

文章编号: 1000-8152(2008)01-0047-06

发电机组的一种多模型自学习控制

袁小芳, 王耀南, 吴亮红

(湖南大学 电气与信息工程学院, 湖南 长沙 410082)

摘要: 针对发电机组励磁与汽门的综合控制, 研究了一种多模型自学习控制(MMSC). 首先, 建立机组不同工况下的样本数据并归纳模糊控制器(FLC)规则, 随后采用模糊聚类算法将样本约简为典型工况, 并得到对应于典型工况的模型库与控制器库. MMSC的控制量为多个FLC输出的加权集成, 而加权系数由模型匹配程度决定. 采用学习能力强的支持向量机来实现FLC的自学习和在线优化. 仿真实验证了MMSC的控制性能和效果.

关键词: 模糊控制; 学习系统; 支持向量机; 多模型; 发电机组

中图分类号: TP273 **文献标识码:** A

A multi-model self-learning control system for synchronous generator

YUAN Xiao-fang, WANG Yao-nan, WU Liang-hong

(College of Electrical and Information Engineering, Hunan University, Changsha Hunan 410082, China)

Abstract: As excitation and turbine control of generators confront with challenges of strong nonlinear characteristics and varying operation points, this paper proposed a multiple models self-learning control(MMSC). Firstly, fuzzy control rules for generators at various operation points were derived from operation samples. Then fuzzy clustering algorithm was employed to reduce the models at various operation points to a multi-model bank with corresponding fuzzy logic controller (FLC). Here the control signal of MMSC was simply the weighted sum of FLC, which were decided by their matching degree of multiple models based on fuzzy logic. Support vector machines (SVM), a power machine learning algorithm, were applied to the self-learning of FLC. Simulation results showed the desirable performance and control capability of the proposed MMSC.

Key words: fuzzy control; learning systems; support vector machines(SVM); multiple models; generator

1 引言(Introduction)

发电机组励磁与汽门的综合控制是改善电力系统暂态稳定性的一种有效措施, 对于提高系统的稳定性和运行质量有重大影响^[1]. 针对励磁和汽门这个多变量、非线性、强耦合的复杂系统, 一些学者探讨了不同的控制方法, 如直接反馈线性化方法^[2], Backstepping解耦控制^[3]、自适应Backstepping方法^[4]、基于Hamilton能量函数的非线性分散控制^[5]、基于扩张状态观测器的分散协调控制^[6], 以及神经网络逆系统方法^[7]、神经网络间接自适应控制^[8]等. 由于这些方法建立在复杂非线性处理或多次迭代运算基础之上, 不易于解决机组综合控制中的非线性、大范围运行及工况变化等问题. 考虑到发电机组工况是变化的, 而同一工况下的控制参数是相同或相近的, 本文研究了一种多模型自学习控制(multiple models

self-learning control, MMSC), 建立针对典型工况的模型库, 并设计相应控制器库.

模糊逻辑控制器(fuzzy logic controller, FLC)应用广泛, 无需被控对象的精确数学模型, 系统鲁棒性强, 因而本文采用FLC设计控制器库. 由于FLC规则是根据经验设定的, 不具有学习和适应的能力, 文章由支持向量机(support vector machines, SVM)^[9,10]算法来调整FLC规则, 实现控制规则的自学习. SVM是Vapnik等提出的新的机器学习算法, 非线性逼近能力和学习能力强, SVM离线逼近FLC规则曲面, 再以梯度学习算法在线调整SVM网络权值的方式实现FLC规则的学习和优化.

2 控制问题描述(Problem introduction)

在多机电力系统中, 若存在无穷大母线, 就令该母线为参考点, 则第*i*台发电机的数学模型可表示

收稿日期: 2006-03-23; 收修改稿日期: 2007-03-07.

基金项目: 国家自然科学基金资助项目(60775047); “863”计划资助项目(2007AA04Z244).

为^[6]:

$$\begin{cases} \dot{\delta}_i = \omega_i - \omega_0, \\ \dot{\omega}_i = \frac{\omega_0}{H}(P_{mi} - P_{ei}) - \frac{D}{H}(\omega_i - \omega_0), \\ \dot{E}'_{qi} = \frac{1}{T_{d0i}}(u_{fi} - E_{qi}), \\ \dot{P}_{mi} = -\frac{1}{T_{Bi}}(P_{mi} - P_{m0i} - \mu_i), \\ \dot{\mu}_i = -\frac{1}{T_{\mu i}}(\mu_i - \mu_{0i}) + \frac{1}{T_{\mu i}}u_{2i}. \end{cases} \quad (1)$$

电气约束方程:

$$\begin{cases} I_{di} = -E'_{qi}B_{ii} + \sum_{j=1, j \neq i}^n E'_{qi}Y_{ij} \sin(\delta_{ij} - \phi_{ij}), \\ I_{qi} = E'_{qi}G_{ii} + \sum_{j=1, j \neq i}^n E'_{qi}Y_{ij} \cos(\delta_{ij} - \phi_{ij}), \\ P_{ei} = E'^2_{qi}B_{ii} + E'_{qi} \sum_{j=1, j \neq i}^n E'_{qi}Y_{ij} \cos(\delta_{ij} - \phi_{ij}), \\ Q_{ei} = -E'^2_{qi}B_{ii} + E'_{qi} \sum_{j=1, j \neq i}^n E'_{qi}Y_{ij} \sin(\delta_{ij} - \phi_{ij}), \\ E_{qi} = E'_{qi} + (x_{di} - x'_{di})I_{di} = x_{adi}I_{fi}, \\ V_{ti} = \frac{\sqrt{P_{ei}^2 + Q_{ei}^2}}{\sqrt{I_{di}^2 + I_{qi}^2}}. \end{cases} \quad (2)$$

以上各式中: δ 为功角, ω 为转速, V_t 为端电压, μ 为主汽门开度, u_f 和 u_2 分别为励磁控制和汽门调节, 其他各个变量的物理意义详见文[6].

3 多模型自学习控制系统(Multiple models self-learning control system)

发电机组综合控制就是协调各台机组的励磁控制量 u_f 与汽门开度控制量 u_2 , 达到稳定功角 δ 和端电压 V_t 的目的^[7]. 当实际变量值 δ 和 V_t 与期望值 δ_r 和 V_{tr} 存在一定偏差时, 综合控制中就以调控 u_2 与 u_f 来实现. 多模型自学习控制(MMSC)结构如图1所示, 包括模型库与控制器库2个部分. 模型库中包含了 N 种子模型, 对应于机组的 N 种典型工况. 控制器库由 N 个模糊控制器(FLC)构成, 且每一个FLC是针对一种子模型设计规则.

3.1 模型库(Multiple models bank)

采用变量(δ, V_t)来衡量机组的工况, 以此建立模型库. 设模型库的规模为 N , 用 n 表示每一种子模型, $n = 1, 2, \dots, N$. 由模糊集理论计算实际工况(δ, V_t)与模型库中子模型 n 的匹配程度 f_n , 并作为MMSC的集成加权系数 w_n ($n = 1, 2, \dots, N$). 图2描述了模型库中的子模型的区间划分, 划分依据为变量(δ, V_t), 图中阴影部分为子模型的重叠或交界

部分, 依据模糊隶属函数值决定其归属.

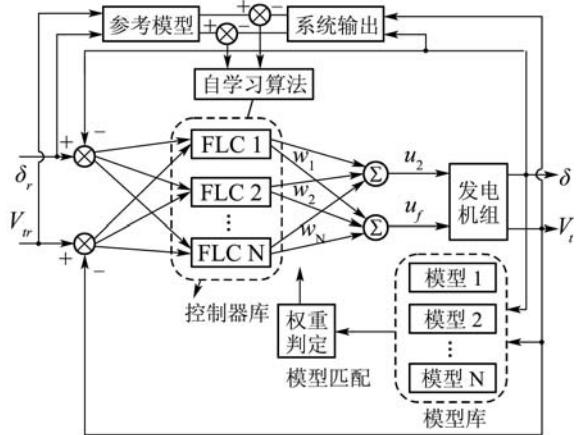


图1 多模型自学习控制系统

Fig. 1 Multiple models self-learning control system

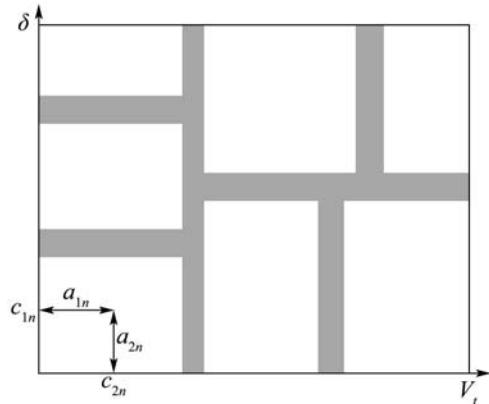


图2 子模型区间划分

Fig. 2 Partition of sub-model range

对于第 n 个子模型区间, 建立变量(δ, V_t)的模糊隶属函数, 其数学式为

$$\mu_{\delta n} = \frac{1}{1 + (\frac{\delta - c_{1n}}{a_{1n}})^2}, \mu_{V n} = \frac{1}{1 + (\frac{V_t - c_{2n}}{a_{2n}})^2}. \quad (3)$$

其中: c_{1n}, c_{2n} 分别表示第 n 个子模型中变量(δ, V_t)的中心值, a_{1n}, a_{2n} 分别表示第 n 个子模型中变量(δ, V_t)的宽度, $n = 1, 2, \dots, N$. 由实际工况与子模型 n 对应变量的隶属度 $\mu_{\delta n}, \mu_{V n}$, 得到当前工况与子模型 n 的匹配度 f_n 为

$$f_n = \mu_{\delta n} * \mu_{V n}. \quad (4)$$

其中 $f_n \in [0, 1]$ 且 $\sum_{n=1}^N f_n = 1$. 匹配度 f_n 越大, 则对应FLC输出的加权系数越大. 加权系数 w_1, w_2, \dots, w_N 在数值上满足

$$[w_1, w_2, \dots, w_N]^T = [f_1, f_2, \dots, f_N]^T. \quad (5)$$

而且 $w_n \in [0, 1]$ 且 $\sum_{n=1}^N w_n = 1$.

3.2 控制器库(Controller bank)

控制器库中的 N 个控制器均为双输入双输出的模糊逻辑控制器(FLC), 其输入为 e_δ, e_{Vt} , 输出为 u_2, u_f , 结构如图3所示, 具体设计详见文[11]. 输入量 e_δ, e_{Vt} 分别为变量(δ, V_t)的误差, 经过模糊化后为 E_δ, E_{Vt} , 利用恰当的量化因子 K_{e1}, K_{e2} 将数据转化为合适的语言值{ NB, NS, Z, PS, PB } = {“负大”, “负小”, “零”, “正小”, “正大”}, 对应于{“-1”, “-0.5”, “0”, “0.5”, “1”}. 同样地, 输出量 u_2, u_f 是 U_2, U_f 选择适当的比例因子 K_{u1}, K_{u2} 并去模糊化后的控制量. 模糊规则采用“IF-THEN”模糊关系式, 模糊判决采取隶属度最大法或加权平均法来计算^[11].

此时, MMSC的实际控制量为 N 个FLC输出的加权集成:

$$u_2 = \sum_{n=1}^N w_n * u_{2n}, u_f = \sum_{n=1}^N w_n * u_{fn}. \quad (6)$$

下标 n 为控制器库中第 n 个FLC的对应量. 这里的集成方式为加权系数方式, 既体现子模型的针对性, 又避免模型切换之间的振荡.

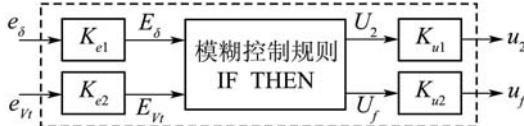


图 3 FLC结构

Fig. 3 FLC structure

4 模型库与控制器库的构造(Multiple models bank and controller bank construction)

4.1 初始样本(Initial operating samples)

根据机组的不同状态 $\vec{\delta} = \{\delta_1, \delta_2, \dots, \delta_a\}, \vec{V}_t = \{V_{t1}, V_{t2}, \dots, V_{tb}\}$, 取不同的(δ, V_t)进行组合, 得到 $a * b = ab$ 种工况, 涵盖了机组的很大范围运行, 作为建立模型库与控制器库的初始样本. 在每一种工况下, 通过给予一定量的汽门开度偏差 Δu_2 和励磁电压偏差 Δu_f , 从而得到相应的功角偏差 e_δ 与端电压偏差 e_{Vt} , 而且给定偏差量 Δu_2 和 Δu_f , 尽量能够使得变量 E_δ, E_{Vt} 分别落入{ NB, NS, Z, PS, PB }区域. 依据专家经验得到了FLC的 $5 \times 5 = 25$ 条规则, 即:

rule1 : IF E_δ is PB and E_{Vt} is PB
THEN U_2 is NS and U_2 is NB ;
:
rule25 : IF E_δ is NB and E_{Vt} is NB
THEN U_2 is PB and U_2 is PS .

用矩阵 $Rule_0$ 来表示控制规则:

$$Rule_{0j} = \begin{bmatrix} PB & PB & NS & NB \\ \vdots & \vdots & \vdots & \vdots \\ NB & NB & PB & PS \end{bmatrix}_{25 \times 4}.$$

其中 $j = 1, 2, \dots, ab$.

若用 {“-1”, “-0.5”, “0”, “0.5”, “1”} 来表示{ NB, NS, Z, PS, PB }, 则矩阵 $Rule_0$ 等价于

$$Rule'_{0j} = \begin{bmatrix} 1 & 1 & -0.5 & -1 \\ \vdots & \vdots & \vdots & \vdots \\ -1 & -1 & 1 & 0.5 \end{bmatrix}_{25 \times 4}.$$

矩阵中第1~4列依次为 $E_\delta, E_{Vt}, U_2, U_f$, 而每一行的4个数值量则对应于一条控制规则rule.

4.2 模型库与控制器库构造(Bank construction based on clustering algorithm)

对于 ab 种工况, 每种工况都依据经验设计了FLC规则, 即 25×4 的矩阵 $Rule'_0$. 通过分析不难发现, 某些工况下的规则矩阵 $Rule'_0$ 是相同或相近的, 因而采用模糊聚类算法^[12]将相同或相近规则矩阵 $Rule'_0$ 所对应的若干种工况归类为一种模型, 由此建立模型库, 每一种子模型采用一个FLC, 从而建立控制器库. 算法步骤如下:

1) 数据转换. 规则矩阵 $Rule'_0$ 中的前两列为前提部分, 是相同的, 而体现规则差别的就是后两列, 即结论部分. 为方便计算, 将矩阵 $Rule'_0$ 的前两列省略, 只留下后两列, 即 25×2 的矩阵, 并将 25×2 的矩阵拉伸为一行 1×50 , 即 $Rule_j = [-0.5 \ -1 \ \dots \ 1 \ 0.5]_{1 \times 50}, j = 1, 2, \dots, ab$. 这样待聚类对象的论域为 $Rule = [Rule_1 \ Rule_2 \ \dots \ Rule_{ab}]^T$, 其中 ab 为样本个数, 每一个样本 $Rule_j (j = 1, 2, \dots, ab)$ 由50个特征参数值来描述, 即 $Rule_j = [Rule_{j1} \ Rule_{j2} \ \dots \ Rule_{j50}]$, 此时 $Rule_{ji}$ 表示第 j 个样本相应于第 i 个特征参数值. 采用标准化处理将特征参数值压缩到[0, 1]区间:

$$Rule'_{ji} = \frac{Rule_{ji} - Rule_{min}}{Rule_{max} - Rule_{min}}, \quad j = 1, 2, \dots, ab, i = 1, 2, \dots, 50.$$

故标准化后的待聚类对象论域为

$$Rule' = [Rule'_1 \ Rule'_2 \ \dots \ Rule'_{ab}]^T.$$

2) 标定. 建立对象的模糊相似关系 R , R 的隶属函数 $\mu_R(Rule'_i, Rule'_j)$ 表示 $Rule'_i$ 与 $Rule'_j$ 按其性质的相似程度. R 为相似矩阵 $R = [r_{ij}], r_{ij} = \mu_R(Rule'_i, Rule'_j)$. 计算 r_{ij} 的方法较多, 如数量积法、相关系数法、绝对指数法等, 这里由最大最小法来计算 r_{ij} :

$$r_{ij} = \frac{\sum_{k=1}^{50} \min(Rule'_{ik}, Rule'_{jk})}{\sum_{k=1}^{50} \max(Rule'_{ik}, Rule'_{jk})}. \quad (7)$$

3) 聚类. 根据模糊理论, 在求出相似矩阵 $R = [r_{ij}]$ 后, 计算 R 的模糊等价关系矩阵 R^* , 再应用 λ 截矩阵进行模糊聚类. 对于任意 $\lambda \in [0, 1]$ 截取的 λ 截关系所对应的 λ 截矩阵 R_λ^* , 这样每一个普通截矩阵 R_λ^* 可以决定一个水平的分类. 对于任一 $\lambda \in [0, 1]$, 分类时 R_λ^* 中各元素改为这样取值: 大于或等于 λ 的元素都改取为 1, 小于 λ 的元素都改取为 0, 根据中的 1 与 0 的排列情况即可分类.

此时 ab 种样本工况就聚类为 N 种典型工况, 根据工况的合并情况确定图 2 所示的子模型区间并建立模型库. 每一种子模型对应于一个 FLC, 便建立了控制器库. 模型库与控制器库的建立依据了一些专家经验的, 显然不是最优的, 实际控制中需要考虑优化调整模型库与控制器库. 由图 2 可知, 所有工况都已经隶属于某一个子模型区间, 为了便于在线优化和计算简便, 这里采取固定的模型库, 而以优化调整控制器库中的控制规则来优化性能. 算法中 λ 取值将影响规模 N 的大小. N 过大, 计算量大, 学习优化不容易; N 过小, 不足以反映不同工况. 就发电机组控制而言, 可以将规模 N 取值在 5~10 之间比较合适.

5 控制器库学习(Learning of controller bank)

支持向量机(SVM)^[9]是 Vapnik 在统计学习理论基础上提出的一种新型机器学习方法, 非线性逼近能力和学习能力强, 在非线性建模与控制领域都得到了不少研究. SVM 学习是基于结构风险最小化(SRM)准则, 比基于经验风险最小化(ERM)准则的神经网络具有更强的理论依据, 而且克服了神经网络过学习、泛化能力不强、依赖经验来选择结构和类型等缺点. 在研究支持向量机-模糊推理自学习控制器^[10]的基础上, 本文将 SVM 回归用于控制器库中 FLC 的学习优化, 其详细描述可参考文[10].

5.1 离线学习(Off-line learning)

聚类后将得到规模为 N 的模型库与控制器库, 每一个 FLC 可以理解为 2 个如图 4 所示的规则曲面, 即 U_2 关于 E_δ 与 E_{Vt} 的规则曲面, U_f 关于 E_δ 与 E_{Vt} 的规则曲面, 离线学习中就是由 SVM 回归来逼近规则曲面, 从而将 FLC 规则转化为 SVM 网络权值参数, 便于由梯度算法实现控制规则的在线自学习.

由聚类得到的控制器库, 建立学习样本集 $\{(E_1, E_2), U\}, \dots, ((E_{1n}, E_{2n}), U_n)\} \subset R^2 \times R$, SVM 回归的学习过程等价于二次规划问题, 其具体学习算法描述见^[9,10]. 学习结果得到支持向量 $((E_{1i}, E_{2i}), U_i)$ 和对应的系数 $(\alpha_i^* - \alpha_i)$, 用 \vec{E}_i 表

示 (E_{1i}, E_{2i}) , 从而得到回归函数为

$$f(\vec{E}) = \sum_{i=1}^g (\alpha_i^* - \alpha_i) K(\vec{E}, \vec{E}_i) + b. \quad (8)$$

这里 g 表示支持向量个数, 用 W_i 表示 $(\alpha_i^* - \alpha_i)$, 采用 RBF 核函数: $K(x_i, x_j) = \exp\left(-\frac{|x_i - x_j|^2}{\sigma^2}\right)$, 方程(8) 可表示为

$$\begin{aligned} f(\vec{E}) &= \sum_{i=1}^g W_i K(\vec{E}, \vec{E}_i) + b = \\ &\sum_{i=1}^g W_i \exp\left(-\frac{|\vec{E} - \vec{E}_i|^2}{\sigma^2}\right) + b. \end{aligned} \quad (9)$$

SVM 在结构上为一个 3 层前向网络, 其输入层节点有 2 个, 对应于 E_1 和 E_2 , 隐层节点数目就是支持向量数目, 即每一个隐层节点对应一个支持向量, 输出层节点 1 个, 即 U . 输入层与隐层的连接权值为 1, 隐层与输出层的连接权值为 $(\alpha_i^* - \alpha_i)$. 由于有 $2N$ 个规则曲面, 因而学习后将得到 $2N$ 个 SVM 网络.

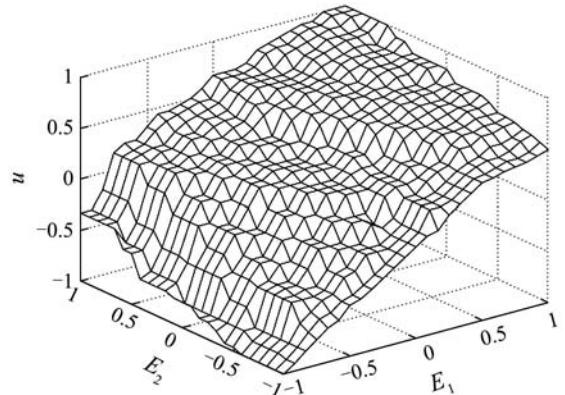


图 4 FLC 的输入-输出规则曲面

Fig. 4 Input-output relation of FLC

5.2 在线自学习(Online self-learning)

变尺度梯度优化(MDFP)算法的基本思想是, 在极小点附近用 2 阶 Taylor 多项式近似目标函数, 进而求出极小点的估计值. 算法的具体推导过程参考文[10], 可知支持向量机网络权值的递推公式为

$$\begin{cases} W_{k+1} = W_k - \frac{H_k E_k \cdot \nabla E_k}{\beta_k}, \\ H_{k+1} = \lambda^{-1} (H_k - \frac{H_k \nabla E_k \cdot \nabla E_k^T \cdot H_k}{\beta_k}), \\ \beta_{k+1} = \lambda + \nabla E_k^T \cdot H_k \cdot \nabla E_k. \end{cases} \quad (10)$$

这里 k 为采样, $0 < \lambda < 1$ 为遗忘因子, H 为 Hessian 矩阵且 $H_1 = I$ (单位阵), E_k 为误差向量, 分别为 $\delta_r - \delta_k$ 和 $V_{tr} - V_{tk}$, ∇E_k 表示 E_k 的梯度. 下文将以 $E_k = \delta_r - \delta_k$ 为例说明 SVM 参数调整的实现. 由于 H_k 是正定的, 从式(10) 中可以看出, H_{k+1} 也是正定阵, β_k 总是正数, 修正公式 W_{k+1} 是沿着 E_k 的负梯

度方向一致收敛, 从而保证学习算法的收敛性。下面计算网络权值的梯度:

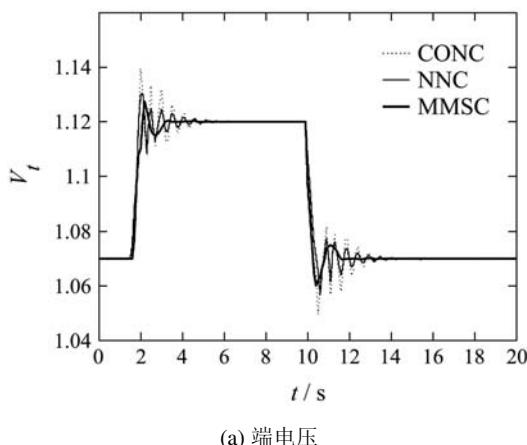
$$\begin{aligned} \nabla E_k = \frac{\partial J}{\partial W_k} &= \frac{\partial J}{\partial \delta_k} \cdot \frac{\partial \delta_k}{\partial u_{2k}} \cdot \frac{\partial u_{2k}}{\partial W_k} = \\ &(\delta_k - \delta_r) \frac{\partial \delta_k}{\partial u_{2k}} K_{u1} w_n K(\vec{E}, \vec{E}_k), \quad (11) \end{aligned}$$

其中 \vec{E}_i 仍为 (E_1, E_2) , $\frac{\partial \delta_k}{\partial u_{2k}}$ 可以用 $\frac{\delta_k - \delta_{k-1}}{u_{2k} - u_{2(k-1)}}$ 近似地计算。实际误差调整量中包含子模型加权系数 w_n , 以此反映其对整个 MMSC 输出的贡献。每一个 SVM 网络均按照类似的梯度算法在线调整优化权值, 经过一定量的学习, SVM 网络权值趋于稳定。

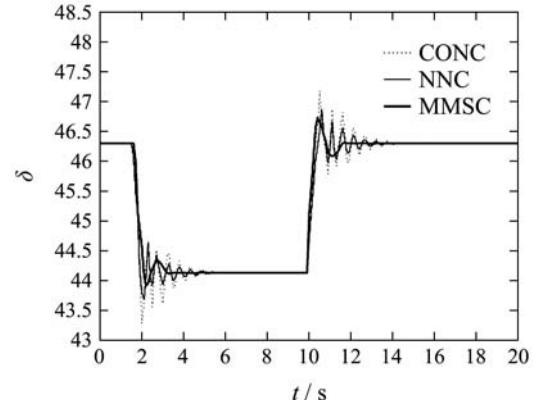
6 实例分析(Simulation study)

这里以文[6]中的典型3机系统进行仿真研究, 3机系统结构图以及实际参数和工作点详见文[6]。这里将 MMSC 与传统的自动电压控制器和汽门调速器(CONC)(结构和参数见[8])、文[8]中的 RBF 网络控制器(NNC)进行了对比。MMSC 设计的相关参数为: 初始样本取 $\delta = \{100, 90, 80, 70, 60, 50, 40, 30, 20\}$, $V_t = \{1.1, 1.0, 0.9, 0.8, 0.7, 0.6, 0.5\}$, 得到 63 组样本数据。在聚类算法中, 取 $\lambda = 0.6$, 将 63 种工况分成了 7 个类, 每一个类中包含 3~12 种工况不等, 从而建立了规模 $N = 7$ 控制器库和模型库。在 FLC 学习中, SVM 参数取值为: $C = 100$, $\sigma = 1.2$, $\varepsilon = 0.05$ 。

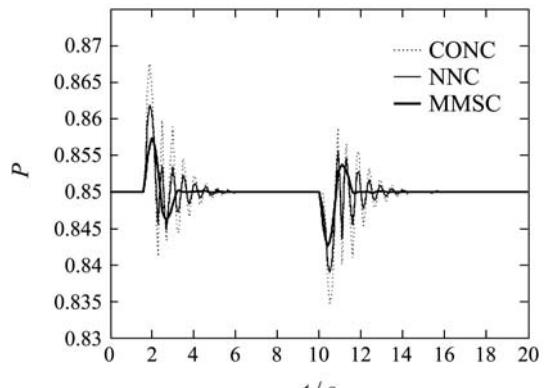
例1 5%电压给定值的扰动。机组 A 和 B 运行在稳定工作点, 在 $t = 2$ s 和 $t = 10$ s 时分别对发电机组端电压给予 5% 的阶跃上升和下降。限于篇幅, 这里仅用图 5 描述了机组 A 的响应曲线。图 5 表明, MMSC 控制性能较优(图中粗实线所示), 机组 A 的端电压能够按照调节要求较快地跟踪给定值, 各个状态变量 V_t , δ , P , ω 都能较快地进入新的稳定状态。CONC(图中虚线所示)、NNC(图中细实线所示)则需要较长的时间才能达到稳定状态, 而且存在超调量和一定的振荡。仿真实验中, 机组 B 的响应曲线也同样表明 MMSC 比另外两个控制器性能更优。



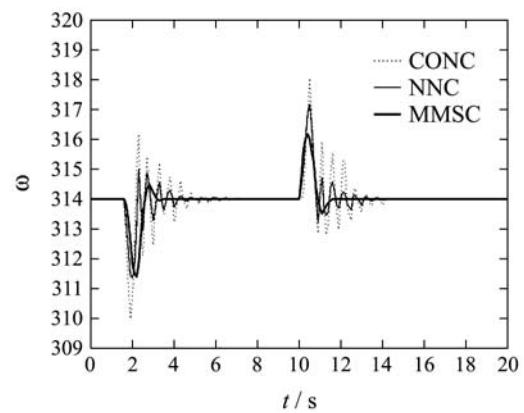
(a) 端电压



(b) 功角



(c) 有功功率



(d) 角速度

图 5 电压扰动时的机组 A 响应曲线

Fig. 5 System responses of Generator A to step changes

例2 机组高压侧出线短路扰动。机组 A 和 B 仍运行在稳定工作点, 在 $t = 2$ s 时机组 A 出线变压器高压侧发生 0.2 s 的三相短路, 而且短路被切除并重合闸成功。图 6 描述了机组 A 有关变量的响应曲线, MMSC 具有较优的调控性能和较强的鲁棒性, 状态变量 V_t , δ , P , ω 都能够在短路切除后迅速得到恢复, 恢复过程比较平稳, 暂态过程中较好地平息机组的机械振荡。而其他两种控制器在阻尼性能方面均不及 MMSC。仿真中, 机组 B 的响应曲线同样地表明了 MMSC 的优良性能。

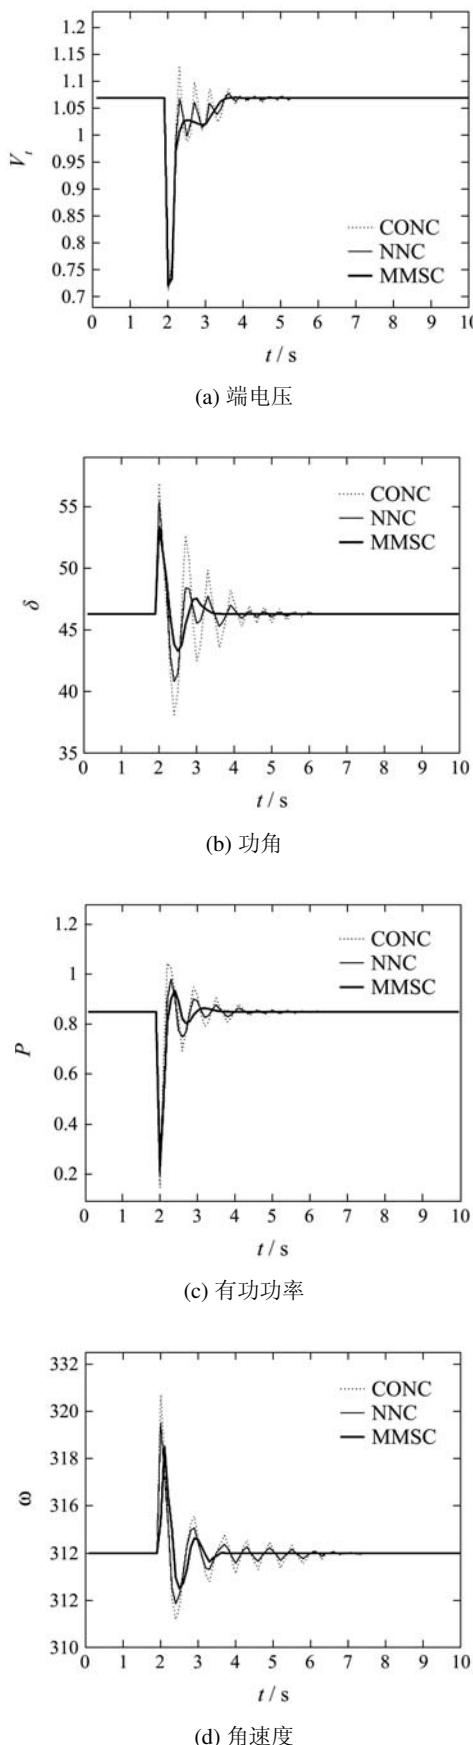


图 6 三相短路时的机组A响应曲线
Fig. 6 System responses of Generator A to three phase short circuit

7 结论(Conclusions)

考虑到发电机组综合控制中非线性、大范围运行及工况变化等实际问题,文章研究了一种多模型自学习控制(MMSC),给出了系统结构和学习算法。与已有控制器相比,本文创新点在于:1) 建立模型库与控制器库,控制规则针对不同工况,能够适应参数大范围变化;2) 基于模糊逻辑计算子模型匹配程度,匹配程度决定了MMSC的集成加权系数,有利于消除模型切换振荡;3) 利用支持向量机来实现模糊控制器的规则优化,自学习能力强。在多MMSC设计中,文章采取固定的模型库,而以学习调整控制器库的方式来优化控制性能,在进一步的研究中可以探讨在线调整模型库,使得系统更加完善。

参考文献(References):

- [1] PAW W, AM S, OH A. Integrated excitation and turbine control in a multimachine power system[J]. *IEE Proceedings-Part C*, 1989, 136(6): 331 – 340.
- [2] 黄健, 涂光瑜, 陈德树. 发电机的非线性综合控制[J]. 电网技术, 1997, 21(3): 5 – 9.
(HUANG Jian, TU Guangyu, CHEN Deshu. Integrated nonlinear control for speed and excitation of synchronous generators[J]. *Power System Technology*, 1997, 21(3): 5 – 9.)
- [3] OKOU A F, DESSAINT L A, AKHRIF O. Global voltage and speed control of large power systems[C] // Proc of IEEE Conf on Decision and Control. Hawaii: IEEE Press, 2003, 5: 4481 – 4486.
- [4] 王宝华, 杨成梧, 张强. 发电机的非线性自适应逆推综合控制[J]. 控制理论与应用, 2006, 23(1): 60 – 64.
(WANG Baohua, YANG Chengwu, ZHANG Qiang. Integrated nonlinear adaptive backstepping controller for synchronous generator[J]. *Control Theory & Applications*, 2006, 23(1): 60 – 64.)
- [5] XI Z R, FENG G, CHENG D Z, et al. Nonlinear decentralized saturated controller design for power systems[J]. *IEEE Trans on Control Systems Technology*, 2003, 11(4): 539 – 547.
- [6] 余涛, 沈善德, 李东海, 等. 基于扩张状态观测器的多机系统非线性协调控制[J]. 清华大学学报, 2004, 44(1): 97 – 101.
(YU Tao, SHEN Shande, LI Donghai, et al. ESO-based decentralized non linear coordinated controller of multimachine power systems[J]. *J of Tsinghua University*, 2004, 44(1): 97 – 101.)
- [7] 戴先中, 张腾, 张凯峰, 等. 发电机励磁与汽门系统解耦控制的神经网络逆系统方法[J]. 中国电机工程学报, 2002, 22(11): 75 – 80.
(DAI Xianzhong, ZHANG Teng, ZHANG Kaifeng, et al. ANN-inverse based decoupling control of excitation and valve system for turbo-generator[J]. *Proceedings of the CSEE*, 2002, 22(11): 75 – 80.)
- [8] JUNG W P, RONALD G H, GANESH K V. Indirect adaptive control for synchronous generator: comparison of MLP/RBF neural networks approach with Lyapunov stability analysis[J]. *IEEE Trans on Neural Networks*, 2004, 15(2): 460 – 464.
- [9] VAPNIK V. An overview of statistical learning theory[J]. *IEEE Trans on Neural Networks*, 1999, 10(5): 988 – 999.
- [10] 袁小芳, 王耀南, 孙炜. 支持向量机-模糊推理自学习控制器设计[J]. 控制理论与应用, 2006, 23(1): 1 – 5.
(YUAN Xiaofang, WANG Yaonan, SUN Wei. Self-learning controller using support vector machines and fuzzy inference system[J]. *Control Theory & Applications*, 2006, 23(1): 1 – 5.)
- [11] 王耀南. 智能控制系统[M]. 第2版, 长沙: 湖南大学出版社, 2006.

(下转第56页)

- (HUANG Shoudao, Wang Yaonan, et al. Study of the control strategy on rotor field orientation for brushless doubly-fed machine[J]. *Trans of China Electrotechnical Society*, 2002, 17(2): 34 – 39.)
- [3] WILLIAMSON S, FERREIRA A C, WALLACE A. Generalised theory of the brushless doubly-fed machines, Part 1: analysis[J]. *IEEE Proc Electr Power Appl*, 1996, 144(2): 111 – 122.
- [4] WILLIAMSON S, BOGER M S. Impact of inter-bar current on the performance of the brushless doubly fed motor[J]. *IEEE Trans on Industry Applications*, 1999, 35(2): 435 – 460.
- [5] 张风阁, 王风翔, 王正. 不同转子结构无刷双馈电机稳态运行特性的对比实验研究[J]. 中国电机工程学报, 2002, 22(4): 52 – 55.
(ZHANG Fengge, WANG Fengxiang, WANG Zheng. Comparative experiment study on the performance of doubly-fed brushless machine with different rotor structures[J]. *Proceedings of the CSEE*, 2002, 22(4): 52 – 55.)
- [6] 舒怀林. PID神经网络对强关联带时延多变量系统的解耦控制[J]. 控制理论与应用, 1998, 15(6): 920 – 924.
(SHU Huailin. PID neural network for decoupling control of strong coupling multivariable time-delay systems[J]. *Control Theory & Applications*, 1998, 15(6): 920 – 924.)
- [7] SHU Huailin. PID neural network control for complex systems[C]//*Proc of the Int Conf on Computational Intelligence for Modeling, Control and Automation (ICCI'99)*. Vienna, Austria: IOS Press, 1999: 166 – 171.
- [8] SHU Huailin, PI Youguo. PID neural networks for time-delay systems[C]//*Proc of the 7th Symposium on Process Systems Engineering (SPSE'2000)*. Keystone, Colorado, USA: [s.n.], 2000: 859 – 862.
- [9] 舒怀林. P1D神经元网络多变量控制系统分析[J]. 自动化学报, 1999, 25(1): 105 – 111.
(SHU Huailin. Analysis of PID neural network multivariable control systems[J]. *Acta Automatica Sinica*, 1999, 25(1): 105 – 111.)

作者简介:

郭红霞 (1982—), 女, 华南理工大学电力学院硕士研究生, 目前正从事电力电子与电力传动研究;

杨金明 (1962—), 男, 博士, 华南理工大学电力学院副教授, 目前从事控制理论及其电气传动在新能源中的应用, E-mail: jmyang@scut.edu.cn;

刘文刚 (1981—) 男, 华南理工大学电力电子与电力传动专业硕士研究生, 研究方向为能源与动力系统中的电力电子技术及控制, E-mail: wengangliu123@163.com.

(上接第46页)

以及相应的未知参数估计的自适应律:

$$\begin{cases} \dot{\hat{\theta}}_{j1} = \sigma_{j1,n+1-j} = \sum_{i=1}^{n+1-j} \tau_{j1i} z_{i+j-1}^{p+1}, \\ \dot{\hat{\theta}}_{j2} = \sigma_{j22} = \tau_{j21} z_j^{p+1} + \tau_{j22} z_{j+1}^{p+1}, \\ \dot{\hat{\theta}}_{n2} = \tau_{n21} z_n^{p+1}, \end{cases} \quad (\text{A37})$$

其中 $j = 2, 3, \dots, n - 1$. 因在前面已经约定 $z_{n+1} = 0$, 所以实际控制(A36)和自适应律(A37)使得

$$\dot{V}_n \leq -\sum_{i=1}^n \frac{|d_i|}{2^{n-i}} z_i^{p+1}. \quad (\text{A38})$$

至此, 控制器设计过程完毕.

作者简介:

孙宗耀 (1979—), 男, 2002年获聊城大学数学系学士学位, 2005年获曲阜师范大学运筹学与控制论专业硕士学位, 现为山东大学控制科学与工程学院博士研究生, 主要研究方向是非线性控制、自适应理论等, E-mail: sunzongyao@sohu.com;

刘允刚 (1970—), 男, 现为山东大学控制科学与工程学院教授, 博士生导师, 主要研究领域为随机控制、非线性系统分析、自适应控制等, E-mail: lygfr@sdu.edu.cn.

(上接第52页)

- [12] XIE X L, BENI G. A validity measure for fuzzy clustering[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1991, 13(8): 841 – 847.

作者简介:

袁小芳 (1979—), 男, 博士研究生, 主要研究方向为智能控制

理论与应用、神经网络、优化计算等, E-mail: yuanxiaof@21cn.com;

王耀南 (1957—), 男, 教授, 博士生导师, 主要研究方向为智能控制理论与应用、模式识别与图像处理等, E-mail: yaonan@hnu.cn;

吴亮红 (1978—), 男, 博士研究生, 主要研究方向为智能优化算法理论与应用、智能机器人等, E-mail: lhwu@hnust.edu.cn.