

DOI:10.3969/j.issn.1001-4551.2014.07.021

基于神经网络 PID 的船用电压型逆变电源研究

王泽楷,何通能*,王崇方,徐 栋

(浙江工业大学 信息工程学院,浙江 杭州 310023)

摘要:针对传统 PID 控制存在着参数整定难、动态性能差等问题,无法满足现代船用三相逆变电源的新要求,从常用的电压型逆变电源入手,选定了三相半桥拓扑。通过坐标变换,将其转换到两相旋转坐标轴下分析问题,利用 SVPWM 算法对其进行了控制。提出了一种神经网络与 PID 控制相结合的方法,利用 BP 神经网络控制灵活、适合时变的或非线性的控制对象等特点,配合简单精确的 PID 控制,使得两者很好地发挥了各自的优势。同时,对改进型 PSO 算法对 BP 神经网络的初始权值进行了优化,并最终通过实验来进行验证。研究结果表明:应用 PSO 优化 BP 神经网络 PID 控制的三相逆变电源有很好的效果,电压总谐波控制在一定指标之内,并且在突加突卸实验时表现出更优异的动态特性,超调更小,响应更快。

关键词:船用逆变电源;SVPWM 算法;PID 控制;BP 神经网络;改进 PSO 优化

中图分类号:TM4;TM91

文献标志码:A

文章编号:1001-4551(2014)07-0916-06

Research of marine voltage inverter based on neural networks PID control

WANG Ze-kai, HE Tong-neng, WANG Chong-fang, XU Dong

(School of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China)

Abstract: Aiming at the problems of the poor dynamic performance and the difficulty caused by tuning parameters in traditional PID control, which was unable to meet the new requirement of modern marine three-phase inverter power supply, a three-phase half bridge topology was selected for the voltage inverter. The coordinate transformation was used to help analyzing the problems in two-phase rotating coordinate axis and also the SVPWM algorithm was chosen to control it. A neural network method combined with PID control was presented because of the characteristics of the BP neural networks which make the control flexible, suitable for time-varying and nonlinear systems and can take good advantages of both. At the same time, the initial weights of BP neural network were optimized through the improved PSO algorithm and it was going to be verified through experiments. The results indicate that three-phase inverter based on the BP-PID control has a very good effect, the total harmonic distortion is controlled in a range and has better dynamic performance smaller overshoot and faster response in sudden-loading/unloading.

Key words: marine inverter; SVPWM algorithms; PID control; BP neural networks; improved PSO

0 引 言

随着经济社会的进步,港口物流、远洋贸易等一系列产业的快速发展,使得海运行业的景气度大大提升,进而传递到上游的造船业。根据数据显示,我国近年来造船行业的订单和利润依然保持着很高幅度的增

加,由此,也对各种船用的电气设备和电子仪器提出了更高的要求。作为用电设备的基础,高品质的船用交流电显然越来越为人们所关注。为了获得高质量的交流电,常用的方式就是利用逆变技术将蓄电池或者柴油发电机输出经整流后的直流电逆变成交流电。

在逆变电源的控制器设计中,PID 控制由于具有

收稿日期:2014-03-03

作者简介:王泽楷(1988-),男,浙江绍兴人,主要从事逆变电源及可逆整流器方面的研究。E-mail:w307718988@163.com.

通信联系人:何通能,男,副教授,硕士生导师。E-mail:hntn@zjut.edu.cn.

简单的原理、鲁棒性和易于实现的特点,被各单位广泛使用。然而传统的 PID 控制的缺点也是显而易见的,尤其是实际应用中,存在着负载突加突卸时,其超调过大、调节时间过长等情况,容易引发许多不良后果。同时,对于 PID 参数的整定,传统做法是先分析得到对象的数学模型,再选择某一整定原则来确定具体参数。这在应用中,面对被控过程复杂且具有高度非线性、时变不确定性和纯滞后等情况时,显得举步维艰^[1-3]。

另一方面,控制理论发展至今已有 100 多年的历史,已进入“智能控制”的阶段。智能控制是多学科交叉的产物,它的发展涉及到人工智能、模糊集理论和生物控制等多种学科。其中,在人工神经网络领域,自 1957 年 Frank Rosenblatt 首次提出并设计制作了著名的感知机(Perceptron),经过几十年的发展,已经取得了非常重大的成果与突破。人工神经网络具备的非线性以及适应性信息处理能力,能够学习和适应严重不确定系统的动态特性,因此表现出很强的鲁棒性和容错性^[4]。

根据上述描述,本研究将传统 PID 控制与 BP 神经网络有机结合起来,主要研究基于神经网络 PID 的船用逆变器控制。针对此种控制性能面临的较依赖于 BP 网络初始权值的问题,笔者加入粒子群优化(Particle Swarm Optimization PSO)算法以优化 BP 网络的初始权值,使得系统的控制量迅速逼近控制目标,同时有较短的响应时间。

1 三相逆变器控制算法

1.1 三相逆变器的拓扑及 SVPWM 算法

三相桥式电压源型逆变器的拓扑结构如图 1 所示。由于全控型器件具有性能优良、小巧轻量、功率密度高等特点,逆变器的电路是利用全控型器件组成的^[5]。




图1 逆变器拓扑结构

U_{dc} —输入的恒定的直流电压; $S_1 \sim S_6$ —IGBT,与并联的二极管一起组成三相桥臂;输出端— Δ/Y 型变压器,有效解决三相不平衡问题

SVPWM 是近年来广受关注的一种控制算法,被广泛应用于电机控制、逆变器或变流器中。其理论根据来自于平均值等效原理,也就是:在一个开关周期内,对几个设定的基本电压矢量按照一定规则进行组合,使得它们的平均值等效为给定的矢量^[6-7]。

为了得到需要被等效的矢量,一般的做法就是在三相平面静止坐标系中,定义 3 个电压空间矢量,它们的值分别等于三相逆变器输出的各相相电压,然后合成为一个旋转的空间矢量。

而为了得到基本电压矢量,可以先得到三相逆变器的开关模式,假设主电路的开关为理想元件,定义开关函数 $S_x (x=A、B、C)$ 为:

$$S_x = \begin{cases} 1, & \text{逆变桥上桥臂导通,下桥臂截止} \\ 0, & \text{逆变桥下桥臂导通,上桥臂截止} \end{cases}$$

由此可以得到 8 种开关模式,对应的基本矢量包括 6 个基本非零矢量 $U_1(100)$ 、 $U_2(110)$ 、 $U_3(010)$ 、 $U_4(011)$ 、 $U_5(001)$ 、 $U_6(101)$ 和两个零矢量 $U_0(000)$ 、 $U_7(111)$ 。

最后,根据定义,对这 8 个基本矢量选取不同的作用时间,就可以得到各桥臂的导通时间,实现 SVPWM 逆变。

1.2 三相电压 dq 坐标变换

对于三相逆变器来说,为了控制输出的电压矢量,通常的做法是将三相平面静止 $A-B-C$ 坐标系下的三相对称电压等效到两相旋转直角 $d-q$ 坐标系中,坐标变换如图 2 所示。




图2 三相电压 $abc-dq$ 坐标变换

图 2 中, $d-q$ 坐标轴以 ω 为角速度进行旋转,速度同三相电压合成矢量旋转速度相同。

电压矢量 $\vec{U}$ 在 $d-q$ 坐标轴上的映射分别为 $\vec{U}_d$ 和 $\vec{U}_q$,当电压矢量与 d 轴重合,即 θ_0 等于 0 的时候, $\vec{U}_d = \vec{U}$, $\vec{U}_q = 0$,因此通过 d 轴的值控制电压矢量的幅值,同时控制 q 轴的值 0,使问题得到了简化。坐标变换公式如下:

$$\begin{bmatrix} u_d \\ u_q \end{bmatrix} = \sqrt{\frac{3}{2}} \begin{bmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{bmatrix} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} u_A \\ u_B \\ u_C \end{bmatrix}$$

2 BP 神经网络算法及其优化

神经网络作为多学科交叉的一项先进技术学科,近些年来凭借其特有的优势:能够充分任意逼近任何复杂的非线性系统;能够学习和适应严重不确定系统的动态特性,引起了控制领域的广泛关注和 Learning。随着研究的深入,神经网络也经历了从简单到复杂、从单层权值可调到多层权值均可学习的变化过程,而 BP 神经网络正是后者中的一员。多层神经网络进行 BP 学习算法的过程,其实可以分为正向和反向传播两个部分。在正向传播阶段,输入层负责把数据信息导入,中间有多个隐含层对其进行处理,最后传递到输出层。每一层的神经元所包含的状态只会对与其相邻的下一层神经元的状态产生作用和影响。通过判断输出层输出的结果与期望输出值的误差是否在一定范围内,如果是则可以确定了所要求的模型,反之如果不是则进入反向传播阶段,利用前面得到的误差为输入信号,由原来的通路的相反方向,对各层神经元的权值进行修正,循环上述步骤直到达到要求。具有单个隐含层的 BP 网络结构如图 3 所示,图 3 中,共有 J 个输入节点, I 个隐含层神经元和 K 个输出节点^[8-9]。




图 3 BP 神经网络结构图

2.1 BP 网络的前馈计算

在训练网络的学习阶段,在有 M 个训练样本的情

$$\begin{cases} g'(Net_i^q) = g(Net_i^q) [1 - g(Net_i^q)] = o_i^q (1 - o_i^q) & (i = 1, 2, \dots, I) \\ g'(Net_k^q) = g(Net_k^q) [1 - g(Net_k^q)] = o_k^q (1 - o_k^q) & (k = 1, 2, \dots, K) \end{cases} \quad (6)$$

2.2 BP 网络的学习

按梯度修正法修正权值, BP 网络的学习可以分为在线学习和离线学习。在线学习对存储单元数量的要求不高,它是对训练集内每个样本的模式对逐一学习,逐一更新网络的连接权值,缺点是有可能增加网络整体输出误差。而离线学习正好相反,在训练集内样本较多的情况下,通过与在线学习的比较可以发现,它的

况下,选择其中一组样本 q 的输入/输出模式对 $\{x^q\}$ 和 $\{t^q\}$ 来对网络进行训练,于是由样本 q 的作用可得隐含层的第 i 个神经元的输入为:

$$Net_i^q = \sum_{j=1}^J \omega_{ij} o_j^q - \theta_i = \sum_{j=1}^J \omega_{ij} x_j^q - \theta_i \quad (i = 1, 2, \dots, I) \quad (1)$$

式中: x_j^q, o_j^q —在选定的样本 q 作用下,输入层节点 j 的输入和输出,由于输入节点可以看作权值为 1, 则有 $x_j^q = o_j^q$; ω_{ij} —输入层神经元 j 和隐含层神经元 i 之间的连接权值; θ_i —隐含层神经元 i 的阈值; J —输入层的节点个数。

在得到隐含层输入的基础上,设 $g(\cdot)$ 为激活函数,则可以得到隐含层第 i 个神经元的输出为:

$$o_i^q = g(Net_i^q) \quad (i = 1, 2, \dots, I) \quad (2)$$

由于 BP 神经网络的除输入层外的基本处理单元都表现为非线性的输入/输出关系,可以选用 Sigmoid 型激活函数:

$$g(x) = \frac{1}{1 + \exp(-(x + \theta_1)/\theta_0)} \quad (3)$$

式中:参数 θ_1 —偏值,正的 θ_1 使得激活函数向左水平移动;参数 θ_0 —决定了 Sigmoid 函数的形状, θ_0 越大则函数越平坦。

隐含层第 i 个神经元的输出 o_i^q , 经过权系数, 正向传递到输出层第 k 个神经元, 成为输入的一部分, 而其余的隐含层神经元也经过同样过程, 最后可以得到输出层第 k 个神经元的总输入:

$$Net_k^q = \sum_{i=1}^I \omega_{ki} o_i^q - \theta_k \quad (k = 1, 2, \dots, K) \quad (4)$$

式中: ω_{ki} —隐含层神经元 i 传递到输出层神经元 k 的连接权值; θ_k —输出层神经元 k 的阈值; I —隐含层的节点个数。

于是得到输出层的第 k 个神经元输出为:

$$o_k^q = g(Net_k^q) \quad (k = 1, 2, \dots, K) \quad (5)$$

最后, 针对隐含层激活函数 $g(Net_i^q)$ 和输出层激活函数 $g(Net_k^q)$ 分别求它们的微分函数, 可以得到:

收敛速度较快^[10-11]。

取训练集内的 M 个样本, 则每个样本 q 的输入模式对可通过二次型误差函数来得到其误差:

$$J_q = \frac{1}{2} \sum_{k=1}^K (t_k^q - o_k^q)^2 \quad (7)$$

如果将每个样本的误差求和, 就可以得到系统的总误差函数:

$$J = \sum_{q=1}^M J_q = \frac{1}{2} \sum_{q=1}^M \sum_{k=1}^K (t_k^q - o_k^q)^2 \quad (8)$$

所以在离线学习过程中,网络的权系数的修正原则是依照 J 函数梯度变化的反方向来调整,使网络满足逐渐收敛。由此,可以得到输出层神经元的权系数修正式:

$$\begin{aligned} \Delta \omega_{ki} = & -\eta \frac{\partial J}{\partial \omega_{ki}} = -\eta \sum_{q=1}^M \left(\frac{\partial J_q}{\partial Net_k^q} \cdot \frac{\partial Net_k^q}{\partial \omega_{ki}} \right) = \\ & -\eta \sum_{q=1}^M \left(\frac{\partial J_q}{\partial Net_k^q} \cdot \frac{\partial}{\partial \omega_{ki}} \left(\sum_{i=1}^I \omega_{ki} o_i^q - \theta_k \right) \right) = \\ & -\eta \sum_{q=1}^M \left(\frac{\partial J_q}{\partial Net_k^q} \cdot o_i^q \right) \end{aligned} \quad (9)$$

式中: η —学习速率,其取值大于0。

令:

$$\begin{aligned} \delta_k^q = & \frac{\partial J_q}{\partial Net_k^q} = -\frac{\partial J_q}{\partial o_k^q} \cdot \frac{\partial o_k^q}{\partial Net_k^q} = (t_k^q - o_k^q) \cdot \\ & g'(Net_k^q) = (t_k^q - o_k^q) \cdot o_k^q (1 - o_k^q) \end{aligned} \quad (10)$$

将 δ_k^q 代入到 $\Delta \omega_{ki}$ 的表达式中,则可以得到最终的输出层任意神经元 k 的权系数修正式:

$$\Delta \omega_{ki} = -\eta \sum_{q=1}^M (\delta_k^q \cdot o_i^q) = \eta \sum_{q=1}^M o_k^q (1 - o_k^q) (t_k^q - o_k^q) o_i^q \quad (11)$$

同理,隐含层的神经元权系数的修正式为:

$$\begin{aligned} \Delta \omega_{ij} = & -\eta \frac{\partial J}{\partial \omega_{ij}} = -\eta \sum_{q=1}^M \left(\frac{\partial J_q}{\partial Net_i^q} \cdot \frac{\partial Net_i^q}{\partial \omega_{ij}} \right) = \\ & -\eta \sum_{q=1}^M \left(\frac{\partial J_q}{\partial Net_i^q} \cdot \frac{\partial}{\partial \omega_{ij}} \left(\sum_{j=1}^I \omega_{ij} o_j^q - \theta_i \right) \right) = \\ & -\eta \sum_{q=1}^M \left(\frac{\partial J_q}{\partial Net_i^q} \cdot o_j^q \right) = \eta \sum_{q=1}^M (\delta_i^q \cdot o_j^q) \end{aligned} \quad (12)$$

式中: η —学习速率,其取值大于0。

$$\begin{aligned} \delta_i^q = & -\frac{\partial J_q}{\partial Net_i^q} = -\frac{\partial J_q}{\partial o_i^q} \cdot \frac{\partial o_i^q}{\partial Net_i^q} = -\frac{\partial J_q}{\partial o_i^q} \cdot g'(Net_i^q) = \\ & -\frac{\partial J_q}{\partial o_i^q} \cdot o_i^q (1 - o_i^q) \end{aligned} \quad (13)$$

输出单元的输入值是其所连接的各个隐含层神经元的输出之和,所以:

$$\begin{cases} V_{id}(k+1) = \omega V_{id}(k) + c_1 r_1 [P_{id}(k) - X_{id}(k)] + c_2 r_2 [P_{id}(k) - X_{id}(k)] \\ X_{id}(k+1) = X_{id}(k) + V_{id}(k+1) \end{cases} \quad (d=1,2,\dots,D; i=1,2,\dots,m) \quad (17)$$

式中: k —当前的迭代次数; c —加速度因子; r —可以取为 $[0,1]$ 之间的随机数; ω —惯性权重,其值的大小决定了上一次的速度影响当前的程度。当 $\omega = 1$ 时,可以将其看作基本 PSO(迭代后期缺少局部搜索的能力)。同时应将其位置和速度进行限制,起到防止粒子盲目搜索的作用。

$$\begin{aligned} -\frac{\partial J_q}{\partial o_i^q} = & -\sum_{k=1}^K \left(\frac{\partial J_q}{\partial Net_k^q} \cdot \frac{\partial Net_k^q}{\partial o_i^q} \right) = \\ & -\sum_{k=1}^K \left(\frac{\partial J_q}{\partial Net_k^q} \cdot \frac{\partial}{\partial o_i^q} \left(\sum_{i=1}^I \omega_{ki} o_i^q - \theta_k \right) \right) = \sum_{k=1}^K \left(-\frac{\partial J_q}{\partial Net_k^q} \right) \cdot \\ & \omega_{ki} = \sum_{k=1}^K \delta_k^q \cdot \omega_{ki} \end{aligned} \quad (14)$$

最后将上述两式回代以后,可以得到隐含层神经元 i 的权系数修正公式为:

$$\begin{aligned} \Delta \omega_{ki} = & \eta \sum_{q=1}^M (\delta_i^q \cdot o_j^q) = \eta \sum_{q=1}^M o_i^q (1 - o_i^q) \\ & \left(\sum_{k=1}^K \delta_k^q \cdot \omega_{ki} \right) o_j^q \end{aligned} \quad (15)$$

经过整理,将权系数修正公式转化为权系数增量式:

$$\begin{cases} \omega_{ki}(k+1) = \omega_{ki}(k) + \eta \sum_{q=1}^M o_k^q (1 - o_k^q) (t_k^q - o_k^q) o_i^q \\ \omega_{ij}(k+1) = \omega_{ij}(k) + \eta \sum_{q=1}^M o_i^q (1 - o_i^q) \left(\sum_{k=1}^K \delta_k^q \cdot \omega_{ki} \right) o_j^q \end{cases} \quad (16)$$

3.3 改进 PSO 算法的 BP 神经网络

粒子群优化算法(PSO)源于对鸟类捕食行为的研究,它从这种生物种群行为特征中受到启发并应用于求解优化问题。由于 BP 神经网络的初始权值是随机得到的,在学习过程中有可能会陷入到局部最优值^[12],而采用粒子群优化算法可以有效解决这个问题,改善控制的性能。

设在一个 D 维搜索空间里,有 m 个例子组成的种群 $X = (X_1, X_2, \dots, X_m)$,其中第 i 个粒子表示为一个 D 维的向量 $X_i = (X_{i1}, X_{i2}, \dots, X_{id})^T$,即第 i 个粒子在 D 维搜索空间中的位置。同时,设第 i 个粒子的运动速度为 $V_i = (V_{i1}, V_{i2}, \dots, V_{id})^T$,第 i 个粒子目前搜索到的最优位置 $P_{bi} = (P_{bi1}, P_{bi2}, \dots, P_{bid})^T$,整个粒子群目前搜索到的最优位置 $P_{bg} = (P_{bg1}, P_{bg2}, \dots, P_{bgD})^T$ 。而衡量粒子目前的位置是否为最优位置,则通过将每个粒子的位置 X_i 代入到一个目标函数中,通过得到的适应度值来确定^[13]。

通过个体极值和群体极值,每个粒子在迭代过程中,不断更新自己的速度与位置,公式如下:

基于 PSO 算法的函数极值寻优算法流程如图 4 所示。

2.4 基于神经网络的 PID 控制器

传统的 PID 控制器增量式为:

$$\begin{aligned} \Delta u(k) = & K_p [e(k) - e(k-1)] + K_i e(k) + \\ & K_d [e(k) - 2e(k-1) + e(k-2)] \end{aligned} \quad (18)$$




图4 PSO 算法流程

若令:

$$\begin{cases} X_1 = e(k) - e(k-1) \\ X_2 = e(k) \\ X_3 = e(k) - 2e(k-1) + e(k-2) \end{cases} \quad (19)$$

则增量式转化为:

$$\Delta u(k) = K_p X_1 + K_i X_2 + K_d X_3 \quad (20)$$

发现与神经网络中的神经元计算公式相同, 可以将其看作阈值为 0, 且 PID 参数为连接权系数, 因此可以将神经网络应用于 PID 控制器中。与传统的 PID 控制器相比, 它的 PID 参数不是固定不变的, 可以进行自适应调整, 同时也大大节省了参数的整定过程。基于神经网络的 PID 控制器的结构框图如图 5 所示^[14]。




图5 神经网络 PID 控制器结构框图

3 实验仿真

TI 公司生产的 TMS320F2812DSP 在 SVPWM 实现上有其独特优势, 研究者利用 DSP2812 的事件管理器 EV 模块, 可以实现通过软件或者硬件两数方法来实现 SVPWM 波形, 尤其是硬件方法相对软件实现方法, 其


开关损耗更小, 电压利用率更高。本研究利用合众达 DSP2812 开发板和西门康 IGBT 来构建样机, IGBT 的开关频率为 16 kHz, 滤波电感为 15 mH, 滤波电容为 30 μ F。

实验样机输出端带三相平衡负载, 输出电压为 400 V; 电压频率 50 Hz。样机如图 6 所示。



图6 逆变电源样机

取 BP 神经网络的结构为 3-5-3; 学习速率 η 取 0.15; 引入动量项; 则取 α 为 0.04; 隐含层和输出层神经元激活函数分别为正负对称 sigmoid 函数 $g_1(x) = (e^x - e^{-x}) / (e^x + e^{-x})$ 和非负 sigmoid 函数 $g_1(x) = e^x / (e^x + e^{-x})$, 粒子群算法的参数为: 粒子种群规模为 50, 粒子维数为 3, 进化次数 100, 惯性权值从 0.95 向 0.1 线性下降, 加速系数为 2。负载为 6 kW 和 15 kW 下的电压波形如图 7(a)、7(b) 所示。



(a) 负载 6 kW 下的电压波形

(b) 负载 15 kW 下的电压波形

图7 负载 6 kW 和 15 kW 下的电压波形

利用功率分析仪, 可以测得输出功率、电压值以及 THD, 可以发现电压的总谐波畸变率都控制在 3% 以内, 如图 8(a)、8(b) 所示。



(a) 负载 6 kW 下的输出性能

(b) 负载 15 kW 下的输出性能

图8 负载 6 kW 和 15 kW 下的输出性能

利用传统 PID 控制下突加突卸时试验的波形如图

9 所示。其中,横轴坐标标尺为 500 ms,横轴坐标标尺为 100 V,得出其超调量约为 8.5%,调节时间约为 300 ms。




图9 传统 PID 控制下突加突卸试验

使用了 PSO 优化的神经网络 PID 调节器如图 10 所示,其超调为 5%,调节时间为 150 ms,相较于传统的 PID 控制在动态性能上有了很大的改善。




图10 PSO 优化神经网络 PID 控制下突加突卸试验

5 结束语

本研究利用 SVPWM 算法和 $abc-dq$ 坐标变换对三相电压型逆变器进行了控制分析,在传统 PID 控制器的基础上,设计了基于改进 PSO 优化的 BP 神经网络 PID 控制器,利用改进 PSO 算法对 BP 网络的初始权值进行了优化,并利用 BP 神经网络对 PID 参数进行了实时在线调整。结合样机试验,研究结果证明,该方法很好地改善了系统的动态性能。

参考文献 (References):

[1] ANG K H, CHONG, G, LI Y. PID control system analysis, design and technology[J]. **IEEE Transaction Control System Techn**,2005(13):559-576.

- [2] 刘迪,赵建华.一种基于 BP 神经网络模型自适应 PID 控制算法[J]. **自动化技术与应用**,2008,7(8):8-10.
- [3] GYONGY I J, CLARKE D W. On the automatic tuning and adaptation of PID controllers [J]. **Control Engineering Practice**,2006,14(2):14-163.
- [4] 刘燕燕.基于人工神经网络改进型参数整定的智能 PID 控制研究[D].北京:中国石油大学计算机与通信工程学院,2009.
- [5] 孙孝峰,顾和荣,王立乔,等.高频开关型逆变器及其并网技术[M].北京:机械工业出版社,2011.
- [6] 滕上千子,顾德英.基于 DSP 的 SVPWM 实现方法研究[J]. **仪器仪表学报**,2005,26(8):701-703.
- [7] 寇正华,刘文生.基于 BP 神经网络的 SVPWM 算法的研究与仿真[J]. **化工自动化及仪表**,2011,38(2):190-193.
- [8] HARASHIMA F, DEMIZV Y, KONDO S, et al. Application of Neural Networksto Power Converter Control [C]// **Conf Rec IEEE-IAS Annual Meeting, Conf-Rec. San Diego** [s. n.],1989:1087-1091.
- [9] 王宝诚,梅强,邬伟扬,等.三相变流器的模糊 PI 神经网络控制研究[J]. **电工技术学报**,2005,20(8):68-73.
- [10] WANG Jiang-jiang, ZHANG Chun-fa, Jing You-yin. Study of Neural Network PID Control in Variable-frequency Air-conditioning System [C]// **2007 IEEE International Conference on Control and Automation. Guangzhou**: [s. n.], 2007:2405-2415.
- [11] WANG Rui-qi, LI Ke, Cui Na-xin, et al. A New PID-type Fuzzy Neural Network Controller based on Genetic Algorithm with Improved Smith Predictor [C]// **IEEE Decision and Control. Shanghai**: [s. n.], 2009:15-18.
- [12] 龙晓林,徐金方.基于优化 BP 神经网络的 PID 控制器研究[J]. **计算机测量与控制**,2003,11(2):106-108.
- [13] 杜荣茂.改进 PSO-BP 神经网络的 PWM 整流器控制研究[D].兰州:兰州交通大学自动化与电气工程,2012.
- [14] 任子武,伞冶,陈俊风.改进 PSO 算法及在 PID 参数整定中应用研究[J]. **系统仿真学报**,2006,18(10):2870-2871.

[编辑:程浩]

本文引用格式:

王泽锴,何通能,王崇方,等.基于神经网络 PID 的船用电压型逆变电源研究[J]. **机电工程**,2014,31(7):916-921.

WANG Ze-kai, HE Tong-neng, WANG Chong-fang, et al. Research of marine voltage inverter based on neural networks PID control[J]. **Journal of Mechanical & Electrical Engineering**, 2014,31(7):916-921.

《机电工程》杂志: <http://www.meem.com.cn>