

DOI: 10.13718/j.cnki.xdzk.2016.11.026

# 自旋忆阻 CPSO-PID 神经网络<sup>①</sup>

李小娟, 段书凯, 王丽丹

西南大学 电子信息工程学院, 重庆 400715

**摘要:** 采用混沌粒子群优化算法(CPSO)对网络初始值进行迭代寻优, 加快系统的收敛速度. 为了实现 PID 神经网络的硬件平台搭建, 新型纳米器件——自旋忆阻器, 由于其独特的记忆特性和纳米级尺寸, 被用来模拟电子突触, 以实现神经元之间的相互连接. 最后, 通过对强耦合系统进行解耦控制验证了该方案的有效性.

**关键词:** PID 神经网络; 混沌粒子群优化算法(CPSO); 混沌; 自旋忆阻器; 突触

**中图分类号:** TN957.52

**文献标志码:** A

**文章编号:** 1673-9868(2016)11-0167-07

传统的 PID 控制器通过调整其参数来对系统进行控制, 且在系统运行过程中具有固定的参数值, 使得控制器在应用过程中不具有自适应性. 神经网络 PID 的出现, 解决了 PID 的参数动态变化的问题, 具有很强的自适应性, 在系统控制过程中能够实时改变参数, 满足系统的控制精度<sup>[1-4]</sup>. 然而, 该控制器需要很长的学习时间和较慢的收敛速度. 针对该问题, 有学者提出了 PID 神经网络<sup>[5]</sup>, 该网络能够根据对象参数的变化来实时调整控制参数. 在解耦控制和时延系统中能够实现很好的控制效果.

初始值的选取对网络的收敛时间具有一定的影响. 使用进化算法初始化神经网络权值能够取得很好的效果<sup>[6-8]</sup>. 混沌粒子群优化算法(Chaotic particle swarm optimization, CPSO)将进化算法与混沌搜索相结合, 对网络初始进行优化的一种全新算法. 混沌的遍历性和随机性, 可以避免 PSO 陷入最小值. 本研究利用参考文献<sup>[9]</sup>中提出的改进混沌粒子群算法初始化忆阻 PID 神经网络的权值, 加快网络收敛速度, 减小算法复杂度.

突触是神经元与神经元之间的连接, 在 PID 神经网络中也必然会有突触的存在. 忆阻器<sup>[10]</sup>作为一种新型的元件, 其记忆特性可以很好的实现电子突触. 该器件的出现很大地促进了电子突触的研究<sup>[11]</sup>. 惠普忆阻器是应用最为广泛的忆阻器模型<sup>[12]</sup>, 但随着忆阻器研究的加深, 该模型已不能很好地模拟真实忆阻器的特性. 相较于惠普忆阻器, 自旋忆阻器具有独特的阈值特性<sup>[13-14]</sup>, 更接近真实的忆阻器模型. 本研究使用自旋忆阻器模拟电子突触, 采用脉冲控制的方式对神经网络权值进行更新, 完成神经元之间的连接, 消除系统控制过程信号对权值的影响, 保持系统稳定性.

① 收稿日期: 2015-09-11

基金项目: 新世纪优秀人才支持计划(教技函[2013]47号); 国家自然科学基金(61372139, 61101233, 60972155); 教育部“春晖计划”科研项目(z2011148); 留学人员科技活动项目择优资助经费(国家级, 优秀类, 渝人社办[2012]186号); 重庆市高等学校优秀人才支持计划(渝教人[2011]65号); 重庆市高等学校青年骨干教师资助计划(渝教人[2011]65号); 中央高校基本科研业务费专项资金(XDJK2014A009, XDJK2013B011).

作者简介: 李小娟(1990-), 女, 四川达州人, 2013级硕士研究生, 主要从事信号与信息处理的研究.

通信作者: 段书凯, 教授, 硕士研究生导师.

# 1 CPSO 优化 PID 神经网络

## 1.1 PID 神经网络

PID 神经网络是分层神经网络, 它分为输入层, 中间层和输出层, 中间层主要由三种类型的神经元组成一个信息处理机制, 分别是比例神经元、微分神经元、积分神经元. 其结构见图 1.

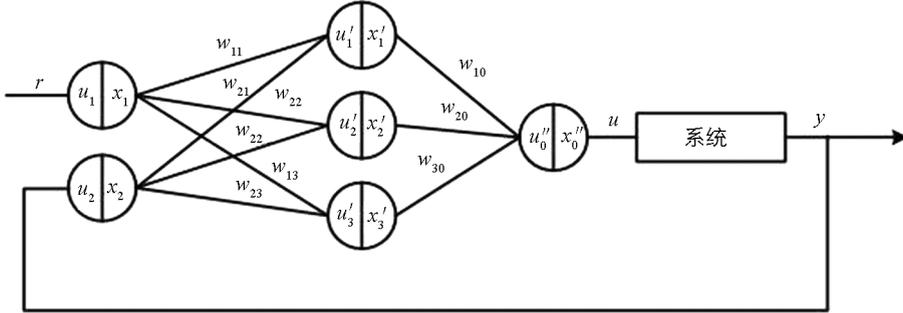


图 1 PID 神经网络结构

系统输入为期望值和系统输出值, 输出为中间层神经元输出与各突触权值的乘累加和. 该神经网络主要通过中间层各神经元对信息进行处理. 不同神经元含有不同的系统函数.

比例神经元  $u'_1$  的输入输出函数为:

$$u'_1(k) = \sum_{i=1}^2 w_{1i}(k)x_i(k) \quad (1)$$

$$x'_1(k) = u'_1(k) \quad -1 \leq x'_1(k) \leq 1 \quad (2)$$

积分神经元的输入输出函数为:

$$u'_2(k) = \sum_{i=1}^2 w_{2i}(k)x_i(k) \quad (3)$$

$$x'_2(k) = x'_2(k-1) + u'_2(k) \quad -1 \leq x'_2(k) \leq 1 \quad (4)$$

微分神经元的输入输出函数为:

$$u'_3 = \sum_{i=1}^2 w_{3i}x_i \quad (5)$$

$$x'_3(k) = u'_3(k) - u'_3(k-1) \quad -1 \leq x'_3(k) \leq 1 \quad (6)$$

神经网络的输出神经元的输入输出为:

$$u''_0 = \sum_{i=1}^3 w'_{i0}(k)x'_i(k) \quad (7)$$

$$x''_0(k) = u''_0(k) \quad -1 \leq x''_0(k) \leq 1 \quad (8)$$

以上为一个 PID 神经元单元组成结构, 在多输入多输出的控制系统中, 使用  $N$  个这样的单元组合来对系统进行自适应控制. 该控制系统的控制目标是使得目标函数取得最小值, 目标函数为

$$J = \sum E = \sum_{k=1}^n [r(k) - y(k)] \wedge 2 \quad (9)$$

其中:  $n$  为输出节点个数,  $y(k)$  为系统实际输出,  $r(k)$  为目标输出.

神经网络权值的修正采用带有惯性项改进梯度下降法, 其修正公式为

$$w_{ij}(k+1) = w_{ij}(k) - u \frac{\partial J}{\partial w_{ij}(k)} + \sigma[w_{ij}(k) - w_{ij}(k-1)] \quad (10)$$

其中:  $u$  和  $\sigma$  是网络的学习速率. 通过在控制过程中不断调整权值的大小, 该 PID 神经网络具有很强的自适

应性. 权值在不断更新的过程中, 必须对其进行保存和累加, 因此便引入了电子突触这一电子器件, 其作用可以类比于真实神经元之间的神经突触. 忆阻器便能很好地满足以上条件.

## 1.2 权值初始化

CPSO 是将混沌局部搜索应用于粒子群算法中的一种新的优化算法<sup>[8-9]</sup>. 利用混沌算法的遍历性和随机性, 避免粒子群法陷入局部最小值. 自该算法提出以来, 引起了很多研究者的兴趣, 他们不断地对其进行改进, 并取得了很好的改进效果.

PSO 的基本规则是初始化一系列的解决方案. 通过迭代来搜索最优解, PSO 的数学公式表达式为:

$$\begin{cases} v_{id}^{k+1} = \omega * v_{id}^k + c_1 r_1 (p_{id}^k - x_{id}^k) + c_2 r_2 (p_{gd}^k - x_{id}^k) \\ x_{id}^{k+1} = x_{id}^k + v_{id}^k \end{cases} \quad (11)$$

式中:  $v_{id}^{k+1}, v_{id}^k, x_{id}^{k+1}, x_{id}^k$  表示粒子  $i$  在时刻  $k+1$  和  $k$  的速度和位置;  $c_1, c_2$  表示个体粒子和粒子组的加速权重系数;  $r_1, r_2$  表示 0 到 1 的随机数; 在搜索过程中,  $p_{id}^k$  表示个体最优位置,  $p_{gd}^k$  表示群体最优位置;  $\omega$  表示自适应惯性因子, 其值为

$$\omega = \begin{cases} \omega_{\min} + \frac{(\omega_{\max} - \omega_{\min})(f - f_{\min})}{f_{\text{avg}} - f_{\min}} & f \leq f_{\text{avg}} \\ \omega_{\max} & f > f_{\text{avg}} \end{cases} \quad (12)$$

其中:  $\omega_{\min}$  和  $\omega_{\max}$  分别是  $\omega$  的最小值和最大值,  $f$  是粒子群当前的适应度值,  $f_{\text{avg}}$  和  $f_{\min}$  分别是所有粒子群的适应度值的平均值和最小值.

Logistic 映射是一个非常简单的混沌映射, 它的数学表达式为

$$x(k+1) = ux(k)(1-x(k)) \quad (13)$$

当  $u=4$  时, 该映射出现混沌现象. 当  $x$  在  $(0, 1)$  范围内时, logistic 映射工作处于混沌状态, 也就是说, 有初始条件  $x_0$  在 logistic 映射作用下产生的序列是非周期的, 不收敛的. 而在此范围之外, 生成的序列必将收敛于某一个特定的值. 因此在做混沌局部搜索时, 需先将权值映射到  $(0, 1)$  的范围中. 改进的混沌 PSO 具体算法流程详见参考文献[9]. CPSO 在进行局部搜索时, 根据最新的最优适应度值和前次的最优适应度值的比值来自动调整混沌粒子群的种群大小, 使得算法更加灵活. 在一定情况下, 该算法可以减小混沌局部搜索的种群大小, 节省搜索的时间和空间.

## 2 自旋忆阻 PID 神经网络

### 2.1 自旋忆阻器

2009 年, 陈怡然教授根据磁畴壁运动的原理提出了一种带有阈值的忆阻器模型——自旋忆阻器<sup>[13]</sup> (图 2). 与 HP 忆阻器类似, 自旋忆阻器也是上下层结构, 下层为参考层, 具有固定的磁化方向, 上层为自由层, 磁化方向可变. 自旋忆阻器的阻值大小和自由层的磁化方向有关. 当自由层的磁化方向和参考层一

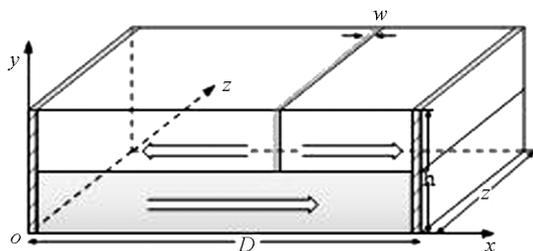


图 2 自旋忆阻器结构图

致时, 忆阻器电阻值最小, 为  $R_{\text{on}}$ ; 当自由层和参考层的磁化方向相反时, 忆阻值最大, 为  $R_{\text{off}}$ . 假设  $r_{\text{H}}$  为单位长度的高电阻值,  $r_{\text{L}}$  为单位长度的低电阻值. 在高低电阻区域的中间, 有一个分界面, 被称为磁畴壁, 该面上的单位电阻是高低单位电阻的平均值, 其值可以忽略不计. 则忆阻器的总的电阻值为:

$$M(l) = r_{\text{H}}l + r_{\text{L}}(D-l) \quad (14)$$

其中:  $l$  为磁畴壁位置,  $D$  为忆阻器的总长度. 设  $x=l/D \in (0, 1)$ , 可以得到与 HP 忆阻器类似的忆阻值

计算公式:

$$M(x) = R_{\text{off}}x + R_{\text{on}}(1 - x) \quad (15)$$

由于磁畴壁的运动速度和流经忆阻器的电流密度相关, 其计算公式为:

$$v = \frac{dl}{dt} = D \frac{dx}{dt} = \Gamma_v \cdot J = \frac{\Gamma_v}{h \cdot z} \cdot \frac{dq}{dt} \quad (16)$$

$$J = \frac{V}{M(x) \cdot h \cdot z} \quad (17)$$

忆阻器的高和宽分别为  $h, z$ ,  $V$  是施加的电压, 则忆阻值方程可以表示为

$$M(t) = R_{\text{on}} + (R_{\text{off}} - R_{\text{on}}) \frac{\Gamma_v}{D \cdot h \cdot z} q(t) \quad (18)$$

其中:  $\Gamma_v$  为磁畴壁的运动系数, 它只与器件结构和材料属性有关. 不同于杂质漂移模型, 自旋忆阻器只有在电流密度大于临界电流密度时, 磁畴壁才会移动, 即当  $J < J_{\text{cr}}$  时,  $\Gamma_v = 0$ . 因此:

$$x = \frac{\Gamma_v}{D} \int_0^t J_{\text{eff}} dt \quad J_{\text{eff}} = \begin{cases} J & J \geq J_{\text{cr}} \\ 0 & J < J_{\text{cr}} \end{cases} \quad (19)$$

其中  $J_{\text{eff}}$  是有效电流密度. 这就是自旋忆阻器的阈值特性.

## 2.2 自旋忆阻器神经突触

大量的研究表明忆阻器的纳米尺寸、信息存储能力和掉电后信息的非易失性非常适合作为神经形态系统中的电子突触. 惠普忆阻器是目前应用最广的忆阻器模型, 它是由惠普实验室在 2008 年提出的. 但由于其为非阈值模型, 在信息处理时, 会引起忆阻值的改变, 导致破坏处理效果. 为了同时保证突触的实时修正和无损信息处理, 具有阈值特性的自旋忆阻器可以更好地仿真电子突触.

自旋忆阻器具有边界和阈值特性. 若给该器件施加太大的电压, 则容易到达边界值; 若施加太小的电压, 小于阈值, 则不能改变忆阻值. 考虑到这个因素, 本研究使用脉冲电压源来控制忆阻值变化. 通过控制加入脉冲的时间周期, 便可以通过改变自由层磁畴壁的位置来改变忆阻值, 从而改变突触权值. 脉冲周期数根据权值改变量来决定:

$$n = \lfloor \Delta\omega / v_m \rfloor \quad (20)$$

由于权值改变量较小, 而自旋忆阻器是纳米级器件, 施加很小的激励便会引起较大的电阻值改变, 而由于其独有的阈值特性, 施加过小的激励又不能对阻值进行改变. 综上因素, 为了提高控制精度, 可将权值改变量进行放大, 选择合适的控制脉冲幅度. 则脉冲周期数计算公式为

$$n = \lfloor \Delta\omega * 100 / v_m \rfloor \quad (21)$$

其中:  $n$  为整数, 其具有正负极性. 当  $n > 0$  时, 给忆阻器施加正脉冲电压, 使得阻值增大, 权值变大; 当  $n < 0$  时, 给忆阻器施加负脉冲电压, 阻值减小, 权值减小; 当  $n = 0$  时, 表示权值变化量很小, 在此忽略该值, 保持原电阻值不变, 则权值保持不变.

权值更新步骤为: ① 使用梯度下降法计算得到权值增量; ② 由权值增量计算得出需要施加的脉冲个数以及电压正负极性; ③ 对忆阻器施加相应脉冲周期; ④ 将得到的忆阻值线性映射为相应突触权值.

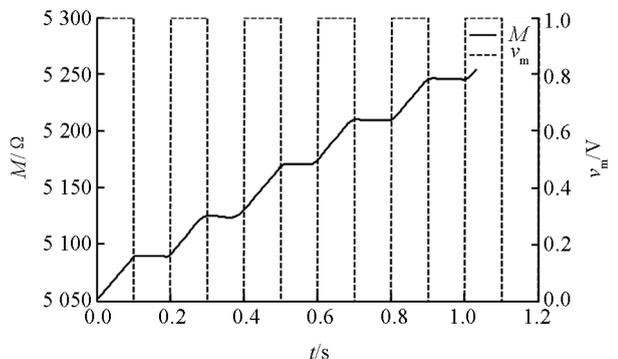


图 3 施加的脉冲电压与相应的忆阻值变化

### 2.3 自旋忆阻 PID 神经网络

将自旋忆阻突触应用在 PID 神经网络中, 其结构见图 4.

由于自旋忆阻器的阈值特性, 使得其能够更好地模拟电子突触, 在以上结构中, 自旋忆阻器突触权值的存储器. 当然在实际的系统应用时, 需要有相应的外围电路来实现突触权值与忆阻值的转换. 权值依然按照梯度下降法更新, 其更新计算过程应在计算机中完成. 忆阻突触在该控制系统工作时, 只要流经该突触的电信号不超过自旋忆阻器阈值, 则不会引起权值的改变. 因此, 采用自旋忆阻突触, 可以将突触更新过程和系统控制过程完全分开, 两个过程相互不会造成干扰, 从而得到更好的控制效果.

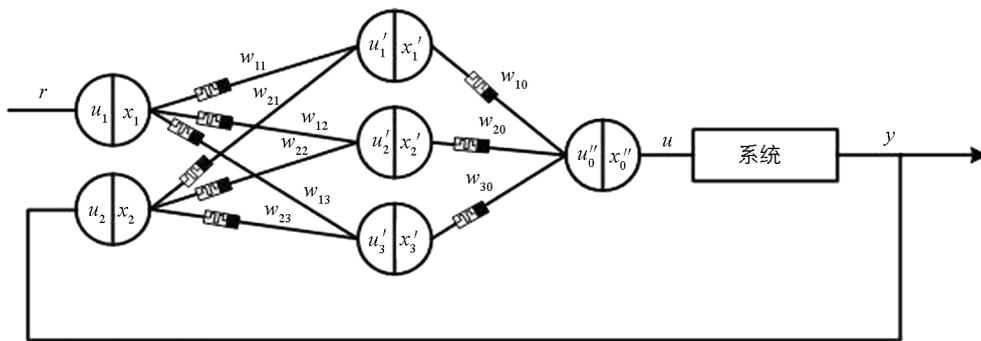


图 4 自旋忆阻 PID 神经网络

### 3 解耦控制

为了验证本文提出 PID 神经网络的实用性, 在此将其应用于含有 3 个变量的强耦合控制系统. 系统方程为:

$$\begin{cases} y_1(k) = 0.4 * y_1(k-1) + u_1(k-1) / [1 + u_1(k-1)^2] + 0.2 * u_1(k-1)^3 + \\ \quad 0.5 * u_2(k-1) + 0.3 * y_2(k-1) \\ y_2(k) = 0.2 * y_2(k-1) + u_2(k-1) / [1 + u_2(k-1)^2] + 0.4 * u_2(k-1)^3 + \\ \quad 0.2 * u_1(k-1) + 0.3 * y_3(k-1) \\ y_3(k) = 0.3 * y_3(k-1) + u_3(k-1) / [1 + u_3(k-1)^2] + 0.4 * u_3(k-1)^3 + \\ \quad 0.4 * u_2(k-1) + 0.3 * y_1(k-1) \end{cases} \quad (22)$$

系统的期望输出为:  $r_1=0.7, r_2=0.764, r_3=0.6$ . 其中:  $r_1, r_2, r_3$  分别是控制量的目标输出;  $u_1, u_2, u_3$  分别为控制系统的控制律;  $y_1, y_2, y_3$  为控制系统的实际输出. 其控制模型见图 5, 仿真结果见图 6.

由仿真结果可以看出, 系统能够很快收敛并保持稳定. 改进粒子群算法的适应度值随着进化次数的增多而逐渐减小, 最后趋于稳定. 在多次迭代以后, 算法完成对网络权值的初始化. 与原来的算法相比, 该算法具有明显优势, 加快了算法的收敛速度, 可以在进化次数较少时, 达到比较理想的优化效果. 进一步, 由误差曲线可以看出, 系统的实际输出和目标输出之间的误差逐渐减小, 最后稳定在一个很小的值. 这表明 SM-PID 控制器能够对强耦合系统进行良好的解耦控制, 具有一定的可行性和有效性. 为忆阻器作为电子突触应用于 PID 神经网络提供了有力的理论基础.

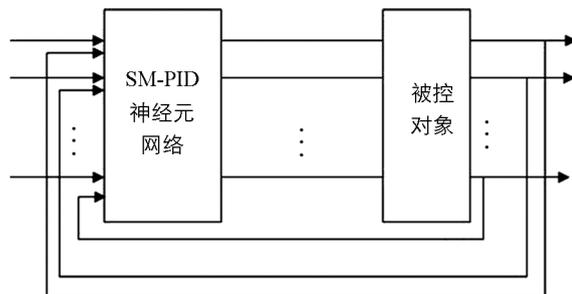
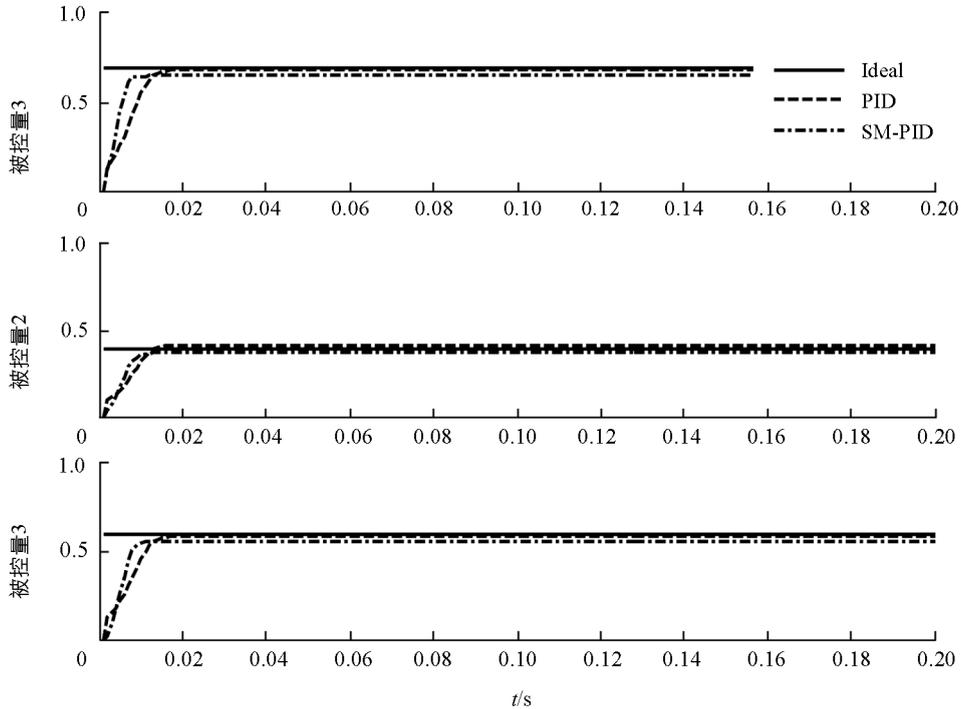
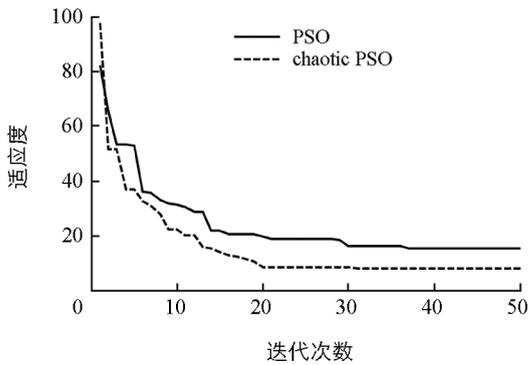


图 5 SM-PID 神经元网络闭环控制系统



(a) PID神经网络控制输出



(b) PSO进化过程

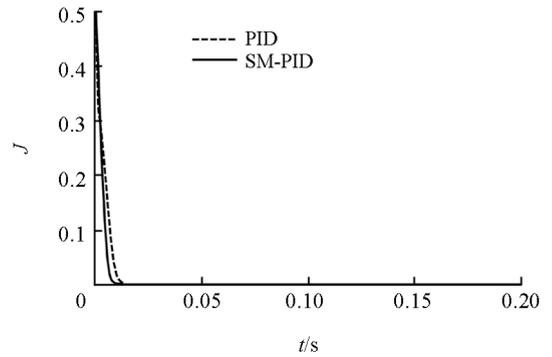
(c) 网络学习目标函数 $J$ 动态曲线

图 6 仿真结果

## 4 总 结

使用改进的粒子群算法来优化 PID 神经网络初始权值, 减小了算法的进化次数, 并自动更新混沌粒子种群的大小, 使得算法更为灵活. 由于自旋忆阻器具有电流阈值特性, 本研究将其作为电阻突触应用在 PID 神经网络中进行建模. 该电子突触可以将突触权值更新与系统信息处理两个过程完全分开, 且互不干扰. 相对于惠普忆阻器而言, 能够更好地建模神经突触. PID 神经网络结合了 PID 控制器和神经网络的优点, 在非线性时延系统和多变量系统控制中, 均能得到很好的控制效果. 本研究所做工作将有助于 PID 神经网络的优化以及建模.

### 参考文献:

- [1] 方晓燕, 王丽丹, 段书凯. 基于忆阻的自适应单神经元多变量解耦 PID 控制器 [J]. 重庆理工大学学报(自然科学版), 2013, 27(3): 91-96.
- [2] 夏思为, 段书凯, 王丽丹, 等. 基于忆阻神经网络 PID 控制器设计 [J]. 计算机学报, 2013, 36(12): 2577-2586.
- [3] 王爽心, 杨 辉, 张秀霞. 基于混沌遗传算法的主汽温系统 RBF-PID 控制 [J]. 中国电机工程学报, 2008, 28(23):

87—92.

- [4] FANG M C, ZHUO Y Z, LEE Z Y. The Application of the Self-Tuning Neural Network PID Controller on the Ship Roll Reduction in Random Waves [J]. *Ocean Engineering*, 2010, 37(7): 529—538.
- [5] SHU H, PI Y. PID Neural Networks for Time-Delay Systems [J]. *Computers & Chemical Engineering*, 2000, 24(2): 859—862.
- [6] FAN L, JOO E M. Design for Auto-Tuning PID Controller Based on Genetic Algorithms [C] // *Industrial Electronics and Applications*, 2009. Lcied: IEEE Conference on IEEE, 2009: 1924—1928.
- [7] GARCIA NIETO P J G, GARCÍA-GONZALO E, LÁSHERAS F S, et al. Hybrid PSO-SVM-Based Method for Forecasting of the Remaining Useful Life for Aircraft Engines and Evaluation of Its Reliability [J]. *Reliability Engineering & System Safety*, 2015, 138: 219—231.
- [8] SOLIHIN M I, TACK L F, KEAN M L. Tuning of PID Controller Using Particle Swarm Optimization (PSO) [J]. *International Journal on Advanced Science, Engineering and Information Technology*, 2011, 1(4): 458—461.
- [9] HEFNY H A, AZAB S S. Chaotic Particle Swarm Optimization [C] // *The 7th International Conference on Informatics and Systems*, 2010: 1—8.
- [10] CHUA L O. Memristor—the Missing Circuit Element [J]. *IEEE Transactions on Circuit Theory*, 1971, 18(5): 507—519.
- [11] KIM H, SAH M P, YANG C, et al. Memristor Bridge Synapses [J]. *Proceedings of the IEEE*, 2012, 100(6): 2061—2070.
- [12] STRUKOV D B, SNIDER G S, STEWART D R, et al. The Missing Memristor Found [J]. *Nature*, 2008, 453(7191): 80—83.
- [13] WANG X, CHEN Y, XI H, et al. Spintronic Memristor Through Spin-Torque-Induced Magnetization Motion [J]. *IEEE Electron Device Letters*, 2009, 30(3): 294—297.
- [14] CHEN Y, WANG X. Compact Modeling and Corner Analysis of Spintronic Memristor [C] // *IEEE/ACM International Symposium on Nanoscale Architectures*, 2009: 7—12.

## The Spintronic Memristor-Based CPSO-PID Neural Network

LI Xiao-juan, DUAN Shu-kai, WANG Li-dan

*School of Electronics and Information Engineering, Southwest University, Chongqing 400715, China*

**Abstract:** PID neural network combines the advantages of conventional PID controller and neural network, which can greatly control the multivariable time-varying systems. In this article, CPSO is used to initial the weights by iteration optimization for the network, accelerating the convergence speed of the system. For building the circuit of PID neural network, the novel nanoscale electronic device, Spintronic Memristor, due to its unique memory properties and nanoscale size, is used to perform the function of electronic synaptic, achieving the interconnection between neurons. Finally, the effectiveness of the proposed scheme in the paper is verified by decoupling the strong coupling system.

**Key words:** PID neural network; chaotic particle swarm optimization(CPSO); chaotic; spintronic memristor; synapse

责任编辑 潘春燕

