

控制与决策

Control and Decision

基于模糊神经网络的有源电力滤波器全局滑模控制

侯世玺, 储云迪, 陈晨

引用本文:

侯世玺, 储云迪, 陈晨. 基于模糊神经网络的有源电力滤波器全局滑模控制[J]. 控制与决策, 2020, 35(10): 2329–2335.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1570>

您可能感兴趣的其他文章

Articles you may be interested in

基于积分滑模控制的非理想变时滞神经网络有限时间同步

Finite-time synchronization of nonidentical neural networks with time-varying delay based on integral sliding mode control

控制与决策. 2019, 34(7): 1559–1564 <https://doi.org/10.13195/j.kzyjc.2017.1689>

基于非奇异快速终端滑模的轧机液压伺服位置系统反步控制

Backstepping control of rolling mill hydraulic servo position system based on nonsingular fast terminal sliding mode

控制与决策. 2018, 33(9): 1649–1656 <https://doi.org/10.13195/j.kzyjc.2017.1001>

基于自适应模糊滑模观测器的永磁同步电机无传感器矢量控制

Sensorless vector control of PMSM based on adaptive fuzzy sliding mode observer

控制与决策. 2018, 33(4): 644–648 <https://doi.org/10.13195/j.kzyjc.2017.0058>

基于滤波器估计的正交函数神经网络非线性系统 H^∞ 控制

H^∞ control of nonlinear system using orthogonal function neural network based on filter estimation

控制与决策. 2017, 32(2): 281–286 <https://doi.org/10.13195/j.kzyjc.2016.1499>

具有未建模动态和输出约束系统的自适应输出反馈控制

Adaptive output feedback control of systems with unmodeled dynamics and output constraint

控制与决策. 2017, 32(1): 55–62 <https://doi.org/10.13195/j.kzyjc.2015.1613>

基于模糊神经网络的有源电力滤波器全局滑模控制

侯世玺[†], 储云迪, 陈晨

(1. 河海大学 物联网工程学院, 南京 210098; 2. 河海大学 江苏省输配电装备技术重点实验室, 南京 210098)

摘要: 针对有源电力滤波器电流跟踪控制问题, 提出一种基于模糊神经网络的全局滑模控制方法. 首先, 为了消除到达阶段和抑制抖振, 设计准全局滑模控制电流控制器; 然后, 在考虑参数摄动和传感器故障的情况下, 利用元认知模糊神经网络设计基于模糊神经网络的全局滑模控制器, 克服全局滑模控制依赖先验知识的缺点. 不同于其他固定结构方法, 元认知模糊神经网络可以实现结构和参数的在线更新, 并利用李雅普诺夫稳定性理论证明所提出的控制策略满足控制目标以及稳定性要求. 仿真和实验结果表明, 所提出的控制方法在稳态和瞬态运行时都具有良好的性能.

关键词: 全局滑模控制; 模糊神经网络; 有源电力滤波器; 结构更新

中图分类号: TP13

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1570

开放科学(资源服务)标识码(OSID):



引用格式: 侯世玺, 储云迪, 陈晨. 基于模糊神经网络的有源电力滤波器全局滑模控制 [J]. 控制与决策, 2020, 35(10): 2329-2335.

Fuzzy neural network based global sliding mode control for active power filter

HOU Shi-xi[†], CHU Yun-di, CHEN Chen

(1. College of IoT Engineering, Hohai University, Nanjing 210098, China; 2. Jiangsu Key Laboratory of Power Transmission and Distribution Equipment Technology, Hohai University, Nanjing 210098, China)

Abstract: This study mainly focuses on the development of a self-organizing global sliding mode control for active power filters. First, a quasi global sliding mode control method is designed for inner current control loop to eliminate the reaching mode and chattering phenomenon. Then, the control law is constructed based on the meta-cognitive fuzzy neural network (MCFNN) rather than the actual systems to overcome the drawbacks of global sliding mode control. Different from the predefined structure approaches, only necessary data can be extracted to adjust the structure and parameters of the networks in the MCFNN. Subsequently, the Lyapunov stability analysis is presented to satisfy the control objectives and system stability requirements at the same time. Finally, simulation and experimental results demonstrate that the proposed control methods offer superior properties in both steady state and transient operation.

Keywords: global sliding mode control; fuzzy neural network; active power filter; structural adaptation

0 引言

近年来,随着电力系统中变流器越来越多,电能质量问题日益突出. 电能质量是一个广义概念,可分为电压波动、电压不稳定、电流谐波等. 电流谐波是电能质量的主要问题,传统的无源滤波器可以解决这类问题. 但是,无源滤波器是一种固定补偿方式,容易出现过补偿或欠补偿,且不能同时实现无功和谐波电流的动态补偿,特别是在牵引负荷波动较大的情况下. 此外,限制电网谐波含量的标准也越来越严格,这

也推动了有源电力滤波器(active power filter, APF)的发展.

目前,为实现高性能电流控制,已有许多控制方法应用于 APF. 文献[1]采用有功控制提高了 APF 电流环的抗干扰性能. 为提高有源电力滤波器的动态性能,文献[2]提出了自适应反演控制方法. 特别地,一些学者已经采用软计算方法解决 APF 系统存在的未知扰动. 文献[3]提出了一种结合神经网络和模糊控制的复合控制算法以提高抗干扰能力和自适应能

收稿日期: 2019-11-12; 修回日期: 2019-12-26.

基金项目: 江苏省自然科学基金项目(BK20170303, BK20171198); 常州市科技创新计划项目(CJ20190056); 中央高校基本科研业务费专项基金项目(B200202215, B200201052, 2017B03014, 2017B20014).

责任编辑: 解学军.

[†]通讯作者. E-mail: houshixi@hhu.edu.cn.

力. 尽管如此, 滑模控制仍是提高系统鲁棒性最好的方法. 传统滑模控制包括两个阶段, 分别是到达阶段和滑动阶段. 必须指出的是, 只有处于滑动阶段系统才具有对参数摄动和外界干扰的鲁棒性, 即传统滑模控制并不具有全局鲁棒性. 于是, 有学者提出全局滑模控制(global sliding mode control, GSMC), 这种控制方法的主要特点在于具有全局鲁棒性^[4].

全局滑模控制存在抖振现象, 其控制性能也依赖于先验知识. 前者可以通过准滑模控制解决^[5], 后者需要用到不确定观测器或估计器. 近几年, 诸如模糊控制、神经网络等智能控制方法相继被用来估计系统未知不确定性, 尤其是模糊神经网络(fuzzy neural network, FNN)^[6-7]. 模糊神经网络能够同时实现模糊推理和神经计算, 因此受到广泛关注. 然而, 大部分模糊神经网络控制策略只考虑参数学习, 并未实现结构调整. 从实际应用看, 模糊神经网络的学习能力受限于存在较大负荷扰动的场景. 文献[8]以城市轨道交通为例, 指出列车运行频率的不连续性引起牵引负载率变化较大, 进而无功损耗和负荷电流变化也较大, 导致APF所需补偿容量变化范围较大; 列车在行车过程中加速、制动、乘客人数、坡度、操作等因素亦使得牵引负载随机波动. 在上述应用背景下, 如果提前设计不合适的模糊规则, 而模糊神经网络不具备结构自调整能力, 控制性能在一定程度上则会受到影响. 因此, 为了提高模糊神经网络的学习性能, 实现参数和结构的在线更新尤为重要. 因为元认知策略适合优化问题, 前述问题可以通过元认知模糊神经网络(meta-cognitive FNN, MCFNN)解决^[9]. 对于MCFNN, 不需要预设精确的模糊规则, 它可以通过数据删除和数据学习策略在线更新网络结构和参数, 从而实现全过程学习.

本文在建立含有集总不确定性的有源电力滤波器数学模型的基础上, 提出基于模糊神经网络的全局滑模电流控制方法. 利用元认知模糊神经网络逼近全局滑模控制器中的未知项, 放松对系统先验知识的依赖, 并通过李雅普诺夫理论分析其稳定性. 仿真和实验结果验证了所提出方法的可行性和有效性.

1 APF数学模型

APF拓扑结构如图1所示. 其中: L_c 、 R_c 为有源电力滤波器的交流侧电感和等效电阻, i_{s1} 、 i_{s2} 、 i_{s3} 为三相电网电流, i_{L1} 、 i_{L2} 、 i_{L3} 为三相负载电流, i_1 、 i_2 、 i_3 为三相APF输出的补偿电流. 一般而言, APF的主要任务是输出补偿电流净化电网电流并维持直流侧电压恒定, 分别命名为内部电流环和外部电压环. 考

虑到外部电压环的参考信号是恒定的, 后者是一个简单的调节任务. 然而, 由于内部电流环的参考电流信号是实时变化的, 前者可被归纳为一个典型的跟踪问题. 本文为内部电流环设计基于模糊神经网络的全局滑模控制器, 实现高效的控制性能.

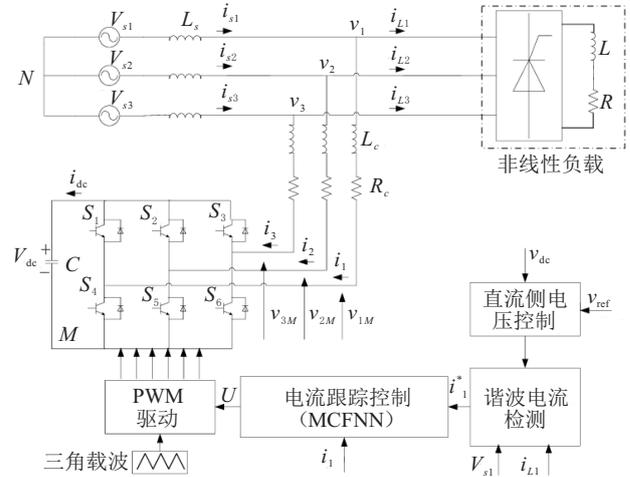


图1 有源电力滤波器拓扑结构

假设三相电网电压平衡, 不考虑零序分量, 根据电路理论和基尔霍夫定律, 可以建立有源电力滤波器电流控制系统动力学模型如下所示:

$$\dot{x} = f(x) + U + H. \quad (1)$$

其中

$$x = [i_1 \quad i_2 \quad i_3]^T,$$

$$f(x) =$$

$$\left[-\frac{R_{c1}}{L_{c1}}i_1 + \frac{v_1}{L_{c1}} \quad -\frac{R_{c1}}{L_{c1}}i_2 + \frac{v_2}{L_{c1}} \quad -\frac{R_{c1}}{L_{c1}}i_3 + \frac{v_3}{L_{c1}} \right]^T,$$

$$H = \begin{bmatrix} h_1 \\ h_2 \\ h_3 \end{bmatrix} =$$

$$\begin{bmatrix} \frac{(R_{c1}\Delta L - L_{c1}\Delta R)i_1 - v_1\Delta L + v_{dc}\Delta L d_{n1}}{L_{c1}(L_{c1} + \Delta L)} + g_1 \\ \frac{(R_{c1}\Delta L - L_{c1}\Delta R)i_2 - v_2\Delta L + v_{dc}\Delta L d_{n2}}{L_{c1}(L_{c1} + \Delta L)} + g_2 \\ \frac{(R_{c1}\Delta L - L_{c1}\Delta R)i_3 - v_3\Delta L + v_{dc}\Delta L d_{n3}}{L_{c1}(L_{c1} + \Delta L)} + g_3 \end{bmatrix},$$

$$U = \left[-\frac{v_{dc}}{L_{c1}}d_{n1} \quad -\frac{v_{dc}}{L_{c1}}d_{n2} \quad -\frac{v_{dc}}{L_{c1}}d_{n3} \right]^T.$$

有源电力滤波器全局滑模控制器通过以下步骤建立.

定义补偿电流和参考电流 x_d 的误差 e 为

$$e = x - x_d. \quad (2)$$

e 的导数定义为

$$\dot{e} = \dot{x} - \dot{x}_d. \quad (3)$$

设计全局滑模面为

$$S = Ce - g(t), \quad (4)$$

其中 C 为一个给定的常数. $g(t)$ 的选择需要满足以下条件: 1) $g(0) = \dot{e}_0 + ce_0$; 2) 当 $t \rightarrow \infty$ 时, $g(t) \rightarrow 0$; 3) $g(t)$ 存在一阶导数. 因此设计 $g(t) = g(0)e^{-kt}$, 其中 k 为一个给定的常数.

S 的导数为

$$\begin{aligned} \dot{S} &= C\dot{e} - \dot{g}(t) = \\ &C[f(x) + U + H - \dot{x}_d] - \dot{g}(t), \end{aligned} \quad (5)$$

进而设计全局滑模控制律 U_{gsm} 为

$$U_{\text{gsm}} = \frac{1}{C}\dot{g}(t) - f(x) + \dot{x}_d - D\text{sgn}(S), \quad (6)$$

其中 $D > 0$.

假设 1 H 是有界的, 即存在一个实数 H_M 使得

$$|H| \leq H_M. \quad (7)$$

证明 选择李雅普诺夫函数为

$$V_1 = \frac{1}{2}S^T S. \quad (8)$$

将李雅普诺夫函数对时间求导, 并代入式 (6), 可得

$$\begin{aligned} \dot{V}_1 &= S^T \left[C(f(x) + \frac{1}{C}\dot{g}(t) - f(x) + \dot{x}_d - \right. \\ &\quad \left. D\text{sgn}(S) + H - \dot{x}_d) - \dot{g}(t) \right] = \\ &S^T C[H - D\text{sgn}(S)] = C[-D\|S\| + S^T H] \leq \\ &C[-D\|S\| + \|S\|H_M] = C\|S\|(H_M - D). \end{aligned} \quad (9)$$

当 $D \geq H_M$ 时, 不等式 (9) 满足 $\dot{V} \leq 0$. 根据李雅普诺夫稳定性理论, 系统状态将到达全局滑模面, 跟踪误差 e 和误差的导数也会收敛到零. \square

GSMC 需要系统的详细信息, 这在实际应用中很难获得, 因此控制器 (6) 不易实现. 为了消除这种缺陷, 后文提出了一种 **MCFNN** 逼近器, 利用 **MCFNN** 对系统未知项进行逼近, 从而获得鲁棒的高性能控制能力.

注 1 在实际控制系统中, 由于电路结构和执行器的限制, 系统状态和控制信号通常被限制在一定的范围内. 对于给定的约束条件, 可以保守地选择集总不确定性上界 H_M . 另外, 在控制器中并未用到 H_M , 关键是选择合适的 D 满足 $D \geq H_M$. 可以根据经验法则选取合适的 D , 一般而言, D 选取太大会引起不必要的抖振, D 选取太小可能导致系统不稳定.

注 2 为了减小抖振, 采用准全局滑模控制代替传统全局滑模控制. 准全局滑模控制在全局滑模控制的设计中引入边界层的概念, 在边界层外采用传统全局滑模控制, 在边界层内采用连续状态反馈控制, 从而有效地避免抖振. 因此, 如果将控制器 (6) 替换为下式, 则能够抑制抖振:

$$U_{\text{gsm}} = \begin{cases} \frac{1}{C}\dot{g}(t) - f(x) + \dot{x}_d - D\text{sgn}(S), & |S| > \beta; \\ \frac{1}{C}\dot{g}(t) - f(x) + \dot{x}_d - D\frac{S}{\beta}, & |S| \leq \beta. \end{cases} \quad (10)$$

2 元认知模糊神经网络

2.1 元认知模糊神经网络结构

为了提高跟踪能力, 消除 **GSMC** 缺陷并降低计算负担, 本节提出一种 **MCFNN** 系统如图 2 所示.

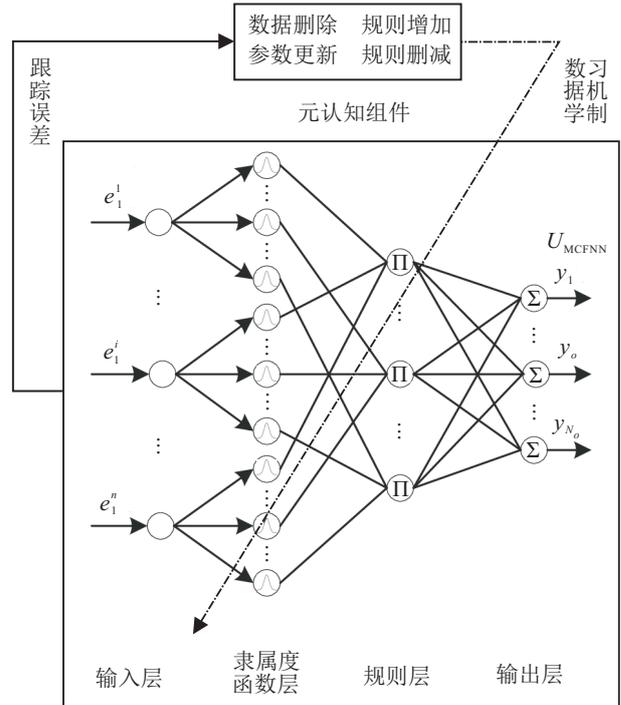


图 2 元认知模糊神经网络结构

系统包括认知组件和元认知组件两部分, 其中认知组件由 4 层 **FNN** 构成, 包含输入层、隶属度层、规则层和输出层, 各层之间的信号传递如下所示:

1) 输入层: 输入变量 $x_i (i = 1, 2, \dots, n)$ 被传递到下一层.

2) 隶属度层: 该层的输入输出关系可表示为

$$\mu_i^j(x_i) = \exp \left[-\frac{(x_i - c_i^j)^2}{(b_i^j)^2} \right], \quad (11)$$

其中 c_i^j 和 $b_i^j (i = 1, 2, \dots, n, j = 1, 2, \dots, N_{pi})$ 分别为第 i 个输入变量第 j 个高斯隶属度函数的中心向量和基宽. N_{pi} 为每个输入变量对应的隶属度函数的个数, 不失一般性, 分别用 b 和 c 表示所有的基宽和中心向量, 有

$$\begin{aligned} b &= \\ &[b_1^1 \dots b_1^{N_{p1}} \ b_2^1 \dots b_2^{N_{p2}} \dots b_n^1 \dots b_n^{N_{pn}}]^T, \\ c &= \\ &[c_1^1 \dots c_1^{N_{p1}} \ c_2^1 \dots c_2^{N_{p2}} \dots c_n^1 \dots c_n^{N_{pn}}]^T, \end{aligned}$$

其中 $N_r = \sum_{i=1}^n N_{pi}$ 为隶属度函数的总个数.

3) 规则层: 该层每个节点 k 实现对输入信号 $\mu_i^j(x_i)$ 的乘法运算, 并输出结果至下一层, 该层输出可表示为

$$l_k = \prod_{i=1}^n \omega_{ji}^k \mu_i^j(x_i) = \exp \left[- \sum_{i=1}^n \frac{(x_i - c_i^j)^2}{(b_i^j)^2} \right]. \quad (12)$$

其中: $l_k (k = 1, 2, \dots, N_y)$ 为该层的第 k 个输出; ω_{ji}^k 为连接权重, 本例设为 1.

4) 输出层: 将上一层输出求和后作为该层的输出 $y_o (o = 1, 2, \dots, N_o)$, 有

$$y_o = \sum_{k=1}^{N_y} \omega_k l_k. \quad (13)$$

为简单起见, 4层FNN的输出可进一步表示为

$$y_o = Wl. \quad (14)$$

其中

$$W = [\omega_1 \ \omega_2 \ \dots \ \omega_{N_y}],$$

$$l = [l_1 \ l_2 \ \dots \ l_{N_y}]^T.$$

2.2 元认知学习机制

基于数据学习策略、数据删除策略和数据保留策略, MCFNN 能够同时实现结构和参数的在线更新. 然而, 对于内存受限的实时控制而言, 由于数据保留策略需要存储大量数据, 不利于实现实时控制, 本文提出的元认知模糊神经网络只考虑了数据学习和数据删除策略.

1) 数据学习策略.

元认知模糊神经网络的数据学习过程主要包括结构调整和参数更新机制. 当 $\|x_i\| > E_a$ 且 $\psi < E_s$ 时, 在隶属度层增加一条新的模糊规则. ψ 是球面势, 用来表示输入数据的新颖性, 定义为

$$\psi = \left| - \frac{2}{N_{pi}} \sum_{q=1}^{N_{pi}} \mu(x_i, c_i^q) \right|, \quad (15)$$

其中 E_s 和 E_a 为给定的阈值.

当增加一条新的模糊规则时, 将其参数初始化为

$$c_i^{N_{pi}+1} = x_i,$$

$$b_i^{N_{pi}+1} = \kappa \min_{\forall j} \|x_i - c_i^j\|, \quad q = 1, 2, \dots, N_{pi},$$

$$\omega_{N_{pi}+1} = 0, \quad (16)$$

其中 κ 为一个正常数.

当 $\|x_i\| > E_l$ 时, 会触发 MCFNN 的参数更新机制. 在 MCFNN 中, 为了减少计算负担并保证闭环系统的稳定性, 基于李雅普诺夫理论推导出的参数自适应律只更新最靠近当前输入变量的模糊规则参

数. 当某条规则几乎对输出不产生影响时, 该条规则应该从规则库移除, 从而进一步降低计算负担.

第 q 条规则对输出的贡献度表示为

$$\beta_q = \mu(x_i, c_i^q) \max |x_i \omega_q|, \quad i = 1, 2, \dots, n. \quad (17)$$

当贡献度 β_q 低于阈值 E_p 时, 该条规则应该被移除.

2) 数据删除策略.

如果当前输入变量不能满足数据学习策略的要求, 则应该从元认知组件中移除, 这样可以避免过度学习和减少计算负担.

2.3 基于元认知模糊神经网络的全局滑模控制器

值得注意的是, $f(x)$ 中存在 v_1, v_2, v_3 , 即需要额外 3 个电压传感器才能实现控制器(6), 而且一旦传感器出现故障, 势必会恶化控制效果, 甚至引起系统失稳, 因此有必要采用 MCFNN 估计 $f(x)$.

假设 2 存在一个理想的元认知模糊神经网络估计不确定函数 $f(x)$, 即 $f(x) = W^* l^* + \varepsilon$, W^*, b^*, c^* 分别为理想权重、理想基宽、理想中心向量, ε 为重构误差, 并满足 $|\varepsilon| \leq \varepsilon_b$.

元认知模糊神经网络的实际输出为

$$\hat{f}(x) = \hat{W} \hat{l}. \quad (18)$$

其中: \hat{W} 为 W^* 的估计值, $\hat{l} = \hat{l}(x, \hat{c}, \hat{b})$, \hat{b}, \hat{c} 分别为 b^*, c^* 的估计值. 理想参数包括两部分, 第一部分代表激活的最近规则的理想参数, 包括 $W_{near}^*, b_{near}^*, c_{near}^*$, 另一部分代表未被激活的规则, 包括 $W_{far}^*, b_{far}^*, c_{far}^*$ ($1 \leq far \leq N_y, far \neq near$). 因此, 有

$$l^*(x, c^*, b^*) = \begin{bmatrix} l_{near}^*(x, c_{near}^*, b_{near}^*) \\ l_{far}^*(x, c_{far}^*, b_{far}^*) \end{bmatrix},$$

$$W^* = [W_{near}^* \ W_{far}^*].$$

同样, 估计值也可以分为 $\hat{W}_{near}, \hat{b}_{near}, \hat{c}_{near}, \hat{W}_{far}, \hat{b}_{far}, \hat{c}_{far}$.

$f(x)$ 真实值和估计值的误差可以表示为

$$f(x) - \hat{f}(x) = W_{near}^* l_{near}^* - \hat{W}_{near} \hat{l}_{near} + \varepsilon =$$

$$W_{near}^* (\hat{l}_{near} + \tilde{l}_{near}) - \hat{W}_{near} \hat{l}_{near} + \varepsilon =$$

$$W_{near}^* \hat{l}_{near} + W_{near}^* \tilde{l}_{near} - \hat{W}_{near} \hat{l}_{near} + \varepsilon =$$

$$\tilde{W}_{near} \hat{l}_{near} + \hat{W}_{near} \tilde{l}_{near} + \tilde{W}_{near} \tilde{l}_{near} + \varepsilon, \quad (19)$$

其中 $\tilde{W}_{near} \tilde{l}_{near} + \varepsilon = \varepsilon_0$ 为逼近误差.

利用泰勒级数展开将 \tilde{l} 表示为

$$\tilde{l}_{near} = \left. \frac{\partial l_{near}}{\partial c_{near}} \right|_{c=\hat{c}} (c_{near}^* - \hat{c}_{near}) +$$

$$\left. \frac{\partial l_{near}}{\partial b_{near}} \right|_{b=\hat{b}} (b_{near}^* - \hat{b}_{near}) + O_h =$$

$$l_c \tilde{c}_{near} + l_b \tilde{b}_{near} + O_h. \quad (20)$$

其中: O_h 为高阶项; \tilde{c}_{near} 、 \tilde{b}_{near} 具有以下形式:

$$\begin{aligned} \tilde{c}_{near} &= c_{near}^* - \hat{c}_{near}, \\ \tilde{b}_{near} &= b_{near}^* - \hat{b}_{near}. \end{aligned} \quad (21)$$

系数矩阵 l_c 、 l_b 分别为

$$l_c = \left[\frac{\partial l_{near}}{\partial c_1^{near}} \quad \cdots \quad \frac{\partial l_{near}}{\partial c_i^{near}} \quad \cdots \quad \frac{\partial l_{near}}{\partial c_n^{near}} \right] \Big|_{c==\hat{c}}, \quad (22)$$

$$l_b = \left[\frac{\partial l_{near}}{\partial b_1^{near}} \quad \cdots \quad \frac{\partial l_{near}}{\partial b_i^{near}} \quad \cdots \quad \frac{\partial l_{near}}{\partial b_n^{near}} \right] \Big|_{b==\hat{b}}. \quad (23)$$

其中

$$\begin{aligned} \frac{\partial l_{near}}{\partial c_i^{near}} &= 2l_{near} \left[\frac{(x_i - c_i^{near})}{(b_i^{near})^2} \right], \\ \frac{\partial l_{near}}{\partial b_i^{near}} &= 2l_{near} \left[\frac{(x_i - c_i^{near})^2}{(b_i^{near})^3} \right]. \end{aligned}$$

由此, 控制器(6)可改写为

$$U_{gsm} = \frac{1}{C} \dot{g}(t) - \hat{f}(x) + \dot{x}_d - D \text{sgn}(S). \quad (24)$$

证明 定义如下李雅普诺夫函数:

$$\begin{aligned} V_2 &= \frac{1}{2} S^2 + \frac{1}{2\eta_1} \tilde{W}_{near}^2 + \frac{1}{2\eta_2} \text{tr}(\tilde{c}_{near}^T \tilde{c}_{near}) + \\ &\quad \frac{1}{2\eta_3} \text{tr}(\tilde{b}_{near}^T \tilde{b}_{near}). \end{aligned} \quad (25)$$

将

$$\frac{1}{2\eta_1} \tilde{W}_{near}^2 + \frac{1}{2\eta_2} \text{tr}(\tilde{c}_{near}^T \tilde{c}_{near}) + \frac{1}{2\eta_3} \text{tr}(\tilde{b}_{near}^T \tilde{b}_{near})$$

设为 M , 并对 V_2 求导, 可得

$$\begin{aligned} \dot{V}_2 &= S\dot{S} + \dot{M} = \\ &SC[f(x) - \hat{f}(x) - D \text{sgn}(S) + H] + \dot{M} = \\ &CS[(\tilde{W}_{near} \hat{l}_{near} + \hat{W}_{near} \tilde{l}_{near} + \varepsilon_0) - \\ &D \text{sgn}(S) + H] + \dot{M}. \end{aligned} \quad (26)$$

将式(20)代入(26), 可得

$$\begin{aligned} \dot{V}_2 &= \\ &CS\tilde{W}_{near} \hat{l}_{near} + CS\hat{W}_{near} (l_c \cdot \tilde{c}_{near} + l_b \cdot \tilde{b}_{near}) + \\ &CSH + CSO_{ho} - DS \text{sgn}(S) + \frac{1}{\eta_1} \tilde{W}_{near} \dot{\tilde{W}}_{near} + \\ &\frac{1}{\eta_2} \text{tr}(\dot{\tilde{c}}_{near}^T \tilde{c}_{near}) + \frac{1}{\eta_3} \text{tr}(\dot{\tilde{b}}_{near}^T \tilde{b}_{near}), \end{aligned} \quad (27)$$

其中 $O_{ho} = \varepsilon_0 + \hat{W}_{near} O_h$.

设计参数自适应律如下:

$$\dot{\tilde{W}}_{near} = -\eta_1 CS \hat{l}_{near}, \quad (28)$$

$$\dot{\tilde{c}}_{near}^T = -\eta_2 CS \hat{W}_{near} l_c, \quad (29)$$

$$\dot{\tilde{b}}_{near}^T = -\eta_3 CS \hat{W}_{near} l_b. \quad (30)$$

将式(28)~(30)代入(27), 可得

$$\begin{aligned} \dot{V}_2 &= CS(H + O_{ho}) - D|S| \leq \\ &|S|(CH_M + CO_M - D). \end{aligned} \quad (31)$$

假设 O_{ho} 存在上界, 满足 $|O_{ho}| \leq O_M$, 那么只要使得 $D \geq C(H_M + O_M)$, 即可保证

$$\dot{V}_2 \leq 0. \quad (32)$$

\dot{V}_2 的负半定性表明, V_2 、 S 都是有界的, 进一步推断出 \dot{S} 也有界. 不等式 $\dot{V}_2 \leq |S|(CH_M + CO_M - D)$ 表明 S 可积, 即

$$\int_0^t \|S\| dt \leq \frac{1}{CH_M + CO_M - D} [V(t) - V(0)].$$

因为 $V(0)$ 有界, 且 $V(t)$ 有界非增, 能够得到 $\lim_{t \rightarrow \infty} \int_0^t \|S\| dt$ 有界. 因为 $\lim_{t \rightarrow \infty} \int_0^t \|S\| dt$ 和 \dot{S} 有界, 根据 Barbalat 定理, $S(t)$ 满足 $\lim_{t \rightarrow \infty} S(t) = 0$. 根据式(4), 跟踪误差也会收敛到 0. \square

注 3 与现有 FNN 不同的是, 提出的 MCFNN 包括数据删除和数据学习策略. 其中: 数据删除策略用来删除未满足数据学习策略要求的输入数据, 不必触发参数更新机制, 从而避免过度学习, 进一步提高实时控制的泛化能力; 数据学习策略实现参数更新与结构调整的同时在线执行, 从而实现所有隶属度函数的自动生成, 无需提前设定.

3 仿真分析

为了验证所设计的基于元认知模糊神经网络的全局滑模控制器的有效性, 通过 Matlab/Simulink 对所提出的有源电力滤波器控制方案的性能进行仿真, 系统参数见表 1. 仿真主要研究以下两个方面:

- 1) 谐波补偿的稳态响应;
- 2) 对负载变化的动态响应.

表 1 APF 系统参数

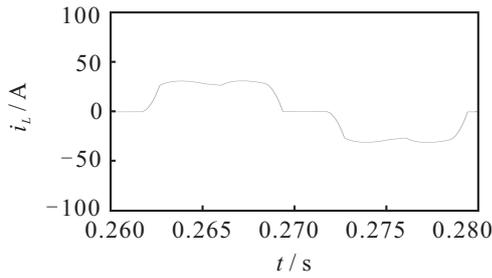
参数	
电源电压	$V_{s1} = V_{s2} = V_{s3} = 220 \text{ V}, f = 50 \text{ Hz}$
非线性负载	$R = 5 \Omega, L = 10 \text{ mH}$
主电路参数	$L_c = 10 \text{ mH}, R_c = 0.1 \Omega, C = 5000 \mu\text{F}$
开关频率	$f_{sw} = 20 \text{ kHz}$

MCFNN 中, 参数初值设为 $c = [-2 \ -1 \ 0 \ 1 \ 2]^T$ 、 $b = [1 \ 1 \ 1 \ 1 \ 1]^T$. 其他参数为 $E_a = 5, E_s = 0.02, \kappa = 0.8, E_p = 0.2, C = 1000, \eta_1 = 1, \eta_2 = 0.01, \eta_3 = 0.01, D = 1000, k = 100$.

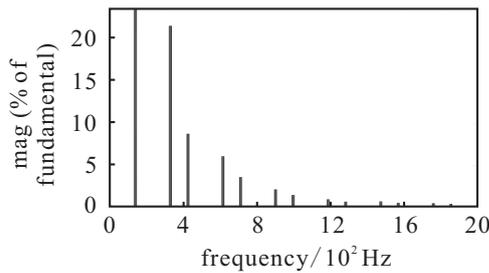
值得一提的是, 上述设计参数的选择会影响控制性能, 如收敛时间和追踪精度, 本文通过试错法选择合适的参数, 使系统性能达到最佳.

负载电流如图 3(a) 所示. 由图 3(a) 可见, 负载电流含有丰富的谐波, 总谐波失真 (THD) 高达 24.72%. 采用本文提出的基于元认知模糊神经网络的全局滑模控制器后, 电源电流如图 4 所示. 可见, 电网侧电流

变为正弦波,谐波得到有效消除,THD仅为1.70%,展现出其优越性.

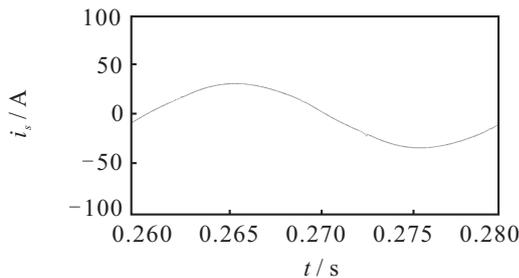


(a) 负载电流

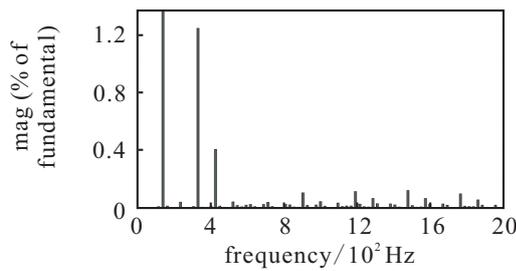


(b) 负载电流频谱

图3 负载电流及其频谱



(a) 电源电流



(b) 电源电流频谱

图4 采用MCFNN的电源电流及其频谱

仿真过程中负载突增和突减的动态结果如图5所示,其中实线为 i_{cref} ,虚线为 i_c .图5中,非线性负载分别在0.1s增大,0.2s减小.可以看出,APF系统在负载电流变化范围较大的情况下,能够快速调整,保持电网稳定,有效地净化电网谐波.补偿电流可以跟踪不同负载条件下的参考电流,表明了所设计的控制器具有较好的鲁棒性.在MCFNN中,模糊规则可以在某一时刻生成或移除.如图6所示,规则库具有清晰的学习过程,最后到达稳态时只有3条规则.相较于文献[3]中传统模糊神经网络的5条模糊规则,本文

MCFNN明显降低了计算复杂度.因此,采用MCFNN的APF在稳态和动态条件下都表现出较好的性能.

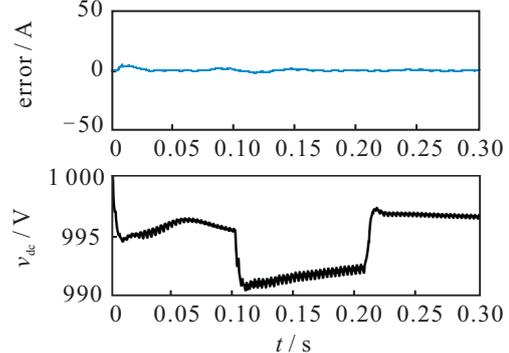
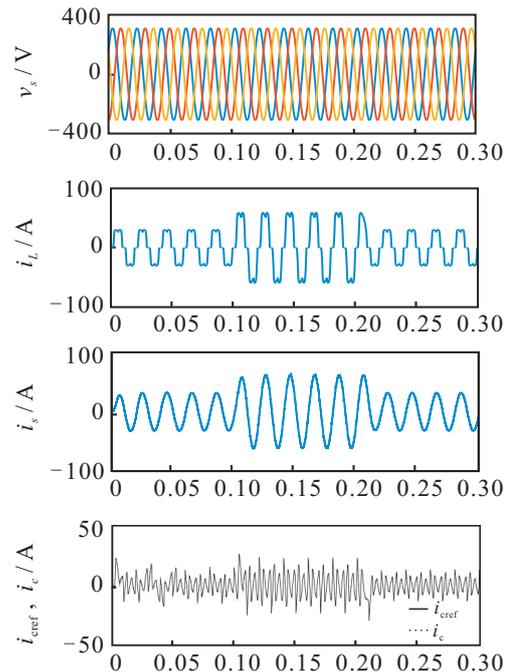


图5 动态仿真结果

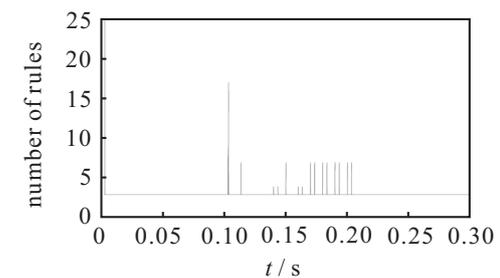


图6 规则演化图

4 实验验证

为了进一步验证所提出控制方法的优越性,本文搭建基于dSPACE1104的有源电力滤波器实验平台进行动静态实验.稳态实验波形如图7所示,波形依次为电网侧电压、负载电流、补偿电流和电网侧电流的稳态波形.由图7可见,负载电流中含有丰富的谐波,总谐波失真达30.28%.采用APF后,电网侧电流接近正弦,THD降至3.26%,表明电网侧电流得到了有效净化.图8为动态实验结果.由图8可见,在负

载电流发生变化时, APF 的输出补偿电流可以快速修正, 有效地消除谐波. 因此, 采用所提出控制器的 APF 在稳态和动态条件下都表现出显著的优势.

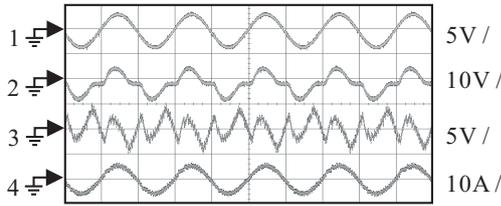
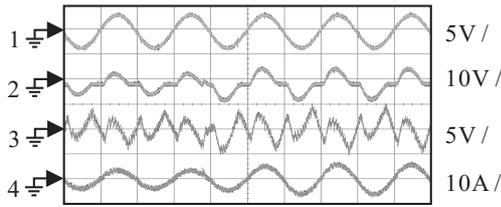
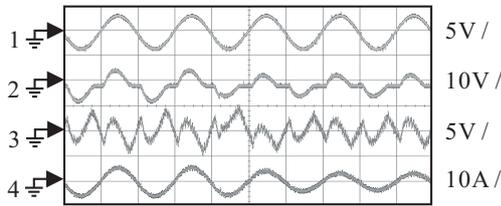


图 7 稳态实验结果



(a) 负载增加



(b) 负载减少

图 8 动态实验结果

5 结论

为了进一步提高有源电力滤波器的鲁棒性和快速收敛性能, 本文设计了一种基于元认知模糊神经网络的全局滑模控制器. 该控制器除了具有全局鲁棒性和无抖振的特点外, 还具有结构在线自组织能力, 并在李亚普诺夫框架下进行了严格的稳定性分析. 此外, 在规则演化过程中, 通过对模糊规则进行动态调整和移除, 确保对负荷扰动的适应能力. 仿真和实验结果表明, 所提出的控制器具有优异的动静态性能.

参考文献 (References)

[1] 黄晓明, 范志华, 刘子文, 等. 基于有功和无功功率协调分配的统一电能质量调节器控制策略[J]. 电力自动化设备, 2018, 38(3): 177-183. (Huang X M, Fan Z H, Liu Z W, et al. Control strategy of UPQC based on active and reactive power coordination distribution[J]. Electric Power Automation Equipment, 2018, 38(3): 177-183.)

[2] Salimi M, Soltani J, Zakipour A. Experimental design of the adaptive backstepping control technique for single-phase shunt active power filters[J]. IET Power Electronics, 2017, 10(8): 911-918.

[3] Hou S, Fei J, Chen C, et al. Finite-time adaptive fuzzy-neural-network control of active power filter[J]. IEEE Transactions on Power Electronics, 2019, 34(10): 10298-10313.

[4] Chu Y, Fei J, Hou S. Dynamic global proportional integral derivative sliding mode control using radial basis function neural compensator for three-phase active power filter[J]. Transactions of the Institute of Measurement and Control, 2018, 40(12): 3549-3559.

[5] Nguyen M L, Chen X K, Yang F. Discrete-time quasi-sliding-mode control with prescribed performance function and its application to piezo-actuated positioning systems[J]. IEEE Transactions on Industrial Electronics, 2017, 65(10): 942-950.

[6] 乔俊飞, 张力, 李文静. 基于尖峰自组织模糊神经网络的需水量预测[J]. 控制与决策, 2018, 33(12): 2197-2202. (Qiao J F, Zhang L, Li W J. Prediction of water demand based on spiking self-organizing fuzzy neural network[J]. Control and Decision, 2018, 33(12): 2197-2202.)

[7] 韩红桂, 林征来, 乔俊飞. 基于 UKF 的增长型模糊神经网络设计[J]. 控制与决策, 2017, 32(12): 2169-2175. (Han H G, Lin Z L, Qiao J F. Growing fuzzy neural network design based on UKF algorithm[J]. Control and Decision, 2017, 32(12): 2169-2175.)

[8] Wu L, Wu M. Single-phase cascaded H-bridge multi-level active power filter based on direct current control in AC electric railway application[J]. IET Power Electronics, 2017, 10(6): 637-645.

[9] Rong J, Yang Z, Wong P, et al. A novel meta-cognitive fuzzy-neural model with backstepping strategy for adaptive control of uncertain nonlinear systems[J]. Neurocomputing, 2017, 230: 332-344.

作者简介

侯世玺 (1988—), 男, 讲师, 博士, 从事智能控制、电能质量等研究, E-mail: houshixi@hhu.edu.cn;

储云迪 (1990—), 女, 讲师, 博士, 从事智能控制、电能质量等研究, E-mail: chuyundi@hhu.edu.cn;

陈晨 (1998—), 男, 本科生, 从事智能控制的研究, E-mail: 1310457414@qq.com.

(责任编辑: 郑晓蕾)