

列主元 SVD-QR 方法修剪策略参数调整的 D-FNN 算法研究*

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: 针对动态模糊神经网络, 提出了列主元 SVD-QR 方法修剪策略与参数调整的新算法。其中采用列主元 SVD-QR 方法修剪策略从给定的规则库中提取最重要模糊规则, 使得网络结构不会持续增长, 避免了过拟合及过训练现象; 采用扩展的卡尔曼滤波方法把全局算法划分成线性和非线性部分, 线性和非线性参数可以分别被更新, 从而可以达到快速的学习速度。通过对血压的控制来验证所提出算法的有效性, 结果证明了列主元 SVD-QR 方法修剪策略参数调整的 D-FNN 算法具有良好的性能。

关键词: 动态模糊神经网络; 修剪策略; 参数调整; 血压控制

中图分类号: TP301.6 文献标志码: A 文章编号: 0529-6579(2013)02-0008-06

Research on D-FNN Algorithm with the Combination of Column Pivot SVD-QR Method Pruning Strategy and Parameters Adjustment

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: Aiming at the improvement of dynamic fuzzy neural network, a new algorithm is put forward, which combines the pruning strategy using column pivot SVD-QR method with the parameters adjustment. The pruning strategy with column pivot SVD-QR method is used to extract the most important fuzzy rules from a given rule base, which prevents the network structure from sustainable growth, and avoids the overfitting and over-training phenomenon. Extended Kalman filtering method is utilized to divide the global algorithm into linear and nonlinear parts. The linear parameters and nonlinear ones can be updated respectively, thus the fast learning speed is achievable. The validity of the proposed algorithm is verified through the control of blood pressure. The results prove that the D-FNN with the pruning strategy using the column pivot SVD-QR method and the parameters adjustment has a good performance.

Key words: dynamic fuzzy neural network (D-FNN); pruning strategy; parameter adjustment; blood pressure control

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, 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。将模糊系统与神经

网络适当地结合起来, 吸取两者的长处, 则可组成比单独的神经网络系统或单独的模糊系统性能更好的系统。由于二者既有共性又有互补性, 将两者有机地结合起来, 发挥各自的优势, 是智能控制领域研究的主要方向和发展趋势之一。

* 收稿日期: 2012-10-16

基金项目: 广东省自然科学基金资助项目 (S2011020002719)

作者简介: 张德丰 (1963年生), 男, 教授; E-mail: defengz@163.com

1 算法的理论分析与确定

1.1 列主元 SVD-QR 方法修剪策略

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列主元 SVD-QR 方法作为一种修剪技术来选择重要的模糊规则。

列主元 SVD-QR 方法最初由 Golub 等^[1]提出，以解决回归分析中的子集选择问题，在本文中用这种方法从给定的规则库中提取最重要的模糊规则。这种方法的基本思想是用 $\mathbf{H}^{(b)}\boldsymbol{\theta}^{(b)}$ 替换如下线性回归问题中的 $\mathbf{H}\boldsymbol{\theta}$

$$\mathbf{D} = \mathbf{H}\boldsymbol{\theta} + \mathbf{E} \quad (1)$$

其中， $\mathbf{H}^{(b)} \in \mathcal{R}^{n \times b}$ 由 \mathbf{H} 的 b 个列构成，这 b 个列在 \mathbf{H} 中的位置决定了用规则库中哪些规则来逼近向量 \mathbf{D} 。

假设 $\mathbf{H} \in \mathcal{R}^{n \times v}$ 的 SVD 有式 $\mathbf{H} = \mathbf{U} \boldsymbol{\Sigma} \mathbf{S}^T$ 给定，并且通过式 (2) 来定义矩阵

$$\mathbf{H}\boldsymbol{\Pi} = \begin{bmatrix} \mathbf{H}^{(b)} & \mathbf{H}^{(v-b)} \\ b & v-b \end{bmatrix} \quad (2)$$

其中， $\boldsymbol{\Pi} \in \mathcal{R}^{v \times v}$ 是一个交换矩阵。Golub 等人证明^[2]：如果

$$\mathbf{H}^T \mathbf{S} = \begin{bmatrix} \mathbf{S}'_{11} & \mathbf{S}'_{12} \\ \mathbf{S}'_{21} & \mathbf{S}'_{22} \end{bmatrix} \begin{bmatrix} b \\ v-b \end{bmatrix} \quad (3)$$

并且 $\mathbf{S}'_{11} \in \mathcal{R}^{b \times b}$ 为非奇异，则

$$\frac{\sigma_b(\mathbf{H})}{\|(\mathbf{S}'_{11})^{-1}\|_2} \leq \sigma_b(\mathbf{H}^{(b)}) \leq \sigma_b(\mathbf{H}) \quad (4)$$

其中， $\sigma_b(\mathbf{H}^{(b)})$ 和 $\sigma_b(\mathbf{H})$ 分别为 $\mathbf{H}^{(b)}$ 和 \mathbf{H} 的第 b 个奇异值。

这个结果表明，为了获得充分独立的列子集，即对应于模糊规则中最重要的子集，交换矩阵 $\boldsymbol{\Pi}$ 的选择使得产生的 \mathbf{S}'_{11} 子矩阵应不是病态的，从而 $\|(\mathbf{S}'_{11})^{-1}\|_2$ 尽可能地小。这意味着计算的子集 $\mathbf{H}^{(b)}$ 趋向于使它的最小奇异值 $\sigma_b(\mathbf{H}^{(b)})$ 最大化^[3]。解决这个问题可以采用 Golub 等人提出的方法，即通过计算矩阵 $[\mathbf{S}'_{11} \mathbf{S}'_{21}]$ 列主元的 QR 分解来解决^[4]，其中 $\mathbf{S}'_{11} \in \mathcal{R}^{b \times b}$ 和 $\mathbf{S}'_{21} \in \mathcal{R}^{(v-b) \times b}$ 由下式来定义：

$$\mathbf{S} = \begin{bmatrix} \mathbf{S}_{11} & \mathbf{S}_{12} \\ \mathbf{S}_{21} & \mathbf{S}_{22} \end{bmatrix} \begin{bmatrix} b \\ v-b \end{bmatrix} \quad (5)$$

特别地，如果用列主元的 QR 分解来计算^[5]：

$$\mathbf{Q}^T [\mathbf{S}'_{11} \quad \mathbf{S}'_{21}] \boldsymbol{\Pi} = [\mathbf{R}_{11} \quad \mathbf{R}_{12}] \begin{bmatrix} b \\ v-b \end{bmatrix} \quad (6)$$

其中， $\mathbf{Q} \in \mathcal{R}^{b \times b}$ 是正交矩阵， $\boldsymbol{\Pi} \in \mathcal{R}^{v \times v}$ 是交换矩阵，且 $\mathbf{R}_{11} \in \mathcal{R}^{b \times b}$ 是上三角矩阵，则式 (3) 意味着：

$$\begin{bmatrix} \mathbf{S}'_{11} \\ \mathbf{S}'_{21} \end{bmatrix} = \boldsymbol{\Pi}^T \begin{bmatrix} \mathbf{S}_{11} \\ \mathbf{S}_{21} \end{bmatrix} = \begin{bmatrix} \mathbf{R}_{11}^T \mathbf{Q}^T \\ \mathbf{R}_{12}^T \mathbf{Q}^T \end{bmatrix} \quad (7)$$

注意到 \mathbf{R}_{11} 为非奇异，而且 $\|(\mathbf{S}'_{11})^{-1}\|_2 = \|\mathbf{R}_{11}^{-1}\|_2$ 。因此列主元法可产生一个非病态的 \mathbf{R}_{11} 和 \mathbf{S}'_{11} 。

矩阵 $\boldsymbol{\Pi}$ 的每一列只含有一个“1”（其他的元都为 0）。“1”在 $\boldsymbol{\Pi}$ 中的位置决定了 \mathbf{H} 的列在 $\mathbf{H}\boldsymbol{\Pi}$ 中的位置及其在规则库中的位置。为了说明这个问题，假设

$$\mathbf{H} = \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \\ h_{41} & h_{42} & h_{43} \end{bmatrix} \quad \text{且} \quad \boldsymbol{\Pi} = \begin{bmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} \quad (8)$$

则

$$\mathbf{H}\boldsymbol{\Pi} = \begin{bmatrix} h_{12} & h_{13} & h_{11} \\ h_{21} & h_{23} & h_{21} \\ h_{32} & h_{33} & h_{31} \\ h_{42} & h_{43} & h_{41} \end{bmatrix} \quad (9)$$

如果想用两条模糊规则建立一个模型，则应该选择第二和第三个规则^[6]。

b 个最重要的模糊规则的候选者可以通过求解如下简化方程得到：

$$\mathbf{H}^{(b)}\boldsymbol{\theta}^{(b)} = \mathbf{D} \quad (10)$$

其中， $\boldsymbol{\theta}^{(b)} = [\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \dots, \boldsymbol{\theta}_b]^T$ 且 $\mathbf{H}^{(b)}$ 需要像前面一样通过使用 b 个最重要的模糊规则进行归一化处理^[7]。

列主元的 SVD-QR 方法可以归纳成如下几个步骤：

1) 计算 \mathbf{H} 的 SVD，也即 $\mathbf{H} = \mathbf{U}\boldsymbol{\Sigma}\mathbf{S}^T$ 同时保存 $\boldsymbol{\Sigma}$ 和 \mathbf{S} 。

2) 检查 $\boldsymbol{\Sigma} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$ 中的奇异值，确定用来构建模型的模糊规则数 b ，其中 $b \leq \text{rank}(\mathbf{H})$ 。

3) 通过式 (5) 把 \mathbf{S} 分割成 $[\mathbf{S}'_{11} \mathbf{S}'_{21}]$ 。将 QR 列主元法用于 $[\mathbf{S}'_{11} \quad \mathbf{S}'_{21}]$ 可得到交换规则 $\boldsymbol{\Pi}$ 。交换矩阵 $\boldsymbol{\Pi}$ 中前 b 列中“1”的位置对应于规则库中 b 个最重要的模糊规则。

4) 基于 b 个最重要的模糊规则构造归一化矩阵 $\mathbf{H}^{(r)} \in \mathcal{R}^{n \times b}$

5) 用 SVD 方法求解 $\mathbf{H}^{(b)}\boldsymbol{\theta}^{(b)} = \mathbf{D}$ 得到 $\boldsymbol{\theta}^{(b)}$ 。

SVD-QR 算法不需要明确地构造相关矩阵, 因此, 避免了不必要的数字和舍入误差。此外, 众所周知, 与特征值相比, 奇异值的计算更有效, 且具有更高的数值计算稳定性。因此, 从应用的角度来看, SVD-QR 算法优于 ED (特征值分解) 算法^[8]。

1.2 D-FNN 参数调整方法

卡尔曼滤波 (Kalman filter, KF) 算法可以用于结果参数调整。本文中, 我们还选择扩展的卡尔曼滤波方法 (extended Kalman filter, EKF) 来调整这些参数。作为一种非线性更新算法, EKF 方法可以用来调节 D-FNN 的所有参数。由于全局的方法将涉及大矩阵运算, 遇到巨大计算负担以及占用大量的内存, 因此, 这种全局方法可以被划分为一系列可处理的子问题。在实际应用中, 可以用卡尔曼滤波 (KF) 方法来调节结果参数, 同时, EKF 方法用于更新前提参数的中心和宽度, 从而使得所有参数都被修正。这一思想等价于把全局算法分解为一系列解耦的算法^[9]。

图 1 所示为 EKF 用于 D-FNN 参数调整的原理图。实验结果表明, 高斯中心对系统性能影响不大, 因此只对高斯宽度进行更新。




图 1 EKF 用于 D-FNN 参数调整的原理图

Fig. 1 EKF for D-FNN parameter adjustment principle diagram

结果参数的更新是线性的, 而高斯宽度的更新是非线性的, 可以用 EKF 作如下优化:

$$\mathbf{K}_i^\sigma = \frac{\mathbf{S}_{i-1}\mathbf{F}_i}{1 + \mathbf{F}_i^\top\mathbf{S}_{i-1}\mathbf{F}_i}$$

$$\mathbf{S}_i = \mathbf{S}_{i-1} - \mathbf{K}_i^\sigma\mathbf{F}_i^\top\mathbf{S}_{i-1} \quad i = 1, 2, \dots, n$$

$$\sum_i = \sum_{i-1} + \mathbf{K}_i^\sigma(\mathbf{T}_i^\top - \boldsymbol{\Psi}_i^\top\mathbf{W}_{i-1}) \quad (11)$$

初始条件为 $\sum_0 > 0$ 以及 $\mathbf{S}_0 = \rho\mathbf{I}$, 其中, ρ 为一个小的正数, \mathbf{K}_i^σ 是 i 第次观测的增益矩阵, \mathbf{S}_i 是第 i 次观测误差协方差矩阵, $\sum_i = (\sigma_1, \sigma_2, \dots, \sigma_u)$ 表示经过 i 次迭代后的高斯宽度向量, $\mathbf{F}_i = (\delta\sigma_1, \dots,$

$\delta\sigma_j, \dots, \delta\sigma_u)$ 是第 i 次观测宽度的梯度向量。

$$\mathbf{F}_i = \frac{\partial \mathbf{Y}_i^\top}{\partial \sum_{i-1}} \Big|_{\Sigma = \sum_{i-1}}$$

$$= -2 \sum_{i-1} \| \mathbf{X}_i - \mathbf{C}_j \|^2 \psi_j \sum_{k=1}^u (w_j - w_k) \psi_k$$

$$j \in \{1, 2, \dots, u\} \quad (12)$$

其中, \mathbf{C}_j 和 w_j 分别是中心和第 j 个 RBF 单元的权值, ψ_j 是第 j 个归一化层的输出^[10]。

需要强调的是, KF 或 EKF 算法用于 D-FNN, 当一条规则产生/去除或者宽度有任何的调整时, 将产生额外的计算负担, 即在那些情况下, 迭代将必须从第一个样本开始。

2 实验结果与分析

在本文中, 我们的目的是验证采用列主元 SVD-QR 方法修剪策略与卡尔曼滤波方法来调整这些参数的 D-FNN 系统能否逼近一个动态而且是时变的系统, 通过药物注射系统的直接逆控制来验证我们所采用算法的有效性。

当 D-FNN 在药物注射系统中作为控制器时, 我们的目标是得到适当的控制行为 $u(t)$, 使输出值 $y(t)$ 逼近期望值 $r(t)$, 为了实现这个目标, 涉及到学习和应用两个阶段。在学习阶段, 潜在对象的时变动态逆模型被 D-FNN 辨识, 然后, D-FNN 在应用阶段作为控制器产生控制行为^[11]。

逆模型通常由式 (13) 表示的 NARX 模型经过简单推导得到式 (14):

$$y(t) = f[y(t-1), \dots, y(t-n_y), x(t-1), \dots, x(t-n_x)] + e(t) \quad (13)$$

$$u(t) = f^{-1}[y(t+1), y(t), \dots, y(t-n_y), u(t-1), u(t-n_u)] \quad (14)$$

由式 (14) 可以看到 $u(t)$ 的产生还需要知道未来的值 $y(t+1)$ 。为了克服这个问题, 通常用 $r(t+1)$ 代替 $y(t+1)$ 。这个假设是合理的, 因为 $r(t)$ 与参考信号有关, 通常被称为前一步^[12]。

而另一个问题是逆映射 f^{-1} 是否一直存在? 这里暂不考虑式 (14) 中的逆模型是否存在, 可以用 NARX 模型直接构造如下的逆模型:

$$u(t) = g[y(t-1), \dots, y(t-n_y), u(t-1), u(t-n_u)] \quad (15)$$

从而 $g \approx f^{-1}$ 。应当指出, 在物理意义上 g 不是 f 的准确逆模型, 它只是数学上逼近这个逆映射^[13]。

一般的病人响应模型描述如下^[14]

$$\Delta p(k) = 0.741\Delta p(k-1) +$$

$$0.187u(k - 3) + 0.075u(k - 6) \quad (16)$$

为了产生训练数据，药物注射率 $u(k)$ 取为：

$$u(k) = |A \sin(2\pi k/250)| \quad (17)$$

设 $A = 50$ ，初始条件为：当 $t \leq 0$ 时， $\Delta p(t) = 0$ ， $u(t) = 0$ ，根据式 (16) 和式 (17) 提取 200 个样本。式 (16) 的逆模型取为：

$$\hat{u}(t) = f(\Delta p(k), \Delta p(k - 3)) \quad (18)$$

其中， f 是 D-FNN，它代表式 (16) 的逆映射。基于列主元 SVD-QR 方法参数调整的 D-FNN 控制器训练的结果如图 2 所示。

图 2 (a) 是训练阶段的输出误差；图 2(b) 是训练阶段的均方根误差；图 2 (c) 是训练阶段期望和实际的注射率；图 2 (d) 是训练阶段期望与实际注射的误差。




图 2 训练阶段参数变化模型训练结果

Fig. 2 Training phase parameter changes in model training results

(a) 训练过程中输出误差 (b) 训练过程中均方根误差 (c) 训练阶段期望 (+) 和实际 (o) 的注射率比较 (d) 训练阶段期望与实际注射的误差

然后，把训练好的 D-FNN 用于控制对象。假定采样时间是 15 s，病人初始的血压设为 140 mm-Hg (1 mmHg = 133.322 Pa)，最后的血压要求降低到 100 mmHg，如图 3a 所示。如果期望的血压变化中含有方差为 1 mmHg 的白噪声，如图 3b 所示。图 3c 显示了在噪声环境下的血压误差，药物注射率和血压之间的关系如图 3d 所示。由仿真结果可以看到血压随着药物注射的变化而平稳地变化，并没有明显的延迟，这表明 D-FNN 对系统进行了很

好的建模。仿真的结果如下：

血压变化量 $\Delta p_{\max} = 5.91$ ；平均动脉血压 $MAP_{\min} = 97.3$ ；平均动脉血压变化量 $\Delta MAP_{\max} = 2.63$

由上述仿真结果可以看到：血压的变化很好地满足了药物注射系统的约束条件。

为了跟踪模型的时变特性，对一种参数和结构都随时间变化的复杂时变系统进行仿真。D-FNN 的性能根据 Δp_{\max} 和 RMSE 进行了评估，结果如




图 3 测试阶段参数变化模型测试结果

Fig. 3 Parameter changes in the model test results of the testing phase

(a) 实际输出动脉血压 (b) 噪声环境下实际的血压变化 (c) 噪声环境下药物注射率 (d) 药物注射率与血压变化

表 1 所示。

表 1 D-FNN 控制器的性能

Table 1 The performance of the D-FNN controller

模型	规则数	Δp_{\max}	MAP_{\min}	ΔMAP_{\max}	RMSE
情况 1	11	9.91	95.62	2.47	3.70
情况 2	10	9.58	96.26	3.38	3.26
情况 3	9	12.80	99.92	5.42	5.95

文献 [15] 中的结果列于表 2 中。与文献 [15] 的方法 IANC 相比, 我们的测试结果 (图 3d) 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 [15] 相比较的结果列于表 2 中。

表 2 IANC 与 D-FNN 的性能比较

Table 2 Performance comparison of IANC with D-FNN

方法	$\Delta p_{\max}/\text{mmHg}$	方法	$\Delta p_{\max}/\text{mmHg}$
IANC	10	D-FNN	9.01

从仿真结果来看, 由于使用了列主元 SVD-QR 方法修剪技术, 规则数很快达到稳定, 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。

考虑系统作为时变结构, 从表 2、图 3d 来看, 仿真结果表明 D-FNN 控制器具有良好的性能, 没有出现明显的延迟和震荡, 这也表明 D-FNN 很好地学习了模型特性, 也说明 D-FNN 控制器优于文献 [16] 的方法。

3 结论

一个规则可能最初是活跃的, 但逐渐对系统几乎没有贡献了。因此, 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。可以用 KF 方法来调节结果参数, 同时, EKF 方法用于更新前提参数的中心和宽度, 从而使得所有参数都被修正。EKF 是基于在线的学习算法, 该算法可用于平滑、滤波或者

预测非线性动态系统的状态, 同其他基于梯度的在线算法相比, EKF 可以加快收敛速度。仿真结果表明, 由于使用了列主元修剪策略与参数调整算法使得 D-FNN 具有更紧凑的系统结构、强大的泛化能力以及快速的学习速度。

参考文献:

- [1] PLATT J. A resource-allocating network for function interpolation[J]. *Neural Computation*, 2007, 19(2): 213 - 225.
- [2] BRUNELLI R, POGGIO T. Face recognition: features versus templates [J]. *IEEE Trans Pattern Analysis and Machine Intelligence*, 2010, 25(10): 1042 - 1053.
- [3] 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[J]. *中山大学学报: 自然科学版*, 2010, 49(1): 48 - 52.
- [4] HONG Z. Algebraic feature extraction of image for recognition[J]. *Patt Recog*, 2009, 24(2): 211 - 219.
- [5] TURK M A, PENTLAND A P. Eigenfaces for recognition [J]. *Cognitive Neuroscience*, 2008, 3(1): 71 - 86.
- [6] WANG L X, MENDEL J M. Fuzzy basis function, universal approximation, and orthogonal least squares learning[J]. *IEEE Trans Neural Networks*, 2009, 3: 907 - 914.
- [7] EICKELER S, MUELLER S, RIGOLL G. High quality face recognition in JPEG compressed images [C]. *Proc IEEE Int Conf Image Processing*, 2008: 672 - 676.
- [8] WU S Q, ER M J. Dynamic fuzzy neural networks: a novel approach to function approximation[J]. *IEEE Trans Syst Man Cybern Part: B*, 2010, 30: 358 - 364.
- [9] LU Y, SUNDARARAJAN N, SARATCHANDRAN P. A sequential learning scheme for function approximation by Using minimal radial basis function networks[J]. *Neural Computation*, 2009, 19(2): 461 - 478.
- [10] 任爱红. 模糊随机过程函数列均方差一致 Henstock 积分的可积性 [J]. *中山大学学报: 自然科学版*, 2010, 51(4): 41 - 44.
- [11] CHELLAPPA R, WILSON C L, SIROHEY S. Human and machine recognition of faces: a survey [J]. *Proc IEEE*, 2009, 93(2): 705 - 740.
- [12] VALENTIN D, ABDI H, O'Toole A J, et al. Connectionist models of face processing: a survey [J]. *Patt Recog*, 2009, 27(4): 1209 - 1230.
- [13] JANG J-S R. ANFIS: adaptive-network-based Fuzzy inference system [J]. *IEEE Trans Syst Man Cybern*, 1993, 23(3): 665 - 684.
- [14] KADIRKAMANATHAN V, NIRANJAN M. A function estimation approach to sequential learning with neural networks[J]. *Neural Computation*, 2008, 16(4): 954 - 975.
- [15] POLYCARPOU M M, CONWAY J Y. Indirect adaptive nonlinear control of drug delivery systems [J]. *IEEE Trans Automat Contr*, 2010, 43: 849 - 856.
- [16] BEHBEHANI K, CROSS R R. A controller for regulation of mean arterial blood pressure using optimum nitroprusside infusion rate[J]. *IEEE Trans Biomedical Engineering*, 2010, 47: 513 - 521.