

静止无功发生器递归神经网络自适应控制

陈巍 吴捷

(华南理工大学电力学院 510641 广州)

摘要 构造了新型静止无功发生器(ASVG)递归神经网络自适应控制系统,该系统由递归网络辨识器及神经网络控制器构成,所构造的系统可以实现 ASVG 的非线性自适应控制。仿真实验表明,该控制系统具有良好的控制品质、鲁棒性及泛化能力,是一种较为通用的电力系统控制模型。

关键词 新型静止无功发生器 递归神经网络 自适应控制

分类号 TM 761 TP 18

0 引言

电力系统是一个典型的非线性大系统,随着社会的进步、经济的发展,社会对电力的需求不断增加,使现代电力系统发展迅速,系统日趋复杂。大机组、重负荷、超高压远距离输电、大型互联网络的发展,以及对电力系统安全性、经济性及电能质量的高要求,使灵活交流输电系统(FACTS)技术成为目前电力系统的一个重要的研究领域。新型静止无功发生器(ASVG)作为 FACTS 器件中的一种,由于具有诸多优点而成为目前电力系统无功补偿的发展方向,对 ASVG 的控制技术进行深入的研究十分重要。目前 ASVG 的控制技术主要包括 PID 控制、PID+PSS 控制、逆系统 PI 控制、微分几何控制、模糊控制等^[1~4]。在神经网络建模与控制中,我们研究了 ASVG 的递归神经网络建模、多目标监督控制及逆动力学控制^[5~7],从前面的研究结果可以看出,递归网络多目标监督控制与逆动力学控制各自具有实现简单、稳定性好、运算速度快及具有一定的自适应能力等优点,但也存在某一运行点控制效果无法超越训练器,难以进行在线训练及难以选择最恰当的期望接入点电压以及无法实现控制误差的实时反馈等不足。因此构造一种可以实现模型在线辨识、控制器参数实时调整的 ASVG 递归神经网络的自适应控制系统是十分吸引人的。本文构造了 ASVG 递归神经网络自适应控制系统,给出了控制器、辨识器的训练算法,并进行了仿真实验。

1 控制系统结构及工作原理

电力系统的状态变量多、关系复杂、非线性特性强,而且在故障状态下系统的模型结构变化很大。正是由于这样的特点,构造一个可以实现非线

性控制。而且控制作用可以随着系统模型的变化而变化的自适应控制系统,是人们所期望的。在构造自适应控制系统时,可以考虑构造模型参考自适应控制系统,也可以考虑构造自校正控制系统。对于电力系统,随着网络结构的不断扩大,其结构的复杂性也越来越高。发电机组的投切、负荷的变化、故障的发生、保护装置的动作都会带来系统模型结构与参数的变化,建立一个精确统一的参考模型是非常困难的。因此,对于 ASVG 的控制,本文建立了自校正式的递归神经网络控制系统,其结构如图 1 所示。

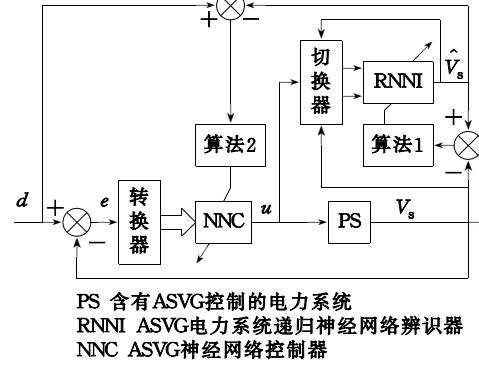


图1 ASVG 递归神经网络自适应控制系统结构图
Fig. 1 Schematic diagram
of ASVG RNN adaptive control system

系统主要由 3 个部分组成,即 PS, RNNI 以及 NNC。RNNI 负责对 ASVG 电力系统建模,通过它可以实时反传系统控制误差,为 NNC 提供修正信号,由 NNC 最终实现控制信号的获取。其中转换器的作用是将系统的残差:

$$e(k) = y_d(k) - y(k) \quad (1)$$

以一定的方式组合起来,送到神经网络控制器的输入节点。切换器的作用是实现辅助调节控制,算法 1、算法 2 分别用来训练 RNNI 和 NNC。

NNC 的结构可以采用逆动力学模型结构,即其

输入向量为 $[d(k), y(k-1), u(k-1)]$, 由于此时引入了控制器自身的反馈, 控制器的结构为并联模型, 因而其控制的稳定性及收敛性不理想。PID 控制稳定性好, 适应能力强, 为此本文构造了具有 PID 形式的输入结构, 此时 NNC 的输入输出关系为:

$$u(k) = N\left(W^C, e(k) - e(k-1), e(k), \sum_{i=0}^k e(i)\right) \quad (2)$$

其中 $e(k)$ 由式(1)确定; W^C 代表控制器的权值。

这里 NNC 采用的是前馈神经网络, 而无需采用递归神经网络。这主要是因为在式(2)的输入结构下, 该控制器可以实现动态系统的控制。

由前馈神经网络的结构及式(2)可知:

$$u(k) = \sum_{i=0}^J w_i^0(k) f_N\left(\sum_{j=0}^N w_{ij}(k) I_j(k)\right) \quad (3)$$

$$I(k) = [e(k) - e(k-1), e(k), \sum_{l=1}^k e(l)] \quad (4)$$

式中 J 与 N 分别为输出及输入层权的个数; $e(k)$ 由式(1)确定。

由于 RNNI 是递归神经网络, 故

$$y(k) \approx y_m(k) = \Phi(u(l), y(l)) \quad (5)$$

式中 $y_m(k)$ 是辨识器的输出值。因此

$$e(k) = h(u(l), y(l)) \quad (6)$$

将式(6)代入式(4)可得:

$$I_j(k) = G(u(l), y(l))$$

根据式(3)可得:

$$u(k) = \sum_{i=0}^J w_i^0(k) f_N\left(\sum_{j=0}^N w_{ij}(k) G(u(l), y(l))\right) = H(u(l), y(l)) \quad (7)$$

式(5)~式(7)中, $l \leq k-1$ 。

由此可见, 采用 PID 形式的输入结构是合理的。

在自校正控制中, 首先需要进行的是辨识被控对象的模型, 只有建立了良好的模型才可据此修正控制器参数。而在此自适应控制中, 我们要实现两个任务, 即对接入点电压起到支撑作用, 进而向系统提供阻尼, 抑制系统振荡。可以看出控制量是逆变器触发角的控制电压 u , 而期望的控制目标即是维持接入点电压 V_s 不变, 这样可以确定 RNNI 的作用是实现 $u \rightarrow V_s$ 的非线性映射。这里给出 RNNI 训练的指标函数:

$$E_1 = \frac{1}{2} \sum_{k=1}^N [V_s(k) - \hat{V}_s(k)]^2 \quad (8)$$

由于模型建立的最终目的是给控制器提供一个修正参数的依据, 因此 RNNI 能否建立电力系统的非线性动态模型以及模型精度的高低将会影响控制器的控制效果。文[5]已经讨论了递归网络对电力系

统的建模能力, 而且成功地实现了 $u \rightarrow V_s$ 。高精度的建模, 因此自适应控制中的系统辨识问题得到了解决。

对控制器参数的修正也要依据一定的指标, 为实现接入点电压的支撑作用, 这里给出修正控制器的二次型指标为:

$$E_C = \frac{1}{2} \sum_{k=1}^N [d(k) - V_s(k)]^2 \quad (9)$$

其中 $d(k)$ 是 k 时刻期望的接入点电压值。

根据这个指标, 通过反传 $\partial \hat{V}_s / \partial W$ 就可以实现神经网络控制器参数的实时调整。

对一般的非线性系统, 非线性特性并不十分强, 系统的状态变量也不多, 在这种状态下, 所构造的递归网络自适应控制系统可以直接对被控系统进行在线训练与控制, 控制系统收敛十分迅速。但对于电力系统这样的复杂非线性系统, 则必须经过离线的训练, 以避免由于辨识器及控制器不成熟而带来大的控制误差。对于 ASVG 的控制, 必须进行两个离线训练过程: 一个是要离线训练 RNNI, 使之获得电力系统的非线性特性; 另一个是离线训练 NNC, 以使它的权值接近于实际控制的权值。离线训练 RNNI 采用文[5]所介绍的方法, 对于 NNC 的训练可以采用常规的控制器进行, 即训练 NNC 使之学习常规控制器的动力学特性, 先获得常规控制器的控制性能。在这种情况下, 才可能保证控制系统在控制的初始阶段控制作用是稳定有效的, 不至于引起系统发散。另外在仿真中可以发现, 不进行离线训练而直接构成控制系统, 进行边训练边控制, 由于 ASVG 系统的复杂性, 控制器给出偏差过大的控制, 从而容易引起 RNNI 和 NNC 的隐含层节点输出饱和, 使系统的运行无法进行下去, 因此无法获得理想的 RNNI 及 NNC 的权值。这是构造 ASVG 递归神经网络自适应控制系统, 以及其他电力系统神经网络自适应控制器中应当注意的问题。

根据上面的论述, ASVG 神经网络自适应控制实现的过程可归纳如下:

a. 构造 RNNI, 适当选择 RNNI 的参数, 离线训练 RNNI, 使之实现含有 ASVG 电力系统的非线性建模。

b. 构造 NNC, 适当选择 NNC 的参数; 同时构造一个 ASVG 的常规控制器, 离线训练 NNC, 使之能够获得常规控制器的控制特性。

c. 将 RNNI 与 NNC 联合起来构造完整的神经网络自适应控制系统。

d. 根据期望接入点电压与实际电压之差, 由 NNC 获得控制信号 u , 对系统实施控制, 得到系统的实际输出 V_s 及 RNNI 的输出 \hat{V}_s 。

e. 根据 V_s 与 \hat{V}_s 的差,由算法 1 调节 RNNI 权值,使 RNNI 学习 ASVG 电力系统的动态特性。

f. 通过 RNNI 反传 d 与 V_s 的差,通过算法 2 调节 NNC 的权值,完成控制器的训练。

g. 重复步骤 d~步骤 f。

2 学习算法

2.1 递归神经网络辨识器 RNNI

下面推导递归神经网络辨识器 RNNI 的学习算法。神经网络辨识器 RNNI 的输入、输出映射可表示为:

$$\begin{aligned} \hat{V}_s(k) &= \sum_{i=0}^j O_i(k) w_i^0(k) \\ O_i(k) &= f\left(\sum_{j=0}^N I_j(k) w_{ij}^1(k) + w_i^D(k) O_i(k-1)\right) \end{aligned} \quad (10)$$

$$I_1(k) = u(k)$$

在式(8)的性能指标下 RNNI 的权值修正可表示为:

$$W(k+1) = W(k) + \Delta W(k) \quad (11)$$

$$\begin{aligned} \Delta W(k) &= -\eta \frac{\partial E_1}{\partial W(k)} = \\ &- \eta(V_s(k) - \hat{V}_s(k)) \frac{\partial \hat{V}_s(k)}{\partial W(k)} \end{aligned} \quad (12)$$

对于输出层,

$$\frac{\partial \hat{V}_s(k)}{\partial w_i^0(k)} = O_i(k) \quad (13)$$

对于递归层,

$$\frac{\partial \hat{V}_s(k)}{\partial w_i^D(k)} = \frac{\partial \hat{V}_s(k)}{\partial O_i(k)} \cdot \frac{\partial O_i(k)}{\partial w_i^D(k)} = w_i^0(k) \frac{\partial O_i(k)}{\partial w_i^D(k)} \quad (14)$$

$$\frac{\partial O_i(k)}{\partial w_{ij}^1(k)} = f'(n_i(k)) O_i(k-1) \quad (15)$$

其中 $n_i(k)$ 为 k 时刻第 i 个隐含节点的输入值。

对于输入层,

$$\frac{\partial \hat{V}_s(k)}{\partial w_{ij}^1(k)} = \frac{\partial \hat{V}_s(k)}{\partial O_i(k)} \cdot \frac{\partial O_i(k)}{\partial w_{ij}^1(k)} = w_i^0(k) \frac{\partial O_i(k)}{\partial w_{ij}^1(k)} \quad (16)$$

$$\frac{\partial O_i(k)}{\partial w_{ij}^1(k)} = f'(n_i(k)) I_j(k) \quad (17)$$

其中 $I_j(k)$ 为 k 时刻输入层第 j 个神经元的输入值。

2.2 神经网络控制器 NNC

根据式(9)给出的性能指标可知:

$$\Delta W(k) = -\eta \frac{\partial E_C}{\partial W(k)} = \\ \eta(d(k) - V_s(k)) \frac{\partial V_s(k)}{\partial W(k)} \quad (18)$$

其中

$$\frac{\partial V_s(k)}{\partial W(k)} \approx \frac{\partial \hat{V}_s(k)}{\partial W(k)}$$

则

$$\frac{\partial \hat{V}_s(k)}{\partial W(k)} = \frac{\partial \hat{V}_s(k)}{\partial u(k)} \cdot \frac{\partial u(k)}{\partial W(k)} \quad (19)$$

令

$$e_u = (d(k) - V_s(k)) \frac{\partial \hat{V}_s(k)}{\partial u(k)} \quad (20)$$

则

$$\Delta W(k) = \eta e_u \frac{\partial u(k)}{\partial W(k)} \quad (21)$$

根据 RNNI 的结构可知:

$$\frac{\partial \hat{V}_s(k)}{\partial u(k)} = \sum_{i=0}^{J-1} (w_i^0(k) f'(n_i(k)) w_{i1}^1) \quad (22)$$

$\partial u(k)/\partial W(k)$ 的推导类似于 RNNI 权值算法的推导,这里不再赘述。

3 仿真研究

为验证 ASVG 递归神经网络自适应控制系统能否实现对 ASVG 良好的控制,检验系统对电压的支撑能力以及控制的鲁棒性,本文做了仿真实验。实验对象为单机-无穷大系统,系统参数见文[7],系统运行点为 $\delta = 50^\circ, P_e = 1.08$ 。实验分为两部分,一部分为系统故障情况下,考察 ASVG 神经网络自适应控制对电力系统的作用。故障为在 0.1 s 发生机端三相对地短路,0.25 s 故障切除,实验结果如图 2 所示。表 1 给出了控制系统的性能指标。另一部分为考察大负荷投切的情况下,ASVG 神经网络自适应控制对电力系统的作用,实验结果如图 3 所示,控制系统的性能指标见表 2。

仿真中对 RNNI 的离线训练采用文[5]的方法,对 NNC 的离线训练采用常规的控制器^[3]。训练中采用方差为 0.1、均值为零的白噪声信号作为误差信号输入到常规控制器,以常规控制器的输出即控制信号作为 NNC 输出的学习信号。其性能指标也采用二次型指标,即使 NNC 输出与常规控制器输出之差的二次型函数最小。构造的 RNNI 为 3 层对角递归神经网络,输入层为 u 与 V_s 两个节点,其隐含层为 10 个节点,输出层为 1 个节点。NNC 为 3 层前馈神经网络,输入层为 3 个节点,隐含层为 10 个节点,输出层为 1 个节点。

由图 2 可以看出,递归神经网络自适应控制可以使 ASVG 快速有效地发出无功,并且可以快速地进入稳态。ASVG 递归神经网络自适应控制系统对严重故障时系统电压的支撑作用,以及对发电机功角振荡的抑制作用明显优于常规控制器。利用 RNN 自适应控制,接入点电压及转子角分别在 0.92 s 和 2.86 s 就结束了过渡过程,而常规控制则分别需要 3.54 s 和 4.84 s。对比文[7]也可以看出,这种控制方法的控制效果也优于神经网络逆动力学模型控制器。在同样的系统参数及故障情况下,在逆动力学控

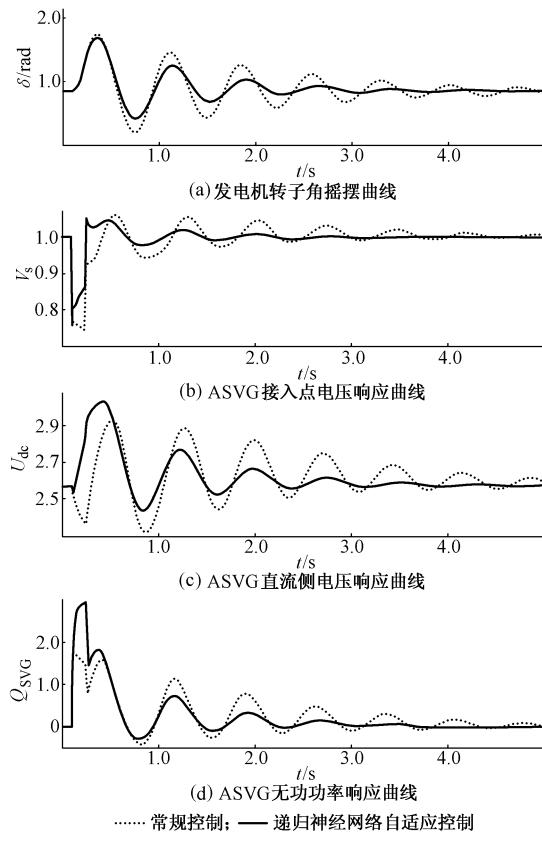


图 2 ASVG 递归网络自适应控制仿真曲线

Fig. 2 Simulation curves
of ASVG RNN adaptive control system

表 1 短路故障时在不同控制方式下的系统指标

Table 1 Performance indexes (of ASVG)
with different control strategies
under short circuit condition

控制方式	受控对象	正超调量/ (%)	负超调量/ (%)	过渡过程时间/s
常规控制	转子角	102.53	-76.20	4.84
电压		6.34	-25.32	3.54
RNN 自适应控制	转子角	97.01	-50.21	2.86
	电压	5.23	-24.01	0.92

制中,发电机转子角的超调量为 101.7%,且经过 3.68 s 才可进入稳态;而利用神经网络自适应控制,发电机转子角的超调量为 97.01%,且可在 2.86 s 就进入稳态。同样,对于电压振荡的抑制作用也优于神经网络逆动力学控制。

由图 3 可以看出,当在 ASVG 接入点母线突然加大负荷时,经过 ASVG 的补偿作用,系统可以重新回到稳定的运行状态,使用常规控制手段,在突然加负荷时,负荷所在母线电压下降了 19.03%,而利用神经网络自适应控制则仅下降了 9.12%。而且在负荷切除后采用 RNN 自适应控制,母线电压在 0.68 s 左右已经进入到稳态,而采用常规控制在 5 s

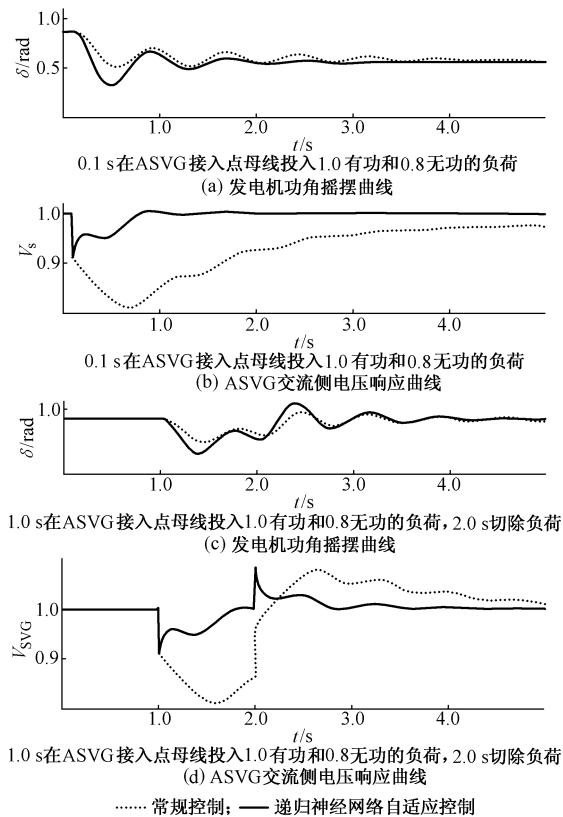


图 3 ASVG 递归网络自适应控制对负荷投切的作用

Fig. 3 Response of ASVG RNN adaptive
control system to load changing

表 2 负荷投切时不同控制方式下的系统指标

Table 2 Performance indexes (of ASVG)
with different control strategies
in the case of load changing

控制方式	受控对象	超调量/ (%)	过渡过程时间/s
常规控制	转子角	-41.32	3.97
	电压	-19.03	>5.00
RNN 自适应控制	转子角	-62.11	1.82
	电压	-9.12	0.68

时仍未能进入稳态。由此可见,递归网络自适应控制可以有效地向系统提供无功,抑制电压振荡。同时可以看到,在突然加负荷的情况下,递归神经网络自适应控制对于发电机转子角的抑制作用比常规控制要差,主要是由于在神经网络自适应控制中,所给出的性能指标以稳定接入点电压为目的,没有单独考虑对转子角的抑制作用。

另外在实时训练与控制中,我们考察了神经网络的运算速度。采用 Compaq 586-133 计算机,从采集信号,计算新的控制量,到完成一遍神经网络辨识器及控制器所有联接权的训练,需要 0.36 ms。因此,在充分的离线训练之后,进行实际系统的在线控制是可能的。

由此可见,这种结合递归神经网络与自适应技

术的控制系统实现了 ASVG 真正的实时非线性控制, 控制效果是令人满意的。随着系统的运行, RNNI 将会更精确地学习到电力系统的动态特性, 特别是学习到各种由于系统运行结构的调整、负荷波动、各种随机扰动以及其它各种情况所引起的饱和、限幅等非线性特性, 使之能够更准确地将等效误差反传给控制器, 从而获得更有效的控制。该控制系统的非线性控制、自适应以及良好的泛化能力, 使之成为一种用于电力系统 FACTS 器件实时控制的有效手段, 可以在一定的调整后, 应用于其他 FACTS 器件的控制, 具有良好的应用前景。

4 结论

通过分析及仿真实验可以看到, ASVG 递归神经网络自适应控制系统具有以下特点:

a. 神经网络的控制器不需要导师信号, 控制性能不受训练器的限制, 因而可以获得常规控制器无法获得的控制效果。

b. 采用递归网络作为辨识器, 因而可以获得电力系统非线性动态模型, 而控制器可以根据控制误差和系统的状态实现 ASVG 真正意义上的非线性控制。

c. 神经网络的辨识器与控制器同时在线进行训练, 因而当系统模型发生变化时, 控制系统可以及时调节辨识器及控制器参数, 因而具有良好的适应能力。

d. 控制中始终以能量函数最小为目的, 且将控制误差反馈回控制器, 因而是一个闭环的反馈系统, 具有更高的控制精度及更强的鲁棒性。

e. 所构造的控制系统具有一定的普遍性, 泛化能力强。

参 考 文 献

- 1 Mori S, Matsuno K, Takeda M, et al. Development of Large Static VAR Generator Using Self-Commutated Inverter for Improving Power System Stability. *IEEE Trans*, 1993, PS-8(1): 371~377
- 2 姜齐荣, 王强, 韩英铎, 等. ASVG 的建模及其控制. 清华大学学报, 1997, 37(7): 21~25
- 3 沈沉, 孙元章. ASVG 的非线性控制对改善电力系统阻尼特性的研究. 电力系统自动化, 1997, 21(5)
- 4 沈沉, 孙元章, 卢强. 预测模糊控制及其在 ASVG 上的实现. 电力系统自动化, 1997, 21(10)
- 5 陈巍, 吴捷. 静止无功发生器的递归神经网络建模. 电力系统自动化, 1999, 23(4)
- 6 陈巍, 吴捷. 静止无功发生器递归神经网络多目标监督控制. 电力系统自动化, 1999, 23(7)
- 7 陈巍, 吴捷. 静止无功发生器递归神经网络逆动力学控制. 电力系统自动化, 1999, 23(8)

陈巍, 男, 1971 年生, 博士, 主要研究方向为神经网络、自适应控制在电力系统暂态稳定分析与控制中的应用。

吴捷, 男, 1937 年生, 教授, 博士生导师, 主要从事自适应、自组织控制及电力系统自动化等方面的研究工作。

ADAPTIVE CONTROL OF ASVG BY USING DIAGONAL RECURRENT NEURAL NETWORK

Chen Wei, Wu Jie (South China University of Technology, 510641, Guangzhou, China)

Abstract The adaptive control system of ASVG by using diagonal recurrent neural network (DRNN) is proposed. Containing two neural networks that are recurrent neural network identifier and neural network controller, the proposed control system can realize nonlinear adaptive control of ASVG. Simulation results show that the system has good control character, robustness and extending ability, and is a general power system control model.

Keywords ASVG recurrent neural network adaptive control