

具有突触特性忆阻模型的改进与模型经验学习特性机理

邵楠 张盛兵 邵舒渊

Modification of memristor model with synaptic characteristics and mechanism analysis of the model's learning-experience behavior

Shao Nan Zhang Sheng-Bing Shao Shu-Yuan

引用信息 Citation: *Acta Physica Sinica*, 65, 128503 (2016) DOI: 10.7498/aps.65.128503

在线阅读 View online: <http://dx.doi.org/10.7498/aps.65.128503>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn/CN/Y2016/V65/I12>

您可能感兴趣的其他文章

Articles you may be interested in

单轴应变 SiNMOSFET 源漏电流特性模型

A Model of channel current for uniaxially strained Si NMOSFET

物理学报.2015, 64(19): 197301 <http://dx.doi.org/10.7498/aps.64.197301>

单轴应变硅 N 沟道金属氧化物半导体场效应晶体管电容特性模型

A model of capacitance characteristic for uniaxially strained Si N-metal-oxide-semiconductor field-effect transistor

物理学报.2015, 64(6): 067305 <http://dx.doi.org/10.7498/aps.64.067305>

一种改进的 WO_x 忆阻器模型及其突触特性分析

An improved WO_x memristor model with synapse characteristic analysis

物理学报.2015, 64(14): 148501 <http://dx.doi.org/10.7498/aps.64.148501>

纳米级尺寸参数对钛氧化物忆阻器的特性影响

Influence of length parameter on the characteristics of nanoscale titanium oxide memristor

物理学报.2015, 64(10): 108502 <http://dx.doi.org/10.7498/aps.64.108502>

两类纳米级非线性忆阻器模型及串并联研究

Two types of nanoscale nonlinear memristor models and their series-parallel circuits

物理学报.2014, 63(12): 128502 <http://dx.doi.org/10.7498/aps.63.128502>

具有突触特性忆阻模型的改进与模型经验学习特性机理

邵楠^{1)†} 张盛兵¹⁾ 邵舒渊²⁾

1) (西北工业大学计算机学院, 西安 710072)

2) (西北工业大学电子信息学院, 西安 710072)

(2016年1月19日收到; 2016年3月18日收到修改稿)

许多忆阻器都具有与生物神经突触功能相似的特性, 这些特性包括记忆与遗忘特性、经验学习特性等. 文献[17]根据记忆与遗忘特性建立了这类忆阻器的模型, 文献[19, 20]在对该模型的仿真研究中发现该模型也具有描述经验学习特性的能力. 在关于这一模型已有研究的基础上, 本文对该模型状态方程的特性与机理给出进一步的分析. 分析中发现原模型的窗口函数的设计和使用存在问题, 并且原模型建模时对于实验现象的解读不够准确. 针对这些问题对原模型的状态方程进行了改进, 完善了模型功能. 对于该模型能够描述经验学习特性的机理, 分别利用对于模型的状态方程的分析以及周期脉冲信号作用下的状态方程解析分析, 对该机理给出定性和定量的讨论. 利用机理分析所得的相关结论, 设计了基于经验学习实验的模型状态方程中的参数和函数的估计方法, 方便了该模型在这一类忆阻器的实验研究中的应用.

关键词: 忆阻器, 记忆与遗忘特性, 经验学习特性, 模型参数估计

PACS: 85.35.-p, 73.43.Cd, 87.19.lv

DOI: 10.7498/aps.65.128503

1 引言

近年来关于忆阻器的实验研究中, 研究者们发现有许多基于不同材料的忆阻器都具有与生物神经突触功能相似的特性, 如 WO_x 忆阻器^[1,2]、 α -IGZO 忆阻器^[3]、 Ag_2S 忆阻器^[4]、PEDOT:PSS 忆阻器^[5]、PVA 忆阻器等^[6]. 这一类忆阻器的研究为构建忆阻仿生神经网络系统^[7-11]提供了材料基础和理论依据.

这类忆阻器的实验研究中观察到的与生物神经突触功能相似的特性主要包括记忆与遗忘特性和经验学习特性. 其中, 记忆与遗忘特性是这类忆阻器最主要的特征, 在所有的这一类忆阻器的实验研究中均有关于这一特性的报道^[1-6]; 经验学习特性也较为常见, 该特性在多篇这类忆阻器的实验研究中都有所报道^[2,3,5]. 图1给出这两个特性的示意

说明.

记忆与遗忘特性是指将忆阻器的电导大小看作记忆内容, 对忆阻器施加周期脉冲电压信号, 电导逐渐增大, 记忆逐渐形成; 去掉外加电压, 电导逐渐减小, 记忆的内容逐渐遗忘. 在遗忘过程中, 遗忘曲线先是快速减小, 然后逐渐收敛, 并保持几乎不变, 遗忘曲线收敛时的电导值大于施加脉冲激励的初始时刻的电导值. 遗忘过程曲线可用如下函数给出较好的拟合:

$$D(t) = D_e + (D_0 - D_e) \exp(-t/\tau), \quad (1)$$

其中, $D(t)$, D_0 和 D_e 分别为 t 时刻、 $t = 0$ 时刻以及遗忘曲线收敛时的电导值, τ 为时间常数 (在实验过程中, 通过观察较小的电压作用下的流过忆阻器的电流的变化来得到忆阻器电导的变化). 由遗忘曲线可以看出, 脉冲激励过程中形成的记忆可分为两个部分: 一部分记忆在去掉激励后会被较快地忘

† 通信作者. E-mail: shao@mail.nwpu.edu.cn

记, 称这部分记忆为短周期记忆 (short-term memory, STM); 另一部分记忆能够被保留较长的时间, 称这部分记忆为长周期记忆 (long-term memory, LTM). 记忆形成过程中所施加的脉冲激励的个数会对遗忘曲线的变化趋势有所影响: 脉冲数量越多, 遗忘曲线的变化将变得更为缓慢, 曲线拟合参数 τ 逐渐增长并趋于饱和, 并且遗忘曲线的收敛值随脉冲数目的增大而增大, 即更多的脉冲激励可使得更多的 STM 变化为 LTM.




图1 记忆与遗忘特性和经验学习特性的示意说明 (a) 实验中施加在忆阻器上的输入电压信号; (b)—(d) 依次为第一次脉冲激励过程中、遗忘过程中以及第二次脉冲激励过程中, 忆阻器的电导变化情况, 其中 (b), (d) 中的各点表示每个脉冲周期开始时的忆阻的电导大小

Fig. 1. Illustrations of memorizing and forgetting function and learning-experience behavior: (a) The input voltage applied to the memristor in the experiment; (b)–(d) the change of memristor's conductance during the first stimulating process, forgetting process and the second stimulating process, respectively. Dots in (b) and (d) represent the conductance of the memristor at the beginning of each cycle.

经验学习特性是指忆阻器在经历周期脉冲激励过程和遗忘过程后, 若再次施加相同的脉冲激励, 电导值将再次增大, 且电导值增大速率明显快于第一次激励过程.

忆阻器件的模型研究是忆阻器件进一步的理论分析^[12,13]以及应用设计^[14,15]的基础. 关于这类忆阻器的模型的研究, 文献^[16]在 WO_x 忆阻模型的状态方程中引入 $-w/\tau$ 一项来描述遗忘过程, 其中, 状态变量 w 的变化反映忆阻器电导值的变化情况, τ 为描述遗忘速率的遗忘时间常数, 这一项的引入虽然能使得忆阻模型能够具有遗忘功能, 但该模型并不能描述记忆与遗忘的实验中观察到的现象, 例如随脉冲数量的增加而产生的 STM 向 LTM 的变化以及遗忘曲线的时间常数的变化等.

文献^[17]充分考虑了记忆与遗忘特性的特点, 对文献^[16]中的 WO_x 忆阻模型进行了改进, 将原模型状态方程中的遗忘过程一项变为 $(\varepsilon - w)/\tau$, 其中 w 意义不变, 状态变量 ε 用来描述 LTM 的变化情况, 状态变量 τ 描述遗忘速率的变化, 改进的模型能够对记忆与遗忘特性给出较好的描述, 并且能对实验测量结果给出较好的拟合. 文献^[17]所建立的模型, 也给出了对于具有记忆与遗忘特性忆阻器的一种建模方法, 文献^[18–20]对这一建模方法给出了进一步讨论: 文献^[18]将文献^[17]提出的记忆遗忘特性的建模方法用在惠普实验室的忆阻模型^[21]上, 并利用所建的模型讨论了具有遗忘能力的神经网络的构建与仿真实验; 文献^[19, 20]对利用该建模方法所建立的模型的特性给出进一步的分析, 并利用模型仿真实验发现该建模方法所建立的模型也具有描述经验学习特性的能力.

在对于文献^[17–20]所讨论的建模方法的分析中, 我们发现该建模方法对于窗口函数的设计和使用存在问题, 并且建模时对于实验现象的解读也不够准确; 根据记忆与遗忘特性的特点所建立的模型也能够描述经验学习特性的机理, 还没有详细的分析与讨论; 根据忆阻器实验结果来估计模型中的参数是该模型使用过程中的一项重要工作, 然而尚未看到有文献对于该模型的这一问题进行讨论.

本文首先对于文献^[17]提出的具有记忆与遗忘特性忆阻器的建模方法给出介绍, 并对模型的状态方程所存在的问题进行分析, 提出改进方案. 对模型能够描述经验学习特性的机理给出分析, 并利用机理分析中所得结论, 设计了基于经验学习实验的模型状态方程中参数与函数的估计方法.

2 具有突触特性的忆阻模型

文献^[17–20]中所讨论的具有类似神经突触功能的忆阻器模型的形式如下:

$$I = (1 - w)f_{\text{off}}(V) + wf_{\text{on}}(V), \quad (2)$$

$$\dot{w} = \left(f_E(V) + \frac{\varepsilon - w}{\tau} \right) \times f_{\text{win}}(V, w; w_{\text{max}}, w_{\text{min}}), \quad (3)$$

$$\dot{\varepsilon} = k_\varepsilon f_E(V) f_{\text{win}}(V, w; w_{\text{max}}, w_{\text{min}}), \quad (4)$$

$$\dot{\tau} = k_\tau f_E(V). \quad (5)$$

其中, (2) 式为基于状态的伏安关系方程, I 和 V 分别为流过忆阻器的电流和忆阻器两端的电压, 函数 $f_{\text{off}}(\cdot)$ 和 $f_{\text{on}}(\cdot)$ 分别描述了忆阻器高阻状态和低阻状态的伏安特性, 状态变量 $w \in [0, 1]$ 决定了这两项的权重, 若是将忆阻器的电导值看作是忆阻器的记忆内容, 则状态变量 w 的大小能够反映忆阻器的记忆情况. 状态方程 (3) 给出 w 的变化规律, 其中, $f_E(V)$ 为关于 V 的单调递增函数, 且满足 $f_E(0) = 0$, 状态变量 $\varepsilon \in [0, 1]$ 描述了忆阻器的长周期记忆, 状态变量 $\tau > 0$ 用于描述遗忘过程的遗忘速率, 当输入电压 $V = 0$ 时, 状态变量 w 收敛于 ε , 收敛速率由状态变量 τ 决定. ε 和 τ 的变化规律由状态方程 (4) 和 (5) 分别给出, 其中 k_ε, k_τ 为正常数. 窗口函数 $f_{\text{win}}(V, w; w_{\text{max}}, w_{\text{min}})$ 用以限制状态变量的变化范围, 其中 w_{max} 和 w_{min} 分别为状态变量 w 的上界和下界, 由状态变量 w 的定义可知 $w_{\text{max}} = 1, w_{\text{min}} = 0$.

窗口函数种类很多, 在几乎所有的关于本文所讨论的这类忆阻器的模型的研究文献中 [16,17,19,20], 都使用了如下窗口函数:

$$\begin{aligned} f_{\text{win}}(V, w; w_{\text{max}}, w_{\text{min}}) \\ = 0.25 [(\text{sign}(V) + 1)(\text{sign}(w_{\text{max}} - w) + 1) \\ + (\text{sign}(-V) + 1)(\text{sign}(w - w_{\text{min}}) + 1)], \quad (6) \end{aligned}$$

本文将针对此窗口函数给出讨论.

3 状态方程的分析与改进

根据前面给出的模型定义可知, 模型中的三个状态变量均是有界的, 然而原模型的三个状态方程均无法保证状态变量在其定义区间内变化, 存在该问题的主要原因是: 1) (6) 式所描述的窗口函数的边界特性存在问题; 2) 原模型中窗口函数的使用方法也存在不合理的地方. (6) 式所描述的窗口函数属于包含状态变量变化趋势信息的一类窗口函数, 上述这两方面问题是这一类窗口函数的设计与使用中应该注意的两个比较重要的问题, 在状态方程中合理地使用具有正确的边界特性的窗口函数才能真正保证状态变量的有界性.

另外, 原模型对于状态变量 τ 的定义区间的设定也有问题, 存在该问题的原因是原模型建模时对于相关实验现象的解读不够准确, 对于该问题的改进能够更好地完善模型功能. 本节将针对原模型

中存在的上述问题, 对模型的状态方程给出分析和改进.

3.1 窗口函数

文献 [22—25] 中提出的窗口函数以及 (6) 式给出的窗口函数通过引入状态变量变化方向的信息, 能够较好地避免许多窗口函数 [21,26—30] 存在的“边界滞留”问题(当状态变量达到边界值时, 由于窗口函数为 0, 状态变量将保持不变). (6) 式给出的窗口函数是包含状态变量变化方向信息的这一类窗口函数中最简单的一种情况, 当状态变量处于最大、最小值之间时, 该窗口函数恒为 1, 该窗口函数在状态方程中的使用, 仅限制了状态变量的变化范围, 并未在定义区间内引入新的动态特性, 这意味着使用此窗口函数时, 状态方程的动态特性的设计和状态变量变化范围的限制这两方面工作可分开进行, 设计模型的动态特性只需考虑非窗口函数部分, 不必考虑窗口函数这一项的影响, 这一特点类似于矩形窗口函数(矩形窗口函数存在“边界滞留”问题), 其他窗口函数在使用时很难具备这一特性.

对于包含状态变量变化方向信息的这一类窗口函数, 应满足状态变量增长至上界或减小至下界时函数值为 0, 以保证状态变量不超出边界, 而 (6) 式给出的窗口函数并不满足此要求: 状态变量增长至上界或减小至下界时, 该窗口函数的函数值为 0.5. 针对该窗口函数的这个问题给出如下修改: 将窗口函数中所使用的 $\text{sign}(\cdot)$ 改为

$$s(x_s) = \begin{cases} 1, & x_s > 0, \\ -1, & x_s \leq 0, \end{cases} \quad (7)$$

修改后的窗口函数为

$$\begin{aligned} f_s(V_g, x; x_{\text{max}}, x_{\text{min}}) \\ = 0.25 [(s(V_g) + 1)(s(x_{\text{max}} - x) + 1) \\ + (s(-V_g) + 1)(s(x - x_{\text{min}}) + 1)], \quad (8) \end{aligned}$$

其中, 第二自变量 x 为所在状态方程对应的状态变量, 其上限、下限分别为 $x_{\text{max}}, x_{\text{min}}$, 第一变量 V_g 用以表征 x 的变化趋势. 修改后的窗口函数保留了原窗口函数的结构和特点, 并解决了原窗口函数的边界特性上的缺陷.

在状态方程中使用此窗口函数时, 状态方程的形式如下:

$$\dot{x} = g_x f_s(V_g, x; x_{\text{max}}, x_{\text{min}}), \quad (9)$$

其中, 变量 g_x 是关于系统输入以及系统状态变量的函数. 为使得窗口函数的第一自变量 V_g 能够反映出状态变量的变化趋势, V_g 的正负应与 g_x 始终保持一致. 在使用此窗口函数时, 可取 $V_g = g_x$, 也可取 V_g 为与 g_x 的正负始终保持一致的其他变量.

3.2 关于 w 的状态方程

原模型中, 关于 w 的状态方程 (3) 除了原窗口函数的边界特性方面的问题以外, 窗口函数的第一自变量的选择也不太合适, 输入变量 V 的正负与状态变量 w 的增减方向并不能始终保持一致. 针对这个问题, 令

$$g = f_E(V) + (\varepsilon - w)/\tau, \quad (10)$$

将变量 g 作为窗口函数的第一自变量即可.

根据上述分析, 对于原模型中关于 w 的状态方程 (3) 的修改为: 将 (3) 式中的窗口函数项 $f_{\text{win}}(V, w; 1, 0)$ 改为 $f_s(g, w; 1, 0)$.

3.3 关于 ε 的状态方程

原模型关于 ε 的状态方程 (4) 在窗口函数中, 所用的第二自变量为 w 而不是 ε , w 和 ε 是两个独立的状态变量, 二者的变化并不同步, 因此 w 并不能反映出 ε 在定义区间中的位置. 另外, 考虑到原模型中所用的窗口函数的边界特性存在问题, 对于原模型中关于 ε 的状态方程 (4) 的修改为: 将 (4) 式中的窗口函数项 $f_{\text{win}}(V, w; 1, 0)$ 改为 $f_s(V, \varepsilon; 1, 0)$.

3.4 关于 τ 的状态方程

状态变量 τ 的物理意义以及状态方程 (3) 的收敛性均要求 $\tau > 0$, 模型的定义中明确给出了状态变量 $\tau > 0$ 这一范围限制, 然而关于 τ 的状态方程 (5) 并不能保证这一要求, 若对系统连续施加负的输入电压信号, 状态变量 τ 将连续递减, 最终会使得 $\tau \leq 0$.

文献 [18] 在关于 τ 的状态方程中加入 $(a - w)$ 这一项, 其中 $a \in (0, 1)$ 为常数, 但这仍然不能保证 $\tau > 0$; 另外, 文献 [18] 在关于 τ 的状态方程中加入 $(a - w)$ 这一项是因为对于文献 [1, 3] 中关于 τ 的实验结果给出如下解读: 在连续正脉冲作用下, τ 首先增长, 然后饱和, 甚至开始减小. 我们认为文献 [18] 给出的这一解读并不准确, 文献 [1, 3] 中的实验结果反映出的情况应为: 在连续正脉冲作用下, τ

首先增长, 然后饱和, 但并没有减小的趋势, 只是在饱和后存在小幅的波动. 这一波动的存在, 一方面是由于在文献 [1, 3] 中 τ 值是对遗忘过程中的实验结果进行曲线拟合时的一个拟合参数, 实验测量精度以及拟合算法的选择均可能对 τ 产生影响; 另一方面实验测量过程中环境温度的波动变化也会对 τ 有所影响 [3,20]. 另外, 文献 [17—20] 所讨论的模型均不能对于 τ 饱和现象给出描述.

实验中观察到的 τ 饱和现象意味着状态变量 τ 也是有上界的. 另外, 实验中观察到的 τ 总是有一个正的下界 [1-6], 因此状态变量 τ 的下界也并非无限趋近于 0.

根据以上分析, 我们对原模型中状态变量 τ 的范围的定义以及关于 τ 的状态方程做出以下修改: 1) 将 τ 的定义区间修改为 $0 < \tau_{\min} \leq \tau \leq \tau_{\max}$; 2) 在关于 τ 的状态方程中加入窗口函数 $f_s(V, \tau; \tau_{\max}, \tau_{\min})$.

3.5 修改后的模型状态方程

根据前面对于原模型状态方程中所存在问题的分析以及相应的修改设计, 修改后的忆阻系统状态方程如下:

$$\dot{w} = g f_s(g, w; 1, 0), \quad (11)$$

$$\dot{\varepsilon} = k_{\varepsilon} f_E(V) f_s(V, \varepsilon; 1, 0), \quad (12)$$

$$\dot{\tau} = k_{\tau} f_E(V) f_s(V, \tau; \tau_{\max}, \tau_{\min}). \quad (13)$$

修改后的模型与原模型的区别主要是在窗口函数上, 这里所给出的修改主要是完善了原模型的边界特性, 当状态变量的变化未达到其定义区间的边界时, 两模型所描述的动态特性完全相同, 因此, 对原模型的上述修改不会影响模型对于记忆与遗忘特性以及经验学习特性的描述能力.

4 经验学习特性机理分析

本文讨论的具有类似突触功能的忆阻模型的最早提出, 是根据记忆与遗忘特性设计的, 在对于该模型的进一步的仿真分析研究中, 发现该模型还具有描述经验学习特性的能力. 本节将对该模型能够描述经验学习特性的机理给出详细分析, 其中, 4.1 节基于模型的状态方程对模型的这一机理给出定性分析, 4.2 节利用状态方程的解析分析结果对模型的经验学习特性的机理给出定量讨论.

4.1 基于状态方程的机理分析

由于状态方程中, 窗口函数的功能仅是限制状态变量的变化范围, 状态方程的特性由状态方程中除窗口函数以外的部分给出描述, 当状态变量始终在其定义范围内变化时, 窗口函数恒为1, 此时的状态方程为:

$$\dot{w} = f_E(V) + \frac{\varepsilon - w}{\tau}, \quad (14)$$

$$\dot{\varepsilon} = k_\varepsilon f_E(V), \quad (15)$$

$$\dot{\tau} = k_\tau f_E(V). \quad (16)$$

在已报道的这类忆阻器的实验研究中^[1-6], 当输入电压为0时, 忆阻器的电导不会增大. 若 $w < \varepsilon$, 则输入电压为0时, 会出现忆阻器的电导值递增, 故这里假设当输入电压始终满足 $V \geq 0$ 时, $w \geq \varepsilon$.

根据模型的定义可知, 状态变量 w 的变化可反映出忆阻器的电导变化情况, 状态方程(14)描述了状态变量 w 的变化规律. 因为 $\tau > 0$, 故 ε 越大, $\dot{w}$ 越大; 经验学习实验中, 输入电压始终满足 $V \geq 0$, 此时 $w \geq \varepsilon$, 故 τ 越大, $\dot{w}$ 越大. 因此, $\dot{w}$ 随 ε 和 τ 的增大而增大, 即 ε 和 τ 的增大会使得状态变量 w 的增长速率更大或递减速率更小. 图2给出 w 初值和输入电压 V 一定时, ε 和 τ 的不同对于状态变量 w 的变化过程的影响.

经验学习实验中, 遗忘过程前后, 两组相同的脉冲激励作用下电导的变化速率不同, 正是由于第二次的脉冲激励过程中系统的 ε 和 τ 比第一次时更大, 因此在第二次的脉冲信号作用过程中, 脉冲激励时, 电导增大得更快, 脉冲间隔时, 电导减小得更慢, 故相同的脉冲信号作用下, 忆阻器电导变化量一定时, 第二次脉冲激励过程中所需要的脉冲数量较少.

由图2给出的仿真分析结果还可以看出, 状态变量 w 的变化量随 ε 的增大而均匀递增, 而随 τ 的增大虽然也会递增, 但递增量逐渐减小. 这是由于状态方程(14)中, 当仅 ε 变化时, $\dot{w}$ 与 ε 呈线性关系, $\dot{w}$ 的变化大小仅与 ε 的变化量 $\Delta\varepsilon$ 有关, 即 $\Delta\varepsilon$ 一定时, $\dot{w}$ 的变化一定; 而当仅 τ 变化时, $\dot{w}$ 与 τ 呈非线性关系, $\dot{w}$ 的变化大小同时与 τ 的大小和 τ 的变化量 $\Delta\tau$ 相关, 当 $\Delta\tau$ 一定时, τ 越大, $\dot{w}$ 的变化量越小. 由状态方程的这一特性可知, 该模型所能描述的经验学习特性会存在如下特点: τ 的初值的大

小会对前后两次脉冲激励过程中电导的增长速率的变化量有所影响, τ 的初值越小, 第二次脉冲激励过程中电导的平均增长速率的增量越大, 电导回到第一次激励过程中所达到的最大值所需的脉冲数就越少.




图2 不同的 ε 和 τ 对于状态变量 w 的变化规律的影响 仿真实验中, 输入脉冲信号周期为0.1 s, 占空比为50%, 脉冲幅值为 V_m 满足 $f_E(V_m) = 5$, $k_\varepsilon = k_\tau = 0$, 即每一次仿真过程中 ε 和 τ 保持不变, w 初值为0.5: (a) $\tau = 0.3$ 时, 不同的 ε 对于 w 的变化规律的影响; (b) $\varepsilon = 0.3$ 时, 不同的 τ 对于 w 的变化规律的影响

Fig. 2. Simulation results of the variation of w with different ε and τ . In the simulation, the pulse signal period is 0.1 s, and the duty cycle is 50%. The amplitude of the pulse signal is V_m , and $f_E(V_m) = 5$. $k_\varepsilon = k_\tau = 0$, which means that ε and τ are constants in each simulation process. The initial value of w is 0.5: (a) The variation of w when $\tau = 0.3$ and ε varies from 0.1 to 0.5 in steps of 0.1; (b) the variation of w when $\tau = 0.3$ and ε varies from 0.1 to 0.5 in steps of 0.1.

图3给出 τ 的初值不同的两组经验学习实验仿真结果, 实验中 w 的初值和遗忘过程中 w 的最终收敛值(即第二次激励过程中 w 的初值)相同, 以对比相同的 w 增量下所经历的脉冲次数的变化情况. τ 的初值为0.1时, w 在第二次脉冲激励过程中, 再次回到第一次的10个脉冲作用后所达到的最大值, 仅需经历5个脉冲, 如图3(a)所示; τ 的初值为1时, 此过程需经历9个脉冲, 如图3(b)所示.

以上所给出的机理分析主要是针对状态方程(14)中 ε 和 τ 的变化对 $\dot{w}$ 的影响进行的讨论,分析中并未涉及状态方程(15)和(16)的信息,也未考虑 w 的变化对 $\dot{w}$ 的影响.因此,前面给出的分析只是

对模型的经验学习特性机理的定性分析,这些分析并不能反映出模型的实际动态过程的所有信息,所得出的结论的应用范围也会存在一定的局限性(例如无法用于一些定量问题的讨论等).




图3 τ 的初值大小对经验学习过程的影响 两次实验所用的脉冲信号周期为0.1 s, 占空比为10%, 脉冲幅值 V_m 满足 $f_E(V_m) = 10$, 第一次脉冲激励包含10个脉冲, 第二次脉冲激励持续至 w 回到第一次脉冲激励过程中所达到的最大值的那个脉冲周期为止, 遗忘过程持续10 s, 系统参数 $k_\varepsilon = 0.1$, $k_\tau = 0.5$, w 和 ε 初值分别为0.1和0: (a) τ 初值为0.1时, 第二次脉冲激励经历5个脉冲; (b) τ 初值为1时, 第二次脉冲激励经历9个脉冲

Fig. 3. Influence of τ 's initial value on the learning-experience behavior. In the simulation, the pulse signal period is 0.1 s, and the duty cycle is 10%. The amplitude of the pulse signal is V_m , and $f_E(V_m) = 10$. The first stimulation process contains 10 pulses, and the second stimulation process would not stop until the cycle in which w rises back to the maximum value that has been reached during the first stimulation process. The forgetting process lasts 10 s. $k_\varepsilon = 0.1$, $k_\tau = 0.5$, and the initial values of w and ε are 0.1 and 0 respectively: (a) The initial value of τ is 0.1, and only 5 pulses are used in the second stimulation process; (b) The initial value of τ is 1, and 9 pulses are used in the second stimulation process.

4.2 解析分析与机理讨论

模型所能够描述的记忆与遗忘特性和经验学习特性的实验中, 输入信号均用到了周期脉冲信号, 本节就系统输入为脉冲周期函数时, 对模型状态方程的时域变化情况给出解析分析, 并利用解析分析结果, 对模型的相关特性进行讨论. 本节的讨论依然假设: 1) $w \geq \varepsilon$; 2) 状态变量仅在定义区间范围内变化, 窗口函数始终为1.

周期脉冲输入信号函数为

$$V(t) = \begin{cases} V_m, & nT < t \leq (n+c)T, \\ 0, & (n+c)T < t \leq (n+1)T, \end{cases} \quad (17)$$

式中, t 为时间, $V_m > 0$ 为脉冲幅值, T 为输入信号周期, $c \in (0, 1)$ 为脉冲信号的占空比,

$n = 0, 1, 2, \dots$. 在此信号作为输入时,

$$f_E(V) = \begin{cases} f_E(V_m), & nT < t \leq (n+c)T, \\ 0, & (n+c)T < t \leq (n+1)T. \end{cases} \quad (18)$$

令 $M_E = f_E(V_m)$, $M_\varepsilon = k_\varepsilon M_E$, $M_\tau = k_\tau M_E$. 将(18)式代入(14)式—(16)式, 得到 nT 到 $(n+1)T$ 的一个周期内系统状态方程为:

$$\dot{w} = \begin{cases} M_E + \frac{\varepsilon - w}{\tau}, & nT < t \leq (n+c)T, \\ \frac{\varepsilon - w}{\tau}, & (n+c)T < t \leq (n+1)T, \end{cases} \quad (19)$$

$$\dot{\varepsilon} = \begin{cases} M_\varepsilon, & nT < t \leq (n+c)T, \\ 0, & (n+c)T < t \leq (n+1)T, \end{cases} \quad (20)$$

$$\dot{\tau} = \begin{cases} M_\tau, & nT < t \leq (n+c)T, \\ 0, & (n+c)T < t \leq (n+1)T. \end{cases} \quad (21)$$

对 (20) 和 (21) 式积分可得:

$$\varepsilon(t) = \begin{cases} M_\varepsilon(t - nT) + \varepsilon(nT), & nT < t \leq (n+c)T, \\ \varepsilon((n+c)T), & (n+c)T < t \leq (n+1)T, \end{cases} \quad (22)$$

$$\tau(t) = \begin{cases} M_\tau(t - nT) + \tau(nT), & nT < t \leq (n+c)T, \\ \tau((n+c)T), & (n+c)T < t \leq (n+1)T, \end{cases} \quad (23)$$

其中

$$\varepsilon((n+c)T) = \varepsilon(nT) + M_\varepsilon cT, \quad (24)$$

$$\tau((n+c)T) = \tau(nT) + M_\tau cT, \quad (25)$$

将 (22) 式和 (23) 式代入 (19) 式可解得:

$$w(t) = \begin{cases} w_1(t), & nT < t \leq (n+c)T, \\ w_2(t), & (n+c)T < t \leq (n+1)T, \end{cases} \quad (26)$$

其中,

$$w_1(t) = \frac{M_E - M_\varepsilon}{M_\tau + 1} \tau(t) + \varepsilon(t) + \left[w(nT) - \frac{M_E - M_\varepsilon}{M_\tau + 1} \tau(nT) - \varepsilon(nT) \right] \times \left[\frac{\tau(nT)}{\tau(t)} \right]^{\frac{1}{M_\tau}}, \quad (27)$$

$$w_2(t) = \varepsilon((n+c)T) + [w((n+c)T) - \varepsilon((n+c)T)] \times \exp\left(-\frac{t - (n+c)T}{\tau((n+c)T)}\right). \quad (28)$$

由解析分析的结果可知, 当状态变量一直保持在定义区间范围内变化时, 在周期脉冲信号作用下, 状态变量 ε 和 τ 在脉冲激励时匀速递增, 脉冲间隔时保持不变, 每个周期的增量分别为 $M_\varepsilon cT$ 和 $M_\tau cT$; 状态变量 w 在脉冲激励过程中按照方程 (27) 逐渐递增, 在脉冲间隔时沿时间常数为 $\tau((n+c)T)$ 的指数曲线递减. 随着脉冲激励过程时间的增大, (27) 式的第三项趋向于 0, 因此, 激励过程中 w 的递增曲线将趋向于沿斜率为 $(M_E M_\tau - M_\varepsilon)/(M_\tau + 1)$ 的直线匀速上升; 随着脉

冲间隔时间的增大, 脉冲间隔时指数递减的 w 逐渐收敛于 $\varepsilon((n+c)T)$.

遗忘过程中与脉冲间隔时系统的输入均为 $V = 0$, 因此遗忘过程中系统的变化情况与脉冲间隔时相同, 遗忘过程中系统的状态变量 w 指数递减, 指数曲线的时间常数和最终的收敛值分别为在遗忘过程中状态变量 τ 和 ε 的值. 在遗忘过程之前的激励过程中, 若初始条件相同, 脉冲数越多, 状态变量 τ 和 ε 增长得越大, 因此遗忘过程中状态变量 w 的变化曲线会受到激励过程中脉冲数目的影响. 对于模型的记忆与遗忘特性的分析与文献 [17] 中的讨论结果相同.

通过分析每个脉冲周期内状态变量 w 的变化情况, 可以对模型的经验学习特性的机理给出解释. nT 到 $(n+1)T$ 的一个周期中, 状态变量 w 在脉冲激励阶段的变化量 Δw_1 和脉冲间隔阶段的变化量 Δw_2 分别为:

$$\begin{aligned} \Delta w_1 &= w((n+c)T) - w(nT) \\ &= \left[w(nT) - \frac{M_E - M_\varepsilon}{M_\tau + 1} \tau(nT) - \varepsilon(nT) \right] \\ &\quad \times \left[\left(\frac{\tau(nT)}{\tau((n+c)T)} \right)^{\frac{1}{M_\tau}} - 1 \right] \\ &\quad + \frac{M_E M_\tau + M_\varepsilon}{M_\tau + 1} cT, \end{aligned} \quad (29)$$

$$\begin{aligned} \Delta w_2 &= w((n+1)T) - w((n+c)T) \\ &= \left\{ \frac{M_E - M_\varepsilon}{M_\tau + 1} (\tau(nT) + M_\tau cT) \right. \\ &\quad + \left[w(nT) - \frac{M_E - M_\varepsilon}{M_\tau + 1} \tau(nT) - \varepsilon(nT) \right] \\ &\quad \times \left[\frac{\tau(nT)}{\tau((n+c)T)} \right]^{\frac{1}{M_\tau}} \left. \right\} \\ &\quad \times \left[\exp\left(-\frac{(1-c)T}{\tau(nT) + M_\tau cT}\right) - 1 \right]. \end{aligned} \quad (30)$$

一个周期内状态变量 w 的变化量为

$$\Delta w = \Delta w_1 + \Delta w_2. \quad (31)$$

对于给定的忆阻系统和输入激励信号, 系统参数 M_E , M_ε 和 M_τ 以及信号参数 c 和 T 均为定值, 由 (29) 和 (30) 式可知, 一个周期内状态变量 w 在脉冲激励过程中的变化量 Δw_1 以及在脉冲间隔过程中的变化量 Δw_2 , 均可表示为忆阻系统状态变量在该周期初始时刻的值 $w(nT)$, $\varepsilon(nT)$ 和 $\tau(nT)$ 的函数. 当 $w(nT)$ 和 $\tau(nT)$ 一定时, Δw_1 和 Δw_2 是

关于 $\varepsilon(nT)$ 的线性单调递增函数, 图4给出 $w(nT)$ 和 $\tau(nT)$ 一定时, Δw_1 和 Δw_2 关于 $\varepsilon(nT)$ 的变化曲线, 设 $\Delta\varepsilon$ 为从 n_1T 时刻到 n_2T 时刻状态变量 ε 的变化量 ($n_1 < n_2$), 即 $\Delta\varepsilon = \varepsilon(n_2T) - \varepsilon(n_1T)$, 由 $\Delta\varepsilon$ 引起的 w_1 和 w_2 的变化量的大小仅与 $\Delta\varepsilon$ 有关. 当 $w(nT)$ 和 $\varepsilon(nT)$ 一定时, Δw_1 和 Δw_2 是关于 $\tau(nT)$ 的非线性函数, 且当 $\tau(nT) \rightarrow \infty$ 时, $\Delta w_1 \rightarrow M_E c T$, $\Delta w_2 \rightarrow 0$, 即 Δw_1 和 Δw_2 会随着 $\tau(nT)$ 的增大而逐渐收敛. 图5给出了 $w(nT)$, $\varepsilon(nT)$ 一定时, Δw_1 和 Δw_2 关于 $\tau(nT)$ 的变化曲线, 设 $\Delta\tau$ 为从 n_1T 时刻到 n_2T 时刻状态变量 τ 的变化量 ($n_1 < n_2$), 即 $\Delta\tau = \tau(n_2T) - \tau(n_1T)$, 由 $\Delta\tau$ 引起的 Δw_1 和 Δw_2 的变化量的大小不仅与 $\Delta\tau$ 大小有关, 还与 $\tau(n_1T)$ (或 $\tau(n_2T)$) 的大小有关, 若




图4 Δw_1 和 Δw_2 关于 $\varepsilon(nT)$ 的变化曲线 其中 $M_E = 10$, $M_\varepsilon = 5$, $M_\tau = 1$, 输入脉冲信号周期 $T = 0.1$, 占空比 $c = 10\%$, $w(nT) = 0.5$, $\tau(nT) = 1$: (a) Δw_1 关于 $\varepsilon(nT)$ 的变化曲线; (b) Δw_2 关于 $\varepsilon(nT)$ 的变化曲线

Fig. 4. The graphs of Δw_1 and Δw_2 against $\varepsilon(nT)$. Let $M_E = 10$, $M_\varepsilon = 5$, $M_\tau = 1$, pulse signal period $T = 0.1$, duty cycle $c = 10\%$, $w(nT) = 0.5$, $\tau(nT) = 1$: (a) The graph of Δw_1 against $\varepsilon(nT)$; (b) the graph of Δw_2 against $\varepsilon(nT)$.

$\Delta\tau$ 一定, $\tau(n_1T)$ (或 $\tau(n_2T)$) 越大, Δw_1 和 Δw_2 的变化量越小.

由以上分析可以看出, 模型的经验学习特性可利用 $\Delta\tau$ 和 $\Delta\varepsilon$ 对于每个脉冲周期内的 Δw 的影响给出解释, 而且 τ 的大小会对模型的经验学习特性有所影响. 这一结论与4.1节中所得出的结论完全一致. 与4.1节的讨论不同的是, 这里所给出的解析分析充分考虑到了所有的状态变量的变化情况以及所有状态方程的信息, 因此这里的讨论对于模型特性反映得更为全面, 与实际情况也更为相符. 另外, 这里的讨论还给出了状态变量 w 的变化量与状态变量初值以及状态方程参数之间的定量关系, 更为清楚地反映出模型的动态特性变化规律.




图5 Δw_1 和 Δw_2 关于 $\tau(nT)$ 的变化曲线 其中 $M_E = 10$, $M_\varepsilon = 5$, $M_\tau = 1$, 输入脉冲信号周期 $T = 0.1$, 占空比 $c = 10\%$, $w(nT) = 0.5$, $\varepsilon(nT) = 0.3$: (a) Δw_1 关于 $\tau(nT)$ 的变化曲线; (b) Δw_2 关于 $\tau(nT)$ 的变化曲线

Fig. 5. The graphs of Δw_1 and Δw_2 against $\tau(nT)$. Let $M_E = 10$, $M_\varepsilon = 5$, $M_\tau = 1$, pulse signal period $T = 0.1$, duty cycle $c = 10\%$, $w(nT) = 0.5$, $\varepsilon(nT) = 0.3$: (a) The graph of Δw_1 against $\tau(nT)$; (b) the graph of Δw_2 against $\tau(nT)$.

5 状态方程参数和函数的估计方法

由上一节中对于模型经验学习特性机理的讨论可以看出, 经验学习实验可以反映出模型状态方程中的信息. 本节利用上一节的讨论所得的结论, 设计基于经验学习实验估计状态方程参数和函数的方法. 这里的状态方程是指前文中所提出的改进的状态方程, 其中需要估计的参数包括 k_ε , k_τ , $\tau_{\max}$, $\tau_{\min}$, 需要估计的函数为 $f_E(\cdot)$.

实验中使用的输入信号如图 1(a) 所示, 输入信号由三部分构成, 依次为: 第一次脉冲激励过程、遗忘过程、第二次脉冲激励过程. 状态方程参数和函数的估计, 需要进行不同脉冲数量的第一次激励过程和不同脉冲幅值的多次实验, 以得到足够的状态方程的特性信息. 设实验中所使用的第一次激励的脉冲数由小到大依次为 $N_1, N_2, \dots, N_p$, 所使用的脉冲幅值由小到大依次为 $V_1, V_2, \dots, V_q$. 将第一次激励过程的脉冲数为 N_i , 脉冲幅值为 V_j 的一次实验记为 E_{ij} ($i = 1, 2, \dots, p, j = 1, 2, \dots, q$), 根据实验 E_{ij} 得到的状态方程的信息用上标为“ ij ”的符号表示, 如 τ^{ij} , ε^{ij} 等. 按照脉冲幅值大小对所做的实验分组, 将脉冲幅值为 V_j 的一组实验记为 E_j , 即 $E_j = \{E_{1j}, E_{2j}, \dots, E_{pj}\}$, 根据 E_j 这一组实验得到的状态方程的信息用上标为“ j ”的符号表示, 如 M_τ^j , M_ε^j . 利用经验学习实验估计状态方程参数和函数的步骤如下.

1) 实验测量. 从相同的初始状态开始, 将所设计的 $p \times q$ 个输入信号分别作用于忆阻器, 并记录每一次实验中忆阻器电导值的变化情况.

2) 遗忘过程的信息分析. 由关于 τ 和 ε 的状态方程可知, 在遗忘过程中状态变量 τ 和 ε 保持不变. 实验 E_{ij} 的遗忘过程中的 τ 可利用对遗忘曲线按照 (1) 式拟合得到的时间常数 τ^{ij} 给出估计; 遗忘曲线收敛时 $\varepsilon = w$, 根据实验测量得到的电导值和伏安关系方程可估计得到状态变量 w , 根据收敛时状态变量 w 的估计值 w^{ij} 即可得到对于遗忘过程中的 ε 的估计值 ε^{ij} .

3) 分析状态变量 τ 随第一次激励过程中的脉冲数量 N 的变化情况. 随 N 的增大, 状态变量 τ 先是随之增大, 然后进入饱和. 假设在 E_j 这一组实验中 $N = N_{r^j}$ ($1 < r^j < p$) 时 τ 开始进入饱和, 将 E_j 这一组实验分为 τ 递增部分 E_j^1 和 τ 饱和部分

E_j^2 , E_j^1 中 $N < N_{r^j}$, E_j^2 中 $N \geq N_{r^j}$.

4) 对状态变量 τ 和 ε 随 N 的递增变化做线性拟合. 由解析分析的结论可知, 状态变量 τ 和 ε 关于第一次激励过程中的脉冲数量 N 的关系为:

$$\tau(N) = M_\tau cTN + \tau_0, \quad (32)$$

$$\varepsilon(N) = M_\varepsilon cTN + \varepsilon_0, \quad (33)$$

其中, τ_0 , ε_0 分别为 τ 和 ε 的初值. 分别对 E_j 这一组实验中得到的 $\{(N_i, \varepsilon^{ij}) | i = 1, 2, \dots, p\}$ 以及 E_j^1 中得到的 $\{(N_i, \tau^{ij}) | i = 1, 2, \dots, r^j\}$ 做直线拟合, 可得到脉冲幅值为 V_j 时对于 M_τ , M_ε , τ_0 , ε_0 的估计值 M_τ^j , M_ε^j , τ_0^j , ε_0^j .

5) 估计脉冲幅值为 V_j 时的 $f_E(V_j)$. 实验 E_{ij} 第二次脉冲激励的第一个脉冲作用后电导的变化量可得到该脉冲周期内状态变量 w 的变化量 Δw^{ij} ; 由遗忘曲线可得到该脉冲周期初始时刻的系统状态变量大小 w^{ij} , ε^{ij} , τ^{ij} , 且满足 $w^{ij} = \varepsilon^{ij}$. 将 Δw^{ij} , τ^{ij} , $w^{ij} = \varepsilon^{ij}$, 上一步得到的 M_τ^j 和 M_ε^j 以及输入信号参数 T 和 c 代入 (29) 式—(31) 式, 可解得到此时的 M_E^{ij} . $f_E(V_j)$ 可利用 E_j^1 这一组实验中得到的 $\{M_E^{ij} | i = 1, 2, \dots, r^j\}$ 估计得到:

$$f_E(V_j) = \frac{1}{r^j} \sum_{i=1}^{r^j} M_E^{ij}. \quad (34)$$

6) 参数 k_τ 和 k_ε 的估计. 根据脉冲幅值为 V_j 一组实验 E_j 可对参数 k_τ 和 k_ε 给出一次估计:

$$k_\tau^j = \frac{M_\tau^j}{f_E(V_j)}, \quad (35)$$

$$k_\varepsilon^j = \frac{M_\varepsilon^j}{f_E(V_j)}. \quad (36)$$

参数 k_τ 和 k_ε 的估计值可通过不同脉冲幅值下的估计取均值得到:

$$k_\tau = \frac{1}{q} \sum_{j=1}^q k_\tau^j, \quad (37)$$

$$k_\varepsilon = \frac{1}{q} \sum_{j=1}^q k_\varepsilon^j. \quad (38)$$

7) 参数 $\tau_{\max}$ 和 $\tau_{\min}$ 的估计. 参数 $\tau_{\max}$ 可根据 τ 达到饱和的那部分实验 E_j^2 的遗忘曲线时间常数的均值给出估计

$$\tau_{\max} = \frac{\sum_{j=1}^q \sum_{i=r^j}^p \tau^{ij}}{\sum_{j=1}^q (p - r^j + 1)}. \quad (39)$$

脉冲幅值为 V_j 一组实验 E_j^1 中, 对 $\{(N_i, \tau^{ij}) | i = 1, 2, \dots, r^j\}$ 直线拟合时得到的 τ_0^j 可视作为对参数 $\tau_{\min}$ 的一次估计, 不同的脉冲幅值得到的 τ_0^j 的均值可作为参数 $\tau_{\min}$ 的估计值

$$\tau_{\min} = \frac{1}{q} \sum_{j=1}^q \tau_0^j. \quad (40)$$

8) 函数 $f_E(\cdot)$ 的估计. 利用实验中得到的 $\{(V_j, f_E(V_j)) | j = 1, 2, \dots, p\}$ 可对函数 $f_E(\cdot)$ 给出估计.

这里对根据经验学习特性实验估计模型状态方程中的参数和函数的方法给出以下几点说明.

1) 经验学习实验中, 输入电压非负, 因此, 这里所设计的实验仅能反映出输入电压非负时状态方程的特性, 所设计的参数和函数的估计方法也仅能估计得到输入电压非负时状态方程的参数和函数. 本文所讨论的模型描述的是具有类似突触功能的忆阻器, 这一类忆阻器的一个重要的应用就是利用它的类似神经突触的特性来构建仿生神经系统, 该模型所能够描述的类似神经突触的特性 (即记忆与遗忘特性和经验学习特性) 的实验均是在输入电压非负的条件下进行的, 因此该模型输入电压非负时的状态方程的信息更具实用价值.

2) 除了参数 $\tau_{\max}$ 以外的其他状态方程的参数和函数的估计需要保证实验过程中状态变量未达到边界值, 由于实验中所用的输入电压非负, 因此保证状态变量未达到其上界即可. 对于状态变量 τ , 将遗忘曲线时间常数达到饱和的实验去掉即可保证 τ 未达上界; 对于状态变量 w 和 ε , 为满足这一要求, 实验中所使用的脉冲信号在每个周期内的激励时间 cT 不可太大, 若在第一次脉冲激励的最后几个脉冲激励中仍可观察到电导值的增大, 则可认为状态变量 w 和 ε 未达到边界值.

3) 实验中遗忘过程的时间应足够长, 以保证遗忘过程结束时, 状态变量 w 已经收敛到 ε .

4) 这里所给出的状态方程的参数和函数的估计方法是在假设忆阻系统的伏安关系已知的前提下设计的. 通常情况下, 根据双极性周期电压信号 (如正弦信号、三角波信号等) 作用下观察到的忆阻系统的伏安曲线, 可对忆阻模型的伏安关系方程给出估计.

5) 原模型中对于状态变量 τ 和 ε 的变化规律, 假设 τ 和 ε 未达到边界时, $\dot{\tau}$ 和 $\dot{\varepsilon}$ 与 $f_E(V)$ 成比

例. 以上实验可对于这个假设的合理性给出验证: 对实验中得到的 $\{(V_j, k_\tau^j) | j = 1, 2, \dots, p\}$ 和 $\{(V_j, k_\varepsilon^j) | j = 1, 2, \dots, p\}$ 分别进行观察, 若不同脉冲幅值下得到的 k_τ^j 和 k_ε^j 仅在某个值附近波动, 则可认为 k_τ^j 和 k_ε^j 与 V_j 不相关, 原假设合理; 若 k_τ^j 和 k_ε^j 随脉冲幅值的变化而沿着某个固定趋势变化 (如递增或递减等), 则可认为 k_τ^j 和 k_ε^j 与 V_j 相关, 原假设不合理. 若原假设不合理, 可将原模型中 τ 和 ε 未达到边界时关于 τ 和 ε 的状态方程改为:

$$\dot{\varepsilon} = f_\varepsilon(V), \quad (41)$$

$$\dot{\tau} = f_\tau(V), \quad (42)$$

其中, 函数 $f_\varepsilon(\cdot)$ 和 $f_\tau(\cdot)$ 可利用 $\{(V_j, M_\varepsilon^j) | j = 1, 2, \dots, p\}$ 和 $\{(V_j, M_\tau^j) | j = 1, 2, \dots, p\}$ 给出估计.

6 结 论

本文在关于具有类似突触特性的这一类忆阻器模型已有研究^[17-20]的基础上, 对该模型给出进一步的分析与讨论.

对于原模型状态方程中存在的问题进行了分析, 并给出相应的改进方案, 完善了模型功能. 其中, 原模型存在的关于窗口函数的问题, 也是“包含状态变量变化方向信息”的这一类窗口函数在设计和使用时应注意的问题, 设计时, 应保证状态变量沿将要超出边界的方向到达边界时, 窗口函数值为 0; 使用时, 用于反映状态变量变化方向信息的自变量应根据状态方程的特点进行选择.

对该模型能够描述经验学习特性的机理进行了研究. 分别利用对模型状态方程的分析以及周期脉冲信号作用下的状态方程解析分析, 对该机理给出定性和定量的讨论. 模型能够描述经验学习特性是由于输入信号作用下状态变量的 τ 和 ε 的增长而使得状态变量 w 的增长速率增快、递减速率减小; 状态变量 τ 的大小会对该模型所描述的经验学习特性有所影响.

利用经验学习机理研究所得相关结论, 设计了基于经验学习实验估计模型状态方程中的参数和函数的方法. 所设计的实验估计方法可方便该模型在这一类忆阻器的实验研究中的应用; 另外, 该实验估计方法还可以对原模型关于 τ 和 ε 的状态方程设计的合理性进行验证.

参考文献

- [1] Chang T, Jo S H, Lu W 2011 *ACS Nano* **5** 7669
- [2] Yang R, Terabe K, Yao Y P, Tsuruoka T, Hasegawa T, Gimzewski J K, Aono M 2013 *Nanotechnology* **24** 384003
- [3] Wang Z Q, Xu H Y, Li X H, Yu H, Liu Y C, Zhu X J 2012 *Adv. Funct. Mater.* **22** 2759
- [4] Ohno T, Hasegawa T, Tsuruoka T, Terabe K, Gimzewski J K, Aono M 2011 *Nat. Mater.* **10** 591
- [5] Li S Z, Zeng F, Chen C, Liu H Y, Tang G S, Gao S, Song C, Lin Y S, Pan F, Guo D 2013 *J. Mater. Chem. C* **1** 5292
- [6] Lei Y, Liu Y, Xia Y D, Gao X, Xu B, Wang S D, Yin J, Liu Z G 2014 *AIP Adv.* **4** 077105
- [7] Chang T, Yang Y C, Lu W 2013 *IEEE Circ. Syst. Mag.* **13** 56
- [8] Adhikari S P, Yang C, Kim H, Chua L O 2012 *IEEE Trans. Neur. Net. Lear. Syst.* **23** 1426
- [9] Adhikari S P, Kim H, Budhathoki R K, Yang C J, Chua L O 2015 *IEEE Trans. Circ. Syst. I* **62** 215
- [10] Wang G, Shen Y, Yin Q 2013 *Chin. Phys. B* **22** 050504
- [11] Duan S K, Hu X F, Dong Z K, Wang L D, Mazumder P 2015 *IEEE Trans. Neur. Net. Lear. Syst.* **26** 1202
- [12] Zhou J, Huang D 2012 *Chin. Phys. B* **21** 048401
- [13] Liu H J, Li Z W, Bu K, Sun Z L, Nie H S 2014 *Chin. Phys. B* **23** 048401
- [14] Min G Q, Wang L D, Duan S K 2015 *Acta Phys. Sin.* **64** 210507 (in Chinese) [闵国旗, 王丽丹, 段书凯 2015 物理学报 **64** 210507]
- [15] Yuan F, Wang G Y, Wang X Y 2015 *Chin. Phys. B* **24** 060506
- [16] Chang T, Jo S H, Kim K H, Sheridan P, Gaba S, Lu W 2011 *Appl. Phys. A* **102** 857
- [17] Chen L, Li C D, Huang T W, Chen Y R, Wen S P, Qi J T 2013 *Phys. Lett. A* **377** 3260
- [18] Chen L, Li C D, Huang T W, Ahmad H G, Chen Y R 2014 *Phys. Lett. A* **378** 2924
- [19] Chen L, Li C D, Huang T W, Hu X F, Chen Y R 2016 *Neurocomputing* **171** 1637
- [20] Meng F Y, Duan S K, Wang L D, Hu X F, Dong Z K 2015 *Acta Phys. Sin.* **64** 148501 (in Chinese) [孟凡一, 段书凯, 王丽丹, 胡小方, 董哲康 2015 物理学报 **64** 148501]
- [21] Strukov D B, Snider G S, Stewart D R, Williams R S 2008 *Nature* **453** 80
- [22] Biolek Z, Biolek D, Biolkova V 2009 *Radioengineering* **18** 210
- [23] Kvatinisky S, Friedman E G, Kolodny A, Weiser U C 2013 *IEEE Trans. Circ. Syst. I-Regul. Pap.* **60** 211
- [24] Ascoli A, Corinto F, Tetzlaff R 2016 *Int. J. Circ. Theo. Appl.* **44** 60
- [25] Corinto F, Ascoli A 2012 *IEEE Trans. Circ. Syst. I-Regul. Pap.* **59** 2713
- [26] Joglekar Y N, Wolf S J 2009 *Eur. J. Phys.* **30** 661
- [27] Prodromakis T, Peh B P, Papavassiliou C, Toumazou C 2011 *IEEE Trans. Electron Dev.* **58** 3099
- [28] Takahashi Y, Sekine T, Yokoyama M 2015 *IEICE Electron. Express* **12** 1
- [29] Mu X M, Yu J T, Wang S N 2015 *Int. J. Numer. Model.* **28** 96
- [30] Yu J T, Mu X M, Xi X M, Wang S N 2013 *Radioengineering* **22** 969

Modification of memristor model with synaptic characteristics and mechanism analysis of the model's learning-experience behavior

Shao Nan^{1)†} Zhang Sheng-Bing¹⁾ Shao Shu-Yuan²⁾

1) (School of Computer Science and Engineering, Northwestern Polytechnical University, Xi'an 710072, China)

2) (School of Electronics and Information, Northwestern Polytechnical University, Xi'an 710072, China)

(Received 19 January 2016; revised manuscript received 18 March 2016)

Abstract

Many memristors fabricated by different materials share the characteristics which are similar to the memory and learning functions of synapse in biological systems. These characteristics include memorizing and forgetting function and learning-experience behavior. A memristor model was proposed in the published paper [Chen L, Li C D, Huang T W, Chen Y R, Wen S P, Qi J T 2013 *Phys. Lett. A* **377** 3260] to describe the memorizing and forgetting function of this kind of memristor. This model includes three state variables w , τ and ε . The change of w describes the variation of the conductance of the memristor, a function $f_E(\cdot)$ is used to the input voltage's influence on the change of w , and τ and ε are used to describe the its forgetting effect. The simulation analyses of this model in the published papers [Chen L, Li C D, Huang T W, Hu X F, Chen Y R 2016 *Neurocomputing* **171** 1637] and [Meng F Y, Duan S K, Wang L D, Hu X F, Dong Z K 2015 *Acta Phys. Sin.* **64** 148501] showed that this model can also describe the learning-experience behavior. This model is further studied in this paper to show its detailed characteristics. The analyses of the state equations of the original model show that these state equations cannot restrict the state variables in their permissible interval because the window function is not appropriately used in all the state equations, and the original window function cannot force the state equation to be identical to zero either when corresponding state variable reaches its bound. An improved window function is introduced and the appropriate utilization of this window function is discussed to deal with this problem. The upper bound of τ is defined in the modified model to describe the saturation of τ that has been observed in the experimental studies of this kind of memristor. The behaviors of the modified state equations are different from those of the original ones only when the state variables reach their bounds, and this modified model has the same ability to describe the memristor's memorizing and forgetting function and learning-experience behavior as original one. The behaviors of the model when the input voltage is not negative are discussed based on the state equations and their analytical solution when the input is the repeated voltage pulses, and the results of the discussion are used to explain how a model designed according to the memorizing and forgetting function can also describe the learning-experience behavior. The analysis shows that the increased rising speed of the state variable w in the stimulating process is caused by increasing the values of τ and ε , and the learning-experience behavior described by this model would also be influenced by the value of τ : a smaller initial value of state variable τ in the learning-experience experiment would lead to a more obvious learning-experience behavior. The analytical results are also used to design an estimation method based on the learning-experience experiment to estimate the parameters and function in the state equation. The further discussion shows that this proposed estimation method can also be used to verify the reasonability of the assumption used in the state equations that the derivatives of τ and ε are proportional to $f_E(V)$.

Keywords: memristor, memorizing and forgetting function, learning-experience behavior, model parameter estimation

PACS: 85.35.-p, 73.43.Cd, 87.19.lv

DOI: 10.7498/aps.65.128503

† Corresponding author. E-mail: shao@mail.nwpu.edu.cn