

# 使用直接神经动态规划方法的 SVC 附加阻尼控制

陆超, 谢小荣, 童陆园, 王仲鸿

(清华大学电机工程与应用电子技术系, 北京市 海淀区 100084)

## SVC SUPPLEMENTARY DAMPING CONTROL USING DIRECT NEURAL DYNAMIC PROGRAMMING

LU Chao, XIE Xiao-rong, TONG Lu-yuan, WANG Zhong-hong  
(Tsinghua University, Haidian District, Beijing 100084, China)

**ABSTRACT:** The great scales, nonlinearities and uncertainties in modern power system are the most intractable problems for dynamic controls. However, direct neural dynamic programming (direct NDP) approach based on on-line measurements can be employed in this situation, which is independent of models. In this paper, a supplementary SVC damping control in a 4-generator 2-area system was implemented using direct NDP method. Two neural networks, action network (AN) and critic network (CN), make up this controller. AN is used to control SVC, and CN is used to evaluate current system states and update AN. The self-learning and adaptive abilities are analyzed in the MATLAB environment, and the simulation results demonstrate the advantages compared to conventional control.

**KEY WORDS:** Electric power engineering; Power system; Dynamic stability; SVC supplementary control; Direct neural dynamic programming

**摘要:** 电力系统具有的规模巨大、强非线性和不确定性等因素一直是动态稳定控制中难以解决的问题, 而直接神经动态规划方法是一种基于测量的不依赖于系统模型的在线控制方法, 文中用于实现 4 机 2 区系统中 SVC 的附加阻尼控制器的设计, 主要由两部分组成: 执行网络和评价网络, 这两部分均为神经网络, 前者用于产生控制信号, 后者用于评价当前的系统状态, 并据此调整控制律。文中还通过在 MATLAB 环境下的仿真, 分析了其学习能力、控制效果和适应能力, 与使用传统方法设计的控制器的比较结果显示了其在适应性上的优越性。

**关键词:** 电力工程; 电力系统; 动态稳定; SVC 附加控制; 直接神经动态规划

## 1 引言

电力系统是世界上最复杂的网络, 由大量性质不同的元件组成。稳定是电网最重要的性质之一, 为此各种各样的现代控制理论在电力系统中得到了广泛应用, 文[1]比较详细的介绍了最优控制、微分几何理论、自适应控制、鲁棒  $H_\infty$  控制<sup>[2]</sup>等的基本原理、应用方法和特点。但是, 这些大部分是建立在系统模型可以较好地描述参数可以大致确定的基础之上的, 但由于电力系统规模巨大、限幅等强非线性现象的存在以及统计调查的困难等原因, 实际系统很难满足上述要求, 在有些方面与理论研究相差较大, 例如电压稳定研究中至关重要的负荷模型与参数, 因为其数量和性质随时间、天气变化较大而难以确定。文献[2]中用故障后实际动态过程记录数据与仿真进行校核时, 在修改了直流、发电机控制、负荷等仿真模型后才取得与实测数据比较吻合的波形。这种现实情况要求有基于实时测量的、不完全依赖于离线模型的控制设计方法。

近年来, 智能控制方法发展迅速, 其中的人工神经网络 (Artificial Neural Network, ANN) 控制由于其本质上的非线性、较好的鲁棒性等特点, 在一定程度上可以解决上述问题, 例如 Narendra 就在自适应控制中加入 ANN, 以克服其假设过于苛刻的缺陷, 取得了一定的效果<sup>[3]</sup>。但仅利用其较好的函数逼近能力和内插特点来代替传统的控制器, 又会遇到通用性 (Generalization) 的问题, 即如何在 ANN 的离线训练过程中充分地体现电力系统的不同运行状况。而 ANN 的学习功能很容易实现, 所以可以发挥这个特点, 在离线训练的基础上进一步增强其

**基金项目:** 国家自然科学基金资助项目 (50323002)。

Project supported by National Science Foundation of China (50323002).

适应性。

近似动态规划 (Approximate Dynamic Programming, ADP) 是一类可以在线地通过与系统 (环境) 的相互作用从而不断改善控制效果的方法, 有强化学习 (Reinforcement Learning, RL) [4]、自适应评价设计 (Adaptive Critic Design, ACD) [5] 等不同的分支和名称。ADP 基于动态规划的原理, 它不需要系统模型, 因此避免了模型参数不准确的问题, 也因此不用专门考虑系统的非线性、不确定性等难以处理的困难 [3]。ADP 通过采用执行-评价 (Actor-Critic) 方法, 提高了动态规划算法的计算效率, 避免了传统动态规划计算中的“维数灾” (Curse of Dimensionality) 问题 [5]。这种方法可在一定的约束条件下使一定时间范围内的控制指标达到近似最优, 且在有解的情况下约束条件越多越容易计算 [6]。ADP 中核心的执行网络 (AN) 和评价网络 (CN) 可以使用任何具有映射关系和更新能力的方法, 例如策略表 [7], 而采用反向传播 (Back-Propagation) 算法的 ANN 由于上述的一些优势, 应用得更加广泛。Venayagamoorthy 已经成功地将 DHP (Dual Heuristic Programming, 一种 ADP 方法) [8] 应用于简单电力系统的稳定控制 [9], 但 DHP 方法中的需要预先训练的模型模块增加了控制设计对系统 (环境) 因素的依赖性, 其控制效果也与此模块训练得好坏密切相关。本文采用的直接神经动态规划 (Direct Neural Dynamic Programming, DNDP) 方法 [10] 几乎完全与系统 (环境) 无关, 在 4 机 2 区电力系统 [11] 中, 实现了 SVC 的附加控制, 以用来抑制互联电网的区间低频振荡。

## 2 仿真系统简介

图 1 为用于仿真的系统, 该系统包括 2 个区域, 共 4 台发电机, 区间通过两回输电线联系, 系统参数和基本的运行方式见文献 [11]。在此运行方式下, 由于 9 号母线处的负荷较大, 联络线上的有功潮流为区域向区域 2 输送 400MW。此系统受到干扰后有多个振荡模式 [12], 两区内的振荡频率约为 1Hz, 可以被较好地抑制, 区间的振荡频率为 0.5Hz 左右, 是故障后振荡的主导模式。

在联络线中点的 8 号母线处设置 1 个 SVC 用于提供电压支撑和阻尼振荡。如果 SVC 只是采用简单的 PI 控制, 则系统在严重的故障后不能保证稳定性, 如设定的联络线上靠近母线 9 处三相短路、74ms

后切除线路 8~9 以清除故障情况, 此时表现为区间振荡引起的功角稳定问题, 所以需要改进 SVC 的控制器——引入一个附加阻尼控制。本文比较了两种附加控制器的设计方法, 一种采用了传统的零极点配置方法 (CONV) [11], 其结构类似于 PSS (Power System Stabilizer), 另一种是 DNDP 方法。两种控制器的原理框图见图 2。

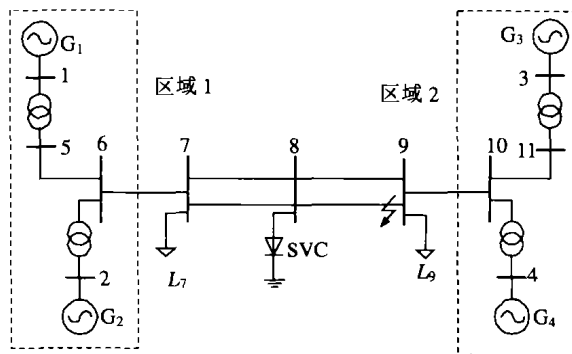


图 1 仿真系统的单线图

Fig. 1 Single-line diagram of the test power system




图 2 两种控制器的原理框图

Fig. 2 Block diagrams of two controllers

图 2 中的  $I$  表示母线 8~9 的线电流, 文献 [11] 在计算了系统的可观性之后认为选择此信号作为控制器的输入可以最好地响应区间振荡模式。 $\Delta\omega$  是包含 3 个发电机转速差的向量, 其中 1 个反映区间振荡、2 个反映区内振荡, 这些数据可以通过 PMU (Phasor Measurement Unit) 获得。 $V_{sup}$  表示附加阻尼控制器的输出。

## 3 DNDP 原理

对于一个给定的离散时间动态系统有

$$X(t+1) = f[X(t), u(t), w(t)] \quad (1)$$

$$t = 0, 1, \dots, T-1$$

式中  $X(t)$  为系统状态;  $u(t)$  为控制量;  $w(t)$  为随机扰动。

给定一个初始状态  $X(0)$ , 动态规划就是要寻求一个容许控制律  $\pi = \{\mu_0, \mu_1, \dots, \mu_{T-1}\}$ , 使式 (2) 表述的代价函数 (cost function) 为极小。

$$J_{\pi}(X(t)) = E_{w(t)} \{g[X(T)] + \sum_{t=0, \dots, T-1} \dots\}$$

$$\sum_{i=0}^{T-1} g[X(t), \mu_i(X(t)), w(t)] \quad (2)$$

这种方法能够求出全局最优解,但是计算效率限制了其更加广泛的应用。

对于一个确定性系统,ACD 是一类通过近似求解 Bellman 方程

$$J^*(X(t)) = \min_{u(t)} \{J^*(X(t+1)) + g(X(t), u(t))\} \quad (3)$$

并以此来获得次优解的一种方法,该方法可以显著降低动态规划的计算代价,DNDP 即属于此类方法。图 3 为其最初的原理图<sup>[10]</sup>,图中虚线表示反向传播的途径。




图3 DNDP 原理图  
Fig. 3 Framework of DNDP

在本文中,  $X(t)$  是向量  $\Delta\omega$ ,  $u(t)$  是附加控制器的输出  $V_{sup}$ ,  $r(t)$  是根据当前系统状态做出的“奖惩”(Reward), 即式(2)中的  $g(t)$ , 定义如下:

$$r(t) = -\sum_{i=1}^3 a_i \Delta\omega_i^2 \quad (4)$$

式(4)反映了系统在动态过程中当前的振荡程度,其绝对值越大,说明振荡越剧烈。 $U_c(t)$  在此处定义为零,表示控制的目标应该是所有的发电机趋于同步,偏差  $e_a(t) = J(t) - U_c(t)$  用来修改 AN 的权重系数,即控制器的策略,从而更好地进行阻尼。 $\alpha$  为折扣系数, CN 的输出误差定义为

$$e_c(t) = \alpha J(t) - [J(t-1) - r(t)] \quad (5)$$

用来调整 CN 的权重系数,从而更好地预测代价函数。这里用  $t$  和  $t-1$  的量代替了式(3)中  $t+1$  和  $t$  的量,因此就不需要专门的模块来模拟系统和预测其在  $t+1$  时刻的状态,这样避免了原有的系统模型和参数不准确以及模块训练的好坏程度不同可能带来的误差。详细的 DNDP 算法见文献[10]。

## 4 仿真结果

仿真在 MATLAB 的 SIMULINK 环境下进行,使用到了 SimPowerSystems 模块集。4机2区系统是 MATLAB 自带的一个示例,在文献[11]的基础上

加入了发电机的 PSS 控制(为了保持与文献[11]中的附加阻尼控制器的可比性,这些 PSS 在本文的仿真中没有使用)。SVC 的基本控制按照文献[11]所述的结构和参数搭建,DNDP 的算法通过 MATLAB 的 S-Function 功能嵌入 SIMULINK 仿真系统。

AN 和 CN 均为 3 层的前馈神经网络,隐层神经元的个数均为 6 个,其权重初始化过程可以为对简单的传统控制器的模拟,本文为了更好的地测试其学习能力,初始值取为在  $(-1, 1)$  内均匀分布的随机数,因此对于不同的训练过程,其开始阶段的控制效果相差比较大,有可能很差。图 4 和图 5 所示为一个比较典型的训练过程,其中,图 4 为附加控制器的输出,图 5 为附加控制器的输入、输出映射关系。整个过程包括 2 个阶段(也就是 2 次暂态稳定仿真),在阶段 1,由于初始化的 AN 不理想,起初的输出与理论上正确的控制行为<sup>[13]</sup>在方向上完全相反,所以还没有仿真到 5s 整个系统已经失稳,观察其输入输出关系也几乎没有什么规律。但是,阶段 1 给 DNDP 控制器提供了大量的“反面”信息,这是阶段 2 能进一步改善控制效果的基础。在阶段 2,控制器基本自学习到了正确的控制策略,从图中可以看出其与阶段 1 的输出有明显的差别,而这一点在输入、输出的映射关系上体现得更加充分,此时已达到了接近理想的线性-限幅关系,严重故障后的初期控制器输出尽快地达到顶值,类似 Bang-Bang 控制,这样有利于充分发挥其能力,在后期因为振荡幅度减小,输出也相应减小,以尽快达到稳态。在阶段 2 的基础上继续训练,将提高控制器的响应速度,即更快地达到限幅值,但总体上控制效果的改善已不明显。

在控制器从随机初始化开始自学习的过程中,有 2 个特点值得注意:

(1)为了获得此控制策略,在控制器的设计中,并没有进行复杂的电力系统分析,没有使用到电力系统模型和参数,因此动态稳定控制中如何处理非线性、不确定性等问题并没有造成困难;

(2)网络权重初始化的随机性使得控制的起始状态相差很大,但都能收敛到基本相同的控制策略,反映在输入输出映射关系上,仅表现为线性部分的斜率略有不同。

2 种不同的附加控制的效果比较见图 6,图中所示曲线为发电机  $G_1$  相对于  $G_3$  的功角  $\delta\omega$ 。可以看出,采用 CONV 控制时的效果与文献[11]中的结果基本一致,经过 7 次振荡后在 13s 左右平息。而采用 DNDP 时在 8s 左右振荡已被基本抑制,效果更好一

些，这也说明其训练所得的控制策略是正确的。




图 4 两阶段训练过程中的控制器输出

Fig. 4 Output of controller in the training process with two stages




图 5 两阶段训练过程的输入输出映射关系

Fig. 5 Mapping of input-output in the training process with two stages

为了进一步验证 DNDP 控制器对不同系统运行条件的适应能力，改变了测试系统故障前的结构，停运一回联络线 7-8，此时主导区间振荡模式的周期约为 3s。故障位置不变，且仍为三相短路故障，但由于改动后系统稳定水平下降，所以减小了故障清除时间。图 7 为 2 种附加控制方法的效果。

由于 CONV 控制器的频响特性仅在 0.5Hz 处具有较高的增益，而且零极点配置也是按照原来的运行方式设计的，所以当区间振荡模式发生明显的变化后，CONV 的控制效果大打折扣，图中 20s 时仍有幅度不小的振荡。对于 DNDP 控制，由于其已经学习到正确清晰的策略（输入、输出映射关系），




图 6 发电机 G<sub>1</sub> 相对于 G<sub>3</sub> 的功角曲线

Fig. 6 Power angle of G<sub>1</sub> relative to G<sub>3</sub>




图 7 发电机 G<sub>1</sub> 相对于 G<sub>3</sub> 的功角曲线

Fig. 7 Power angle of G<sub>1</sub> relative to G<sub>3</sub>

加上具备根据不同情况在线更新的能力，因此仍然能够保持不错的控制效果。

## 5 结语

本文实现了 4 机 2 区系统中 SVC 应用 DNDP 方法的附加阻尼控制，在设计和仿真的过程中可以看出有以下特点：

(1) DNDP 对系统（外部环境）的依赖性很小。设计中只需要简单的系统分析，与模型和参数的关系不大，在应用中表现为系统运行状态的改变对控制效果没什么影响；

(2) DNDP 可以处理强非线性问题，也很容易实现控制的多输入多输出，相对于单输入单输出问题并不需要作额外的工作；

(3) DNDP 具备较好的自学习能力，仿真中从随机初始化状态开始，比较迅速地学习到了清晰的反映系统物理规律的控制策略。如果面对的是一个复杂得多的控制问题，可以期望 DNDP 能够为更好地认识问题本质提供启示。

由于本文研究的这类方法包含了不确定性对象，弱化了假设条件，而且发展时间较短，所以相关的一些理论基础尚不完善，其在参数调整过程中的系统稳定性证明目前还只限于线性二次型（LQ）问题<sup>[14,15]</sup>。而适用于电力系统的稳定性研究还有待于进一步的工作。

## 致谢

美国亚利桑那州立大学的司捷（Jennie Si）教授在本文的研究过程中给予了大量的帮助和指导，在此表示衷心的感谢！

## 参考文献

[1] 吴捷, 刘永强, 陈巍. 现代控制技术在电力系统控制中的应用 (一) [J]. 中国电机工程学报, 1998, 18(6): 377-382.  
Wu Jie, Liu Yongqiang, Chen Wei. The Application of Modern Control Techniques in Power System Control I[J]. Proceedings of the CSEE.

- 1998, 18(6): 377-382.
- [2] Miller WT, Sutton RS, Werbos PJ. *Neural Network Control* [M]. Cambridge: MIT Press, 1990.
- [3] Sutton RS, Barto AG. *Reinforcement Learning: an Introduction* [M]. Cambridge: MIT Press, 1998.
- [4] Prokhorov DV, Wunsch DC. Adaptive Critic Designs [J]. *IEEE Trans. Neural Networks*, 1997, 8(5): 997-1007.
- [5] Si J, Barto AG, Powell W, Wunsch DC. *Learning and Approximate Dynamic Programming: Scaling up to the Real World* [M]. New York: IEEE Press and John Wiley & Sons, 2004.
- [6] Lewis FL. *Optimal Control* [M]. New York: Wiley, 1986.
- [7] Bertsekas DP, Tsitsiklis JN. *Neuro-Dynamic Programming* [M]. Belmont: Athena Scientific, 1996.
- [8] White DA, Sofge DA. *Handbook of Intelligent Control: Neural, Fuzzy and Adaptive Approaches* [M]. New York: Van Nostrand Reinhold, 1992.
- [9] Venayagamoorthy GK, Harley RG, Wunsch DC. Dual Heuristic Dynamic Programming Excitation Neurocontrol for Generators in a Multimachine Power System [J]. *IEEE Trans. Industrial Applications*, 2003, 39(2): 382-394.
- [10] Si J, Wang Y. On-Line Learning Control by Association and Reinforcement [J]. *IEEE Trans. Neural Networks*, 2001, 12(2): 264-276.
- [11] Kundur P. *Power System Stability and Control* [M]. New York: McGraw-Hill, 1994.
- [12] Rogers G. *Power System Oscillations* [M]. Boston: Kluwer Academic, 2000.
- [13] 杨晓东, 房大中, 刘长胜, 等. 阻尼联络线低频振荡的 SVC 自适应模糊控制器研究 [J]. *中国电机工程学报*, 2003, 23(1): 55-59.  
Yang Xiaodong, Fang Dazhong, Liu Changsheng, et al. An Adaptive SVC Fuzzy Controller for Damping Tie-Link Low Frequency Oscillation [J]. *Proceedings of the CSEE*, 2003, 23(1): 55-59.
- [14] Bradtke SJ. *Incremental Dynamic Programming for On-line Adaptive Optimal Control* [R]. Amherst, University of Massachusetts, 1994.
- [15] Ten Hagen SHG. *Continuous State Space Q-Learning for Control of Nonlinear System* [D]. Amsterdam, University of Amsterdam, 2001.

---

收稿日期: 2004-06-24。

作者简介:

陆超 (1977-), 男, 博士研究生, 研究方向为电力系统稳定控制;  
谢小荣 (1975-), 男, 助理研究员, 目前研究方向为电力系统广域动态监测与稳定控制;

童陆园 (1946-), 男, 教授, 研究方向为电力系统稳定控制和 FACTS 技术;

王仲鸿 (1933-), 男, 研究员, 研究方向为电力系统稳定控制和 FACTS 技术。