用于图像增强的仿生自适应忆阻细胞神经网络

郑雅文¹, 胡小方^{2*}, 周跃³, 罗丽³, 段书凯²

1. 西南大学计算机与信息科学学院, 重庆 400715

2. 西南大学人工智能学院, 重庆 400715

3. 西南大学电子信息工程学院, 重庆 400715

* 通信作者. E-mail: huxf@swu.edu.cn

收稿日期: 2019-08-08; 修回日期: 2019-10-08; 接受日期: 2019-11-22; 网络出版日期: 2020-10-21

国家自然科学基金 (批准号: 61976246, 61601376, 61672436)、国家重点研发计划 (批准号: 2018YFB1306600, 2018YFB1306604)、中国博士后科学基金特别资助 (批准号: 2018T110937) 和重庆市留学人员创业创新支持计划 (批准号: cx2019126) 资助项目

摘要 细胞神经网络 (cellular neural network, CNN) 具有简单的局部互联结构和高速并行处理能力, 是构造人工视网膜的基础模型, 可被应用于机器视觉中图像处理时的图像增强等方面. 然而, 现有的此类图像增强方法尚存在一些不足, 例如, 在处理实际复杂图像时, 采用固定模板难以取得理想效果; 而且, 未能模拟人类视觉系统的全局和局部自适应调节特性, 缺乏仿生考虑. 因此, 本文融合自适应三高斯 (tri-Gaussian) 理论和纳米信息器件忆阻器, 提出了一种用于图像增强的新型仿生自适应忆阻细胞神经网络. 其中, 基于忆阻器的可编程性、非易失性、突触可塑性等优点, 构建忆阻细胞神经网络架构. 基于神经元感受野三高斯模型, 利用高斯核函数和细胞神经网络的图像处理特征, 提出对应的仿生自适应图像增强模板设计算法. 最后, 分别以灰度和彩色图像为例进行了图像增强实验和对比分析, 结果表明, 提出的仿生自适应忆阻细胞神经网络能够显著提高图像的全局亮度、局部对比度和清晰度. 本研究可为细胞神经网络提供自适应模板设计及实现方案, 提升细胞神经网络的仿生特性和硬件实现的可行性, 并为图像增强等智能图像处理提供新思路.

关键词 细胞神经网络, 图像增强, 自适应三高斯模型, 仿生图像处理, 忆阻器

1 引言

图像增强^[1,2]可以突出图像中感兴趣的部分, 也可以提升退化图像的质量. 而退化因素通常包括人为因素和自然因素. 人为因素, 例如由拍摄抖动造成的运动模糊、相机电路问题产生的噪声^[3]、曝光不足等. 自然因素, 如烟、雨、雾、霾等天气原因导致的图像模糊^[4,5], 光照原因导致的图像过亮或过暗等. 典型的增强方法有: 直方图均衡法^[6]、小波变换法和偏微分方程法等. 近年来, 研究者也从人类视觉系统的生物特性出发, 提出了用于图像增强的新技术^[7,8]. 例如, Land^[9]和Jobson等^[10]提出了

引用格式: 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, doi: 10.1360/SSI-2019-0167
Zheng Y W, Hu X F, Zhou Y, et al. Biomimetic adaptive memristive cellular neural network for image enhancement (in Chinese). Sci Sin Inform, 2020, 50: 1850–1866, doi: 10.1360/SSI-2019-0167

基于 Retinex 理论的图像增强算法,该方法能够获得较好的图像增强效果,但由于同时进行局部对比度增强和动态范围压缩,使得整个增强过程难以控制.后来, Wang 等^[11]提出了一种仿生彩色图像增强方法,该方法不但分步进行局部对比度增强和动态范围压缩,而且考虑到人类视觉系统的全局和局部自适应调节特性^[12],取得了良好的增强效果,但对图像边界的处理效果不佳,使得整体对比度不高.在视网膜建模方面, Li 等^[13]提出了三高斯 (tri-Gaussian) 模型,实现了对视网膜神经节细胞的仿生建模,该模型利用 3 个高斯核函数分别描述神经节细胞传统感受野的中心区、外周区,和在传统感受野外存在的大范围去抑制区.在此基础上,有研究者将视觉系统的全局和局部自适应特性和三高斯模型相结合,提出了一种新的仿生图像增强方法^[14],该方法既能很好地增强图像的边缘对比,又可有效地提升区域亮度对比和亮度梯度信息.进一步,文献 [15,16] 提出,在三高斯模型中加入自适应机制,使得原来的静态模型变为动态模型,更符合生理特性.文献 [17] 提出,根据像素点的局部特征,用 Sigmoid 函数来调节三高斯模型中的参数,模拟兴奋性细胞的激活函数,可以得到良好的图像增强效果.然而,目前针对仿生图像增强的研究主要集中于数学模型和软件算法,若要执行实时图像处理任务,则亟待硬件友好的智能图像处理系统及其大规模硬件实现.

细胞神经网络 (cellular neural network, CNN) 是由 Chua 和 Yang^[18] 于 1998 年提出的一种大规模并行模拟信息处理阵列,网络中单元细胞结构相同,细胞与细胞之间具有规律的局部连接特征,是最适宜大规模集成电路实现的神经网络模型之一^[19].细胞神经网络广泛应用于图像处理^[20]、目标检测^[21]和模式识别^[22]等诸多领域,也是构造人工视网膜的模型基础.在细胞神经网络中,模板是决定网络输出的关键因素,不同参数模板实现不同功能.因而,通过设计合适的参数模板,利用细胞神经网络可有效实现图像增强.对于模板的设计,可直接基于理论推导进行参数求值;也可通过在网络状态方程中加入相应的约束条件进行反复训练,得到能处理与该样本类似问题的模板,如,分流抑制细胞神经网络^[23]、具有复杂权值的细胞神经网络^[24]等.但这类方法得到的模板往往存在过拟合现象,缺乏自适应性.

当处理大型复杂图像时,细胞神经网络的规模会对应增大.由于传统 CMOS 制造工艺和单元电路尺寸的限制,难以高效实现大规模细胞神经网络硬件电路.然而,新兴的纳米级器件忆阻器^[25,26]的出现为此带来新的希望.忆阻器具有高速、低功耗、状态切换、非易失性、易集成、可编程等特性^[27~29],是实现新一代高密度存储器和非易失运算器的新型有力技术.同时,基于忆阻器状态转换特征与生物突触的极大相似性,纳米忆阻器成为构建微纳米神经突触电路的理想元件.近年来,利用忆阻器实现细胞神经网络的突触连接和细胞单元电路,优化细胞神经网络结构并显著增大网络的功能密度和适应性,以实现图像的高速并行处理,成为研究热点^[30~32].

本文融合三高斯模型、细胞神经网络和纳米忆阻器,提出一种新型硬件友好的用于图像增强的仿生自适应忆阻细胞神经网络 (biomimetic adaptive memristive CNN, BAM-CNN).其中,改进了典型的自适应三高斯模型,提出硬件友好的线性化自适应三高斯模型;在此基础上,提出一种仿生自适应细胞神经网络模板设计算法,显著提升细胞神经网络的图像增强效果;同时,给出基于忆阻器的网络硬件架构,为大规模电路集成、硬件加速和芯片化的端侧实时图像处理提供有益的方案.最后,以灰度图像和彩色图像为例进行了大量实验,并使用图像对比度评价指标 EME (measure of enhancement by entropy) 值和图像清晰度评价指标 SMD2 (sum modulus difference 2) 值定量对比分析多种图像增强方法的增强结果,验证了本文所提方案的有效性和优越性.

2 忆阻细胞神经网络

传统二维细胞神经网络^[18]由一层规则排列的细胞构成,是一种非线性模拟信息处理系统.细胞

图 1 (网络版彩图) 细胞神经网络拓扑模型

Figure 1 (Color online) CNN topology model

图 2 (网络版彩图) 忆阻细胞单元电路

Figure 2 (Color online) Memristive neuron circuit

神经网络中任一细胞仅与相邻细胞相连并且相互影响, 如图 1 所示, 每个圆形代表一个细胞, 是信息处理的基本单元.

忆阻细胞神经网络与传统细胞神经网络类似, 同样具有规则的阵列结构, 其中每一个基本单元内部电路结构相同. 图 2 展示了忆阻细胞的等效电路图, 电路中含有一个独立电压源 E_{ij} 、一个独立电流源 I 、一个忆阻器状态电阻 M 、一个线性电容 C 和两个压控电流源. 在忆阻器模型选择方面, 本文采用结构简单、准确, 计算复杂度低, 并能模拟多种忆阻器模型特征的 VTEAM 忆阻器模型^[33].

忆阻细胞 $C_{i,j}$ 的动态特性主要取决于独立电流源提供的电流 I , 输入电流 u_{ij} 和自身状态变量 x_{ij} . 基于电路 KCL 原理, 其状态方程如下^[34]:

$$C \frac{dx_{ij}(t)}{dt} = -m(x_{ij}(t)) + \sum_{C_{k,l} \in N_r(i,j)} [A_{ij,kl} y_{kl}(t) + B_{ij,kl} u_{kl}(t)] + I, \quad (1)$$

其中 $x_{ij}(t)$ 表示中心细胞 $C_{i,j}$ 的状态变量, $N_r(i,j)$ 表示中心 $C_{i,j}$ 的半径大小为 1 的邻域, $C_{k,l}$ 表示该邻域内所有细胞, C 和 m 为常数, $A_{ij,kl}$ 表示向邻域细胞 $C_{k,l}$ 的输出 $y_{kl}(t)$ 与中心细胞 $C_{i,j}$ 的连接权值, $B_{ij,kl}$ 表示来自邻域细胞的输入 $u_{kl}(t)$ 与中心细胞的连接权值, I 为固定偏置电流.

对于大小为 $M \times N$ 的忆阻细胞神经网络, 其输入方程为

$$u_{ij} = E_{ij}, \quad 1 \leq i \leq M, \quad 1 \leq j \leq N, \quad (2)$$

图 3 (网络版彩图) 忆阻桥突触电路

Figure 3 (Color online) Memristive bridge synapse circuit

图 4 (网络版彩图) 3×3 邻域细胞神经网络模板Figure 4 (Color online) Template of CNN with 3×3 neighborhood

输出方程为

$$y_{ij}(t) = f(x_{ij}(t)), \quad (3)$$

$$f(x_{ij}(t)) = \frac{1}{2}(|x_{ij}(t) + 1| - |x_{ij}(t) - 1|), \quad 1 \leq i \leq M, \quad 1 \leq j \leq N, \quad (4)$$

其中 E_{ij} 表示电压源, u_{ij} 为中心细胞 $C_{i,j}$ 的输入, $x_{ij}(t)$ 表示中心细胞 $C_{i,j}$ 的状态, $y_{ij}(t)$ 为中心细胞的输出.

相邻细胞之间的连接强度由 3×3 的反馈模板 A 和控制模板 B 中的参数控制, 并通过由忆阻器构成的桥突触电路的权值实现, 如图 3 所示^[35]. 此结构实现的突触输入与输出之间的关系式及突触权值分别为

$$V_{\text{out}} = \left(\frac{M_2}{M_1 + M_2} - \frac{M_4}{M_3 + M_4} \right) V_{\text{in}}, \quad (5)$$

$$W = \frac{M_2}{M_1 + M_2} - \frac{M_4}{M_3 + M_4}, \quad (6)$$

其中 V_{in} 表示突触的输入电压, V_{out} 表示突触的输出电压, W 表示突触权值, M_1, M_2, M_3 和 M_4 分别表示忆阻桥突触电路中忆阻器 M_1, M_2, M_3 和 M_4 的忆阻值. A, B 模板对系统动态行为的影响和作用示意图如图 4 所示. 在本文图像增强应用中, 模板 A 的参数固定为零, 模板 B 的参数设计将由基于视觉机制的三高斯核函数和单高斯核函数实现.

图 5 (网络版彩图) 三高斯模型的空间结构. (a) 中心兴奋模块; (b) 外周抑制模块; (c) 边缘兴奋模块; (d) 三高斯模型

Figure 5 (Color online) Spatial structure of tri-Gaussian function model. (a) Intermediate exciting module; (b) surrounding inhibition module; (c) edge exciting module; (d) tri-Gaussian model

3 融合视觉特征的自适应图像增强

3.1 线性化自适应三高斯模型

视网膜神经节细胞感受野的三高斯模型用 3 个高斯核函数分别表示神经节细胞感受野的中心区、外周区和边缘区^[13]:

$$G(x, y) = A_1 \exp\left(-\frac{x^2 + y^2}{2\sigma_1^2}\right) - A_2 \exp\left(-\frac{x^2 + y^2}{2\sigma_2^2}\right) + A_3 \exp\left(-\frac{x^2 + y^2}{2\sigma_3^2}\right), \quad (7)$$

其中 (x, y) 为感受野平面, $G(x, y)$ 由中心兴奋模块、外周抑制模块和边缘兴奋模块构成. A_1, A_2, A_3 分别表示中心、外周、边缘的峰值系数, $\sigma_1, \sigma_2, \sigma_3$ 分别表示中央、外周和边缘的尺度参数. 利用该模型来处理亮度对比边缘时, 既能很好地增强边缘对比, 又可有效地提升被感受野中心或外周拮抗机制所滤除的区域亮度对比和梯度信息. 三高斯模型的空间结构如图 5 所示.

虽然传统三高斯模型模拟了神经节细胞感受野, 具有较好的图像增强效果, 但是模型函数使用固定参数, 缺乏针对不同处理对象的灵活适应性. 而自适应三高斯模型^[16] 根据像素点的局部特征, 利用非线性函数来灵活调节模型中参数 A_1 和 σ_2 的大小. 具体地, 在一幅图像中, 选取一个被处理点, 该点的像素值定义为 Lum. 以该点为中心取大小为 3×3 的邻域, 邻域内所有像素值的标准差定义为 Con. 自适应三高斯模型根据图像某一像素点的局部对比度 Con 和处理点亮度 Lum, 利用 Sigmoid 函数, 更新三高斯模型中参数 A_1 和 σ_2 的大小, 实现参数的自适应调节. 模型其他参数 A_2, A_3, σ_1 和 σ_3 为常值.

自适应三高斯模型中感受野兴奋区敏感度 A_1 与 Con 的关系为

$$A_1 = 6 + \frac{1}{1 + \exp(-10 \times (\text{Con} - 0.5))}. \quad (8)$$

图 6 (a) 感受野中心兴奋区敏感度 A_1 随 Con 的变化曲线图; (b) 感受野抑制区半径 σ_2 随 Lum 的变化曲线图
Figure 6 (a) The curve of the sensitivity A_1 of receptive field sensitivity zone to Con ; (b) The curve of the radius σ_2 of receptive field suppression zone to Lum

自适应三高斯模型中感受野抑制区半径 σ_2 与 Lum 的关系为

$$\sigma_2 = 1.25 + \frac{1}{1 + \exp(10 \times (Lum - 0.45))}, \quad (9)$$

根据图 6(a) 感受野中心兴奋区敏感度 A_1 随 Con 的变化曲线可知, 当刺激 (如图片的像素值) 对比度降低时, A_1 减小, 即中心兴奋区的兴奋响应在一定程度上被抑制, 感受野抑制区对中心区的抑制作用增强; 当刺激对比度升高时, A_1 增大, 即中心兴奋区的响应增强, 感受野抑制区对中心区的抑制作用减弱. 根据图 6(b) 感受野抑制区半径 σ_2 随 Lum 的变化曲线分析可知, 当刺激降低时, 感受野抑制区的半径 σ_2 变大, 抑制区对中心兴奋区的抑制作用增强, 像素值差异越小的点之间对比度越弱; 而当刺激增大时, 感受野抑制区的半径 σ_2 变小, 抑制区对中心兴奋区的抑制作用减弱, 局部像素值差异越大的点之间对比度越强. 这种动态自适应机制能增强图像的局部对比, 符合人眼感知光亮时“暗处越暗、亮处越亮”的视觉特征.

在 Con 和 Lum 的值很小或很大的区间里, 感受野中心兴奋区敏感度 A_1 随 Con 的变化趋势和感受野抑制区半径 σ_2 随 Lum 的变化都趋于平缓. 从而在对图像中的这些区域进行滤波增强时, A_1 和 σ_2 不会发生剧烈变化, 在一定程度上可以避免噪声的产生.

虽然 Sigmoid 函数可以较好地模拟视觉模型参数的自适应性, 但这种光滑的非线性曲线在实际电路中难以实现. 因此, 本文把非线性 Sigmoid 函数曲线分成若干个区段, 进行线性化处理, 以简化自适应三高斯模型的数值计算以及硬件实现. 由式 (8) 和 (9) 中两个非线性 Sigmoid 函数得到的分段线性函数 F_1 和 F_2 分别如式 (10) 和 (11) 所示, 这样对应的线性化自适应三高斯模型可以表示为式 (7), (10) 和 (11).

$$F_1 : A_1 = \begin{cases} 6 + \frac{1}{1 + \exp(3.5)}, & Con \leq 0.25, \\ \left[\frac{1}{1 + \exp(-2)} - \frac{1}{1 + \exp(2)} \right] / 0.6 \times (Con - 0.5) + 10.5, & 0.25 < Con \leq 0.75, \\ 6 + \frac{1}{1 + \exp(-3.5)}, & 0.75 < Con \leq 1, \end{cases} \quad (10)$$

$$F_2 : \sigma_2 = \begin{cases} 1.25 + \frac{0.1}{1 + \exp(-3.5)}, & Lum \leq 0.25, \\ \left[\frac{0.1}{1 + \exp(2.5)} - \frac{0.1}{1 + \exp(-1.5)} \right] / 0.4 \times (Lum - 0.45) + 0.07, & 0.25 < Lum \leq 0.75, \\ 1.25 + \frac{0.1}{1 + \exp(3.5)}, & 0.75 < Lum \leq 1. \end{cases} \quad (11)$$

3.2 融合视觉特征的细胞神经网络自适应模板设计

由 3.1 小节可知, 对于图像上某像素点, 由分段线性函数 F_1 和 F_2 分别计算出以该点为中心点时空间邻近三高斯核函数的可变参数 A_1 和 σ_2 的值, 可以得到分段线性化自适应三高斯模型. 而与传统忆阻细胞神经网络类似, 仿生自适应的忆阻细胞神经网络具有如下图像增强模板形式:

$$A = \begin{bmatrix} 0 & 0 & 0 \\ 0 & a & 0 \\ 0 & 0 & 0 \end{bmatrix}, \quad B = \begin{bmatrix} b_{i-1,j-1} & b_{i,j-1} & b_{i+1,j-1} \\ b_{i-1,j} & b_{i,j} & b_{i+1,j} \\ b_{i-1,j+1} & b_{i,j+1} & b_{i+1,j+1} \end{bmatrix}, \quad I = Z, \quad (12)$$

其中模板 A 的参数 $a = 0$, 阈值 $I = Z = 0$.

模板的参数不再是固定的数值, 而是由三高斯模型的位置滤波和单高斯模型的亮度滤波相结合的双边滤波决定, 同时考虑了邻域像素在数值和位置上与中心像素点之间的相似性. 表达式如下:

$$b_{kl} = G_{rij,kl} G_v(I_{ij,kl}), \quad (13)$$

其中 $G_{rij,kl}$ 表示位置滤波, 反映邻域内各像素点到中心像素点的位置相似性, 由关于中心细胞 $C_{i,j}$ 和半径为 1 的邻域内细胞 $C_{k,l}$ 的空间邻近三高斯核函数决定,

$$G_{rij,kl} = A_1 \exp\left(-\frac{(i-k)^2 + (j-l)^2}{2\sigma_1^2}\right) - A_2 \exp\left(-\frac{(i-k)^2 + (j-l)^2}{2\sigma_2^2}\right) + A_3 \exp\left(-\frac{(i-k)^2 + (j-l)^2}{2\sigma_3^2}\right), \quad (14)$$

其中 A_1, A_2, A_3 分别表示神经节细胞感受野中心区、外周区、边缘区的峰值系数, $\sigma_1, \sigma_2, \sigma_3$ 分别表示神经节细胞感受野中心区、外周区、边缘区的尺度参数. A_1 的具体表达式为式 (10), σ_2 的具体表达式为式 (11).

$G_v(I_{ij,kl})$ 为亮度滤波, 反映了邻域内各像素与中心像素值的相似性. 其大小因各像素与中心像素的亮度差而改变, 亮度差越大, 其值越小, 反之则越大. 定义为

$$G_v(I_{ij,kl}) = \exp\left(-\frac{(I(i,j) - I(k,l))^2}{2\sigma_v^2}\right), \quad (15)$$

其中 $I(i,j)$ 是核函数中心的像素值, $I(k,l)$ 是半径为 1 的邻域内细胞的像素值, σ_v 是数值高斯滤波的尺度参数, 控制了函数的径向作用范围.

由参数线性化自适应的空间邻近三高斯核函数 (式 (14)) 和数值相似性高斯核函数 (式 (15)) 计算细胞神经网络控制模板 B 的参数, 可设计出具有双重自适应特性的细胞神经网络控制模板 B : (i) 细胞神经网络控制模板 B 通过高斯方程组自适应变化; (ii) 高斯方程组中三高斯核函数的部分参数 A_1 和 σ_2 , 分别通过函数 F_1 和 F_2 , 根据像素点的局部信息自适应变化. 具体的设计和计算方法如下:

$$G_{rij,kl} = \begin{bmatrix} c_1 & c_2 & c_3 \\ c_4 & c_5 & c_6 \\ c_7 & c_8 & c_9 \end{bmatrix}, \quad G_v(I_{ij,kl}) = \begin{bmatrix} d_1 & d_2 & d_3 \\ d_4 & d_5 & d_6 \\ d_7 & d_8 & d_9 \end{bmatrix}, \quad (16)$$

$$B = G_{rij,kl} G_v(I_{ij,kl}) = \begin{bmatrix} c_1 & c_2 & c_3 \\ c_4 & c_5 & c_6 \\ c_7 & c_8 & c_9 \end{bmatrix} \odot \begin{bmatrix} d_1 & d_2 & d_3 \\ d_4 & d_5 & d_6 \\ d_7 & d_8 & d_9 \end{bmatrix}. \quad (17)$$

3.3 仿生自适应忆阻细胞神经网络及图像增强流程

3.2 小节给出了忆阻细胞神经网络的自适应控制模板 B 的设计方法, 本小节则使用该模板实现仿生图像增强. 首先, 对图像进行预处理, 即对原始图像进行全局亮度归一化变换. 通过对全局明暗度的线性调整, 同时实现对图像中暗区域增强^[14]. 其变换公式为

$$u_g = u/255, \quad (18)$$

其中 u 是大小为 $m \times n$ 的矩阵, 储存原始图像 (大小为 $m \times n$) 各像素点的 3 个颜色通道分值的最大值. u_g 是归一化后的亮度矩阵.

图像矩阵 u_g 符合自适应仿生图像增强方法的输入要求. 而且由数据可知, 输入矩阵 u_g 的数值在 $[0, 1]$ 之间, 符合忆阻细胞神经网络输入量的范围要求. 接着使用自适应控制模板 B 实现仿生图像增强. 忆阻细胞神经网络实现图像增强时, 不需要使用反馈模板 A , 而只需要用到控制模板 B , 因此忆阻细胞 $C_{i,j}$ 的状态方程可以改写为

$$x_{ij}(t) = -x_{ij}(t) + \sum_{C_{k,l} \in N_r(i,j)} B(i,j;k,l)u_g(t), \quad (19)$$

其中 $x_{ij}(t)$ 表示中心细胞 $C_{i,j}$ 的状态, $N_r(i,j)$ 表示中心细胞的半径大小为 1 的邻域, $C_{k,l}$ 表示该邻域内所有细胞, $B(i,j;k,l)$ 表示邻域细胞 $C_{k,l}$ 的输入 $u_g(t)$ 与中心细胞 $C_{i,j}$ 的连接权值.

对于大小为 $M \times N$ 的忆阻细胞神经网络, 其输入方程为

$$u_{ij} = E_{ij}, \quad 1 \leq i \leq M, \quad 1 \leq j \leq N, \quad (20)$$

输出方程为

$$y_{ij}(t) = f(x_{ij}(t)), \quad (21)$$

$$f(x_{ij}(t)) = \frac{1}{2}(|x_{ij}(t) + 1| - |x_{ij}(t) - 1|), \quad 1 \leq i \leq M, \quad 1 \leq j \leq N, \quad (22)$$

其中 E_{ij} 表示电压源, u_{ij} 为中心细胞 $C_{i,j}$ 的输入, $x_{ij}(t)$ 表示中心细胞 $C_{i,j}$ 的状态, $y_{ij}(t)$ 为中心细胞的输出.

经过忆阻细胞神经网络迭代后, 由相关参数计算可证明 x_{ij} 总是满足 $-1 < x < 1$, 所以简化忆阻细胞神经网络的输出公式, 得到输出方程:

$$y_{ij}(t) = x_{ij}(t), \quad (23)$$

约束条件:

$$|x_{ij}(0)|, \quad 1 \leq i \leq M, \quad 1 \leq j \leq N, \quad (24)$$

$$|u_{ij}(t)|, \quad 1 \leq i \leq M, \quad 1 \leq j \leq N, \quad (25)$$

对称条件:

$$A(i,j;k,l) = A(k,l;i,j), \quad 1 \leq i \leq M, \quad 1 \leq j \leq N. \quad (26)$$

进一步, 使用提出的 BAM-CNN 进行图像 (灰度和彩色图像) 增强的流程如图 7 所示, 具体如下:

步骤 1. 对于彩色图像, 输入一幅彩色图像, 分别对每个像素点, 提取其在 RGB 空间中的 R, G, B 3 个分量值中的最大值, 储存为矩阵 u . 对 u 做归一化处理, 计算出忆阻细胞神经网络的输入矩阵 u_g . 对于灰度图像, 输入一幅灰度图像, 对全部像素点做归一化处理, 计算出忆阻细胞神经网络的输入矩阵 u_g .

图 7 彩色图像增强流程
Figure 7 Color image enhancement process

步骤 2. 对于图像上某像素点, 由函数 F_1 和 F_2 计算出以该点为中心点时, 空间邻近三高斯核函数的参数 A_1 和 σ_2 的值. 从而确定以该点为中心的三高斯函数. 由三高斯函数和单高斯函数组成的高斯方程组, 确定该处忆阻细胞神经网络控制模板 B 的参数.

步骤 3. 利用步骤 1 和 2 的结果 (忆阻细胞神经网络的输入矩阵 u_g 和控制模板 B 的参数), 进行忆阻细胞神经网络的迭代运算, 当网络稳定时, 便得到仿生增强后的灰度图像.

步骤 4. 对忆阻细胞神经网络的输出结果进行恢复处理, 还原图像像素等信息.

4 实验结果及分析

本文在标准图像处理库 DIP3E-Original-Images 中随机选取了大量图片进行实验, 并进行统计分析. 进一步, 选择了大量来自真实医疗图像数据库 ALL-Mias 中的图片进行处理, 以给出更为全面的评价. 具体地, 本文进行了两组比较: (i) 典型图像增强技术 (如直方图均衡化、对于灰度图的分流抑制细胞神经网络^[23] (shunting inhibitory cellular neural networks, SICNN) 和对于彩色图像的 Retinex 方法^[10] 等) 和本文提出的 BAM-CNN 之间的比较; (ii) 新型图像增强模型之间的比较, 包括传统三高斯模型、自适应三高斯模型、线性化自适应三高斯模型、融合传统三高斯模型的 CNN、融合自适应三高斯模型的 CNN 和 BAM-CNN 模型.

4.1 多种图像增强方法的增强效果比较

实验比较了 6 种图像增强方法的增强效果, 包括直方图均衡化、仿生 Retinex 方法、同态滤波法、小波变换法、灰度线性变换法和本文提出的 BAM-CNN. 总体结果显示, 相较于其他 5 种图像增强方法, 使用本文方法处理的灰度和彩色图像能获得更好的对比度. 而对于背景本身较亮且含有较多细节信息的图片, 本文方法对性能提升不大. 本节选取 Room 图像和 Tower 图像作为展示图像, 增强结果如图 8 所示. 由图 8 可知, 原始图像整体较暗; 直方图均衡化的增强结果在明暗对比上得到一定程度的提升, 但损失了许多局部细节信息; 使用 SICNN 实现的图像增强, 虽然在一定程度上实现了亮度增强, 但是图像有的部分增强过亮 (如 Room 图像的天空和窗户部分); 使用 Retinex 的增强结果在一定程度上实现了亮度增强, 但是色彩对比度不强. 而使用本文的 BAM-CNN 方法则达到了良好的综合图

图 8 (网络版彩图) 增强效果对比图. (a) Room 图; (b) Tower 图

Figure 8 (Color online) Enhanced effect comparison. (a) Room; (b) Tower

像增强效果, 整体亮度得到了显著的提高, 而且局部对比度明显加强, 符合人眼的视觉特性.

另外, 也可以利用图像经过不同方法增强后的直方图来评价图像的一些重要性质: 对于低亮度图像, 其直方图在低灰度区域分布较多; 而对于高亮度图像, 其直方图在高灰度区域分布比较多; 对于低对比度图像, 其直方图狭窄; 而对于高对比度图像, 其直方图覆盖的灰度级很宽. 所以从直观上来看,

表 1 6 种方法增强效果 (EME 值) 比较
Table 1 Comparison of the effects (EME) of the six enhancement methods

No	Origin	HE	Retinex	HF	WT	GSL	BAM-CNN
1	652.4262	793.3994	772.3151	793.2867	775.8123	765.9624	796.9342
2	568.8201	698.4078	661.9563	686.7693	559.4216	720.0508	818.2679
3	428.2354	634.4120	611.5280	624.0064	431.6045	695.7376	676.8831
4	214.3378	260.6652	190.0746	255.1763	201.0840	351.3541	388.8343
5	668.4836	755.3688	397.2203	761.9537	725.5078	751.9514	907.3139
6	235.5166	379.8441	242.6934	458.4887	235.3616	443.3711	459.3054
7	392.0305	639.9298	579.2962	656.0020	427.1555	624.6440	600.0791
8	536.4732	673.0242	494.2527	747.4195	554.4671	653.2434	794.5018
9	366.8843	438.9627	382.8986	466.4004	391.8464	441.3711	542.5105
10	553.1127	707.4049	573.0594	728.4262	600.4264	686.2060	760.8238
11	496.2885	464.8486	493.9914	455.6647	492.6860	552.0750	535.5896
12	204.1674	276.9846	215.0037	214.5829	166.0431	204.1674	406.9582
13	181.6859	242.8295	202.4264	290.8129	234.6048	235.5157	346.4498
14	571.5830	860.7786	571.9902	436.9282	560.3997	866.4457	798.4308
15	240.2980	215.3778	240.9412	226.5606	240.5550	240.8652	337.4020

如果一幅图像其像素分散分布于全部可能的灰度区间, 而且主要分布在高灰度区间, 那么这样的图像有比较高的亮度和较强的对比度. 由图 8 可知, 经过直方图均衡化处理后, Room 图像的直方图集中分布于高灰度区间, 因此具有较高的亮度但是对比度较弱; Tower 图像的直方图分布分散但是在中灰度区间分布较多, 因此 Tower 图像对比度较强但是亮度不高. SICNN 增强结果的直方图则倾向于灰度级过高的一侧, 所以 SICNN 增强后亮度过高; Retinex 方法增强结果的直方图过于集中, 因此增强后图像对比度很弱; 而 BAM-CNN 增强结果的直方图中, 像素分布在全部可能的灰度级中, 并且主要分布在高灰度区间, 显示增强后的图像有较高的亮度和较强的对比度, 与直观分析结论一致.

4.2 图像增强效果的客观评价

本小节进一步对增强的结果进行定量的客观评价, 本文采用文献 [36] 提出的图像增强效果客观评价指标 EME. 通过比较灰度或彩色图像增强前后 EME 的值来表征对比度的变化, 从而判断图像增强的效果.

计算 EME 值时, 一般把图像平均分成若干个相同大小的局部图像, 然后对每一个局部图像计算出它的最大像素值 $V_{\max,k,l}$ 和最小像素值 $V_{\min,k,l}$. EME 的定义式为

$$\text{EME} = \frac{1}{k_1 k_2} \sum_{l=1}^{k_2} \sum_{k=1}^{k_1} 20 \ln \frac{V_{\max,k,l}}{V_{\min,k,l}}. \tag{27}$$

其中 k_1 和 k_2 分别表示图像被划分成的行数和列数.

EME 的值越大说明图像的平均动态范围越大, 增强后的图像具有更好的增强对比度. 本文从大量实验结果里随机抽取一定量的图像进行定量评价, 并进行了统计分析. 定量实验比较了 6 种图像增强方法的增强效果, 如表 1. 鉴于篇幅考虑, 表 1 列出 15 幅图像, 其中序号为 1, 3, 6 和 11 的图像来自医疗图像数据库, 使用 6 种图像增强方法的比较数据. 每一行比较数据中, 增强效果最好的数值用

图 9 (网络版彩图) House 图像仿生增强. (a) 原图; (b) 三高斯模型; (c) 自适应三高斯模型; (d) 线性化自适应三高斯模型; (e) 融合自适应三高斯模型的 CNN; (f) BAM-CNN

Figure 9 (Color online) House image bionic enhancement. (a) Original image; (b) tri-Gaussian model; (c) adaptive tri-Gaussian model; (d) linearized adaptive tri-Gaussian model; (e) CNN fused with adaptive tri-Gaussian model; (f) BAM-CNN

粗体表示. 可以看出, 本文 BAM-CNN 的增强结果的 EME 值普遍大于其他 5 种增强方法处理结果的 EME 值, 验证了本文方法在提升图像对比度方面的优势. 而对于背景本身较亮且含有较多细节信息的图片 (序号为 3, 7, 11 和 14 的图像), 本文方法对性能提升不大.

4.3 多种新型图像增强模型比较结果及评价

本小节比较了 6 种新型图像增强模型的增强效果, 包括传统三高斯模型、自适应三高斯模型、线性化自适应三高斯模型、融合传统三高斯的 CNN、融合自适应三高斯的 CNN 和 BAM-CNN. 增强类型包括明暗程度、不均匀光校正和清晰度增强. 进一步, 本小节对大量由烟、雨、雾、霾等天气原因导致的模糊图像进行清晰化实验, 并进行统计分析. 总体结果显示, 使用本文 BAM-CNN 方法能明显提高灰度和彩色图像的清晰度、全局亮度和对比度. 而对于背景本身较亮且含有较多信息的图片, 增强后的图像虽然清晰度和亮度提高, 但是对比度减弱. 本节选取 House 灰度图像和 Couple 彩色图像作为展示图像. 经过实验得到各模型的增强结果如图 9 和 10 所示.

由实验结果可以看出, 使用传统三高斯模型增强后的图像, 全局亮度得到了很好的提升, 而且局部对比度明显增强 (比如 House 图像门窗与外墙的对比更强、Couple 图像画框与墙壁的对比度更强). 使用自适应三高斯模型的增强图像局部对比度更强, 更符合人眼的视觉特性. 使用线性化自适应三高斯模型的增强图像保持了自适应三高斯模型在对比度和亮度方面的优势. 使用本文 BAM-CNN 模型

图 10 (网络版彩图) Couple 图像仿生增强. (a) 原图; (b) 三高斯模型; (c) 自适应三高斯模型; (d) 线性化自适应三高斯模型; (e) 融合自适应三高斯模型的 CNN; (f) BAM-CNN

Figure 10 (Color online) Couple image bionic enhancement. (a) Original image; (b) tri-Gaussian model; (c) adaptive tri-Gaussian model; (d) linearized adaptive tri-Gaussian model; (e) CNN fused with adaptive tri-Gaussian model; (f) BAM-CNN

得到的增强图像,不但继承了线性化自适应三高斯模型在对比度和亮度方面的优势,增强效果更符合人眼的视觉特性,而且相较于传统三高斯模型提升了图像清晰度.此外, BAM-CNN 不仅可以高效地实现多种复杂图像增强,而且基于纳米忆阻器的设计方案,可使电路尺寸大幅缩减,推进仿生图像增强的硬件加速和大规模应用.

进一步,为了验证本文方法对于提高图像清晰度的有效性,对增强后的图像进行定量的客观评价,这里采用清晰度评价指标 SMD2. 通过比较图像增强前后 SMD2 的值来表征清晰度的变化,从而判断图像增强的效果. SMD2 的定义式为

$$\text{SMD2} = \sum \sum |I(x, y) - I(x + 1, y)| \times |I(x, y) - I(x, y + 1)|. \quad (28)$$

对于模糊的图像,整个图像的灰度较为均匀,相邻像素之间的差值较小,相乘的积较小,累加后 SMD2 较小;图像越清晰,边缘跟其周围像素灰度的差值越大,相乘的积累加后越大. SMD2 的值越大说明图像越清晰,增强后的图像具有更好的增强效果.

本文从大量实验结果中随机抽取一定量的图像进行了定量评价,并进行统计分析. 定量比较了 6 种新型图像增强模型的增强效果. 考虑到篇幅限制,表 2 列出 20 幅标准图像使用 6 种图像增强模型比较数据,其中序号为 1, 2, 4, 6, 8 和 11 的图像来自医疗图像数据库,序号为 16, 17, 18, 19, 20 的图像是由烟、雨、雾、霾等天气原因导致的模糊图像. 增强类型包括明暗程度、不均匀光校正和图像清

表 2 6 种新型模型增强效果比较

Table 2 Comparison of the effects of the six enhancement models

No.	Evaluation index	Origin	TGM	ATGM	LATGM	CNN-TGM	CNN-ATGM	BAM-CNN
1	EME	516.7271	574.7419	575.0046	575.0046	676.8831	676.8831	676.8831
	SMD2	4050246	7195030	7282118	7270258	30977436	31472958	31520264
2	EME	243.7382	275.5480	275.5480	275.5480	459.1279	459.3054	459.3054
	SMD2	1594525	3167996	3179766	3178265	5450193	5604472	5615845
3	EME	424.0944	643.9899	643.9899	643.9899	644.3513	600.0791	600.0791
	SMD2	98474377	166954625	167164355	167153301	186762626	185927054	185878806
4	EME	375.9151	428.4620	428.4620	428.4620	535.5896	535.5896	535.5896
	SMD2	3786709	7293439	7337408	7331335	19553768	19613745	30031026
5	EME	818.3787	313.2185	313.2185	313.2185	313.1769	313.1769	313.1769
	SMD2	14373051	17552085	17587905	17577407	31787078	31811886	31801532
6	EME	638.3819	449.2624	449.2653	449.2624	789.0090	789.0090	796.9342
	SMD2	41016820	50170828	50303836	50288306	81008360	80827900	239619331
7	EME	545.3247	691.5614	691.5614	691.5614	760.7921	760.8160	760.8238
	SMD2	37916146	76333187	76946567	76829900	294066564	293730676	293743101
8	EME	409.6000	321.9660	321.9660	321.9660	330.6879	378.2778	378.2835
	SMD2	1578587	3015839	3045405	3042080	10409059	10914315	10925921
9	EME	587.5047	702.2330	702.2330	702.2330	714.8868	818.2679	818.2679
	SMD2	53099370	43866606	43869362	44086474	121734667	147002589	147304736
10	EME	469.7769	615.2829	615.2829	615.2829	741.8416	741.9090	741.9090
	SMD2	15012384	55617848	56008629	55950050	233029446	232946196	232927961
11	EME	687.2862	687.2862	687.2862	687.2862	687.2862	687.2862	687.2862
	SMD2	3603688	5887550	5914441	5911444	17806158	15963913	16147183
12	EME	240.2980	326.2426	326.6014	326.6014	337.4020	337.4020	337.4020
	SMD2	3012108	13620247	13682373	13674132	23959523	24344829	24304184
13	EME	728.6271	728.3553	728.3553	728.3553	728.4551	728.3553	728.3553
	SMD2	255930555	53888055	54143765	54098895	154063947	133577888	135459162
14	EME	562.2581	685.2473	685.2473	685.2473	688.5457	688.5457	688.5457
	SMD2	2491177	3833026	3890344	3884939	17480651	17498549	17490717
15	EME	605.3837	519.2382	519.2382	519.2382	572.9556	573.0366	573.0366
	SMD2	67393400	65403398	65802209	65740477	171877694	171273138	171206923
16	EME	260.7194	288.1046	288.2781	288.2781	383.6287	383.6287	383.6287
	SMD2	661453	4483283	4529402	4523482	14942187	13842137	13762008
17	EME	303.6955	239.0931	239.0918	239.0931	410.2250	410.2250	410.2250
	SMD2	1093784	3612458	3645373	3642404	11263263	10117695	10056009
18	EME	263.7576	211.8428	211.9743	211.8428	380.7958	380.7958	380.7958
	SMD2	710809	7606842	9192230	7655291	31747832	29260373	29079092
19	EME	303.2979	209.0489	209.0489	209.0489	409.5968	409.5968	409.5968
	SMD2	676089	4377827	4418391	4399980	14625390	12534276	12534276
20	EME	200.8583	342.2648	342.2648	342.2648	342.3068	342.3068	342.3068
	SMD2	34374241	50726776	50936495	50862594	93001493	93160126	93095410

晰化. 每一行比较数据中, 增强效果最好的数值用粗体表示. 可以看出, 使用 BAM-CNN 的增强结果的对比度指标 EME 和清晰度指标 SMD2 普遍大于使用其他 5 种模型处理结果的 EME 值和 SMD2 值, 验证了本文方法在提升图像对比度和清晰度方面的优势. 而对于背景本身较亮且含有较多信息的

图片, 增强后的图像虽然清晰度和亮度提高, 但是对比度减弱 (如表 2 中序号为 3, 5, 8, 13 和 15 的图像).

5 结论

本文融合模拟人类视觉特性的三高斯模型、易于大规模硬件实现的并行阵列式图像处理器-细胞神经网络, 以及可编程的非易失纳米忆阻器, 提出了新型的图像增强 BAM-CNN. 首先, 针对传统细胞神经网络模板不易更新、电路难以实现等困难, 提出并介绍了忆阻细胞神经网络架构, 其模板电路可以根据需要及时更新而不需要改变电路结构, 同时便于大规模硬件实现. 然后, 针对细胞神经网络方向的研究难点和重点——模板设计, 考虑硬件友好性, 提出了分段线性化的自适应三高斯模型, 进一步, 首次提出了融合神经元感受野自适应三高斯模型的模板设计算法, 构建了 BAM-CNN, 用于图像增强. 而该模板设计方法的复杂性较高, 更适用于对图像增强效果要求高且具有强大计算力的应用系统. 最后, 本文进行了大量的实验和对比分析, 增强实验类型包括明暗程度、不均匀光校正和图像清晰化. 结果显示, 使用本文方法处理后的图像更贴近人眼增强效果, 即具有更高的全局亮度、清晰度和更强的局部对比度. 通过 EME 指标和 SMD2 指标对增强结果进行客观评价, 定量验证了本文 BAM-CNN 的优越性.

BAM-CNN 的模板具有自适应性, 消除了传统细胞神经网络固定模板灵活性不足的劣势. 基于忆阻器的独特优势, 该模板还具有可编程性、多功能性和硬件友好性, 利于大规模电路集成, 便于实现硬件加速和芯片化的端侧实时图像处理. 本文提出的仿生模板设计方案, 弥补了细胞神经网络模板设计缺少仿生考虑的不足, 显著提升了图像增强效果, 为更多应用提供先进的模板设计新范例.

参考文献

- 1 Zhan Y D, Wang S H, Zhou Z Y, et al. Color image enhancement based on HVS and PCNN. *Sci China Inf Sci*, 2010, 40: 909–924 [张焜东, 王水花, 周振宇, 等. 基于 HVS 与 PCNN 的彩色图像增强. *中国科学: 信息科学*, 2010, 40: 909–924]
- 2 Tang Q L, Sang N, Liu H H, et al. Detecting natural image contours by combining visual perception and machine learning. *Sci Sin Inform*, 2013, 43: 1124–1135 [唐奇伶, 桑农, 刘海华, 等. 视觉感知结合学习的自然图像轮廓检测. *中国科学: 信息科学*, 2013, 43: 1124–1135]
- 3 Shen H F, Li X H, Zhang L P, et al. Compressed sensing-based inpainting of aqua moderate resolution imaging spectroradiometer band 6 using adaptive spectrum-weighted sparse bayesian dictionary learning. *IEEE Trans Geosci Remote Sens*, 2014, 52: 894–906
- 4 Li X H, Shen H F, Zhang L P, et al. Recovering quantitative remote sensing products contaminated by thick clouds and shadows using multitemporal dictionary learning. *IEEE Trans Geosci Remote Sens*, 2014, 52: 7086–7098
- 5 Muhammad F R, Asmala A, Othman M, et al. Quantifying haze from satellite using haze optimized transformation (HOT). *Appl Math Sci*, 2015, 9: 1407–1416
- 6 Ding C, Dong L L, Xu W H. Image details enhancement by gradient field bi-interval equalization. *Acta Electron Sin*, 2017, 45: 1165–1174 [丁畅, 董丽丽, 许文海. 图像梯度场双区间均衡化的细节增强. *电子学报*, 2017, 45: 1165–1174]
- 7 Kolb H. How the retina works. *Am Sci*, 2003, 91: 29–35
- 8 Tao L, Asari V K. A robust image enhancement technique for improving image visual quality in shadowed scenes. In: *Image and Video Retrieval*. Berlin: Springer, 2005. 395–404
- 9 Land E H. The retinex theory of color vision. *Sci Am*, 1997, 237: 108–129
- 10 Jobson D J, Rahman Z, Woodell G A. Properties and performance of a center/surround retinex. *IEEE Trans Image Process*, 1997, 6: 451–462
- 11 Wang S J, Ding X H, Liao Y H, et al. A novel bio-inspired algorithm for color image enhancement. *Acta Electron Sin*, 2008, 36: 1970–1973

- 12 Webster M. Human colour perception and its adaptation. *Netw Comput Neural*, 1996, 17: 587–601
- 13 Li C Y, Pei X, Zhou Y X, et al. Role of the extensive area outside the x-cell receptive field in brightness information transmission. *Vision Res*, 1991, 31: 1529–1540
- 14 Zhao G Z, Duan H B. Progresses in biological eagle-eye vision technology. *Sci Sin Technol*, 2017, 47: 514–523
- 15 Solomon S G, White A J R, Martin P R. Extraclassical receptive field properties of parvocellular, magnocellular, and koniocellular cells in the primate lateral geniculate nucleus. *J Neurosci*, 2002, 22: 338–349
- 16 Nolt M, Kumbhani R, Palmer L. Contrast-dependent spatial summation in the lateral geniculate nucleus and retina of the cat. *J Neurosci*, 2004, 24: 1708–1717
- 17 Ringach D L, Shapley R M, Hawken M J. Orientation selectivity in macaque V1: diversity and laminar dependence. *J Neurosci*, 2002, 22: 5639–5651
- 18 Chua L, Yang L. Cellular neural networks: theory. *IEEE Trans Circ Syst*, 1998, 35: 1257–1272
- 19 Zhang H G, Wang Z S. Global asymptotic stability of delayed cellular neural networks. *IEEE Trans Neural Netw*, 2007, 18: 947–950
- 20 Yang T, Duan S K, Wang L D, et al. Color image edge extraction using memristor-based CNN. *Sci Sin Inform*, 2017, 47: 863–877 [杨婷, 段书凯, 王丽丹, 等. 基于改进忆阻细胞神经网络的彩色图像边缘提取. *中国科学: 信息科学*, 2017, 47: 863–877]
- 21 Roska T, Boros T, Radványi A, et al. Detecting moving and standing objects using cellular neural networks. *Int J Circ Theor Appl*, 1992, 20: 613–628
- 22 Suzuki H, Matsumoto T, Chua L O. A CNN handwritten character recognizer. *Int J Circ Theor Appl*, 1992, 20: 601–612
- 23 Bouzerdoum A, Pinter R B. Shunting inhibitory cellular neural networks: derivation and stability analysis. *IEEE Trans Circ Syst I: Fundamental Theory Appl*, 1993, 40: 215–221
- 24 Kondo K, Lguch M, Lshigaki H, et al. Design of complex-valued CNN filters for medical image enhancement. In: *Proceedings Joint 9th IFSA World Congress and 20th NAFIPS International Conference*, 2001. 1642–1646
- 25 Kim H, Sah M, Yang C, et al. Neural synaptic weighting with a pulse-based memristor circuit. *IEEE Trans Circ Syst*, 2012, 59: 148–158
- 26 Hyuncheol C, Ram B, Sedong P, et al. Linear programming of voltage-controlled memristors with an anti-serial memristor circuit. In: *Proceedings of IEEE International Symposium on Circuits and Systems*, 2015. 1142–1145
- 27 Hu X F, Feng G, Duan S K, et al. A memristive multilayer cellular neural network with applications to image processing. *IEEE Trans Neural Netw Learn Syst*, 2017, 28: 1889–1901
- 28 Kvatinsky S, Friedman E, Kolodny A, et al. TEAM: Threshold adaptive memristor model. *IEEE Trans Circ Syst*, 2012, 60: 211–221
- 29 Wang L D, Li H F, Duan S, et al. Pavlov associative memory in a memristive neural network and its circuit implementation. *Neurocomputing*, 2016, 171: 23–29
- 30 Yu Y H, Chang C C. A new edge detection approach based on image context analysis. *Image Vision Comput*, 2006, 24: 1090–1102
- 31 Wang L D, Duan M T, Duan S K, et al. Neural networks based on STDP rules and memristor bridge synapses with applications in image processing. *Sci Sin Inform*, 2014, 44: 920–930 [王丽丹, 段美涛, 段书凯, 等. 基于 STDP 规则和忆阻桥突触的神经网络及图像处理. *中国科学: 信息科学*, 2014, 44: 920–930]
- 32 Zheng M W, Li L X, Peng H P, et al. Fixed-time synchronization of memristive fuzzy BAM cellular neural networks with time-varying delays based on feedback controllers. *IEEE Access*, 2018, 6: 12085–12102
- 33 Kvatinsky S, Ramadan M, Friedman E, et al. VTEAM: a general model for voltage-controlled memristors. *IEEE Trans Circ Syst II: Express Briefs*, 2015, 62: 786–790
- 34 Duan S K, Hu X F, Dong Z K, et al. Memristor-based cellular nonlinear/neural network: design, analysis, and applications. *IEEE Trans Neural Netw Learn Syst*, 2015, 26: 1202–1213
- 35 Kim H, Sah M, Yang C, et al. Memristor bridge synapses. *Proc IEEE*, 2011, 100: 2061–2070
- 36 Agaian S S, Silver B, Panetta K A. Transform coefficient histogram-based image enhancement algorithms using contrast entropy. *IEEE Trans Image Process*, 2007, 16: 741–758

Biomimetic adaptive memristive cellular neural network for image enhancement

Yawen ZHENG¹, Xiaofang HU^{2*}, Yue ZHOU³, Li LUO³ & Shukai DUAN²

1. College of Computer and Information Science, Southwest University, Chongqing 400715, China;

2. College of Artificial Intelligence, Southwest University, Chongqing 400715, China;

3. College of Electronic and Information Engineering, Southwest University, Chongqing 400715, China

* Corresponding author. E-mail: huxf@swu.edu.cn

Abstract Cellular neural networks (CNN) have a simple local interconnect structure and high-speed parallel processing capability. As the basic model for a constructing artificial retina, CNNs can be applied to image enhancement in the machine vision field. However, existing image enhancement methods based on CNNs face several challenges. For example, when using common fixed templates, it is difficult to obtain ideal results when handling complex images in real-world applications. In addition, the lack of bionic considerations can cause failures when simulating the powerful global and local adaptive adjustment characteristics of human vision. Therefore, this paper proposes a biomimetic adaptive memristive CNN (BAM-CNN) that combines CNNs, human visual adaptive tri-Gaussian theory and memristor, and nano information devices. The proposed CNN can be used for image enhancement. Specifically, the memristive CNN is constructed based on emerging memristors that are programmable, non-volatile, and synapse-plastic. Merged with the tri-Gaussian model for the receptive field of neurons, an adaptive CNN template design algorithm for biomimetic image enhancement is proposed using the image processing features of the Gaussian kernel function and CNNs. In this paper, gray-scale and color images are taken as target examples in image enhancement experiments. The experimental results demonstrate that the proposed BAM-CNN significantly improves the global brightness, local contrast, and sharpness of the image. This paper provides a novel design and implementation scheme for adaptive templates of CNNs, which can improve CNNs' biomimetic characteristics and hardware implementation feasibility. The proposed BAM-CNN can be used to develop innovative techniques for intelligent image processing besides image enhancement.

Keywords cellular neural networks (CNN), image enhancement, adaptive tri-Gaussian model, biomimetic image processing, memristors

Yawen ZHENG was born in 1999. She managed the first two years of undergraduate study in Software Engineering at Southwest University, Chongqing, China until 2019. She is currently pursuing a bachelor degree in Information Technology at the Faculty of Science, Engineering and Built Environment at Deakin University, Melbourne, Australia. Her research interests include artificial neural networks and image processing.

Xiaofang HU was born in 1984. She received her Ph.D. degree at the City University of Hong Kong, Hong Kong in 2015. She is currently an Associate Professor at the College of Artificial Intelligence, Southwest University. Her current research interests include memristor and memristive systems, neuromorphic computing systems, chaotic systems, and intelligent signal processing.

Yue ZHOU was born in 1985. He received his B.S. degree in Automation and M.S. degree in Control Science and Engineering from Nanjing University, Nanjing, China in 2009 and 2012, respectively. He is currently pursuing a Ph.D. degree at the College of Electronic and Information Engineering, Southwest University, Chongqing, China. His current research interests include machine learning, deep learning, memristive devices and systems, and information security.

Shukai DUAN was born in 1973. He received his Ph.D. degree in Computer Science from Chongqing University, Chongqing, China in 2006. He is currently a Professor at the College of Artificial Intelligence, Southwest University. His current research interests include memristor and memristive systems, neuromorphic computing systems, and intelligent signal processing.