finally, the approach ability of the dynamic fuzzy neural network was confirmed through the control of blood pressure. The simulation results show that the use of sliding window and pruning techniques D-FNN controller has good performance.

Key words: D-FNN; fuzzy rule; pruning technology; blood pressure;

模糊神经网络控制在控制领域里目前已经成为一个研究热点, 其原因在于神经网络和模糊系统两者之间的互补性质。把神经网络应用于模糊系统, 可以解决模糊系统中的知识抽取问题; 把模糊系统应用于神经网络, 神经网络就不再是黑箱了, 人类的知识就很容易融合到神经网络中。目前日本已把模糊神经网络视为发展高技术工业的法宝并把模糊神经网络称为 21 世纪的核心技术。模糊神经网络

控制技术已经对家电产品产生了巨大的影响。

本项目研究中的“动态”是指模糊神经网络的网络结构不是预先设定的, 而是动态变化的, 即在学习开始之前, 没有一条模糊规则, 其模糊规则是在学习过程中逐渐增长而形成的。较之常见的模糊神经网络方法, 本方法所得到的模糊规则并不随输入变量的增加而按指数增长; 特别是本方法无须领域的专家知识就可以对系统自动建模及抽取模糊

* 收稿日期: 2009-04-07

基金项目: 广东省自然科学基金资助项目 (9151040701000002)

作者简介: 马莉 (1977 年生), 女, 讲师; E-mail: molly_917@163.com

规则。由于所得到的模糊神经网络具有结构小的特点、避免了出现过拟合的现象, 因此给使用者带来了很大的方便。

1 D-FNN 理论分析与算法确定

1.1 奇异值分解 (SVD) 的修剪技术

修剪技术对于动态时变非线性系统的辨识是非常必要的。如果在学习进行时, 检测到不活跃的模糊规则并加以剔除, 则可获得更为紧凑的 D-FNN 结构。在本文中我们将采用 SVD 方法作为一种为修剪技术来选择重要的模糊规则。与 QR 分解不同, 矩阵 $H \in \mathbf{R}^{n \times v}$ 可以用 SVD 方法分解为下式:

$$H = U \Sigma S^T \quad (1)$$

其中, $U = (u_1, u_2, \dots, u_n) \in \mathbf{R}^{n \times n}$ 和 $S = (s_1, s_2, \dots, s_v) \in \mathbf{R}^{v \times v}$ 为正交矩阵, $\Sigma = \text{diag}(\xi_1, \xi_2, \dots, \xi_v) \in \mathbf{R}^{n \times v}$ 为对角矩阵, 同时 $\xi_1 \geq \xi_2 \geq \dots \geq \xi_v \geq 0$ 。矩阵 Σ 的对角元通常称为矩阵 H 的奇异值。

SVD 分解的一个重要特性就是反映出了矩阵 H 的秩, 即 $\text{rank}(H) = \text{rank}(\Sigma)$ 。因此, 非零奇异值的个数就是矩阵 H 的秩。假设 $b = \text{rank}(H)$, 则等式 (1) 可以表示成如下形式:

$$H = \sum_{i=1}^b \xi_i u_i s_i^T \quad (2)$$

其中, $\xi_1, \xi_2, \dots, \xi_b$ 是矩阵 H 的 b 个非零奇异值, u_i 和 s_i 分别是矩阵 U 和 S 的第 i 列。把式 (2) 代入 $D = H\theta + E$, 同时经过简单的代数运算, 可以得到:

$$\theta = \sum_{i=1}^b \frac{u_i^T D}{\xi_i} s_i \quad (3)$$

可以证明这个解最小化 $\|D - H\theta\|_2$ 的同时具有最小的 2-范数。实际上, 最小的 2-范数解通常可以由下式来近似:

$$\hat{\theta} = \sum_{i=1}^{\hat{b}} \frac{u_i^T D}{\xi_i} s_i \quad (4)$$

其中, \hat{b} 根据 $\xi_i \geq \delta$ 来选择。这里的 δ 根据系统的性能预先选定。显然, 当 $\hat{b} \leq b$ 时, $\hat{\theta}$ 最小化 $\|D - \hat{H}\hat{\theta}'\|_2$, 其中

$$\hat{H} = \sum_{i=1}^{\hat{b}} \xi_i u_i s_i^T \quad (5)$$

是最接近 H 的矩阵。

用 \hat{H} 代替 H 等价于过滤最小的奇异值, 当 H 是从有噪声的数据中得到时显得更有意义。但在本文中, 存在小的奇异值是指在所得的规则库中出现了多余的或者不太有用的规则。由于每个奇异值都相应地与一个模糊规则相关, 同时它在 H 中的位

置预示了它在规则库中的相关规则的位置, 因此, 这个方法的关键思想在于确定奇异值在 H 矩阵中的原始位置。这里将采用 Jacobi 算法来计算矩阵 H 的奇异值。

首先, 对 H 进行一连串单边 Jacobi 变换可以得到

$$B = U^T H \quad (6)$$

其中, B 是行正交的矩阵, U 是行、列均正交的矩阵。然而, 计算 B^T 的 QR 分解并作转置, 即:

$$B = (B^T)^T = (Q_B R_B)^T = R_B^T Q_B^T \quad (7)$$

其中, R_B 实际上是一个对角矩阵, 它的对角元包含了 H 的奇异值。

令

$$\Sigma = R_B^T \quad \text{和} \quad S^T = Q_B^T \quad (8)$$

就可以得到矩阵 H 的奇异值并以原始的顺序出现。

1.2 滑动窗技术理论分析

根据滑动窗口设置的大小接收最新的数据并删除最旧的数据进行更新, 这样, 就总是保持固定长度的数据来调整参数, 避免了数据饱和。根据规则产生准则, 假定 n 个观测数据产生了 u 个模糊规则, N 节点的输出可以写成式 (9) 矩阵形式:

$$\psi = \begin{bmatrix} \psi_{11} & \dots & \psi_{1n} \\ \vdots & \vdots & \vdots \\ \psi_{u1} & \dots & \psi_{un} \end{bmatrix} \quad (9)$$

于是, 对于任意的输入 $X_j(x_{1j}, x_{2j}, \dots, x_{nj})$, 系统的输出 y_i 可写成如下紧凑形式:

$$W\Psi = Y \quad (10)$$

其中, 对于 S 模型, $W \in \mathbf{R}^u$, $\Psi \in \mathbf{R}^{u \times n}$ 。对于 TSK 模型, W 由下式给出:

$$W = (\alpha_{10} \dots \alpha_{u0} \quad \alpha_{11} \dots \alpha_{u1} \quad \alpha_{1r} \dots \alpha_{ur}) \quad (11)$$

假定理想的输出为 $T = (t_1, t_2, \dots, t_n) \in \mathbf{R}^n$, 我们的目标是: 给定 $\Psi \in \mathbf{R}^{(r+1) \times n}$ 和 $T \in \mathbf{R}^n$ 之间的如下关系:

$$Y = W \times \Psi \quad (12)$$

$$\tilde{E} = \|T - Y\| \quad (13)$$

寻找一个最优的系数向量 $W^* \in \mathbf{R}^{(r+1) \times u}$ 使误差能量 $\tilde{E}^T \tilde{E}$ 最小化。该问题可以用如下的线性最小二乘法 (LLS) 逼近:

$$W^* \times \Psi = T \quad (14)$$

最优的 W^* 具有如下形式:

$$W^* = T(\Psi^T \Psi)^{-1} \Psi^T \quad (15)$$

其中, Ψ^T 是 Ψ 的转置, $\Psi^+ = (\Psi^T \Psi)^{-1} \Psi^T$ 是 Ψ 的广义逆。

作为一种选择, 回归最小二乘法 (RLS) (也

称为卡尔曼滤波算法) 也可以用于确定以下权值:

$$W_i = W_{i-1} + S_i \Psi_i^T (T_i - \Psi_i W_{i-1})$$

$$S_i = S_{i-1} - \frac{S_{i-1} \Psi_i^T \Psi_i S_{i-1}}{1 + \Psi_i S_{i-1} \Psi_i^T} \quad i = 1, 2, \dots, n \quad (16)$$

其中, 初始条件为 $W_0 = 0$ 和 $S_0 = \chi I$ 。 S_i 是第 i 个观测数据的误差协方差矩阵, Ψ_i 是 Ψ 的第 i 列, W_i 是经过 i 次迭代后的系数矩阵, χ 是一个足够大的正数, 而 I 是 $u(r+1) \times u(r+1)$ 维单位矩阵。

需要指出的是, 如果 D-FNN 用于在线辨识或者过程控制, 当收集到的样本数据越来越多时, 线性最小二乘法会逐渐进入饱和状态而失去调整功能, 特别是当输入数据具有时变特性时, 线性最小二乘法的自适应能力将会大大降低。在这种情况下, 就需要减小旧数据的影响。为此, 可以采取如下策略:

采用一个滑动窗。设 l_s 为窗的长度, 当第 n 个观测数据 ($n > l_s$) 进入滑动窗时, 如果 $n \leq l_s$, 则所有的数据保留在窗中, 否则, 窗中的数据通过接收 l_s 个最新的数据并删除最旧的数据进行更新, 这样就总是保持固定长度的数据来调整参数, 避免了数据饱和。这种方法对时变系统的辨识是非常有效的。

2 实验结果与分析

在本文中, 我们的目的是检测采用滑动窗技术与修剪技术的 D-FNN 能否逼近一个动态而且是时变的系统, 以验证我们所采用技术的有效性。如图 1 所示是 D-FNN 作为直接控制器的原理图, 其中参考模型的作用是用来产生训练样本数据。对药物注射系统的详细控制方案如图 2 所示。

首先给出病人的 MAP 对 SNP (硝普钠) 注射响应的经验动态模型, 该模型如下所示:

$$MAP = p_0 + \Delta p + p_d + n \quad (17)$$

其中, MAP 是指平均动脉血压, p_0 是初始血压, Δp 是由 SNP 的注射引起的血压变化量, p_d 是高血压蛋白酶的反应行为引起的血压改变, n 是随机噪声。

描述血压的变化 Δp 和 SNP 注射率 u 之间关系的传递函数为:

$$\Delta p(s) = \frac{ke^{-T_s}(1 + \alpha e^{-T_c s})}{1 + \tau s} u(s) \quad (18)$$

其中, Δp 是血压的变化量, u 是 SNP 注射率, k 表示对 SNP 的敏感性, α 是循环系数, T_c 是循环延时, T_s 是注射位置开始的初始传送延时, τ 是滞后时间常数。多年来, 式 (18) 给出的模型一直作为 SNP 影响的有效表达, 目前已被普遍接受。

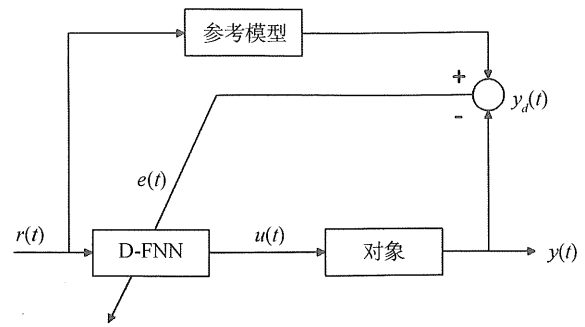


图 1 直接逆控制方法

Fig. 1 direct inverse control method




图 2 注射系统控制方案

Fig. 2 Injection Control scheme

基于式 (18), 给出了病人在 SNP 影响下, MAP 的离散时间模型:

$$\Delta p(k) = a_0 \Delta p(k-1) + b_0 u(k-d) + b_1 u(k-m) + n(k) \quad (19)$$

其中, $u(k)$ 和 $\Delta p(k)$ 分别表示在离散时刻 k 的 SNP 注射率及其初始血压引起的 MAP 变化。参数 a_0 、 b_0 、 b_1 、 d 和 m 由给定的连续时间模型 (式 18) 参数在指定的采样时间 T 下通过计算得到。

假定初始条件为: 当 $t \leq 0$ 时 $u(t) = 0, y(t) = 0$ 。为产生样本数据以训练 D-FNN, 输入根据式 $u(k) = |A \sin(2\pi k/250)|$ 来选择, 且取 $A = 15$, 逆模型为 $\hat{u}(t) = f(\Delta p(k), \Delta p(k-3))$ 。

为了跟踪模型的时变特性, 如 1.2 小节所述, 其方法之一是使用一个滑动窗口。这里, 设置窗口的长度 $l_s = 110$ 。

参数变化模型的训练结果如图 3 所示。其中图 3a 是模糊规则的产生, 图 3b 是训练过程中实际的输出误差, 图 3c 是在训练阶段的均方根误差, 图 3d 是在训练阶段期望和实际的注射率比较。参数变化模型的测试结果如图 4 所示。图 4a 是期望的血压变化, 图 4b 是由 D-FNN 控制的实际与期望的血压变化。如果扰动选择方差为 1mmHg 的白噪声, 实际药物注射率测试结果如图 4c 所示, 药物

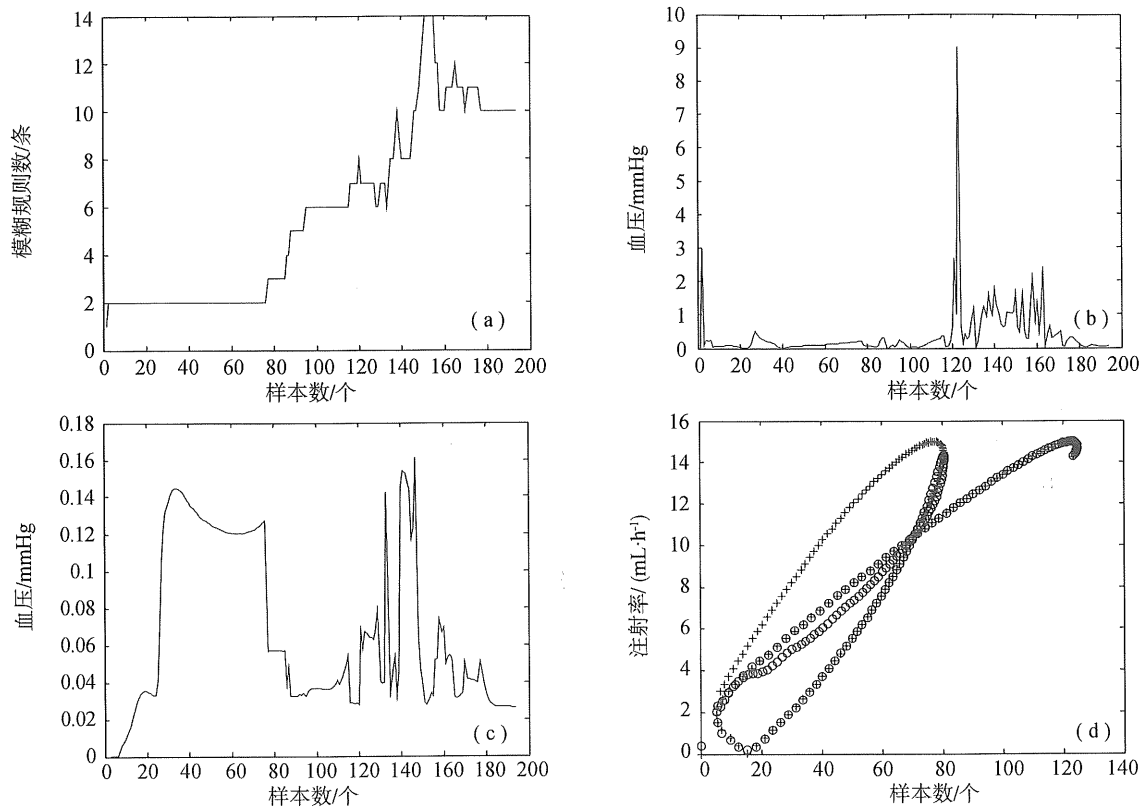


图 3 参数变化模型的训练结果

Fig. 3 The parameter changes the model training result

(a) 模糊规则的产生；(b) 训练过程中输出误差；(c) 训练过程中均方根误差；(d) 期望 (+) 和实际 (o) 输出

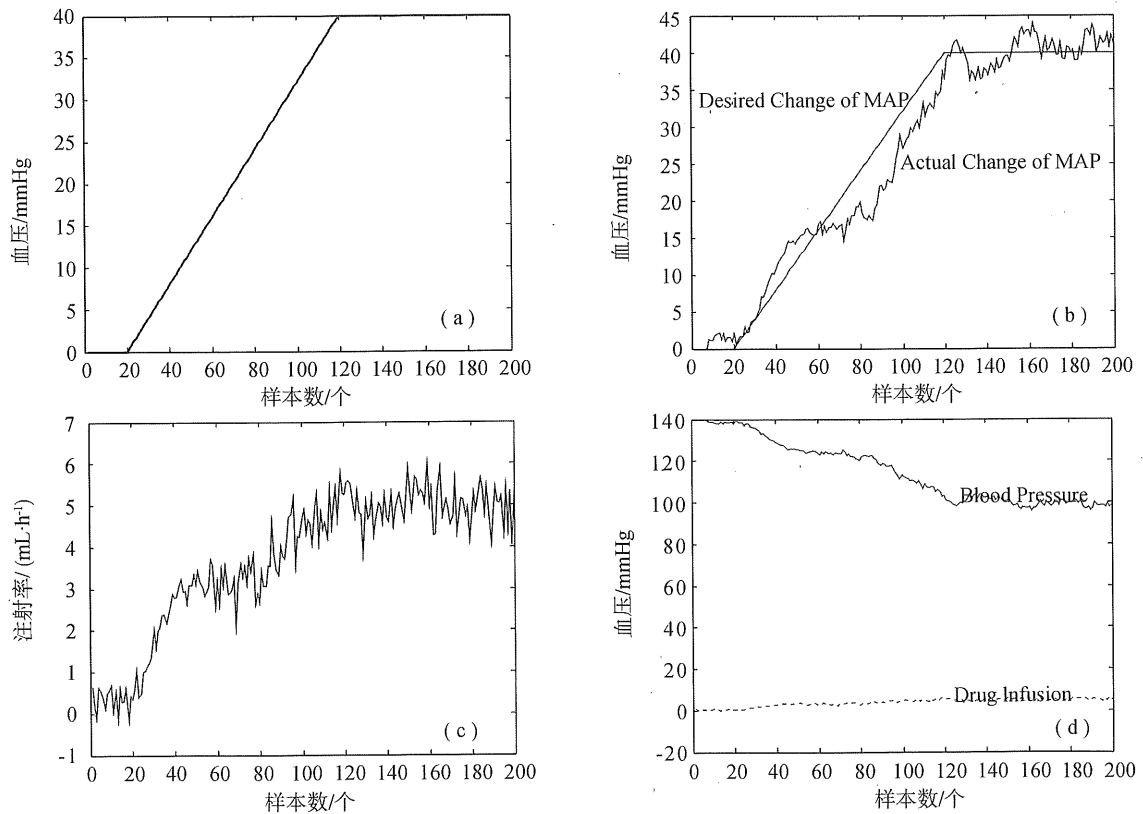


图 4 参数变化模型的测试结果

Fig. 4 The parameter changes the model testing result

(a) 期望的血压变化；(b) 实际与期望血压变化；(c) 噪声下药物注射率；(d) 药物注射率与血压变化

注射率和血压之间的关系如图 4d 所示。

文献 [6] 中的结果列于表 1 中。与文献 [6] 的方法 IANC 相比, 我们的测试结果 (图 4d) 非常稳定, 即使在噪声环境下也没有大的振荡。D-FNN 控制器的性能根据期望和实际 MAP 变化的最大误差 Δp_{\max} 来评估, 同时, 与文献 [6] 相比较的结果列于表 1 中。

表 1 IANC 与 D-FNN 的性能比较

Table 1 IANC with the D-FNN Performance Comparison

方法	$\Delta p_{\max}/\text{mmHg}$	方法	$\Delta p_{\max}/\text{mmHg}$
IANC	10	D-FNN	9.02

值得注意的是, 窗的长度 l_s 在辨识时变系统中起着非常重要的作用。较小的 l_s 将会导致极大地遗漏前面的数据, 而较大的 l_s 可能会导致 D-FNN 的更新能力下降, 使得时变参数无法辨识。

通过使用不同的窗长度, 做了大量的仿真。D-FNN 的性能根据 Δp_{\max} 和 RMSE (均方误差) 进行了评估, 结果如表 2 所示。从表 2 中可以看出最优 l_s 的范围是 $90 \leq l_s \leq 110$ 。

表 2 D-FNN 在不同窗长度下的性能

Table 2 D-FNN in the performance of different window lengths

l_s	Δp_{\max}	RMSE	l_s	Δp_{\max}	RMSE
80	426.62	201.64	130	10.58	4.68
90	9.72	3.50	150	10.32	4.10
100	10.39	3.61	170	446.07	131.84
110	9.02	3.22	—	—	—

从仿真结果来看, 由于使用了修剪技术, 使得网络结构没有持续增长, 避免了过拟合及过训练现象, 因而确保了系统的泛化能力。

3 结 论

当观测数据进入滑动窗时, 根据窗口设置的大小接收最新的数据并删除最旧的数据进行更新, 这样, 就总是保持固定长度的数据来调整参数, 避免了数据饱和。仿真结果说明这种方法对时变系统的辨识是非常有效的。准确地确定哪条规则重要是很难的。因此, 所谓“重要的模糊规则”应当看成相对的度量以及基于特定的应用来考虑。仿真结果

说明具有 SVD 修剪技术的系统可以给予更加简洁的结构以及更好的泛化性能。

参考文献:

- [1] HONG Z. Algebraic feature extraction of image for recognition[J]. *Pattern Recognition*, 2007, 24(2): 211-219.
- [2] TURK M A, PENTLAND A P. Eigenfaces for recognition[J]. *Cognitive Neuroscience*, 2006, 3(1): 71-86.
- [3] LU Y, SUNDARARAJAN N, Saratchandran P. A sequential learning scheme for function approximation by Using minimal radial basis function networks[J]. *Neural Computation*, 2007, 19(2): 461-478.
- [4] CHELLAPPA R, WILSON C L, SIROHEY S. Human and machine recognition of faces: a survey[J]. *Proc. IEEE*, 2005, 93(2): 705-740.
- [5] VALENTIN D, ABDI H, O'TOOLE A J, et al. Connectionist models of face processing: a survey[J]. *Pattern Recognition*, 2004, 27(4): 1209-1230.
- [6] POLYCARPOU M M, CONWAY J Y. Indirect adaptive nonlinear control of drug delivery systems[J]. *IEEE Trans. Automat. Contr.*, 2007, 43: 849-856.
- [7] JANG J-S R. ANFIS: adaptive-network-based Fuzzy inference system[J]. *IEEE Trans. Syst, Man, Cybern.*, 1993, 23(3): 665-684.
- [8] KADIRKAMANATHAN V, NIRANJAN M. A function estimation approach to sequential learning with neural networks[J]. *Neural Computation*, 2004, 16(4): 954-975.
- [9] PLATT J. A resource-allocating network for function interpolation[J]. *Neural Computation*, 2007, 19(2): 213-225.
- [10] BRUNELLI R, POGGIO T. Face recognition: features versus templates[J]. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 2003, 25(10): 1042-1053.
- [11] WANG L X, MENDEL J M. Fuzzy basis function, universal approximation, and orthogonal least squares learning[J]. *IEEE Trans. Neural Networks*, 2006, 3: 907-914.
- [12] EICKELER S, MUELLER S, RIGOLL G. High quality face recognition in JPEG compressed images. *Proc. IEEE Int. Conf. Image Processing*, 2007, 672-676.
- [13] WU S Q, ER M J. Dynamic fuzzy neural networks: a novel approach to function approximation[J]. *IEEE Trans. Syst, Man, Cybern. Part B*. 2005, 30: 358-364.