



基于忆阻器的 RBM 及其在车牌图像处理中的应用

徐聪, 王春华*, 孙晶茹

湖南大学信息科学与工程学院, 长沙 410082

* 通信作者. E-mail: wch1227164@hnu.edu.cn

收稿日期: 2022-01-17; 修回日期: 2022-03-22; 接受日期: 2022-04-18; 网络出版日期: 2022-12-16

国家自然科学基金 (批准号: 91964108, 61971185, 62171182) 和湖南省自然科学基金 (批准号: 2020JJ4218) 资助项目

摘要 车牌识别在智能交通和公共安全领域具有十分重要的意义. 由于拍摄环境、拍摄设备等因素的影响, 获取的车牌图像分辨率较低、图像模糊, 影响了车牌识别的准确率. 图像超分辨率和图像去噪技术可以改善图像质量, 提高车牌图像的识别率. 本文提出了基于忆阻器的受限玻尔兹曼机 (restricted Boltzmann machine, RBM) 的全电路设计, 并将其应用于车牌图像处理. 忆阻 RBM 电路主要包含 3 个模块: 隐单元生成模块、可见单元重构模块和隐单元再生模块. 忆阻电路采用片上训练方式, 提高了网络的训练效率, 实现了实时的在线学习. 最后, 将基于忆阻器的 RBM 应用于车牌图像超分辨率和图像去噪, 通过计算图像的结构相似性 (structural similarity, SSIM) 和峰值信噪比 (peak signal to noise ratio, PSNR), 并与传统的图像处理方法进行对比分析, 验证了所提出的基于忆阻器的 RBM 在图像处理中的有效性和优越性.

关键词 忆阻器, 神经网络, 车牌图像处理, 受限玻尔兹曼机, 电路设计

1 引言

随着机动车的广泛使用, 交通违章和交通肇事逃逸案件也逐渐增多. 因此, 车牌识别在智能交通和公共安全领域具有十分重要的意义. 然而, 由于拍摄环境、成像设备等因素的影响, 获取的车牌图像质量通常较低, 如图像模糊化、图像分辨率较低等, 严重影响了车牌识别的准确性. 因此, 提高车牌图像质量是车牌识别的关键. 要获得高质量的图像, 最直接的方法是改进拍摄设备, 但投资成本较高. 因此, 高效的图像处理技术研究变得越来越重要. 目前针对图像处理技术的研究主要集中于算法的优化, 然而由于传统的冯·诺依曼 (von Neumann) 结构计算机存在计算与存储分离的问题, 使得运算速度慢, 无法应对大规模数据的处理要求^[1], 这也限制了图像处理技术的发展. 因此, 研究具备高效图像处

引用格式: 徐聪, 王春华, 孙晶茹. 基于忆阻器的 RBM 及其在车牌图像处理中的应用. 中国科学: 信息科学, 2023, 53: 164–177, doi: 10.1360/SSI-2022-0027

Xu C, Wang C H, Sun J R. A memristor-based RBM circuit implementation and application in license plate image processing (in Chinese). Sci Sin Inform, 2023, 53: 164–177, doi: 10.1360/SSI-2022-0027

理能力的硬件系统势在必行. 近年来, 许多具备并行计算特性的新型纳米器件被提出^[2~4]. 其中, 忆阻器因其与生物突触的高相似性而拥有巨大的应用前景, 给图像处理硬件系统的实现带来了新的机遇. 忆阻器作为第 4 种基本电路元件, 首次由蔡少棠^[5]于 1971 年提出. 直到 2008 年, HP 实验室制作出第一种实物忆阻器^[6]. 此后, 越来越多的忆阻器模型被提出用来构建神经突触电路. 忆阻器所表现出的低功耗、纳米尺寸、可编程性、非易失性和记忆性等特性, 在逻辑运算^[7~10]、混沌系统^[11~13]、神经网络^[14~18]、图像处理^[19,20]等领域得到了广泛的应用.

为了实现大规模图像的并行处理, 基于忆阻器的图像处理技术引来了众多学者的研究. 具有联想记忆功能的 Hopfield 神经网络 (Hopfield neural network, HNN) 在图像处理领域有着广泛的应用. 因此, Hong 等^[21]和 Zhou 等^[22]提出了基于忆阻器的 HNN 电路并应用于图像恢复等问题. 双向联想记忆网络 (bidirectional associative memory, BAM) 是一种双层双向网络, 可以实现双向异联想. Yang 等^[23]提出了一种用于图像联想记忆和图像填充的忆阻 BAM 电路. 另外, 学者们证实了忆阻器与一些仿生算法也具有相似性^[24]. 利用蚁群优化算法 (ant colony optimization, ACO) 与忆阻器件之间的映射关系, Pajouhi 等^[25]和 Yu 等^[26]提出了基于 ACO 的忆阻器交叉阵列来实现图像边缘检测, 仿真结果表明, 这些图像处理方法具有高效和低功耗的优势. Karamani 等^[27]结合忆阻器和元胞自动机的结构特点, 提出了一种用于图像边缘检测的忆阻学习元胞自动机. Zhu 等^[28]利用忆阻器的阻值变化特性对图像进行处理, 介绍了一种基于忆阻器的图像增强方案. 针对图像分割任务, Zhang 等^[29]采用软硬件结合的计算方式, 提出了基于忆阻器的深度卷积神经网络, 为实时、低功耗的图像处理实现提供了新的途径.

图像超分辨率和图像去噪是图像处理技术的两个重要分支. 高质量的图像一般具有高分辨率和低噪声的特点. 然而, 由于拍摄设备的硬件限制、信息传输等因素的影响, 获得的图像往往具有低分辨率或高噪声等缺陷. 图像超分辨率和图像去噪技术可以提高图像质量, 有助于图像的进一步分析和处理. 因此, 图像超分辨率和图像去噪技术因其学术研究意义和实际应用价值, 在交通安全、医学图像、卫星图像、军事应用等领域备受关注. 利用图像超分辨率技术, 可以通过低分辨率 (low resolution, LR) 图像恢复出高分辨率 (high resolution, HR) 图像, 从而克服了成像设备固有的分辨率限制. 现有的超分辨率方法主要分为 3 种: 基于重建的方法、基于插值的方法和基于学习的方法. 此外, 图像在传输过程中容易受到各种噪声的干扰, 如高斯 (Gauss) 噪声、泊松 (Poisson) 噪声、椒盐噪声等. 图像去噪是指减少图像噪声的过程. 目前主要有三类图像去噪方法: 基于滤波器的方法^[30]、基于稀疏字典的方法^[31]、基于深度学习的方法^[32]. 近年来, 随着人工智能的发展, 神经网络在图像超分辨率^[33,34]和图像去噪^[35,36]中也得到了广泛的应用, 在图像质量改善方面具备显著优势.

上述图像超分辨率和图像去噪的方法重点在软件算法或网络结构的优化上, 但随着图像规模的不断增加, 存算分离的冯·诺依曼结构计算机很难应对日益增长的数据处理要求. 因此, 研究可执行图像超分辨率和图像去噪任务的硬件系统势在必行. 本文结合忆阻器的特性和神经网络的发展, 提出了基于忆阻器的受限玻尔兹曼机 (restricted Boltzmann machine, RBM) 网络的全电路设计, 完成了算法的硬件实现. 并将其应用于车牌图像超分辨率和图像去噪, 有效地提升了车牌图像质量. 本文的主要贡献如下:

(1) 提出了采用片上训练方式的忆阻 RBM 全电路设计. 该电路主要由 3 个模块组成: 隐单元生成模块、可见单元重构模块和隐单元再生模块. 全电路设计将训练算法从软件转移到硬件, 实现了实时的在线学习.

(2) 基于忆阻器的 RBM 电路应用于车牌图像超分辨率和图像去噪. 仿真结果显示, 车牌图像质量得到了明显改善, 并使用图像质量评价标准结构相似性 (structural similarity, SSIM) 和峰值信噪比 (peak

signal to noise ratio, PSNR) 进行分析, 证实了本文提出的基于忆阻器的 RBM 电路在图像处理中的有效性.

(3) 通过与传统图像处理方法对比, 本文提出的基于忆阻器的 RBM 电路在图像处理应用中有更好的性能. 另外, 与其他基于忆阻器的神经网络相比, 本文提出的忆阻神经网络具有实际应用价值.

本文第 2 节阐述了忆阻器和 RBM 的理论基础; 第 3 节详细介绍了基于忆阻器的全电路设计和仿真; 第 4 节提出了基于忆阻器的 RBM 电路在车牌图像处理中的应用; 第 5 节与其他图像处理方法进行了对比分析. 第 6 节给出了结论.

2 理论基础

2.1 忆阻器模型

作为第 4 种基本的电子元件, 忆阻器是神经网络硬件实现中模拟突触的最佳选择. 对于具有阈值的忆阻器模型. 当输入电压在阈值范围内时, 忆阻器的阻值大小保持不变, 否则当输入正电压时阻值会减小; 输入负电压时阻值增大. 本文采用的压控阈值忆阻器^[37]的数学表达式如下:

$$R(t) = R_{\text{on}} \frac{\omega(t)}{D} + R_{\text{off}} \left(1 - \frac{\omega(t)}{D} \right), \quad (1)$$

$$\frac{d\omega(t)}{dt} = \begin{cases} \mu_v \frac{R_{\text{on}}}{D} \frac{i(t)}{i_{\text{on}}} f(\omega(t)), & v(t) < V_{T-} < 0, \\ 0, & V_{T-} \leq v(t) \leq V_{T+}, \\ \mu_v \frac{R_{\text{on}}}{D} \frac{i_{\text{off}}}{i(t) - i_0} f(\omega(t)), & v(t) > V_{T+} > 0. \end{cases} \quad (2)$$

其中 i_{off} , i_0 和 i_{on} 是常数, μ_v 表示平均离子迁移率, R_{on} 和 R_{off} 表示最小忆阻值和最大忆阻值, 而 V_{T-} 和 V_{T+} 分别表示负阈值电压和正阈值电压, 窗函数可表示为

$$f(\omega(t)) = 1 - \left(\frac{2\omega(t)}{D} - 1 \right)^{2p}. \quad (3)$$

在仿真实验中, 忆阻的参数设置如下: $R_{\text{on}} = 100 \Omega$, $R_{\text{off}} = 16 \text{ k}\Omega$, $\mu_v = 1 \times 10^{-10} \text{ m}^2 \cdot \text{s}^{-1} \cdot \Omega^{-1}$, $i_{\text{on}} = 1 \text{ A}$, $i_{\text{off}} = 1 \times 10^{-5} \text{ A}$, $i_0 = 1 \times 10^{-3} \text{ A}$, $V_{T+} = 1 \text{ V}$, $V_{T-} = -1 \text{ V}$, $p = 10$. 仿真结果如图 1 所示, 当输入的负电压超过负阈值时, 忆阻阻值增大; 当输入正电压超过正阈值时, 忆阻阻值减小; 当输入电压小于阈值时, 忆阻阻值保持不变.

2.2 受限玻尔兹曼机

受限玻尔兹曼机 (RBM) 是一个具有两层结构的随机神经网络, 如图 2(a) 所示. 训练数据的维数对应于可见单元数, 隐层单元数根据实际情况给定. 网络的两层之间的神经元之间存在完全连接, 同一层内的神经元之间没有连接.

对比散度 (contrastive divergence, CD) 算法是 Hinton^[38] 于 2002 年提出的一种有效的 RBM 训练算法. CD 算法提高了 RBM 的学习效率, 使 RBM 得到了广泛的应用. 如图 2(b) 所示, CD 算法的训练过程可分为 4 个步骤: 隐单元生成、可见单元重构、隐单元再生和权重更新. CD 算法的详细步骤如算法 1 和 2 所示.




图 1 (网络版彩图) 忆阻模型的 PSPICE 仿真结果. (a) 输入电压; (b) 阻值随时间的变化

Figure 1 (Color online) PSPICE simulation result of memristor model. (a) Input voltage; (b) time variation of memristance




图 2 (a) RBM 结构图; (b) CD 算法的训练过程

Figure 2 (a) Structure of RBM; (b) process of CD algorithm

3 基于忆阻器的受限玻尔兹曼机全电路设计及仿真

3.1 基于忆阻器的神经元

忆阻器具有与生物突触相同的调节机制, 当输入的电压 V_i ($i = 1, 2, \dots, n$) 超过忆阻器的阈值电压时, 忆阻阻值将发生变化, 否则忆阻阻值保持不变. 本文所提出的基于忆阻器的神经元结构如图 3 所示. 电路中第 1 行的第 2 个运算放大器的输出 V_o 可表示为

$$V_o = R_f \cdot I = R_f \left(\frac{1}{M_{11}} V_1 + \dots + \frac{1}{M_{n1}} V_n + \frac{1}{R_b} V_b \right), \quad (4)$$

其中 I 表示电流值, M_{i1} ($i = 1, 2, \dots, n$) 表示忆阻的阻值, R_b , R_f 和 R 表示电阻. 神经元的输出 V_o 表示如下:

$$V_o = \begin{cases} V_-, & V_o < V_-, \\ R_f \sum_{i=1}^n \frac{1}{M_{i1}} V_i + R_f \frac{V_b}{R_b}, & V_- \leq V_o \leq V_+, \\ V_+, & V_o > V_+. \end{cases} \quad (5)$$

算法 1 CD algorithm

Input: training data x ; the maximum training period T ; learning rate β ;
Output: updated weight W' ; updated bias a' of visible layer; updated bias b' of hidden layer;

- 1: The initial value of the visible layer is x . W , bias a and b are random numbers;
- 2: **for** $t = 1$ to T **do**
- 3: **for** $j = 1$ to m (all hidden units) **do**
- 4: $p(h_j = 1 | v) = \text{sigmoid}(b_j + \sum W_{ij}v_i)$;
- 5: Sample $h_j \in \{0, 1\}$ from $p(h_j = 1 | v)$;
- 6: **end for**
- 7: **for** $i = 1$ to n (all visible units) **do**
- 8: $p(v'_i = 1 | h) = \text{sigmoid}(a_i + \sum W_{ji}h_j)$;
- 9: Sample $v'_i \in \{0, 1\}$ from $p(v'_i = 1 | h)$;
- 10: **end for**
- 11: **for** $j = 1$ to m (all hidden units) **do**
- 12: $p(h'_j = 1 | v') = \text{sigmoid}(b_j + \sum W_{ij}v'_i)$;
- 13: **end for**
- 14: $W' \leftarrow W + \beta(p(h = 1 | v)v - p(h' = 1 | v')v')$;
- 15: $a' \leftarrow a + \beta(v - v')$;
- 16: $b' \leftarrow b + \beta(p(h = 1 | v) - p(h' = 1 | v'))$;
- 17: **end for**

算法 2 Sample function in CD algorithm

Input: $p(h = 1 | v)$;
Output: h ;

- 1: **for** $j = 1$ to m **do**
- 2: random number $r_j \in (0, 1)$;
- 3: **if** $r_j < p_j$ **then**
- 4: $h_j = 1$;
- 5: **else**
- 6: $h_j = 0$;
- 7: **end if**
- 8: **end for**

3.2 基于忆阻器的受限玻尔兹曼机

基于忆阻交叉阵列结构, RBM 的电路结构如图 4 所示. 该电路主要包括 3 个模块: 隐单元生成模块、可见单元重构模块和隐单元再生模块. 电路中, M_{ij_l} ($i = 1, 2, \dots, n; j = 1, 2, \dots, m; l = 1, 2, 3$) 表示忆阻, 阻值会随着施加在两端的电压发生改变; R_f 和 R 表示电阻; v_i 表示输入电压; VF_{ij} 表示反馈电压; V_{ref} 表示比较器的阈值; p_{h_j} 和 h_j 表示隐单元生成模块中的输出电压; p_{v_i} 和 v'_i 表示可见单元重构模块中的输出电压; p'_{h_j} 表示隐单元再生模块中的输出电压. 另外, 电路的输入由开关 SW 控制, 开关 SW 由两个传输门组成. V_c 是开关 SW 的控制信号, 当控制信号 V_c 处于高电平时, 电压 v_i 作为电路的输入; 否则, 反馈电压 VF_{ij} 作为电路的输入用来进行权值调整. 隐层中的权值是可见层权值的转置. 下面详细描述 CD 算法在忆阻电路中的具体实现步骤.

步骤 1. 当控制信号 V_c 处于高电平时, 电压 v_i ($i = 1, 2, \dots, n$) 作为忆阻电路的输入. 此时, 输入




图 3 基于忆阻器的神经元
Figure 3 Memristor-based neuron




图 4 (网络版彩图) 基于 CD 算法的忆阻 RBM 电路
Figure 4 (Color online) Memristive circuit of RBM based on CD algorithm

小于忆阻器的阈值, 因此该阶段的忆阻保持不变. 隐层神经元的输出 p_{h_j} ($j = 1, 2, \dots, m$) 可以表示为

$$p_{h_j} = \sum \frac{R_f}{M_{ij-1}} v_i, \tag{6}$$

其中 v_i 表示网络的输入; $\frac{R_f}{M_{ij-1}}$ 表示网络的权重 W . 将式 (6) 与 CD 算法 (见算法 1) 中隐单元的生成概率 p 的计算公式对比可知, 电路中的输出电压 p_{h_j} 对应为算法中隐单元的生成概率. 接着通过采样函数获得隐层的输出 h_j . 在电路中, 采用比较器实现采样函数, 比较器的 V_H 和 V_L 分别对应于 ‘1’ 和 ‘0’. 如果输出 p_{h_j} 超过比较器的阈值 (V_{ref}), 则 h_j 等于 V_H , 否则 h_j 等于 V_L . 表达式如下:

$$h_j = \begin{cases} V_H, & p_{h_j} > V_{ref}, \\ V_L, & p_{h_j} < V_{ref}. \end{cases} \tag{7}$$

步骤 2. 在可见单元重构模块中, 隐层的权值是可见层权值的转置. 重构模块中各神经元的输出 p_{v_i}



图 5 训练样本

Figure 5 Digit images for training

和 v'_i 计算如下:

$$p_{v_i} = \sum \frac{R_f}{M_{ij_2}} h_j, \quad (8)$$

$$v'_i = \begin{cases} V_H, & p_{v_i} > V_{\text{ref}}, \\ V_L, & p_{v_i} < V_{\text{ref}}. \end{cases} \quad (9)$$

步骤 3. 电路中隐单元再生模块用于计算隐单元的输出, 权值大小与第一个模块相同. 将前一个模块的输出 v'_i 作为该模块的输入值, 然后得到输出 p'_{h_j} , 计算公式如下:

$$p'_{h_j} = \sum \frac{R_f}{M_{ij_3}} v'_i. \quad (10)$$

步骤 4. 控制电压 V_c 在步骤 1~3 中都处于高电平, 在此步骤中 V_c 处于低电平, 反馈电压对电路的权重进行调节. 忆阻器的阻值根据相应的调节电压 VF_{ij} 进行更新. 调节电压计算方式如下:

$$VF_{ij} = v_i p_{h_j} - v'_i p'_{h_j}. \quad (11)$$

3.3 仿真结果及分析

PSPICE 仿真验证了基于忆阻器的 RBM 电路训练过程的有效性. 如图 5 所示, 采用数字图像作为训练样本, 其大小为 5×5 . 首先将像素值映射为电压值, 表示为 $v = [v_1, v_2, \dots, v_{25}]$, 其中黑色和白色像素分别对应于 -1 V 和 1 V.

基于 CD 算法的无监督训练机制中, 网络的重构误差通常被用作评估 RBM 性能的标准. 其中重构误差是指原始输入数据与训练后的重构输出之间的差值. 以数字图像“3”为例, 初始输入电压为 $v = [-1, -1, -1, -1, 1, 1, 1, 1, 1, -1, 1, -1, 1, 1, 1, 1, 1, -1, -1, -1, -1, -1, -1]$ V, 可见单元的重构输出如图 6 所示. 以输出 v'_7 的结果为例, 在训练阶段 (0~48 ms) 输出为 -1 V; 然后在 48 ms 时发生变化; 48 ms 后输出值保持稳定, 并且与原始输入 v_7 相等. 对于输出 v'_{21} , 可以看到输出值为 -1 V, 与原始输入 v_{21} 相等. 因此它对应的权值不需要调整并保持稳定. 104 ms 后, 可见层单元的重构输出为 $v' = [-1, -1, -1, -1, 1, 1, 1, 1, 1, -1, 1, -1, 1, 1, 1, 1, 1, -1, -1, -1, -1, -1, -1]$ V, 网络输出保持稳定并等于原始输入, 训练完成. 由以上分析结果得出, 采用 CD 算法的忆阻 RBM 电路的训练是有效的.

为了更好地观察忆阻在训练过程中的变化, 忆阻 M_{71_2} 的更新过程如图 7 所示. 如图 7(a) 所示, 可见单元重构模块中的输出 v'_7 在 48 ms 后保持稳定, 并等于原始输入信号 v_7 . 因此, 忆阻 M_{71_2} 仅在 0~48 ms 内进行调节. 训练周期由两个阶段组成, 即前馈计算和反馈调节. 信号 V_c 控制两个阶段的有序进行. 如图 7(b)~(d) 所示, 当 V_c 处于高电平时, 电压 v_7 传输至电路中, 此时的电压值低于忆

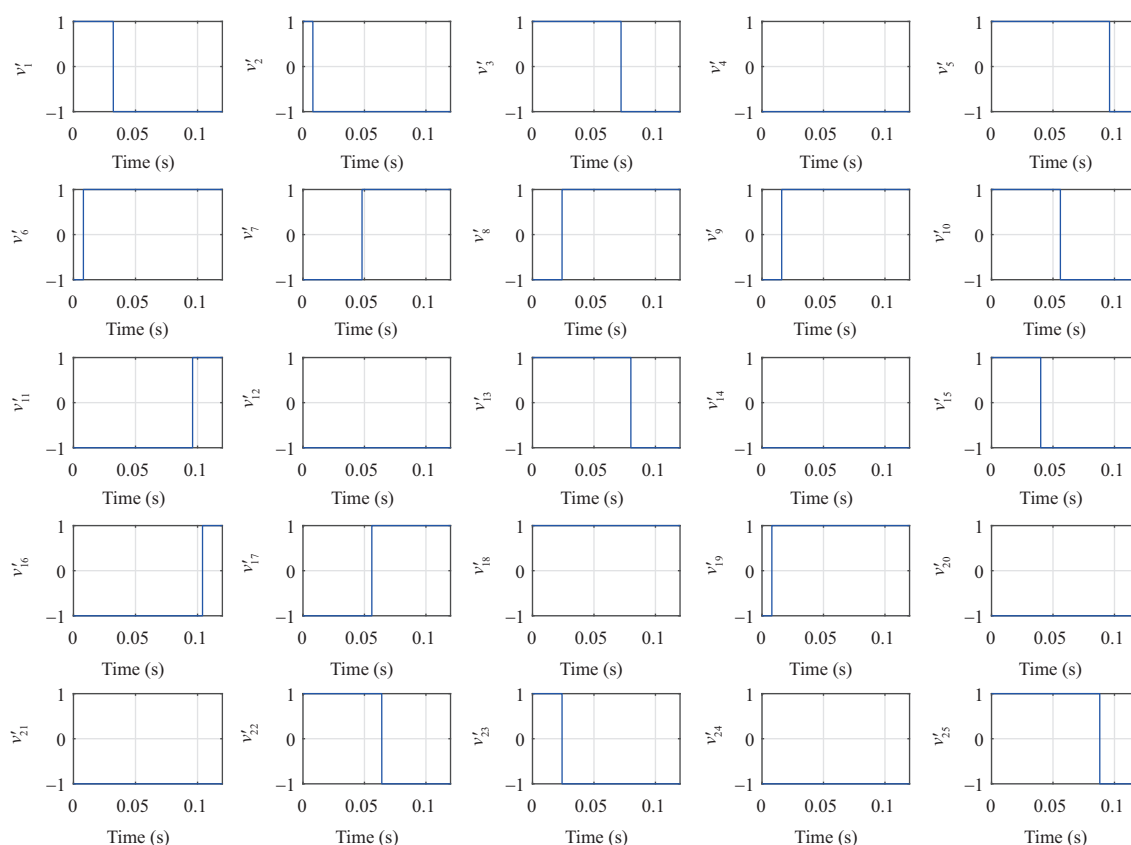


图 6 (网络版彩图) 训练过程中可见单元重构模块的输出

Figure 6 (Color online) The outputs of the reconstructed visible layer during the training process

阻器的阈值, 忆阻保持不变, 进行前馈计算阶段. 当 V_c 处于低电平时, 电路进入反馈调节阶段. 正向调节电压 V_{F71} 反馈传输至电路进行权值更新, 忆阻阻值不断减小. 在 48 ms 后, 调节电压逐渐减小至等于忆阻的阈值, 忆阻阻值保持稳定, 训练完成.

4 车牌图像处理的应用

在信息时代, 图像是人类获取信息、表达信息、传递信息的最重要方式. 因此, 图像处理正成为社会生活中不可缺少的一部分. 车牌是车辆识别的重要线索, 车牌图像的质量直接影响其实际应用. 高质量的成像设备能有效改善图像质量, 但成本高. 所以图像处理技术的研究备受关注, 也被广泛应用于智能交通领域. 图像超分辨率和图像去噪方法可以有效改善车牌图像质量, 提高车牌识别率. 本节将提出的基于忆阻器的 RBM 电路应用于车牌图像超分辨率和图像去噪. 仿真结果验证了忆阻 RBM 网络在车牌图像处理中的有效性和优越性.

4.1 车牌图像超分辨率

图像超分辨率是利用低分辨率 (LR) 图像生成高分辨率 (HR) 图像的方法. 图像超分辨率方法主要分为两个阶段: 字典训练和图像重构. 而字典训练是图像超分辨率技术的一个关键过程. 本文采用基于忆阻器的 RBM 电路进行字典训练. 首先将 LR 图像块 y 和 HR 图像块 x 的特征值设置为网络




图 7 (网络版彩图) 训练过程的仿真结果

Figure 7 (Color online) Simulation results of the training process. (a) Output v_7' of the reconstructed visible layer; (b) control signal V_c ; (c) input voltage V_{in} of memristor $M_{71,2}$, which is the alternation between input voltage v_7 and adjusting voltage V_{F71} ; (d) variation of $M_{71,2}$

的输入, 隐单元对应稀疏系数、权重 W 对应于字典, 其中连接 x 和隐层单元的权值对应于高分辨率字典块 D_h ; 连接 y 和隐层单元的权值对应于低分辨率字典 D_l . 基于忆阻 RBM 的字典训练的车牌图像超分辨率的详细过程为: 首先, 对 HR 图像的训练样本进行下采样, 得到相应的 LR 图像. 再通过图像分割方法将图像分割为大小为 5×5 的 HR 和 LR 图像块; 然后将这些图像块进行归一化处理, 即将范围为 $0 \sim 255$ 的像素值归一化为 $0 \sim 1$ 之间的数值, 并转为对应大小的电压值; 接着将电压向量输入至忆阻 RBM 电路. 通过 CD 训练算法进行训练, 训练过程如第 3.2 小节所述. 训练好的权重分别对应于 HR 和 LR 字典块; 最后, 利用忆阻电路训练得到的字典块 D_l 和 D_h 将 LR 图像生成 HR 图像.

车牌超分辨率的仿真结果如图 8 所示. 图 8(a), (f), (k) 表示 LR 图像. 采用传统双三次插值方法重构的 HR 图像如图 8(b), (g), (l) 所示, 采用 RAISA 方法^[39] 重构的 HR 图像如图 8(c), (h), (m) 所示, 采用耦合字典训练方法^[40] 重构的 HR 图像如图 8(d), (i), (n) 所示, 图 8(e), (j), (o) 是采用本文所提出的方法重构的 HR 图像. 从人眼视觉效果来看, 本文提出的方法重构出的 HR 图像中汉字更加清晰. 此外, 重构图像的 PSNR 和 SSIM 值如表 1 所示, 较高的 PSNR 和 SSIM 表明获得的图像质量较好. 因此, 实验对比结果表明, 本文所提出的图像超分辨率方法比其他几种方法的效果更好.

4.2 车牌图像去噪

图像去噪是在不丢失图像细节的情况下去除噪声的过程, 有助于进一步的图像分析、处理和应用. 高噪声的车牌图像会影响其在交通安全中的应用. 因此, 车牌图像去噪具有很高的实用价值. 在车牌图像去噪的应用中, 基于忆阻器的 RBM 电路的可见单元数量取决于车牌图像的大小, 通过重构图像与原始图像的差值计算重构误差并调节权重. 训练之前, 利用高斯噪声生成车牌图像对应的噪声图像样本, 并将所有图像转换为二值图像进行预处理. 基本的训练步骤如下: 首先, 二值化后的噪声图像和




图 8 低分辨率图像以及重构的高分辨率图像. (a), (f), (k) LR 图像; (b), (g), (l) 基于双三次插值法的 HR 图像; (c), (h), (m) 基于 RAISR 方法的 HR 图像; (d), (i), (n) 基于耦合字典训练方法的 HR 图像; (e), (j), (o) 基于本文方法的 HR 图像

Figure 8 LR images and reconstructed HR images. (a), (f), (k) LR images; (b), (g), (l) reconstructed HR images by the classical bicubic interpolation method; (c), (h), (m) reconstructed HR images by RAISR method; (d), (i), (n) reconstructed HR images by the coupled dictionary training method; (e), (j), (o) reconstructed HR images by the proposed method

表 1 重构图像的 PSNR 和 SSIM
Table 1 PSNR and SSIM of the reconstructed images

Methods	PSNR			SSIM		
	Image 1	Image 2	Image 3	Image 1	Image 2	Image 3
Proposed method	26.4730	26.5015	26.4129	0.9493	0.9428	0.9127
Bicubic interpolation method	24.8076	24.4238	25.7343	0.8179	0.8319	0.8406
RAISR method ^[39]	22.4305	23.2031	24.6887	0.7537	0.8352	0.8005
Coupled dictionary training method ^[40]	25.8809	25.6299	25.9723	0.8487	0.8552	0.8306

原始图像的像素都归一化为 $[-1, 1]$, 并转换为电压矢量 V ; 接着, 将噪声图像对应的电压矢量作为隐单元模块的输入, 并利用式 (6)~(10) 获得可见单元重构模块和隐单元再生模块的输出; 然后计算重构单元的输出与原始图像的差值得到反馈电压 V_F . 最后, 忆阻器的阻值根据对应反馈电压进行调节. 经过前馈计算和反馈调节的多次迭代, 可成功获得去噪图像. 图像去噪仿真结果如图 9 所示. 图 9(a), (f), (k) 是带有高斯噪声的图像; 图 9(b), (g), (l) 是采用传统的基于滤波器的方法获得的去噪图像; 图 9(c), (h), (m) 是采用稀疏字典方法^[41] 获得的去噪图像; 图 9(d), (i), (n) 是采用深度学习方法^[42] 获得的去噪图像; 图 9(e), (j), (o) 是通过本文提出的图像去噪方法获得的图像. 从图中对比可以看出, 本文提出的去噪方法获得的的车牌图像汉字更清晰. 所以, 基于忆阻器的 RBM 的图像去噪方法具有更好的效果.

5 比较分析

本文提出的基于忆阻器的 RBM 网络全电路设计具有以下优势. (1) 采用忆阻器实现神经网络突触: 基于电阻和晶体管搭建的人工神经网络电路, 突触权值不容易改变, 无法模拟突触的可塑性. 忆阻器具有非易失性, 而且其阻值能随着电压变化而变化, 是硬件实现突触的最佳方式. 另外, 忆阻具有功耗低、集成度高等特性, 使得基于忆阻器的 RBM 网络电路比用电阻和晶体管搭建的网络电路性能更




图 9 带噪声图像与去噪图像。(a), (f), (k) 带噪声图像; (b), (g), (l) 基于滤波器方法的去噪图像; (c), (h), (m) 基于稀疏字典方法的去噪图像; (d), (i), (n) 基于深度学习的去噪图像; (e), (j), (o) 基于本文方法的去噪图像

Figure 9 Noise image and reconstructed denoising images. (a), (f), (k) Images with noise; (b), (g), (l) denoising images by the filter-based method; (c), (h), (m) denoising images by the sparse dictionary-based method; (d), (i), (n) denoising images by the deep learning-based method; (e), (j), (o) denoising images by the proposed method

表 2 与其他基于忆阻的图像处理方法的对比

Table 2 Comparison with other memristor-based image processing methods

	Proposed method	The work in [21]	The work in [23]
Training mode	On-chip	On-chip	Off-chip
Image processing task	Image SR and image denoising	Image restoration	Image fill-in
Image processing object	License plate images	Simple digital images	Simple letter images
Comparison experiment	Yes	No	No

加优越。(2) RBM 网络硬件实现采用全电路设计: 神经网络的硬件实现中, 离线训练方式需要利用计算机对神经网络进行辅助训练得到权重更新值, 再对忆阻阵列的阻值进行调整, 这种频繁的软硬件数据交互不能提供实时的权重更新. 本文提出的基于忆阻器的 RBM 网络全电路设计, 采用在线训练方式, 将训练算法从软件转移到硬件, 可以实时地更新忆阻的阻值, 更具有实用性. 基于忆阻器的 RBM 与其他基于忆阻器的神经网络的比较结果如表 2 所示. Yang 等^[23]提出的忆阻电阻采用片外训练方式, 即通过软件计算权重, 然后映射到电路中. 片外训练模式不能提供实时的权重更新. Hong 等^[21]和 Yang 等^[23]提出的图像处理方法都仅在简单的字母或数字图像上进行测试, 没有考虑在真实图像中的应用. 此外, 这些方法没有与其他图像处理方法进行对比分析. 本文提出的基于忆阻器的 RBM 采用片上训练模式, 能够实现实时的在线学习. 同时该电路可以处理两种图像处理任务: 图像超分辨率和图像去噪, 具有普遍实用性. 另外, 通过对真实车牌图像的实验仿真, 也证明了该方法的有效性. 此外, 仿真实验中也与其他传统的图像处理方法进行了对比分析, 充分说明了本文提出的基于忆阻器的 RBM 电路在图像处理中的优越性.

6 结论

本文提出了一种采用片上训练方式的 RBM 忆阻电路, 并将其应用于车牌图像处理中. 基于忆阻器的 RBM 全电路设计主要为 3 个模块: 隐单元生成模块、可见单元重构模块和隐单元再生模块. PSPICE 仿真验证了基于 CD 算法的 RBM 训练的有效性. 考虑到车牌在交通安全中的重要性, 将

提出的忆阻 RBM 电路应用于车牌图像处理中,有助于车牌图像的识别或分析.首先,将基于忆阻器的 RBM 电路应用于图像超分辨率,可以从 LR 图像重构 HR 图像.其次,为了证明所提出的记忆 RBM 电路的通用性,又将该电路应用于图像去噪,成功地去除了图像中的噪声.仿真结果表明,所提出的基于忆阻器的 RBM 电路在图像处理中是可行的.此外,与其他传统图像处理方法相比,本文提出的图像处理方法具有更好的效果.车牌图像超分辨率和图像去噪是车牌识别系统中的关键技术问题,可在现实生活中的许多场景中进行应用,比如,高速道路管理、城市道路监控、停车场收费管理、小区物业管理等.因此,本论文提出的基于忆阻的 RBM 网络具有实际应用价值.另外,RBM 网络除了应用于车牌图像处理,还可以用于其他领域,比如,医学或遥感影像图像分类、数字或字符识别.在下一步工作中,我们将进一步研究 RBM 及由它构建的深度学习网络,构建更加有效的大规模忆阻神经网络电路系统,实现多领域应用.

参考文献

- 1 Zidan M A, Strachan J P, Lu W D. The future of electronics based on memristive systems. *Nat Electron*, 2018, 1: 22–29
- 2 Cheng C D, Tiw P J, Cai Y M, et al. In-memory computing with emerging nonvolatile memory devices. *Sci China Inf Sci*, 2021, 64: 221402
- 3 Kim H, Hwang S, Park J, et al. Silicon synaptic transistor for hardware-based spiking neural network and neuromorphic system. *Nanotechnology*, 2017, 28: 405202
- 4 Wang Z R, Joshi S, Savel'ev S E, et al. Memristors with diffusive dynamics as synaptic emulators for neuromorphic computing. *Nat Mater*, 2017, 16: 101–108
- 5 Chua L O. Memristor—the missing circuit element. *IEEE Trans Circuit Theor*, 1971, 18: 507–519
- 6 Strukov D B, Snider G S, Stewart D R, et al. The missing memristor found. *Nature*, 2008, 453: 80–83
- 7 Hong Q H, Shi Z R, Sun J R, et al. Memristive self-learning logic circuit with application to encoder and decoder. *Neural Comput Applic*, 2021, 33: 4901–4913
- 8 Yuan R, Ma M Y, Xu L Y, et al. Efficient 16 Boolean logic and arithmetic based on bipolar oxide memristors. *Sci China Inf Sci*, 2020, 63: 202401
- 9 Wang H P, Lin C C, Wu C C, et al. On synthesizing memristor-based logic circuits with minimal operational pulses. *IEEE Trans VLSI Syst*, 2018, 26: 2842–2852
- 10 Luo L, Dong Z K, Hu X F, et al. Reconfigurable logic circuit design for stateful Boolean logic computing. *Sci China Inf Sci*, 2021, 64: 189401
- 11 Lin H R, Wang C H, Yao W, et al. Chaotic dynamics in a neural network with different types of external stimuli. *Commun Nonlinear Sci Numer Simul*, 2020, 90: 105390
- 12 Xie W L, Wang C H, Lin H R. A fractional-order multistable locally active memristor and its chaotic system with transient transition, state jump. *Nonlinear Dyn*, 2021, 104: 4523–4541
- 13 Lin H R, Wang C H, Hong Q H, et al. A multi-stable memristor and its application in a neural network. *IEEE Trans Circuits Syst II*, 2020, 67: 3472–3476
- 14 Moon J, Wu Y T, Zhu X J, et al. Neural connectivity inference with spike-timing dependent plasticity network. *Sci China Inf Sci*, 2021, 64: 160405
- 15 Xu C, Wang C H, Jiang J G, et al. Memristive circuit implementation of context-dependent emotional learning network and its application in multi-task. *IEEE Trans Comput-Aided Des Integr Circuits Syst*, 2021. doi: 10.1109/TCAD.2021.3116463
- 16 Zhou E R, Fang L, Liu R L, et al. Area-efficient memristor spiking neural networks and supervised learning method. *Sci China Inf Sci*, 2019, 62: 199103
- 17 Xu C, Wang C H, Sun Y C, et al. Memristor-based neural network circuit with weighted sum simultaneous perturbation training and its applications. *Neurocomputing*, 2021, 462: 581–590
- 18 Yang L M, Wang C H. Emotion model of associative memory possessing variable learning rates with time delay. *Neurocomputing*, 2021, 460: 117–125

- 19 Hu X F, Shi W Q, Zhou Y, et al. Quantized and adaptive memristor based CNN (QA-mCNN) for image processing. *Sci China Inf Sci*, 2022, 65: 119104
- 20 Zheng Y W, Hu X F, Zhou Y, et al. Biomimetic adaptive memristive cellular neural network for image enhancement. *Sci Sin Inform*, 2020, 50: 1850–1866 [郑雅文, 胡小方, 周跃, 等. 用于图像增强的仿生自适应忆阻细胞神经网络. *中国科学: 信息科学*, 2020, 50: 1850–1866]
- 21 Hong Q H, Li Y, Wang X P. Memristive continuous Hopfield neural network circuit for image restoration. *Neural Comput Applic*, 2020, 32: 8175–8185
- 22 Zhou Y, Wu H Q, Gao B, et al. Associative memory for image recovery with a high-performance memristor array. *Adv Funct Mater*, 2019, 29: 1900155
- 23 Yang Z J, Wang X P. Memristor-based BAM circuit implementation for image associative memory and filling-in. *Neural Comput Applic*, 2021, 33: 7929–7942
- 24 Pershin Y V, Di Ventra M. Memcomputing implementation of ant colony optimization. *Neural Process Lett*, 2016, 44: 265–277
- 25 Pajouhi Z, Roy K. Image edge detection based on swarm intelligence using memristive networks. *IEEE Trans Comput-Aided Des Integr Circuits Syst*, 2018, 37: 1774–1787
- 26 Yu Y B, Deng Q X, Ren L Y, et al. Memristor crossbar array based ACO for image edge detection. *Neural Process Lett*, 2020, 51: 1891–1905
- 27 Karamani R E, Fyrigos I A, Tsakalos K A, et al. Memristive learning cellular automata for edge detection. *Chaos Solitons Fractals*, 2021, 145: 110700
- 28 Zhu R H, Tang Z R, Ye S Z, et al. Memristor-based image enhancement: high efficiency and robustness. *IEEE Trans Electron Devices*, 2021, 68: 602–609
- 29 Zhang L, Hu X F, Zhou Y, et al. Memristive DeepLab: a hardware friendly deep CNN for semantic segmentation. *Neurocomputing*, 2021, 451: 181–191
- 30 Senthil S A, Kumar K P M, Dhanasekeran S, et al. Denoising of images from salt and pepper noise using hybrid filter, fuzzy logic noise detector and genetic optimization algorithm (HFGOA). *Multimed Tools Appl*, 2020, 79: 4115–4131
- 31 Wen B H, Li Y J, Bresler Y. Image recovery via transform learning and low-rank modeling: the power of complementary regularizers. *IEEE Trans Image Process*, 2020, 29: 5310–5323
- 32 Hong I, Hwang Y, Kim D. Efficient deep learning of image denoising using patch complexity local divide and deep conquer. *Pattern Recognit*, 2019, 96: 106945
- 33 Wang Y, Qi F, Wang J K. Terahertz image super-resolution based on a complex convolutional neural network. *Opt Lett*, 2021, 46: 3123–3126
- 34 Pandey G, Ghanekar U. Single image super-resolution using multi-scale feature enhancement attention residual network. *Optik*, 2021, 231: 166359
- 35 Remez T, Litany O, Giryes R, et al. Class-aware fully convolutional Gaussian and Poisson denoising. *IEEE Trans Image Process*, 2018, 27: 5707–5722
- 36 Lan R, Zou H Z, Pang C, et al. Image denoising via deep residual convolutional neural networks. *Signal Image Video Process*, 2021, 15: 1–8
- 37 Zhang Y, Wang X P, Li Y, et al. Memristive model for synaptic circuits. *IEEE Trans Circ Syst II*, 2017, 64: 767–771
- 38 Hinton G E. Training products of experts by minimizing contrastive divergence. *Neural Comput*, 2002, 14: 1771–1800
- 39 Romano Y, Isidoro J, Milanfar P. RAISR: rapid and accurate image super resolution. *IEEE Trans Comput Imag*, 2017, 3: 110–125
- 40 Yang J C, Wang Z W, Lin Z, et al. Coupled dictionary training for image super-resolution. *IEEE Trans Image Process*, 2012, 21: 3467–3478
- 41 Elad M, Aharon M. Image denoising via sparse and redundant representations over learned dictionaries. *IEEE Trans Image Process*, 2006, 15: 3736–3745
- 42 Zhang K, Zuo W M, Chen Y J, et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising. *IEEE Trans Image Process*, 2017, 26: 3142–3155

A memristor-based RBM circuit implementation and application in license plate image processing

Cong XU, Chunhua WANG* & Jingru SUN

College of Computer Science and Electronic Engineering, Hunan University, Changsha 410082, China

* Corresponding author. E-mail: wch1227164@hnu.edu.cn

Abstract License plate image processing is crucial in the field of intelligent transportation and public safety. Because of the influence of the shooting environment, imaging equipment, and other factors, the quality of the obtained license plate image is usually low, which affects the accuracy of license plate recognition. Image super-resolution reconstruction and image denoising technology not only improve image quality but also help further analysis and processing of the image. In this work, a memristive circuit of the restricted Boltzmann machine (RBM) is designed and applied in license plate image processing. The memristive circuit design mainly contains three modules: a generation module of hidden units, a reconstruction module of visible units, and a regeneration module of hidden units. The training process is transferred from software to on-chip implementation by the memristive circuit implementation. After applying license plate image super-resolution and image denoising, the effectiveness and superiority of the proposed memristive RBM circuit are verified by simulation and comparison results.

Keywords memristor, neural network, license plate image processing, restricted Boltzmann machine, circuit design