

# 基于修剪策略的 D-FNN 直接逆控制算法研究

张彩霞<sup>1,2</sup> 刘国文<sup>1,2</sup>

**摘要** 神经网络是模拟人脑结构,它具有大规模并行及分布式信息处理能力,但是不能处理和描述模糊信息.模糊系统具有推理过程容易理解,但它很难实现自适应学习的功能.如果结合神经网络与模糊系统,可以取长补短.基于此,本文提出了一种新型动态模糊神经网络(Dynamic fuzzy neural network, D-FNN)学习算法.因为它具有结构和参数同时调整且学习速度快等优点,所以既可以在模糊逻辑系统中包含低级的神经网络学习和计算功能,也可以为神经网络提供高级的类似人的思维和推理的模糊逻辑系统.此外,本文还开发了生物医学工程应用算法程序,针对药物注射系统的直接逆控制案例进行了仿真,结果表明: D-FNN 具有实时学习和控制能力强、参数估计和结构辨识同时进行等优点.

**关键词** 动态模糊神经网络,神经网络,模糊逻辑,模糊规则

**引用格式** 张彩霞,刘国文.基于修剪策略的 D-FNN 直接逆控制算法研究.自动化学报,2019,45(8):1599–1605

**DOI** 10.16383/j.aas.c190038

## Research on D-FNN Direct Inverse Control Algorithm Based on Pruning Strategy

ZHANG Cai-Xia<sup>1,2</sup> LIU Guo-Wen<sup>1,2</sup>

**Abstract** The neural network simulates the human brain structure with the capabilities processing large-scale parallel and distributed information, which cannot process and describe fuzzy information. The inference processing of the fuzzy system is easy to understand, but it is difficult to realize the adaptive learning. If combining neural networks with fuzzy systems, they can learn from each other. This paper proposes a novel dynamic fuzzy neural network (D-FNN) learning algorithm. Because it has the advantages of simultaneous adjustment of structure and parameters and fast learning speed, it can not only include low-level neural network learning and calculation functions in fuzzy logic systems, but also provide the neural network with the high-level fuzzy logic system which is similar to human thinking and reasoning. In addition, this paper also develops a biomedical engineering application algorithm program, which simulates the direct inverse control case of the drug injection system. The simulating results show that D-FNN has many advantages such as real-time learning, robust control ability, simultaneous parameter estimation and structure identification.

**Key words** Dynamic fuzzy neural network (D-FNN), neural network, fuzzy logic, fuzzy rules

**Citation** Zhang Cai-Xia, Liu Guo-Wen. Research on D-FNN direct inverse control algorithm based on pruning strategy. *Acta Automatica Sinica*, 2019, 45(8): 1599–1605

一个训练好的神经网络可以看成是一种知识的表达,与模糊系统中使用 IF-THEN 规则表达局部

知识不同,神经网络通过它的结构,更确切地说,通过它的连接权和局部处理单元,以一种分布式的或局部的方法来储存知识.神经网络中的前馈计算与模糊系统中的前向推理扮演同样的角色.这两种系统都能根据当前情况通过对存储知识的操作来执行任务,以得到期望输出.通过给定一个合适的行为来响应新情况是这两种系统的核心.但是,两者完成任务的方法是不同的.模糊系统是基于逻辑推论的插值推理,而神经网络是基于泛化能力的代数计算.模糊系统通常是从领域专家处获取知识,这个知识借助模糊逻辑理论融入系统.相反,神经网络通常从样本中获取知识,这个知识通过训练被吸收到神经网络中.模糊系统和神经网络的结合就形成了模糊神经网络,这种网络致力于两种方法的优点,同时避免它们各自的缺陷.把神经网络应用于模糊系统,可以解决模糊系统中提取模糊规则的问题,把模糊系统

收稿日期 2019-01-26 录用日期 2019-04-15

Manuscript received January 26, 2019; accepted April 15, 2019  
广东省教育厅省级重大科研项目(2014KZDXM063),广东省智慧城市基础设施健康监测与评估工程技术研究中心,国家自然科学基金青年基金(61803087, kg33201, 61703104)资助

Supported by Guangdong Provincial Department of Education Provincial Major Scientific Research Project (2014KZDXM063), Guangdong Province Smart City Infrastructure Health Monitoring and Evaluation Engineering Technology Research Center, and National Natural Science Foundation Youth Fund (61803087, kg33201, 61703104)

本文责任编辑 刘艳军

Recommended by Associate Editor LIU Yan-Jun

1. 佛山科学技术学院自动化学院 佛山 528000 2. 广东省智慧城市基础设施健康监测与评估工程技术研究中心 佛山 528000

1. College of Automation, Foshan University, Foshan 528000  
2. Guangdong Province Smart City Infrastructure Health Monitoring and Evaluation Engineering Technology Research Center, Foshan 528000

应用于神经网络, 可以避免任意选择初值.

### 1 动态模糊神经网络理论分析

#### 1.1 动态模糊神经网络的结构

本文提出的动态模糊神经网络 (Dynamic fuzzy neural network, D-FNN) 学习算法的特点是: 不仅参数可以在学习过程中调整, 同时, 也可以自动确定模糊神经网络的结构. 从功能上看, 它等同于一个 TSK (Takagi-Sugeno-Kang) 模糊系统, 该系统采用高斯隶属函数和 T-范数乘积算子<sup>[1]</sup>.

D-FNN 结构如图 1 所示.

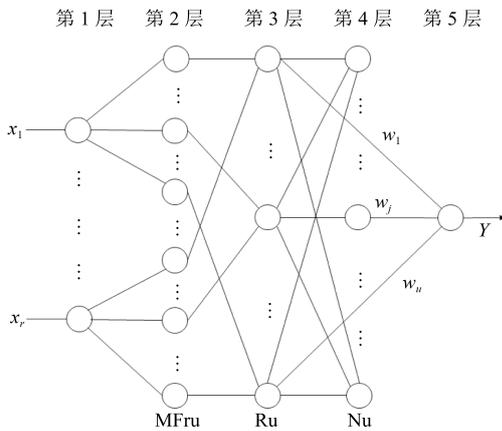


图 1 D-FNN 示意图

Fig. 1 D-FNN schematic

在图 1 中,  $x_1, x_2, \dots, x_r$  是系统的输入数据,  $Y$  是系统的输出数据,  $MF_{ru}$  是隶属函数<sup>[2]</sup>.

高斯函数表示的隶属函数为

$$\mu_{ij}(x_i) = \exp\left(-\frac{(x_i - c_{ij})^2}{\sigma_j^2}\right) \quad (1)$$

$i = 1, 2, \dots, r, \quad j = 1, 2, \dots, u$

其中,  $c_{ij}$  是  $x_i$  的第  $j$  个高斯隶属函数的中心,  $\sigma_j$  是  $x_i$  的第  $j$  个高斯隶属函数的宽度.

$N_j$  为第  $j$  个节点的输出

$$\psi_j = \frac{\varphi_j}{\sum_{k=1}^u \varphi_k}, \quad j = 1, 2, \dots, u \quad (2)$$

总输出信号为

$$y(\mathbf{X}) = \sum_{k=1}^u w_k \cdot \psi_k \quad (3)$$

其中,  $y$  是输出信号,  $w_k$  是模糊规则. 对于 TSK 模型<sup>[3]</sup>

$$w_k = a_{k0} + a_{k1}x_1 + \dots + a_{kr}x_r \quad (4)$$

$k = 1, 2, \dots, u$

### TSK 模型

$$y(\mathbf{X}) = \frac{\sum_{i=1}^u \left[ (a_{i0} + a_{i1}x_1 + \dots + a_{ir}x_r) \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{\sigma_i^2}\right) \right]}{\sum_{i=1}^u \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{\sigma_i^2}\right)} \quad (5)$$

#### 1.2 分级学习思想

D-FNN 的结构不仅由接收域决定, 还由系统误差决定, 尽管这两种方法都可以划分为分级自组织方法. 由输出误差确定是否应该加入新模糊规则.

输出误差判断描述如下:  $(\mathbf{X}_i, t_i)$  是第  $i$  个输入数据,  $\mathbf{X}_i$  表示第  $i$  个输入向量,  $t_i$  表示第  $i$  个期望的输出, 动态模糊神经网络输出为  $y_i$ .

定义

$$\|e_i\| = \|t_i - y_i\| \quad (6)$$

如果

$$\|e_i\| > k_e \quad (7)$$

此时, 增加一条新的模糊规则.  $k_e$  值是根据动态模糊神经网络期望的精度预先选定的<sup>[4]</sup>. 分级学习主要思想能保证更简洁的结构和更短的学习时间.  $k_e$  是个变量

$$k_e = \max[e_{\max} \times \beta^i, e_{\min}] \quad (8)$$

这里, 最大误差为  $e_{\max}$ , 动态模糊神经网络的精度为  $e_{\min}$ , 收敛常数是  $\beta$  ( $0 < \beta < 1$ )<sup>[5]</sup>.

#### 1.3 D-FNN 修剪技术

修剪策略采用的是误差下降率 (Error reduction rate, ERR) 方法. 用 ERR、SVD (Singular value decomposition) 和 ED (Eigenvalue decomposition) 方法的不同的修剪策略将导致不同的 D-FNN 结构, 即不同模糊规则数以及对于某个特定的性能, 每条规则的参数不同. 实验说明, ERR 方法具有明显的物理意义和稳定的数值计算, 这就是该方法被广泛使用的原因.

$\mathbf{T} = (t_1, t_2, \dots, t_n) \in \mathbf{R}^n$  为系统理想输出,  $\mathbf{Y} \in \mathbf{R}^n$  为系统实际输出.  $\mathbf{\Psi} \in \mathbf{R}^{(r+1)u \times n}$  和  $\mathbf{T} \in \mathbf{R}^n$  之间有如下关系<sup>[6]</sup>

$$\mathbf{Y} = \mathbf{W} \times \mathbf{\Psi} \quad (9)$$

$$\tilde{E} = \|\mathbf{T} - \mathbf{Y}\| \quad (10)$$

$\tilde{E}^T \tilde{E}$  表示误差能量.  $\{X(i), t(i), i = 1, 2, \dots, n\}$  为第  $n$  个输入-输出对, 把式 (9) 代入式 (10) 推导出线性回归模型<sup>[7]</sup> 为

$$D = H\theta + E \quad (11)$$

其中, 期望输出为  $D = T^T \in \mathbf{R}^n$ , 回归向量为  $H = \Psi^T = (h_1 \cdots h_v) \in \mathbf{R}^{n \times v}$ ,  $v = u \times (r + 1)$ , 实参数为  $\theta = W^T \in \mathbf{R}^n$ , 误差向量为  $E \in \mathbf{R}^n$ , 回归量为  $h_i$ . 回归量为  $q_i$ , 期望输出方差为  $\sum_{i=1}^v g_i^2 q_i^T q_i / n$ . 误差下降率为

$$\text{err}_i = \frac{(q_i^T D)^2}{q_i^T q_i D^T D}, \quad i = 1, 2, \dots, v \quad (12)$$

$\text{err}_i$  值如果很大, 那么  $q_i$  和  $D$  的相似程度就很大<sup>[8]</sup>,  $q_i$  对于输出结果影响显著. 式 (12) 的几何意义也很显著. 向量  $q_i$  和  $D$  的夹角设为  $\phi_i$ , 那么

$$\cos^2 \phi_i = \text{err}_i = \frac{(q_i^T D)^2}{q_i^T q_i D^T D}, \quad i = 1, 2, \dots, v \quad (13)$$

若  $\phi_i = 90^\circ$ ,  $\text{err}_i = 0$ , 表示两个向量正交, 意味着  $q_i$  对  $D$  无影响, 如果, 若  $\phi_i = 0$ ,  $\text{err}_i = 1$ , 意味着  $q_i$  对  $D$  影响显著.  $\Delta = (\delta_1, \delta_2, \dots, \delta_u) \in \mathbf{R}^{(r+1) \times u}$  为  $\text{err}_i$  ( $i = 1, 2, \dots, (r + 1)u$ ) 重新排列的矩阵,  $\Delta$  的第  $i$  列  $\delta_i$  是误差下降率<sup>[9]</sup>. 定义

$$\eta_i = \sqrt{\frac{\delta_i^T \delta_i}{r + 1}} \quad (14)$$

第  $i$  个模糊规则的重要性用  $\eta_i$  表达, 值  $\eta_i$  越大, 表示第  $i$  个模糊规则越重要<sup>[10]</sup>. 假设

$$\eta_i < k_{\text{err}} \quad (15)$$

预先设置阈值为  $k_{\text{err}}$ , 则第  $i$  个模糊规则可以剔除<sup>[11]</sup>.

未修剪时的训练误差总是比修剪后的误差小, 但是经过修剪, 无论是用 ERR 还是 SVD 或 ED 方法, 系统的测试误差 (用 RMSE (Root-mean-square error) 来评判) 总是小于未修剪的系统.

#### 1.4 结果参数确定的分析

假定  $u$  个模糊规则是由  $n$  个观测数据产生的, 可以写成式 (16)  $N$  节点的模糊规则矩阵输出形式

$$\Psi = \begin{bmatrix} \psi_{11} & \cdots & \psi_{1n} \\ \vdots & \ddots & \vdots \\ \psi_{u1} & \cdots & \psi_{un} \end{bmatrix} \quad (16)$$

$X_j(x_{1j}, x_{2j}, \dots, x_{rj})$  是输入的观测数据,  $y_i$  是系统的输出数据, 可写成式 (17) 形式<sup>[12]</sup>

$$W\Psi = Y \quad (17)$$

对于 TSK 模型,  $W$  由下式给出

$$W = (\alpha_{10} \cdots \alpha_{u0}, \alpha_{11} \cdots \alpha_{u1}, \dots, \alpha_{1r} \cdots \alpha_{ur}) \quad (18)$$

对于 S 模型,  $W^T \in \mathbf{R}^u$ ,  $\Psi \in \mathbf{R}^{u \times n}$ .

如何使误差能量  $\tilde{E}^T \tilde{E}$  最小, 决定于一个最优的系数向量  $W^* \in \mathbf{R}^{(r+1)u}$ . 式 (19) 给出了利用线性最小二乘法 (Linear least squares, LLS) 逼近该问题的方法

$$W^* \times \Psi = T \quad (19)$$

具有如下表达形式的  $W^*$  是属于最优的<sup>[13]</sup>

$$W^* = T(\Psi^T \Psi)^{-1} \Psi^T \quad (20)$$

其中,  $\Psi$  的转置为  $\Psi^T$ ,  $\Psi$  的广义逆为  $\Psi^+ = (\Psi^T \Psi)^{-1} \Psi^T$ .

卡尔曼滤波算法用于确定以下权值

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

$$S_i = S_{i-1} - \frac{S_{i-1} \Psi_i^T \Psi_i S_{i-1}}{1 + \Psi_i S_{i-1} \Psi_i^T}, \quad i = 1, 2, \dots, n \quad (21)$$

其中,  $W_0 = 0$  和  $S_0 = \chi I$  为初始条件. 经过  $i$  次迭代后的系数矩阵为  $W_i$ , 第  $i$  个观测数据的误差协方差矩阵为  $S_i$ ,  $\chi$  是一个正数,  $\Psi$  的第  $i$  列为  $\Psi_i$ ,  $u(r + 1) \times u(r + 1)$  为单位矩阵  $I$ .

给予最新的数据最大的加权, 而最旧数据加权最小, 乃至被遗忘<sup>[14]</sup>. 其实现方法是加入一个遗忘因子  $\lambda$ . 采用数据遗忘法的回归最小二乘法公式如下

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

$$S_i = \frac{1}{\lambda} \left( S_{i-1} - \frac{S_{i-1} \Psi_i^T \Psi_i S_{i-1}}{\lambda + \Psi_i S_{i-1} \Psi_i^T} \right), \quad i = 1, 2, \dots, n \quad (22)$$

其中,  $0 < \lambda < 1$ ,  $\lambda$  越小, 表明数据遗忘越快.

当收集到的数据越来越多时, 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, 就需要减少旧数据的影响.

## 2 实验结果与分析

$\Delta p$  是血压的变化, SNP (Sodium nitropruside) 是硝普钠,  $u$  为 SNP 注射率, 它们之间关系的传递函数为

$$\Delta p(s) = \frac{ke^{-T_i s}(1 + \alpha e^{-T_c s})}{1 + \tau s} u(s) \quad (23)$$

其中, 循环延时为  $T_c$ , 初始传送延时为  $T_i$ , 硝普钠的敏感性表示为  $k$ , 滞后时间常数为  $\tau$ , 循环系数为  $\alpha$ .

根据式 (23), 在硝普钠影响下给出了平均动脉血压 (Mean artery pressure, MAP) 的离散数学模型

$$\Delta p(k) = a_0 \Delta p(k-1) + b_0 u(k-d) + b_1 u(k-m) + n(k) \quad (24)$$

参数  $m$ ,  $a_0$ ,  $b_0$ ,  $b_1$  和  $d$  在采样时间下通过计算式 (19) 连续时间模型得到<sup>[15]</sup>.

我们采用直接逆控制方法来检测 D-FNN 能否逼近一个动态时变的系统. 所谓直接逆控制法, 就是基于系统的参考模型, 模糊神经网络学习或逼近该模型的逆系统模型, 并作为控制器与控制对象简单串接在一起, 使合成的系统能够在期望响应  $r(t)$  和被控系统的输出  $y(t)$  之间形成一个一致的映射. D-FNN 作为直接逆控制方法的原理图如图 2 所示. 其中参考模型的作用是用来产生训练样本数据.

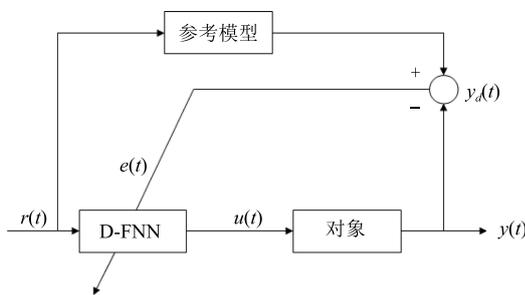


图 2 控制方法数学模型  
Fig. 2 Mathematical model of control method

在系统中 D-FNN 作为控制器时, 为了使输出值  $y(t)$  逼近期望值  $r(t)$ , 目标是要得到适当的控制行为  $u(t)$ . 这个仿真实验需要两个阶段即学习阶段与应用阶段. 在学习阶段, D-FNN 辨识了潜伏在对象的时变动态逆模型. 在应用阶段, D-FNN 作为控制器产生控制行为.

逆模型通常由带外输入的自回归非线性模型 (Nonlinear auto regressive with exogenous input, NARX) 经过简单的推导得到

$$u(t) = f^{-1}[y(t+1), y(t), \dots, y(t-n_y), u(t-1), \dots, u(t-n_u)] \quad (25)$$

由式 (25), 可以看到计算  $u(t)$  的值需要知道  $y(t+1)$  的值, 而  $y(t+1)$  是未来值. 为了解决这个问题, 一般情况下用  $r(t+1)$  代替  $y(t+1)$ . 由于  $r(t)$  与参考信号有关联, 这个代替是合理的.

可以用 NARX 模型直接构造如下的逆模型:  $u(t) = g[y(t+1), \dots, y(t-n_y), u(t-1), \dots, u(t-$

$n_u]$  取  $g \approx f^{-1}$ . 实际上  $g$  不是  $f$  的准确逆模型, 它只是数学上逼近这个逆映射.

在注射系统标准时不变模型与注射系统参数变化模型仿真研究中, 通过对血压的控制来验证 D-FNN 逼近能力及所提控制方案的有效性.

## 2.1 注射系统标准时不变模型

病人响应的数学模型表达如下:

$$\Delta p(k) = 0.742 \Delta p(k-1) + 0.188 u(k-3) + 0.076 u(k-6) \quad (26)$$

为了产生训练数据, 药物注射率  $u(k)$  取为

$$u(k) = |A \sin(2\pi k/250)| \quad (27)$$

设  $A = 50$ , 初始条件为: 当  $t \leq 0$  时  $\Delta p(t) = 0$ ,  $u(t) = 0$ , 根据式 (26) 和式 (27) 提取 200 个样本. 式 (26) 的逆模型取为  $\hat{u}(k) = f(\Delta p(k), \Delta p(k-3))$  其中,  $f$  是 D-FNN, 它代表式 (22) 的逆映射. D-FNN 预定义的参数选择如下:  $d_{\min} = 2$ ,  $d_{\max} = 35$ ,  $e_{\min} = 0.5$ ,  $e_{\max} = 50e_{\min}$ ,  $\gamma = (\frac{d_{\min}}{d_{\max}})^{2.5/200}$ ,  $\beta = (\frac{e_{\min}}{e_{\max}})^{1/100}$ ,  $\sigma_0 = 35$ ,  $k = 2.5$ ,  $k_w = 1.05$ ,  $k_{\text{err}} = 0.0007$  训练结果如图 3 所示. 其中, 图 3(a) 是训练阶段期望和实际注射的差别, 图 3(b) 是训练阶段的均方根误差, 图 3(c) 是训练阶段期望 (-) 和实际注射率 (o) 比较.

控制器采样间隔是 15 s, 高血压病人的血压设定为 140 mmHg, D-FNN 控制器训练好后用于控制对象, 最后病人的血压要求降低到 100 mmHg, 如图 4 所示. 其中, 图 4(a) 可以看到血压随着硝普钠注射的变化而平稳地变化, 并没有发生时延和震荡, 这表明 D-FNN 很好地学习了模型的特性, 对系统进行了很好的建模. 图 4(b) 是血压的实际的变化和期望的变化, 期望的血压变化中含有方差为 1 mmHg 的白噪声, 图 4(c) 是仿真结果的血压误差. 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系统结构以及快速的学习速度.

仿真的结果如下:  $\Delta p_{\max} = 5.91$ ;  $\Delta MAP_{\max} = 2.61$ ;  $\Delta MAP_{\min} = 97.1$ .

由上述仿真结果可以看到: D-FNN 控制器能够使血压平稳的变化, 能够满足实际的要求.

## 2.2 注射系统参数变化模型

根据式 (26), 得到了病人在 SNP 作用下, 最大后验概率 (Maximum a posteriori estimation) 的离散数学模型

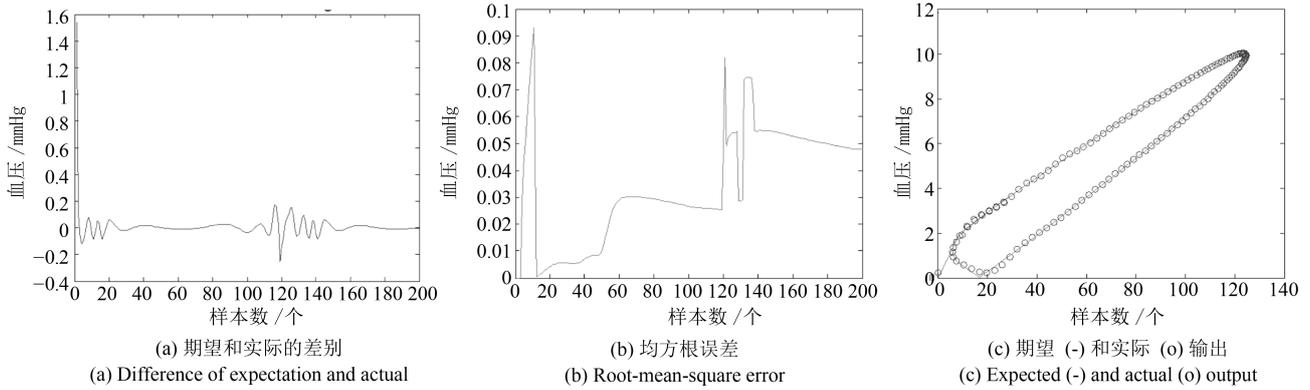


图 3 标准时不变系统的训练结果

Fig. 3 Training results for standard time invariant systems

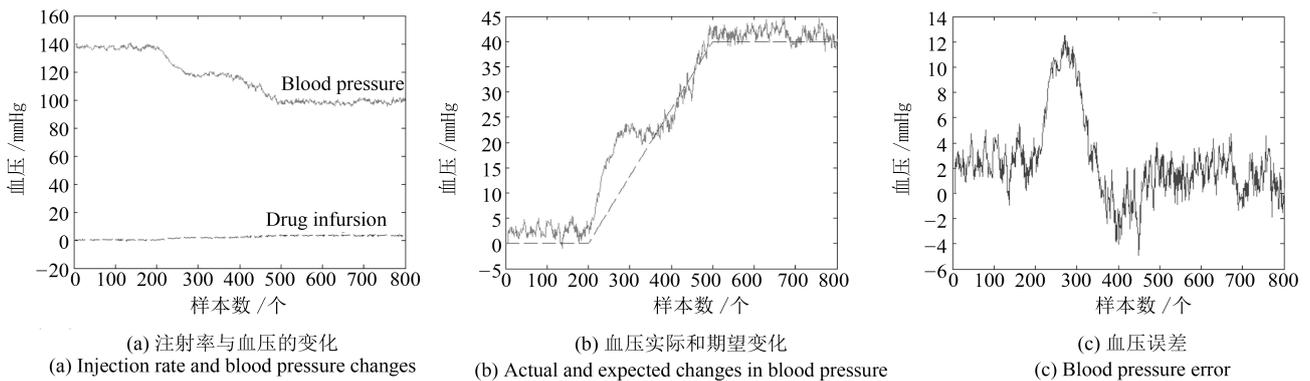


图 4 D-FNN 对系统进行的仿真

Fig. 4 D-FNN simulation of the system

$$\Delta p(k) = a_0 \Delta p(k-1) + b_0 u(k-d) + b_1 u(k-m) + n(k) \quad (28)$$

设定初始条件为: 当  $t \leq 0$  时  $u(t) = 0, y(t) = 0$ . 用训练 D-FNN 的样本数据的产生, 根据输入式  $u(k) = |A \sin(2\pi k/250)|$  来选择训练样本, 且取  $A = 15$ , 逆模型为  $\hat{u}(t) = f(\Delta p(k), \Delta p(k-3))$ .

为了观察药物注射系统参数变化模型的时变特性, 使用一个移动窗口. 设置移动窗口的宽度  $w = 120$ . 其中药物注射系统变化模型的训练结果如图 5 所示. 图 5(a) 是 D-FNN 控制器训练阶段的期望 (+) 和实际 (o) 输出比较, 图 5(b) 是训练时均方根误差, 图 5(c) 是训练阶段的输出误差. 其中变化模型的测试结果见图 6. 图 6(a) 是药物注射率和血压之间的关系, 图 6(b) 是 D-FNN 控制器的实际与期望的血压变化比较, 图 6(c) 是噪声环境下的药物注射率, 其中扰动选择方差为 1 mmHg 的白噪声.

表 1 是文献 [16] 与 D-FNN 中的仿真性能比较结果. IANC 方法与 D-FNN 方法相比, D-FNN 的仿真结果 (图 6(a)) 非常理想, 即使在扰动选择方

差为 1 mmHg 的白噪声环境下也没有大的延迟和振荡. 用最大误差  $\Delta p_{\max}$  来评估期望和实际 MAP (平均动脉血压) 变化的 D-FNN 控制器的性能, IANC 方法与 D-FNN 方法相比较的结果列于表 1 中.

表 1 D-FNN 与 IANC 的性能比较 (mmHg)  
Table 1 Performance comparison between D-FNN and IANC (mmHg)

方法	$\Delta p_{\max}$	方法	$\Delta p_{\max}$
D-FNN	9.01	IANC	10.1

仿真时应注意到, 移动窗的宽度  $w$  在辨识时变系统中有着重要的作用. 宽度  $w$  较小时, 会遗漏一些重要的数据; 而宽度  $w$  较大时, 收集到的样本数据越来越多, D-FNN 逐渐进入饱和而失去调整功能, 使得时变参数无法辨识.

通过使用不同移动窗宽度, 做了多次的仿真. 根据 RMSE(均方误差) 和  $\Delta p_{\max}$  进行评估 D-FNN 的性能, 仿真结果表明, 最优宽度  $w$  的范围是  $90 \leq w \leq 110$ .

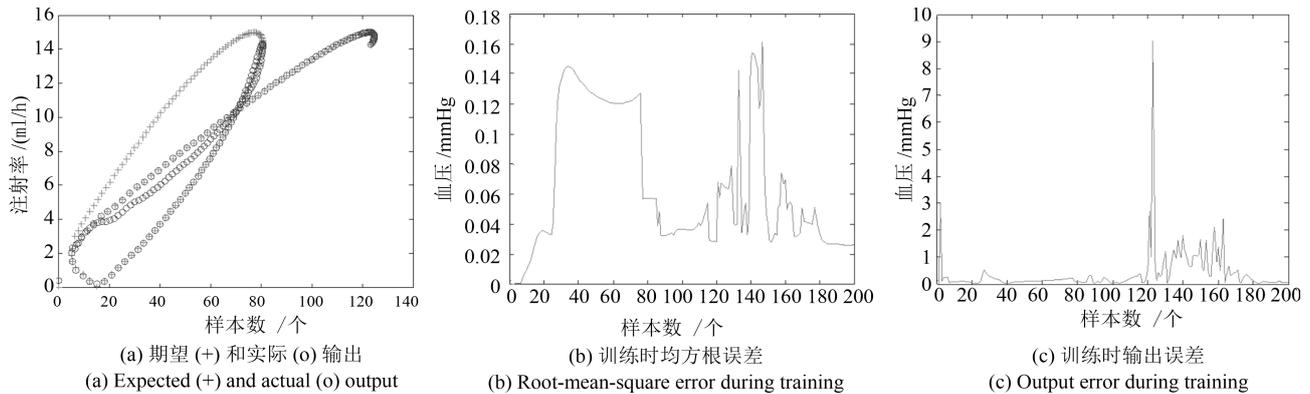


图5 参数变化模型的训练结果

Fig. 5 Training results of the parameter change model

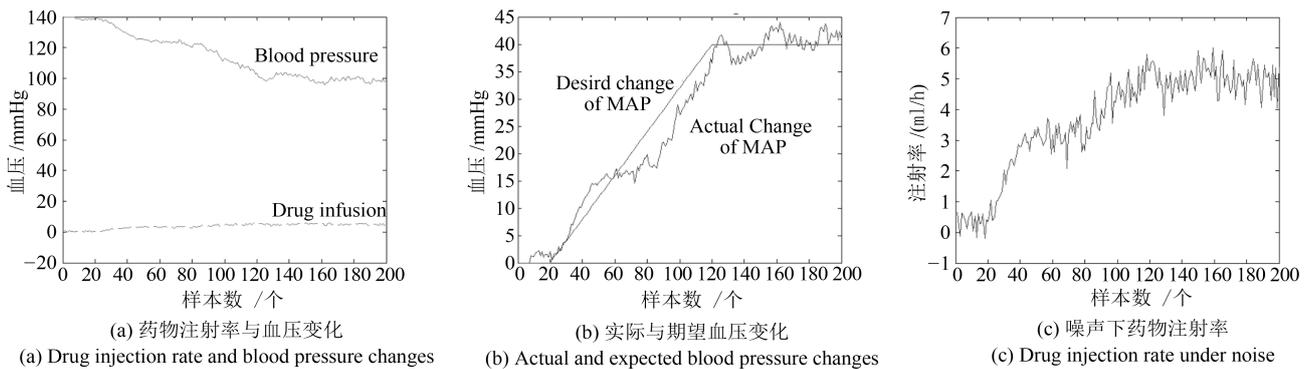


图6 参数变化模型的训练结果

Fig. 6 Test result of parameter change model

从仿真结果来看, 由于使用了修剪技术与移动窗技术, 使得网络结构没有持续增长, 可获得更为紧凑的 D-FNN 结构, 因而确保了系统的泛化能力.

### 3 结论

采用分级学习的思想能保证更简洁的结构和更短的学习时间, 分级学习策略的一大好处是可以缓解学习过程中的震荡问题. 实验结果表明, D-FNN 控制器具有强大的在线学习能力, 特别是当外部环境出现扰动时, D-FNN 具有很强的自适应性和鲁棒性可以把轨迹误差迅速地减少到接近零. D-FNN 可以根据对控制系统的重要性及系统的复杂性自动地产生或者删除模糊规则, 在线学习时模型不需要预先设定, 可以从训练数据设置次序自适应地学习, 从而补偿了非线性系统建模误差处理外部扰动. 通过仿真研究, 动态模糊神经网络将会在许多实时自动控制系统中得到应用. D-FNN 学习的快速性未来还有进一步改进的空间.

### References

- Chen R J, Zhao A, Chen H L, Zhao Z H, Cai J, Wang C C, et al. Cardiopulmonary benefits of reducing indoor particles of outdoor origin: a randomized, double-blind crossover trial of air purifiers. *Journal of the American College of Cardiology*, 2015, **65**(21): 2279–2287
- Chao C T, Chen Y J, Teng C C. Simplification of fuzzy neural systems using similarity analysis. *IEEE Transactions on Systems, Man, and Cybernetics, Part B, Cybernetics*, 1996, **26**(2): 344–354
- He Zheng-Feng, Zhang De-Feng, Sun Ya-Min. Research on adaptive dynamic fuzzy neural network algorithms with Gauss activation function and eigenvalue decomposition pruning technologies. *Acta Scientiarum Naturalium Universitatis Sunyatseni*, 2013, **52**(1): 34–39  
(何正风, 张德丰, 孙亚民. 高斯激活函数特征值分解修剪技术的 D-FNN 算法研究. 中山大学学报(自然科学版), 2013, **52**(1): 34–39)
- Ma Li, Zhang De-Feng, Xu Yong. A bio-engineering algorithm research based on dynamic fuzzy neural networks. *Computer Engineering and Science*, 2010, **32**(3): 137–140  
(马莉, 张德丰, 许勇. 基于动态模糊神经网络的生物工程算法研究. 计算机工程与科学, 2010, **32**(3): 137–140)
- Zhang De-Feng, Lu Qing-Hua, Zhou Yan. Novel dynamic fuzzy neural networks algorithm. *Control Engineering of China*, 2009, **16**(4): 464–467, 471  
(张德丰, 卢清华, 周燕. 一种新型的动态模糊神经网络算法. 控制工程, 2009, **16**(4): 464–467, 471)
- Ma Li, Zhang De-Feng, Ma Zi-Long. Dynamic fuzzy neural network method research of the glide window and pruning

- technology. *Acta Scientiarum Naturalium Universitatis Sunyatseni*, 2010, **49**(1): 48–52  
(马莉, 张德丰, 马子龙. 滑动窗与修剪技术的动态模糊神经网络方法研究. 中山大学学报(自然科学版), 2010, **49**(1): 48–52)
- 7 Zuo Jun, Zhou Ling, Li Xiao-Dong. The rule criteria and pruning strategy based on D-FNN algorithm research. *Acta Scientiarum Naturalium Universitatis Sunyatseni*, 2015, **54**(5): 43–48  
(左军, 周灵, 李晓东. 基于规则产生准则与修剪策略的 D-FNN 算法研究. 中山大学学报(自然科学版), 2015, **54**(5): 43–48)
- 8 Platt J. A resource-allocating network for function interpolation. *Neural Computation*, 1991, **3**: 213–225
- 9 Sun Yu-Chao, Li De. Vector map zero-watermark algorithm based on node feature. *Geography and Geo-information Science*, 2017, **33**(3): 17–21  
(孙俞超, 李德. 基于节点特征的矢量地图零水印算法. 地理与地理信息科学, 2017, **33**(3): 17–21)
- 10 Lu Y, Sundararajan N, Saratchandran P. A sequential learning scheme for function approximation by using minimal radial basis function networks. *Neural Computation*, 1997, **9**: 461–478
- 11 Wang Yong-Jie, Bai Yan-Ping. Application of PSO-BP algorithm based on principal component analysis in prediction of GDP and CPI. *Journal of Chongqing University of Technology (Natural Science)*, 2017, **31**(4): 150–154  
(王永杰, 白艳萍. 基于主成分分析的 PSO-BP 算法在 GDP 和 CPI 预测中的应用. 重庆理工大学学报(自然科学), 2017, **31**(4): 150–154)
- 12 Wu S, Er M J. Dynamic fuzzy neural networks—a novel approach to function approximation. *IEEE Transactions on Systems, Man, and Cybernetics, Part B, Cybernetics*, 2000, **30**(2): 358–364
- 13 Peng Y, Yue M. A zero-watermarkings scheme for vector map based on feature vertex distance ratio. *Journal of Electrical and Computer Engineering*, 2015, **2015**(2): 1–6
- 14 Er M J, Wu S. A fast learning algorithm for parsimonious fuzzy neural systems. *Fuzzy Sets and Systems*, 2002, **126**(3): 337–351
- 15 Chen Zi-Hao, Long Hua, Cao Wei. Based on the improved PSO-BP neural network algorithm in the quality assessment of water environment. *Information Technology*, 2017, (8): 11–15, 20  
(陈子豪, 龙华, 曹伟. 基于改进型 PSO-BP 神经网络算法的水质评价. 信息技术, 2017, (8): 11–15, 20)
- 16 Polycarpou M, Conway J. Indirect adaptive nonlinear control of drug delivery systems. *IEEE Transactions on Automatic Control*, 1998, **43**(6): 849–856



**张彩霞** 博士, 佛山科学技术学院自动化学院副教授. 研究方向为智能计算, 智能控制系统与多源信息融合. 本文通信作者. E-mail: zh\_caixia@163.com  
(**ZHANG Cai-Xia** Ph.D., associate professor at the Automated Institute, Foshan University. Her research interest covers intelligent computing, intelligent control system, and multi-source information fusion. Corresponding author of this paper.)



**刘国文** 佛山科学技术学院硕士研究生. 主要研究方向为智能数据处理, 机器学习. E-mail: keanu.l@outlook.com  
(**LIU Guo-Wen** Master student at Foshan University. His research interest covers intelligent data processing and machine learning.)