

三电平逆变器 IGBT 开路的复杂故障检测

崔力慧, 刘洋

(山东科技大学 电气与自动化工程学院, 山东 青岛 266590)

摘要:针对三电平逆变器绝缘栅双极型晶体管(IGBT)的开路故障,分析了在逆变器交叉两桥臂各有一个 IGBT 开路故障时的输出电压信号特点;然后利用傅里叶变换提取故障电压信号的直流分量、基波幅值、基波相位以及二次谐波相位,然后转换为故障特征向量,并由此采用 BP 神经网络来进行故障诊断。为了提高故障诊断的精度,利用改进的粒子群算法(PSO)来优化 BP 神经网络的参数。最后,通过对三电平逆变器的仿真进行实验验证,仿真结果证明了该方法的正确性和可行性。

关键词:三电平逆变器;故障诊断;BP 神经网络;粒子群算法

中图分类号:TM464

文献标志码:A

文章编号:1672-3767(2017)04-0108-07

DOI: 10.16452/j.cnki.sdkjzk.2017.04.016

Complex Open-circuit Fault Detection of the IGBT in a Three-level Inverter

CUI Lihui, LIU Yang

(College of Electrical Engineering and Automation, Shandong, University of
Science and Technology, Qingdao, Shandong 266590, China)

Abstract: To solve the open-circuit fault of insulated gate bipolar transistor (IGBT) in three-level inverter, the characteristics of output voltage signal when the crossed two bridge arms were subject to an IGBT open circuit were analyzed in this paper. The DC component, the fundamental amplitude, the fundamental phase and the second-harmonic phase were extracted from fault voltage signal by using Fourier transform, which were later converted into a fault feature vector and fault diagnosis was conducted by BP neural network. In order to improve the diagnostic accuracy, the improved PSO (particle swarm optimization) was used to optimize parameters of BP neural network. By the simulation of the three-level inverter, its correctness and feasibility were verified.

Key words: three-level inverter; fault diagnosis; BP neural network; PSO

大功率多电平逆变器适合高压、大容量的场合,近年来在工业生产中得到愈来愈广泛地应用。在现有的多电平逆变器中,三电平逆变器是被广泛使用的一种,相比于传统的两电平逆变器,随着电平数的增加,每一相桥臂都由更多的功率开关管和二极管组成,使得三电平逆变器结构更加复杂,且调制策略也更加复杂;同时,复杂的调制策略又令功率开关管连续开断,使逆变器不停地工作在多种模式下,势必造成开关器件故障的概率随之增加。每个开关器件都会对逆变器的可靠、高效运行产生影响,轻则会降低逆变器的工作效率,严重时甚至会产生重大事故^[1]。

收稿日期:2017-04-07

基金项目:中国博士后科学基金项目(2016M600546);青岛市博士后研究人员应用研究项目(20161112);山东科技大学研究生科技创新项目(SDKDYC170354)

作者简介:崔力慧(1993—),男,山东莱州人,硕士研究生,主要从事故障检测与诊断研究。E-mail:ccuilihui@163.com

刘洋(1988—),男,辽宁海城人,博士后,主要从事最优滤波、闭环系统、故障检测与诊断研究,本文通信作者。

E-mail:lianinliyan@163.com

由于短路时,过大的电流会使 IGBT 损坏,使得短路故障最终还是归结为开路故障。所以,事实上对三电平逆变器的故障诊断,其实就是对功率开关管(IGBT)的开路故障诊断^[2]。当三电平逆变器发生功率管开关开路故障时,逆变器仍能工作,但其输出电压波形会发生畸变。文献[3]将三电平逆变器的开路故障分为 9 大类。其中,第一到第三大类故障为发生在同一桥臂的简单故障,共 25 种;第 4 到第 9 大类为交叉两桥臂各有一个功率管开关器件同时发生开路的复杂故障,共 48 种。文献[4]最早以不同触发角下的故障波形作为神经网络的输入,以晶闸管开路故障作为神经网络的输出建立神经网络,随后进行神经网络的训练,映射出故障波形和故障类型之间的关系,从而完成对三相整流电路的故障诊断,但只研究了仅有一个功率管发生开路故障的简单诊断。文献[5]使用建立 BP 神经网络的方法完成对故障的诊断,但 BP 神经网络存在收敛速度慢,且易于陷入局部最优等弊端^[6]。文献[7]觉察到 BP 神经网络存在的缺点正是遗传算法(GA)的优势,是与其结合遗传算法来优化 BP 神经网络中的初始权值与阈值,从而使优化后的 BP 神经网络可以得到更好的预测输出。

同遗传算法相似,粒子群算法(PSO)是仿真鸟类觅食的行为模式,被提出来用于解决优化问题的方法^[8]。仿照鸟类觅食行为,粒子种群初始化为一群随机粒子,同时所有粒子都有一个优化函数确定的适应度值来衡量其好坏,然后通过不断地迭代,每一个粒子都经过寻求两个极值来更新自己。其中,一是当前粒子自身找到的最优解,是自己的个体极值;二是整个群体找到的最优解,是全局极值。相比于遗传算法,粒子群算法更简单,计算更方便,求解速度更快。因此,本研究在以上文献的基础上,对文献[3]提到的 48 种复杂故障,采样三电平逆变器输出信号为测量信号,并用 PSO 优化 BP 神经网络中的权值和阈值,完成对二极管中点箝位式三电平逆变器的 IGBT 开路故障诊断的研究。

1 三电平逆变器的故障分析和提取

1.1 逆变器的故障分析

本文考虑的二极管中点箝位式三电平逆变器是由直流电源、三相三电平逆变桥、三相 LC 滤波器及三相负载组成,其拓扑结构如图 1 所示。

由图 1 可见其主电路拓扑结构具有一定程度上的对称性,所以其逆变器的输出波形也表现出一定的对称性^[9]。故此以 A 相为例,当三电平逆变器工作在无故障(正常)情况时,逆变器输出端将产生如图 2 所示的平稳正弦波。




图 1 二极管箝位式三电平逆变器主电路图

Fig. 1 The main circuit diagram of three-level diode-clamped inverter




图 2 三电平逆变器 A 相相电压

Fig. 2 The phase A phase voltage of the three-level inverter

当三电平逆变器发生故障时,由于其结构较为复杂,分别对每个 IGBT 的状态进行检测实现起来比较困难。因此,针对不同故障的情形,并且考虑到逆变器的输出电流会随着负载的改变而发生相对应的改变,本文选取检测逆变器的三相输出电压波形来作为我们分析故障的信息。

首先,采样逆变器输出的三相电压波形,并进行降维处理,经 $d-q$ 变换后,得:

$$\begin{pmatrix} U_d \\ U_q \end{pmatrix} = \sqrt{\frac{2}{3}} \begin{pmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{pmatrix} \begin{pmatrix} U_a \\ U_b \\ U_c \end{pmatrix} \quad (1)$$

继而对 U_q 和 U_d 进行傅里叶变换,提取各次谐波幅值与相位。

如图 3 为 S_{a1} 和 S_{b1} 同时发生故障时的 U_d 电压波形,并对 U_d 进行傅里叶变换后,得到如图 4 所示的 U_d 的频谱图。




图 3 S_{a1}, S_{b1} 故障时 U_d 波形

Fig. 3 U_d waveform with open-circuit fault of S_{a1}, S_{b1}

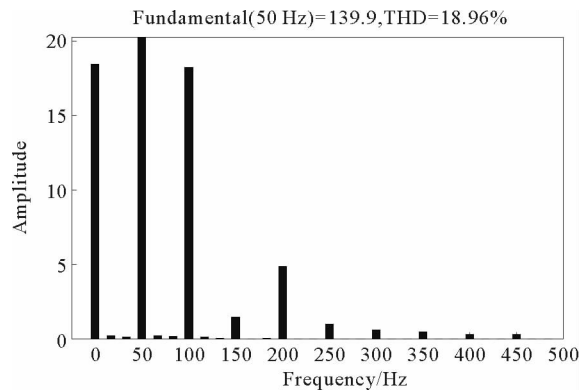


图 4 S_{a1}, S_{b1} 故障时 U_d 频谱图

Fig. 4 U_d spectrum with open-circuit fault of S_{a1}, S_{b1}

分析图 4 可以发现, U_d 进行傅里叶变换后,包含直流分量在内,前二次谐波分量含量最高,其他次谐波总的谐波畸变率不足 5%。因此,直流分量以及其前两次谐波的幅值和相位中就基本上蕴含了可以进行故障诊断的特征信息。同样地, U_q 进行变换后的波形分析与 U_d 相似。本研究选用 U_d 和 U_q 各自的直流分量、基波幅值、基波相位和二次谐波相位,作为构成故障特征向量的元素,并以此作为后面我们神经网络训练样本的输入。仿真实验时发现,利用更多的奇次谐波分量构成故障特征向量,由于增加了神经网络的输入维数,使得结构更复杂,权值与阈值的寻优时间增加,训练难度加大,学习时间更长,并且得到的结果准确率还略微有所下降。

此外,如图 5 所示,当 S_{a4} 和 S_{b4} 同时发生故障时,波形沿 X 轴对折反转后与上述图 4 故障的波形形状相同,仅是相位相差 180°。用数学关系可以表示成 $U_1(t) = -U_2(t + T/2)$,其输出电压波形经过傅里叶变换后得各次谐波的幅值相等,奇数次谐波的相位相等,偶数次谐波相位相差 $T/2$ 周期,总的谐波畸变率(total harmonic distortion, THD)相等^[10]。经过分析,研究的 48 种故障中,两两具有这种关系。

1.2 逆变器故障特征提取

按上节分析,利用傅里叶变换提取 48 种故障情况下的故障特征向量,因篇幅所限,仅列出部分的故障特征向量,如表 1。

从表 1 中仍然可以看出 1.1 节中所说的两两对应的关系。由此,将 48 种复杂故障的情形分为 24 类,采用五位二进制数按对应的十进制 0~24 来编号表示,具有两两对应关系的两种故障则表示形式相同;最后在




图 5 S_{a4}, S_{b4} 故障时 U_d 波形

Fig. 5 U_d waveform with open-circuit fault of S_{a4}, S_{b4}

末位再加一位,用来区分具有两两对应关系的两类故障。这样就完成了用六位二进制数对 48 种故障编码工作,而且故障编码也会作为本研究后续神经网络的期望输出。实验证明,比起普通 6 位二进制编码,采用这种编码方式时,神经网络的学习时间较短且测试正确率更高^[10]。

表 1 故障特征向量及其编码

Tab.1 Fault feature vector and its coding

U_d				U_q				故障	故障
直流分量	基波幅值	基波相位	二次相位	直流分量	基波幅值	基波相位	二次相位	编码	类型
73.180 0	144.9	132.1	10.1	50.120	209.1	58.8	-46.8	000001	S_{a1}, S_{b1}
73.790 0	151.9	151.6	-16.8	48.100	202.7	42.7	225.1	000010	S_{a1}, S_{c1}
71.960 0	146.0	132.4	191.6	50.010	208.8	58.5	133.1	000011	S_{b1}, S_{c1}
1.549 0	189.6	140.3	267.8	97.950	154.6	53.0	175.0	100001	S_{b1}, S_{a1}
73.510 0	152.4	151.3	169.8	48.570	202.4	42.6	49.1	100010	S_{c1}, S_{a1}
0.248 7	188.9	140.4	94.2	99.150	153.4	52.8	-2.3	100011	S_{c1}, S_{b1}
25.770 0	140.2	128.1	-12.4	57.710	207.0	60.1	126.4	000100	S_{a1}, S_{b1}
30.150 0	142.5	153.1	29.2	54.720	203.4	39.6	65.9	000101	S_{a1}, S_{c1}
54.940 0	191.6	139.7	-12.1	3.649	139.9	51.0	99.7	000110	S_{b1}, S_{c1}
24.280 0	140.2	127.6	169.7	57.260	206.7	60.1	-49.3	100100	S_{a1}, S_{b1}
29.920 0	143.1	152.7	208.9	53.500	203.7	39.7	239.2	100101	S_{a1}, S_{c1}
56.230 0	191.3	139.8	176.8	2.783	139.1	51.3	-81.0	100110	S_{b1}, S_{c1}

2 基于改进 PSO 优化 BP 神经网络的故障诊断

在标准 BP 神经网络中,权值和阈值的修正是正比于误差函数沿梯度降低,由于误差函数可能存在多个极值点,会使网络陷入局部最小值,从而不能保证其为误差平面的全局最小值。于是,出现了诸如附加动量因子和自适应学习效率方法与仿真学算法相结合的思想。利用 PSO 优化调节 BP 网络的权值和阈值,可以从本质上解决 BP 算法依赖梯度下降法的固有缺点。

2.1 数学描述

粒子群算法的数学描述如下:在 D 维的目标搜寻空间中,初始化 N 个粒子,其中: $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ 表示第 i 个粒子的当前位置; $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ 为第 i 个粒子到目前为止的最优值; $P_{gi} = (p_{gi1}, p_{gi2}, \dots, p_{giD})$ 为到目前为止的全部粒子的最优值。则传统的标准的 PSO 就是按下面的公式更新自身的速度和位置^[11]:

$$V_i(k+1) = \omega V_i(k) + c_1 r_1 (P_i(k) - X_i(k)) + c_2 r_2 (P_g(k) - X_i(k)), \quad (2)$$

$$X_i(k+1) = X_i(k) + V_i(k+1). \quad (3)$$

式中: k 是迭代次数, c_1, c_2 是学习常数, r_1, r_2 是介于 0 和 1 之间的随机数, ω 为惯性权重。

从公式(2)~(3)可以看出,粒子的移动方向由 $V(k), P(k) - X(k)$ 和 $P_g(k) - X(k)$ 所决定,因此其各自系数就决定了各自的重要性^[12]。

惯性权重 ω 是粒子群算法中极其重要的一个参数。目前,普通选用惯性权重 ω 是迭代次数的函数(沿直线从 0.9 线性递减到 0.4 的线性函数)的方法,即:

$$\omega(ite\text{r}) = -0.5 \times \frac{ite\text{r}}{ite\text{r}_{\max}} + 0.9. \quad (4)$$

其中, $ite\text{r}$ 为当前迭代次数, $ite\text{r}_{\max}$ 为最大迭代次数。线性递减的惯性权重(本文称之为标准的 PSO)使粒子在迭代过程的不同时期具有不同的探寻和开发能力,即在迭代初期收敛速度较快,迭代后期局部搜寻能力也

不错,但这会导致收敛速度慢,容易陷入局部极小;同时,这种调节方式及其衍生的线性调节方式^[13]都有个很大的弊端,所有迭代当中都不可能产生相同的惯性权重,倘若迭代过程中,某一次产生的惯性权重对某几次甚至以后所有的迭代都是最优的,那么这种方法将错过这个最优的值。

2.2 改进粒子群算法

针对上述标准 PSO 的弊端,本研究采取一种自适应动态随机调整粒子群惯性权重的方法。取(0,1)之间的随机数作为惯性权重的值,使粒子在各个时期都有获得合理探索和开发能力的机会。首先,产生一个随机数作为初始惯性权重,在全局最优值不断变化时,保持惯性权重不变;当在全局最优值未发生变化时,此时希望能够加大惯性权重,使粒子具有较强的全局搜索能力;但取值(0,1)区间的随机数的概率是相同的,不能保证其一定能取到期望的较大的随机数,若能恰巧取到所需要的数值最好,但若取到较小的随机数,又会陷入局部最优值。因此,再对惯性进行线性调节,即令 $\omega = \omega + \text{rand}(0,1)\omega$ 。同时 ω 取值不能无限增大下去,要保证粒子具有均衡的全局和局部探索能力。所以为了兼顾局部探索能力,当 $\omega > 1$ 时,令 $\omega = \omega - \text{rand}(0,1)\omega$ 。同时,由于 ω 的随机性,也加大了速度 v 的随机性,当 v 过小时,粒子位置变化就不明显,甚至若恰好使得 $v = 0$,那么粒子在下次或者以后多次的迭代中,甚至会出现停滞不前的情况。针对这个问题,对速度的最小值进行限定 $v = 0.5$,以保证粒子能在大范围内寻求最优值。

3 仿真与验证

为了验证所提出的方法的正确性和可行性,建立三层结构的 BP 神经网络,输入层节点数同故障特征向量的维数相等为 8,输入层和隐含层之间的神经元采用 tansig 函数;输出层节点数同前文所提到的故障编码位数相同为 6,输出层和隐含层之间的神经元采用 logsig 函数;隐层节点数由试凑法及以往经验,选取节点数为 22 个;而在改进的 PSO 算法中,初始化种群粒子数目为 40,PSO 学习因子 $c_1 = 2, c_2 = 2$,最大迭代次数 $\text{iter} = 1500$,继而对 BP 神经网络的权值和阈值的迭代过程,利用改进的 PSO 的迭代过程取代。另外 PSO 的优化函数采用均方误差根函数:

$$E = \sqrt{\frac{1}{H} \sum_{k=1}^H \sum_{l=1}^6 (T_{kl} - Z_{kl})^2} \quad (5)$$

其中: H 为训练样本数, T_{Hh} 、 Z_{Hh} 分别为期望输出和实际输出值。

仿真时,选取三电平逆变器输入电压为 350、400、450 V,负载功率分别为 40、45、50 kW 情况下的故障数据,作为样本共计 9 组 432 个数据,取其中 6 组作为神经网络的训练样本,其余三组作为测试神经网络训练结果的样本,设定目标误差为 0.001。如图 6 为标准 PSO 与改进后的 PSO 误差收敛曲线,从图中可以很明显的看出,改进后的 PSO 算法误差收敛速度比标准 PSO 更快,收敛准确度更高,收敛后的误差值极低;而误差函数值越低,说明神经网络训练的效果越好,实际输出与期望输出越接近,故障诊断的准确性就越高。

我们再将测试样本输入到网络中,由于篇幅所限,仅给出 9 大类中第 4 大类(上半桥交叉两桥臂各有一个 IGBT 发生开路故障)的 12 种复杂故障的部分测试数据,如表 2。以 S_{a1} 、 S_{b2} 故障为例,期望输出故障的编码为 100110,仿真的输出真实值与期望输出十分接近。对仿真的输出进行四舍五入后,能够看出,仿真的输出与期望的输出一致,并且分类结果稳定,正确率近乎百分之百。从而,当三电平逆变器发生开路故障时,从神经网络的输出可以判定到底发生的是哪一种故障,进而完成对逆变器的故障诊断。




图 6 误差收敛曲线图

Fig. 6 Convergence curve of the error

表 2 神经网络测试结果
Tab.2 The test results of neural network

神经网络实际输出						期望输出	故障编码
0.997 80	0.000 95	0.143 76	0.988 54	0.928 19	0.000 01	100110	S _{a1} , S _{b2}
0.998 47	0.000 05	0.969 39	0	0.022 13	0.995 36	101001	S _{a1} , S _{c2}
0.977 84	0.143 05	0.999 08	0.000 06	0.984 06	0	101010	S _{b1} , S _{a2}
0.990 05	0.001 27	0.987 14	0.987 14	0	0.593 84	101101	S _{b1} , S _{c2}
0.998 66	0.000 08	0.883 69	0.993 84	0.996 34	0.800 62	101111	S _{c1} , S _{a2}
0.997 76	0.962 93	0.033 04	0.000 01	0.000 30	0.992 57	110001	S _{c1} , S _{b2}
0.000 05	0.133 30	0.990 91	0	0.000 18	0.101 40	001000	S _{a1} , S _{b1}
0.325 33	0.229 12	0.998 99	0.000 01	0.998 92	0.963 31	001011	S _{a1} , S _{c1}
0.229 12	0.000 06	0.997 85	0.991 95	0.000 14	0.951 80	001101	S _{b1} , S _{c1}
0.007 31	0.997 02	0.014 20	0.984 27	0.000 49	0.000 10	010100	S _{a2} , S _{b2}
0.111 25	0.995 99	0.000 01	0.971 20	0.994 91	0.997 13	010111	S _{a2} , S _{c2}
0.000 22	0.834 37	0.992 01	0.000 01	0.013 02	0.996 79	011001	S _{b2} , S _{c2}

最后,通过上述仿真结果的分析,对比文献[10],可以发现,相比附加动量因子和自适应学习效率的 BP 神经网络方法,本文采用的方法,训练次数少近乎一半,收敛速度快,期望误差更低,同时兼顾了系统的稳定性和网络的收敛速度;对比文献[7]可以发现,相比 GA 算法优化后的 BP 神经网络方法,本研究采用的方法,训练次数要更多,收敛速度稍慢,而期望误差及其分类结果的稳定性近似相同,但本方法在计算的方便性及编程实现问题上,优势则相对明显,易于在实践中实现。

4 结论

文中对三电平逆变器复杂开路故障进行了故障诊断研究。首先分析了逆变器输出电压的故障电压信号,并对输出的故障电压进行傅里叶变换,提取所需的故障特征向量信息;利用一种改进的 PSO 优化 BP 神经网络的方法对故障特征向量进行训练,通过神经网络的输出可以判定到底发生的是哪一种故障。通过仿真实验可以看出,该方法收敛速度快、精度高,并且由于 PSO 的简单可操作性,使其在实践中易于实现。

参考文献:

[1]KHOMFOI S, TOLBERT L M. Fault diagnostic system for a multilevel inverter using a neural network[J]. IEEE Transactions on Power Electronics, 2007, 22(3):1062-1069.

[2]廖俊勃, 帕孜来, 支焯, 等. 三电平逆变器 IGBT 的开路故障诊断研究[J]. 电测与仪表, 2015, 52(20):35-40.
LIAO Junbo, PAZILAT, ZHI Chan, et al. Study on open-circuit fault diagnosis of the IGBT in three-level inverter[J]. Electrical Measurement & Instrumentation, 2015, 52(20):35-40.

[3]肖刚. 三电平逆变器故障诊断研究[D]. 西安:西安理工大学, 2007.

[4]马皓, 徐德鸿. 基于神经网络的电力电子电路故障诊断[J]. 电力电子技术, 1997, 31(4):10-12.
MA Hao, XU Dehong. Fault diagnosis of power electronic circuits based on neural network[J]. Power Electronics, 1997, 31(4):10-12.

[5]杨金宝, 张昌宏, 陈平. 基于改进 BP 神经网络的网络故障诊断研究[J]. 计算机与数字工程, 2012, 40(2):65-67.
YANG Jinbao, ZHANG Changhong, CHEN Ping. Network fault diagnosis based on improved BP neural network[J]. Computer and Digital Engineering, 2012, 40(2):65-67.

[6]闻新, 李新, 张兴旺. 应用 MATLAB 实现神经网络[M]. 北京:国防工业出版社, 2015.

- [7]姜立昌. 多电平逆变器 IGBT 故障诊断方法的研究[D]. 天津:河北工业大学,2014.
- [8]KENNEDY J. Particle swarm optimization[C]//IEEE International Conference on Neural Networks,2002:1942-1948.
- [9]王琛琛,李永东. 多电平变换器拓扑关系及新型拓扑[J]. 电工技术学报,2011,26(1):92-99.
WANG Chenchen,LI Yongdong. Multilevel converter topologies and two novel topologies[J]. Transactions of China Electrotechnical Society,2011,26(1):92-99.
- [10]张国锋. 多电平逆变器的故障建模及诊断[D]. 长沙:中南大学,2012.
- [11]刘坤,谭莹,何新贵. 基于粒子群优化的过程神经网络学习算法[J]. 北京大学学报(自然科学版),2011,47(2):238-244.
LIU Kun,TAN Ying,HE Xingui. Particle swarm optimization based learning algorithm for process neural networks[J]. Acta Scientiarum Naturalium Universitatis Pekinensis,2011,47(2):238-244.
- [12]韩月娇. 粒子群算法的改进及其在 BP 神经网络中的应用[D]. 南昌:南昌航空大学,2012.
- [13]张丹,韩胜菊,李建,等. 基于改进粒子群算法的 BP 算法的研究[J]. 计算机仿真,2011,28(2):147-150.
ZHANG Dan,HAN Shengju,LI Jian,et al. BP algorithm based on improved particle swarm optimization[J]. Computer Simulation,2011,28(2):147-150.

(责任编辑:吕海亮)

(上接第 100 页)

参考文献:

- [1]PATHAK K,FRANCH J,AGRAWAL S K. Velocity and position control of a wheeled inverted pendulum by partial feedback linearization[J]. IEEE Transactions on Robotics,2005,21(3):505-513.
- [2]SALERNO A,ANGELES J. On the nonlinear controllability of a quasiholonomic mobile robot[C]//IEEE International Conference on Robotics and Automation,2003:3379-3384.
- [3]任红格,阮晓钢. 基于 Skinner 操作条件反射的两轮机器人自平衡控制[J]. 控制理论与应用,2010,27(10):1423-1428.
REN Hongge,RUAN Xiaogang. Self-balance control of two-wheeled robot based on Skinner's operant conditioned reflex [J]. Control Theory and Applications,2010,27(10):1423-1428.
- [4]HAY S. Trajectory tracking control for navigation of the inverse pendulum type self-contained mobile robot[J]. Robotics and Autonomous Systems,1996,17(1):65-80.
- [5]KIM Y,KIM S H,KWAK Y K. Dynamic analysis of a nonholonomic two-wheeled inverted pendulum robot[J]. Journal of Intelligent and Robotic Systems,2005,44(1):25-46.
- [6]BLANKESPOOR A,ROBERT R. Experimental verification of the dynamic model for a quarter size self-balancing wheelchair [C]//American Control Conference,Proceedings of the IEEE,2004:488-492.
- [7]GRASSER F,DARRIGO A,COLOMBI S. JOE: A mobile, inverted pendulum[J]. IEEE Transactions on Industrial Electronics,2002,19(1):107-114.
- [8]SALERNO A,OSTROVSKAYA S,ANGELES J. The development of quasiholonomic wheeled robots[C]//IEEE International Conference on Robotics and Automation,2002,4:3514-3520.
- [9]AMBROSE,ROBERT O. Mobile manipulation using NASA's Robonaut[C]//IEEE International Conference on Robotics and Automation,2004,2:2104-2110.

(责任编辑:吕海亮)