

基于 T-S 模型的模糊神经网络光伏 MPPT 控制*

赵剑飞, 卢航宇, 丁朋飞

(上海大学 机电工程与自动化学院, 上海 200072)

摘要: 为了克服传统最大功率点跟踪 (MPPT) 方法的一些缺点, 使光伏系统更加快速准确地工作在最大功率输出点, 提出了基于模糊控制和神经网络控制相结合的自适应控制方法。该方法充分利用模糊神经网络处理非线性问题的优点, 通过模糊控制来改变步长, 利用神经网络的自学习能力来快速达到平衡, 使光伏 MPPT 在跟踪速度和稳定性之间达到一个较优的平衡。仿真和试验结果表明, 基于模糊神经网络自适应控制的 MPPT 方法具有较强的鲁棒性和自适应能力。

关键词: T-S 模型; 模糊神经网络; 最大功率点跟踪

中图分类号: TP 273 **文献标志码:** A **文章编号:** 1673-6540(2018)11-0116-05

A Photovoltaic Maximum Power Point Tracking Control Based on Fuzzy Neural Network of T-S Model*

ZHAO Jianfei, LU Hangyu, DING Pengfei

(School of Mechatronics Engineering and Automation, Shanghai University, Shanghai 200072, China)

Abstract: In order to overcome some shortcomings of the traditional maximum power point tracking (MPPT) method and make the photo voltaic (PV) system work more quickly and accurately at the maximum power output point, an adaptive control method based on fuzzy control and neural network control was proposed. This method made full use of the advantages of fuzzy neural network to deal with nonlinear problems. The fuzzy control was used to change the step size, and the self-learning ability of the neural network was used to achieve the balance quickly. The PV MPPT achieved a better balance between tracking speed and stability. Simulation and experimental results showed that the MPPT method based on fuzzy neural network adaptive control had strong robustness and adaptive ability.

Key words: T-S model; fuzzy neural network; maximum power point tracking (MPPT)

0 引言

随着环境污染的不断加剧以及化石能源的短缺, 风能、太阳能等新型可再生能源的开发与利用不断增加^[1]。太阳能具有可再生、无污染、受地理环境影响小等优点, 是未来能源的主要来源之一^[2]。光伏发电是利用太阳能的最有效方式, 在光伏发电系统中, 若以相同的光照、温度的条件下

输出最多的电能, 可以通过实时的调整光伏电池阵列的工作点, 使之稳定在最大功率点附近, 即最大功率点跟踪 (Maximum Power Point Tracking, MPPT)^[3-4]。MPPT 过程本质上讲是一个不断寻优的过程, 即通过控制太阳能电池阵列端电压来间接控制最大功率的输出^[5]。目前, MPPT 方法主要包括: 恒定电压法、电导增量法和扰动观察法^[6]。恒定电压法控制系统简单, 便于数字化实

* 基金项目: 台达环境与教育基金会 (DREG2016015)

作者简介: 赵剑飞 (1977—), 男, 博士, 研究方向为电力电子与电力传动。

卢航宇 (1994—), 男, 硕士研究生, 研究方向为电力电子与电力传动。

丁朋飞 (1993—), 男, 硕士研究生, 研究方向为新能源汽车。

现,但是其忽略了温度对整个系统的影响,故控制精度不高。电导增量法虽然能够适应光强度的快速变化,但由于需要高精度的传感器,所以实现起来较困难。扰动观察法结构简单、被测参数少,从而被广泛应用,其问题同样是控制精度不高。

传统光伏 MPPT 控制方法根据光伏阵列的输出特性来作出判断,是一个不断的寻优过程。模糊控制以及神经网络控制用于 MPPT 控制中属于新兴的控制手段。模糊控制鲁棒性好、抗干扰能力强,以模糊集和理论为基础,通过结合自动控制技术而形成的模糊控制理论在应对复杂的非线性控制中可以得出有效控制策略^[7]。神经网络作为现代信息智能处理的一种方法,在很多领域的应用中可以体现其优越性,在自动控制中的应用成果就是神经网络控制^[8]。鉴于神经网络在非线性控制中的自学习、自调整和实时处理能力,本文采用单神经元 PI 控制器代替传统的 PI 控制,利用其智能的参数自调整能力来降低传统 PI 参数调试的工作量。因此,本文将神经网络控制和模糊控制相结合,使系统快速稳定地运行在最大功率点上。最后通过 MATLAB/Simulink 仿真以及试验验证了本方法的可行性和有效性。

1 光伏电池模型和特征曲线

1.1 光伏电池的等效模型

光伏电池利用光伏效应把太阳光能直接转化为电能,转换原理即半导体 PN 结的光伏效应^[9]。光伏电池等效电路如图 1 所示。




图 1 光伏电池等效电路

图 1 中, I_{ph} 是光伏电池光生电流,其值的大小与光伏电池的面积和光照强度成正比; I_d 为二极管电流; R_{sh} 为分流电阻,其值一般为几千欧; R_s 为电路串联电阻,其值一般情况小于 $1\ \Omega$; I 为光伏电池负载端输出电流; U 为光伏电池输出电压; R_o 为光伏电池的外接负载。由图 1 可得:

$$I = I_{ph} - I_d - I_{sh} \quad (1)$$

其中:

$$I_d = I_0 \left[e^{\frac{q(U+IR_s)}{AKT}} - 1 \right] \quad (2)$$

$$I_{sh} = \frac{U + IR_s}{R_{sh}} \quad (3)$$

式中: I_0 ——二极管反相饱和电流;

A ——PN 结理想因子;

K ——玻尔兹曼常数;

q ——单位电子电量;


T ——电池温度。

将式(2)和式(3)代入式(1)可得光伏电池等效电路输出特性表达式为


$$I = I_{ph} - I_0 \left[e^{\frac{q(U+IR_s)}{AKT}} - 1 \right] - \frac{U + IR_s}{R_{sh}} \quad (4)$$

1.2 光伏电池的输出特性

由式(4)可以看出,影响光伏电池输出特性的 2 个关键因素为温度和光照,因此其输出特性为非线性的。图 2(a)和图 2(b)所示为光伏阵列在不同的光照和温度条件下 P/U 曲线。



(a) 不同光照强度下的 P/U 特性曲线



(b) 不同温度下的 P/U 特性曲线

图 2 光伏阵列的 P/U 特性曲线

通过比较图 2(a) 中光伏电池在不同光照强度下的 P/U 特性曲线可知,在相同的温度条件下,光伏电池最大输出功率随着光照强度的增加而上升;比较图 2(b) 中光伏电池在不同环境温度下的 P/U 特性曲线可知,光照强度不变时,随着温度的上升,最大输出功率随之下降。因此,在面对复杂多变的外界环境时,需要使光伏发电系统快速追踪锁定到最大功率点,高性能的 MPPT 控

制器就必不可少。本文就此提出了基于 T-S 模型的模糊神经网络 MPPT 控制方法,可得到较优的控制效果。

2 基于 T-S 模型的模糊神经网络自适应控制器

2.1 控制方案设计

在光伏发电过程中,影响光伏阵列输出功率的决定因素是温度和光照强度,但是在实际情况中温度和光照强度时刻变化,就造成了最大功率点也在时刻变化,需要对其进行及时的跟踪。对最大功率点跟踪时,通过不断地调整 Boost 电路中 IGBT 的占空比 D ,使光伏阵列工作在最大功率点上。由图 2 可以看出,当偏差变化率 $e(k)$ 为零时,光伏阵列工作于最大功率点,因此在系统工作时需要测量的量为光伏阵列各时刻输出的电压 $U(K)$ 、电流 $I(K)$,并由此得到这一时刻的输出功率 $P(K)$ 。MPPT 自适应控制器的原理图如图 3 所示。




图 3 MPPT 自适应控制原理图

由图 3 可以看出,最大功率点控制器的输入为偏差变化率 $e(k)$ 和偏差变化率变化量 $\Delta e(k)$ 。通过比较 k 时刻以及 $(k+1)$ 时刻的状态化,判断系统的工作状态趋势,来调节占空比的增减。

2.2 T-S 模型模糊神经网络结构图

T-S 模型的特点是局部为单一规则的线性映射,在全局则为规则重叠的非线性映射^[10]。在 T-S 模糊神经网络模型中,网络后件为输入变量的精确线性组合;网络前件采用模糊形式,其作用是用来匹配各输入变量的隶属度函数。该模型总的输出为各后件的加权和,加权系数为各网络前件的适用度。其模型结构如图 4 所示。

该模型的前件模糊网络共包括 4 层,第 1 层为输入层,该层将各输入量 $[x_1 \ x_2 \ \cdots \ x_n]$ 传递到下一层,第 2 层作用是计算各输入量的隶属度函数,选择三角形为隶属度函数的形状,第 3 层用来匹配模糊规则的适用度,即 $\alpha_i = \min\{\mu_1^i, \mu_2^i, \cdots, \mu_m^i\}$,或者 $\alpha_i = \mu_1^i \cdot \mu_2^i \cdot \mu_m^i$,第 4 层用来实现解模糊处




图 4 基于 T-S 模型的模糊神经网络结构

理,采用重心法解模糊,即 $\omega_i = \sum_{j=1}^m x_j \alpha_j / \sum_{j=1}^m \alpha_j$ 。

后件网络采用线性函数描述,后件网络的第 1 层为输入层;第 2 层有 m 个节点,每一个节点代表一条规则,即:

$$y_{ij} = p_{j0}^i + p_{j1}^i x_1 + \cdots + p_{jn}^i x_n =$$

$$\sum_{l=0}^n p_{jl}^i x_l (j = 1, 2, \cdots, m; i = 1, 2, \cdots, r) \quad (5)$$

第 3 层用来计算最终的输出,其第 i 条控制规则如下:

$$R^i: \text{if } x_1^i \text{ is } A_1^i, \text{ and } x_2^i \text{ is } A_2^i, \cdots, \text{ and } x_j^i \text{ is } A_j^i$$

$$\text{THEN } y_i = L_0^i + L_1^i x_1 + \cdots + L_j^i x_j \quad (6)$$

式中: x_i ——第 i 个输入变量;

A_j^i ——对应输入变量 x_j 采用的模糊子集;

L_j ——后件参数。

第 3 层最终的输出形式如式(7)所示:

$$y_j = \sum_{j=1}^m y_{ji} \omega_j \quad (7)$$

2.3 参数实现

在 T-S 模型中,前件网络隶属度函数的选择直接影响到最大功率点的跟踪速度及准确性。当跟踪误差较大时,希望可以快速逼近最大功率点;当跟踪误差较小时,希望可以达到更精确的跟踪。因此,本文选择可以改变定比因子 r 的优化隶属度函数。当偏差 e 及偏差变化量 Δe 较大时隶属

度函数的分布较疏;当误差较小时隶属度函数分布较密,以期及时准确地调节占空比的值。

模糊控制隶属函数图如图 5 所示。




图 5 模糊控制隶属函数图

图 5 中定比因子 $r=a/b=b/c$ 。本文选择 r 值为 1.5。此时后件网络类似 BP 神经网络,是 3 层单向的前向网络, P_{ji}^k 相当于输入层到隐含层的连接权值,需要自学习调整,而隐含层到输出层的权值 ω_i 已经由前件网络确定。输出层和隐含层的输入为前一节点各输出的加权和,通过不断学习来调整权值大小。该神经网络中的每一个节点如图 6 所示,图 6 中 $f(x)$ 表示增益函数。




图 6 单神经元基本结构

由于在相同的控制规则下,后件网络参数越多,调试越困难,因此采用简化 T-S 模型,可显著地减少后件参数。权值 P_{ji}^k 的学习算法如下。

取误差代价函数的表达式为

$$E = \frac{1}{2} \sum_{i=1}^k (y_r - y_i)^2 \quad (8)$$

式中: y_r ——期望输出;

y_i ——实际输出。

则权值 P_{ji}^k 的学习算法的表达式为

$$\frac{\partial E}{\partial P_{ji}^k} = \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial y_{kj}} \frac{\partial y_{kj}}{\partial P_{ji}^k} = -(y_r - y_i) \omega_j x_i \quad (9)$$

$$P_{ji}^k(n+1) = P_{ji}^k(n) - \beta \frac{\partial E}{\partial P_{ji}^k} =$$

$$P_{ji}^k(n) + \beta (y_r - y_i) \omega_j x_i \quad (10)$$

其中: β 表示学习速率; $i=1, 2, \dots, m, j=1, 2, \dots, k; n=0, 1, \dots, k-1$ 。

3 仿真与试验结果分析

为了电压、功率的样本数据对该模糊神经网络模型进行训练,学习函数采用梯度下降法来调

整权值 P_{ji}^k 的大小,经过反复的训练直到误差在所要求的 0.002 以下,最后使系统的输出误差达到最小。如图 7 所示,经过 63 次训练后,输出误差达到要求。图 8 所示为训练完成后,各个光照强度和温度下的仿真电压与实际电压的对比图,共取一天中 15 个时刻点。




图 7 训练误差曲线




图 8 仿真电压值与实际电压值对比曲线

图 9 所示为试验系统框图,主要由光伏板、控制器、Boost 电路以及负载组成。试验采用 4 块型号为 GREENTECHY/PWM-55 的太阳能电池板,每块板的标准功率为 55 W,最大功率点电压为 17 V,开路电压为 21.4 V,短路电流为 3.42 A,电容 C_1 、 C_2 均为 330 μ F,电感 L 为 1.202 mH,负载 R 为 20 Ω 。




图 9 试验电路原理图

控制 Boost 电路的模糊神经网络控制器芯片为 TI 公司的 TMS320F28335,通过对 T-S 模型进行训练后即可投入使用。通过对输出电压、电流进行采样,来调节 Boost 电路占空比值,直到达到

最大功率点。图 10 所示为光照强度发生突变时的光伏电池输出电压、电流波形图。




图 10 光照强度突变时试验波形

由试验结果可以看出:当外界环境相对稳定时,系统较平稳地运行于最大功率点;当外界环境突变时,系统可以准确、快速地调整到最大功率点,运行效果良好。

4 结 语

本文结合模糊控制的表达定性知识能力与神经网络的自学习能力,同时结合 T-S 模型处理非线性问题的优点,提出了基于 T-S 模型的模糊神经网络自适应 MPPT 控制方法。该方法利用模糊神经网络解决非线性控制的优点,可以较好地解决传统 MPPT 控制的快速性和稳定性的矛盾。仿真及试验结果表明:采用基于 T-S 模型的模糊神经网络自适应控制光伏发电系统可以快速准确地达到最大功率点,并且在外界环境变化时,系统可以快速适应新环境,以较高精度运行。

【参 考 文 献】

[1] 姚志垒,肖岚,魏星.双降压全桥并网逆变器[J].中国电机工程学报,2011,31(12): 29-33.

[10] FAN Y, CHAU K T, CHENG M. A new three-phase doubly salient permanent magnet machine for wind power generation[J]. IEEE Transactions on Industry Applications, 2006, 42(1): 53-60.

[11] 张建忠,程明.新型直接驱动外转子双凸极永磁风力发电机[J].电工技术学报,2007,22(12): 15-21.

[12] 朱德明,周楠,张卓然,等.直驱式多转子极电励磁双凸极风力发电机[J].电工技术学报,2009,24(12): 32-37.

[13] BIAN D, ZHAN Q. A novel single phase doubly salient permanent magnet motor [C] // IEEE 1999 International Conference on Power Electronics and Drive Systems, IEEE, 1999: 725-729.

[2] 张世坤,许晓光.我国当前的能源问题及未来能源发展战略[J].能源研究与信息,2004,20(4): 211-219.

[3] 彭志辉,和军平,马光,等.光伏发电系统 MPPT 输出功率采样周期的优化设计[J].中国电机工程学报,2012,32(34): 24-29.

[4] CARRASCO J M, FRANQUELO L G, BIALASIEWICZ J T, et al. Power-electronic systems for the grid integration of renewable energy sources: a survey [J]. IEEE Transactions on Industrial Electronics, 2006, 53(4): 1002-1006.

[5] 周林,武剑,栗秋华,等.光伏阵列最大功率点跟踪控制方法综述[J].高电压技术,2008,34(6): 1145-1154.

[6] 朱拓斐,陈国定.光伏发电中 MPPT 控制方法综述[J].电源技术,2011,35(10): 1322-1324, 1328.

[7] LEE C H, TENG C C. Identification and control of dynamic systems using recurrent fuzzy neural networks[J]. IEEE Transactions on Fuzzy Systems, 2000, 8(4): 349-366.

[8] GAO J, YUAN R, YI J, et al. A novel approach to generating an interval type-2 fuzzy neural network based on a well-behaving type-1 fuzzy TSK system [C] // 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Budapest, 2016: 3305-3311.

[9] 赵晶,赵争鸣,周德佳.太阳能光伏发电技术现状及其发展[J].电气应用,2007,26(10): 6-10, 136.

[10] 姜滨,孙丽萍,曹军.木材干燥过程温湿度的 T-S 型模糊神经网络控制器设计[J].电机与控制学报,2016,20(10): 114-120.

收稿日期: 2018-07-06

(上接第 109 页)

[14] 万伟悦,严仰光,孟小利.基于分布式发电的单相双凸极直流发电机原理和时步有限元分析[J].大功率变流技术,2010(6): 15-21.

[15] AFINOWI I A A, ZHU Z Q, GUAN Y, et al. A novel brushless AC doubly salient stator slot permanent magnet machine [J]. IEEE Transactions on Energy Conversion, 2016, 31(1): 283-292.

[16] QIJI Z, LIANG D, KOU P, et al. Improvement of power generation performance in a doubly salient permanent magnet generator with a capacitive energy recovery converter [J]. IET Electric Power Applications, 2017, 11(1): 108-120.

收稿日期: 2018-07-01