

基于 PC-MSPCNN 模型和 SLIC 的彩色图像分割方法

李新颖*, 冉思园, 廉敬

兰州交通大学电子与信息工程学院, 甘肃 兰州 730070

摘要 针对简单线性迭代聚类(SLIC)方法对图像边缘细节处理效果不佳的问题,提出一种参数可控、改进的简化脉冲耦合神经网络模型(PC-MSPCNN)与 SLIC 结合的彩色图像分割方法。该方法首先改进 MSPCNN 模型的加权矩阵和连接系数,并增设辅助参数,以提高分割准确度。随后将彩色图像输入至 PC-MSPCNN 模型中,依据改进模型中输出 Y 值的分布划分物体的边缘,使分割结果更好地贴合物体的边缘,利用所提出的相似性准则合并散布的碎片,减小后续处理的复杂度;其次,在 SLIC 度量相似距离的基础上引入 PC-MSPCNN 中 RGB 三个通道的内部活动项 U 值,完成对图像剩余部分的加权融合聚类,改进聚类效果。实验结果表明,本文方法能更精确地贴合图像中物体的边界,大幅减少碎片,有效提高图像的边缘贴合度。

关键词 图像处理; 图像分割; 超像素分割; 脉冲耦合神经网络; 简单线性迭代聚类

中图分类号 TP391.41

文献标志码 A

doi: 10.3788/LOP202158.0210023

Color Image Segmentation Method Based on Parameter-Controlled MSPCNN and SLIC

Li Xinying*, Ran Siyuan, Lian Jing

School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China

Abstract The simple linear iterative clustering (SLIC) method does not perform well in edge detail processing in image segmentation. Thus, a modified color image segmentation algorithm is proposed combining a “parameter-controlled modified simplified” pulse coupled neural network (PC-MSPCNN) and SLIC. The proposed algorithm works in two steps. First, the weighted matrix and connection coefficient of the MSPCNN model are improved, and the auxiliary parameters are added to improve the accuracy of the segmentation. Then, the color image is input into the PC-MSPCNN model, and the edge of the object is divided according to the distribution of the output Y value in the improved model so that the segmentation results appropriately fit the edge of the object, and the proposed similarity criterion is used to merge the scattered fragments to reduce the complexity of subsequent processing. Second, based on the measurement similarity of the SLIC, the internal activity term U values of the three RGB channels in the PC-MSPCNN are introduced to achieve weighted fusion clustering for the remaining parts of the image to improve clustering. Experimental results show that the proposed algorithm can accurately fit the edge of an object, considerably reduce the number of pieces, and effectively improve adherence of the image edge.

Key words image processing; image segmentation; superpixel segmentation; pulse coupled neural network; simple linear iterative clustering

OCIS codes 100.2000; 170.1420

收稿日期: 2020-06-01; 修回日期: 2020-06-24; 录用日期: 2020-07-22

基金项目: 国家自然科学基金(61941109, 61861024)、兰州市人才创新创业项目(2014-RC-33)

* E-mail: 929507189@qq.com

1 引言

图像分割是图像处理的关键步骤,其目的是分割出图像中的感兴趣区域,为后续信息提取与识别提供依据。超像素^[1]利用像素之间存在的相似纹理、颜色、形状等特征将像素分类,可以减少不必要的冗余信息,降低后续图像处理的复杂度。现有的超像素分割算法可分为两类^[2],一类是基于图论的能量优化方法^[3-6],一类是基于梯度下降的特征优化方法,后者以 SLIC (Simple Linear Iterative Clustering)^[7]为基础,曾提出一些改进方法,其中有:多特征自适应更新权重的 CAS (Content-Adaptive Superpixel)^[8],它以颜色、纹理、轮廓和空间距离 4 种特征更新权重完成分割;采用线性路径度量特征的 SCALP (Contour Adherence Using Linear Path)^[9],它以颜色和边缘轮廓特征的线性路径寻优;无参数和无迭代的 SLIC——非迭代模式的 SNIC (Simple Non-Iterative Clustering)^[10]。虽然这些算法对 SLIC 进行了不同程度的优化,但边缘贴合度均不够理想。

脉冲耦合神经网络(PCNN)是 Eckhorn 等^[11]于 20 世纪 90 年代提出的一种基于猫的视觉原理构建的简化神经网络模型,该模型指出动物的大脑皮层所发出的脉冲诱发相邻多个神经元同步发放脉冲后,可以迅速找到图像中的同质区域,通过调节神经元的联结强度,可以分割出物体的细节。研究表明,该模型在边缘和细节处理方面具有独特的优势。文献[12]提出一种改进的单元链接脉冲耦合神经网络(UL-PCNN),能够分割不同环境下的绝缘子图像,保留丰富的图像细节。文献[13]运用双通道 PCNN,有效地提取源图像的特征信息,解决了医学图像融合中边缘模糊的问题。文献[14]将外部特征作为输入刺激 PCNN 模型,使得源图像的区域边界融合效果得到了一定的改善。近年来,研究者相继提出了 SPCNN (Simplified Pulse Coupled Neural Network)^[15]和 MSPCNN (Modified Simplified Pulse Coupled Neural Network)^[16],有效克服了上述模型参数较多的缺点,但是对细节、边缘的保留不够完整。

为克服 MSPCNN 模型的不足,本文在 MSPCNN 基础上提出 PC-MSPCNN 模型,进一步提高分割的精确度,并将此模型与 SLIC 进行结合完成图像分割。该方法依据 PC-MSPCNN 中像素对应的神经元输出 Y 值的分布对图像划分边缘,合并像素块和

碎片以有效保留目标物体边界,引入 PC-MSPCNN 中的内部活动项 U 值对像素进行加权融合聚类,以实现良好的分割效果。

2 基本原理

2.1 MSPCNN 模型

研究者在传统 PCNN^[17]的基础上提出 SPCNN 模型,相比 PCNN 模型,该模型有限定的分割步骤,在每一次的迭代中能够自动地选择合适的阈值完成分割。但在联结强度较紧密的区域,需要计算的参数过多,分割过程不够收敛。为此,Lian 等^[16]对 SPCNN 模型进行了进一步改进,提出了 MSPCNN 模型。MSPCNN 的迭代方程为

$$F_{ij}(n) = S_{ij}, \quad (1)$$

$$L_{ij}(n) = \sum_k \sum_l W_{ij}(k, l) Y_{kl}(n-1), \quad (2)$$

$$U_{ij}(n) = \exp(-\alpha) U_{ij}(n-1) + S_{ij} (1 + \beta \sum_k \sum_l W_{ij}(k, l) Y_{kl}(n-1)), \quad (3)$$

$$Y_{ij}(n) = \begin{cases} 1, & \text{if } U_{ij}(n) > E_{ij}(n-1) \\ 0, & \text{else} \end{cases}, \quad (4)$$

$$E_{ij}(n) = \exp(-\alpha) E_{ij}(n-1) + V Y_{ij}(n), \quad (5)$$

其中

$$\alpha = \ln\left(\frac{1}{S'}\right), \quad (6)$$

$$\beta = \frac{1 - S'}{4S'}, \quad (7)$$

$$V = 1 + S'^2 - S'^8, \quad (8)$$

$$W_{ij} = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 0 & 1 \\ 0 & 1 & 0 \end{bmatrix}, \quad (9)$$

式中: S_{ij} 为图像 S 在像素 (i, j) 点的灰度值; $F_{ij}(n)$ 为神经元的反馈输入项; $L_{ij}(n)$ 为链接输入,代表神经元 8 邻域的神经元;所有输入受耦合系数 β 调节形成内部活动项 $U_{ij}(n)$,内部活动项 $U_{ij}(n)$ 受衰减因子 $\exp(-\alpha)$ 调节; $E_{ij}(n)$ 为动态阈值; $Y_{ij}(n)$ 为输出;如果 $U_{ij}(n)$ 大于 $E_{ij}(n)$,神经元点火, $Y_{ij}(n)$ 为 1, $E_{ij}(n)$ 瞬时增大,反之,神经元不点火, $Y_{ij}(n)$ 为 0, $E_{ij}(n)$ 衰减; S' 为标准 Otsu 阈值; α 为衰减因子,随着 S' 的减少而增加; W_{ij} 为突触权重矩阵, $W_{ij}(k, l)$ 表示 W_{ij} 中第 k 行第 l 列元素; V 为权重因子。

2.2 PC-MSPCNN 模型

本文基于 MSPCNN 模型,提出 Parameter-Controlled MSPCNN (PC-MSPCNN) 模型,进一步

扩展了 PCNN 模型的应用范围,该模型的表达式为

$$F_{ij}(n) = S_{ij}, \quad (10)$$

$$L_{ij}(n) = \sum_k \sum_l W_{ij}(k, l) Y_{kl}(n-1), \quad (11)$$

$$U_{ij}(n) = \exp(-\alpha) U_{ij}(n-1) + S_{ij} \left[1 + \beta S' \sum_k \sum_l W_{ij}(k, l) Y_{kl}(n-1) \right], \quad (12)$$

$$Y_{ij}(n) = \begin{cases} 1, & \text{if } U_{ij}(n) > E_{ij}(n-1) \\ 0, & \text{else} \end{cases}, \quad (13)$$

$$E_{ij}(n) = \exp(-\alpha) E_{ij}(n-1) + V K_n Y_{ij}(n), \quad (14)$$

式中: $F_{ij}(n)$ 表示神经元的馈送输入; $L_{ij}(n)$ 表示神经元的链接输入; $U_{ij}(n)$ 表示神经元的内部活动项, 它由三部分组成, 第一部分是迭代状态值, 记录了内部活动项前一次迭代的计算数值, 第二部分为馈送输入值, 第三部分是馈送输入、链接输入和输入图像 Otsu 阈值的耦合值; $E_{ij}(n)$ 表示神经元的动态阈值, 它的大小由幅度值 V 、辅助参数 K_n 和衰减因子 $\exp(-\alpha)$ 共同决定。

PC-MSPCNN 模型参数的含义与 MSPCNN 一致, 但参数的设置方法有较明显区别, 如下所示:

$$\alpha = \ln\left(\frac{1}{S'}\right), \quad (15)$$

$$\beta = \frac{1}{6}, \quad (16)$$

$$V = S'^3 + S'^2 + S', \quad (17)$$

$$K_n = \sqrt{\ln(n+1)}, \quad (18)$$

$$W_{ij} = \exp(-\alpha) \begin{bmatrix} 0.5 & 1 & 0.5 \\ 1 & 0 & 1 \\ 0.5 & 1 & 0.5 \end{bmatrix}. \quad (19)$$

PC-MSPCNN 模型中的参数均为自适应参数, 可直接获得最终的图像处理结果, 该模型参数的设定依据如下:

1) 突触权重矩阵 W_{ij} 表示周围神经元对中心神经元的影响程度。MSPCNN 模型中的 4 邻域突触权重矩阵无法精确地衡量周边神经元对中心神经元的影响, 容易产生欠拟合和欠分割的现象, 而传统的 8 邻域突触权重矩阵容易产生过分割现象。为了防止上述现象的产生, 本研究将 8 邻域突触权重矩阵与一个衰减系数 $\exp(-\alpha)$ 相乘, 保证每次取值在上述两个传统权重值之间, 通过精确合理地控制神经元之间的突触权重值, 可以确保后续分割细节的提取, 因此将该矩阵重新设定为 SPCNN 中 8 邻域突触权重矩阵与 $\exp(-\alpha)$ 的乘积。

2) 耦合系数 β 为神经元间联结强度, MSPCNN 模型中其参数值的设定方法容易产生过分割或欠分割的情况。针对上述情况, 将突触权重矩阵 W_{ij} 的各项系数值相加, 求出倒数, 得到耦合系数 β 的值, 其值为 $1/6$ 。

3) 为了防止神经元二次点火, 影响动态阈值的调节, 设置一个辅助参数 K_n 。

4) 根据文献[15], 当像素对应神经元在第 $l+1$ 次迭代时点火, 其第 $l+2$ 次迭代内部活动项的最小值大于第 $l+1$ 次迭代时的动态阈值, 同时, 其第 $l+1$ 次迭代内部活动项的最大值小于第 l 次迭代时的动态阈值。 $Y(0)$ 、 $U(0)$ 和 $E(0)$ 的初始值设置为 0。当 $l=1$ 时, 可得第二次迭代时神经元的点火条件为

$$\begin{cases} U_{\text{high}}(3) \leq E(2) \\ U_{\text{low}}(2) > E(1) \end{cases}. \quad (20)$$

为了在第二次迭代中增加神经元点火的数量, 防止发生欠分割等情况, 点火条件(20)式被重新设置为

$$U_{\text{low}}(2) > E(1). \quad (21)$$

根据(12)、(15)、(16)和(19)式, 在第二次迭代中, $\sum_k \sum_l W_{ij}(k, l) Y_{kl}(1) = 6$, 其内部活动项为

$$U_{\text{low}}(2) = S_{\text{low}} [1 + \exp(-\alpha) + 6\beta \exp(-\alpha) \cdot \exp(-\alpha)] = S_{\text{low}} M(2). \quad (22)$$

根据(14)、(15)和(18)式, 可得 $E(1) = V$ 。之后根据(20)、(21)和(22)式, 可得

$$S_{\text{low}} M(2) > V. \quad (23)$$

标准化 Otsu 阈值 S' 总是大于 S_{low} , 因此 S_{low} 被替换为 S' , 即

$$S' M(2) > V, \quad (24)$$

V 可取到最大值, 即

$$V = S' M(2), \quad (25)$$

根据(15)、(16)、(18)、(22)和(25)式, 可得

$$V = S'^3 + S'^2 + S'. \quad (26)$$

3 基于 PC-MSPCNN 模型和 SLIC 的彩色图像分割方法

SLIC 方法根据像素间的 LAB 值和空间坐标值对像素进行 K-means 聚类, 聚类后将小区域的像素块合并到邻近超像素块。该方法会导致图像出现过分割和欠分割现象, 分割结果不能有效地贴合物体边缘。PC-MSPCNN 是一种有生物学依据的人工神经网络, 该模型将图像上的每个像素对应为神经元, 对图像中物体的边缘具有高度敏感性。因此将

PC-MSPCNN 模型运用到 SLIC 分割方法中,其过程包括划分、聚类和合并三个步骤。

3.1 划分

PC-MSPCNN 的神经元输出 Y 值,即(13)式的值,包含图像区域边缘特征信息,是界定边缘的有效



依据,它的输出为二值序列,其中图像上从 0 到 1 的变化即为物体与物体间的边缘区域。因此,将图像输入 PC-MSPCNN 模型,根据 PC-MSPCNN 的神经元输出 Y 值分布可得到物体的边缘,如图 1 左图所示。



图 1 碎片合并过程示意图

Fig. 1 Process of generating fragments to merge

3.2 第一次合并

利用神经元输出 Y 值进行划分后,物体的边缘周围聚集了大量的碎片,为了消除划分时产生的冗余数据,将这些碎片进行合并。与 SLIC 合并方法不同,本文合并碎片分两个步骤完成:1)把两个最相似的小像素块合并在一起形成一个像素块,2)把游离的碎片合并到与其最相似的像素块中。最终合并效果如图 1 右图所示。

合并碎片的规则如下:

$$d_{\text{RGB}}(l, p) = \sqrt{(\bar{R}_l - \bar{R}_p)^2 + (\bar{G}_l - \bar{G}_p)^2 + (\bar{B}_l - \bar{B}_p)^2}, \quad (27)$$

$$d_{xy}(l, p) = \sqrt{(\bar{x}_l - \bar{x}_p)^2 + (\bar{y}_l - \bar{y}_p)^2}, \quad (28)$$

$$D(l, p) = d_{\text{RGB}}(l, p) + \gamma d_{xy}(l, p), \quad (29)$$

式中: $D(l, p)$ 表示像素块间的距离, $D(l, p)$ 越大,像素越相似; $d_{\text{RGB}}(l, p)$ 表示颜色距离; $d_{xy}(l, p)$ 表示空间距离; $\bar{R}_l, \bar{G}_l, \bar{B}_l$ 表示彩色图像中像素块 l 的平均 RGB 值; $\bar{R}_p, \bar{G}_p, \bar{B}_p$ 表示彩色图像中像素块 p 的平均 RGB 值; \bar{x}_l, \bar{y}_l 表示像素块 l 的平均坐标; \bar{x}_p, \bar{y}_p 表示像素块 p 的平均坐标; γ 表示权衡因子,

取固定值 2,以增强空间距离的影响,保证像素块形状的规则度。

3.3 聚类

经过上述步骤,只标记出物体的边缘,结果中依然存在需要继续分割的区域,故需将剩下的区域进行聚类。

依照 SLIC 算法,设聚类中心 $C_k = \{l_k, a_k, b_k, x_k, y_k\}, k=1, 2, \dots, K$,其中 l_k, a_k, b_k 为当前子块内所有像素在 l, a, b 各个分量的平均值, x_k, y_k 为子块内所有像素横纵坐标的平均值,子块内每一个像素 p 与聚类中心 C_k 的距离为 $d(p, C_k) = m * d_{\text{lab}} + n * d_{xy}$,其中, d_{lab} 和 d_{xy} 分别表示聚类中心 C_k 所处的像素块中每个像素点 p 与聚类中心 C_k 的颜色距离和空间距离, m 和 n 为控制颜色和空间距离的常数,其数值越大,对分割的影响就越大,反之亦然。由于一个像素对应一个神经元,内部活动项 U 表示神经元的内部行为,故可将其作为像素的特征。因此本文在聚类时引入神经元的内部活动项 U ,即(12)式的值,从而改进聚类效果,使处于边缘的像素能够更准确地聚类到相似的超像素块中,表达式为

$$d_U(p, C_k) = \sum_{q \in L(p)} \sqrt{(u_{1q} - u_{1k})^2 + (u_{2q} - u_{2k})^2 + (u_{3q} - u_{3k})^2} \cdot \omega_{pq}, \quad (30)$$

其中, $L(p)$ 表示以像素点 p 为中心、大小为 3×3 的邻域像素集, u_{1q}, u_{2q}, u_{3q} 分别为像素点 q 在 RGB 三个通道的内部活动项 U 值,通过计算像素点 p 邻

域内的 U 值标准差可以得出各点的权重 ω_{pq} ,权重满足 $\sum_{q \in L(p)} \omega_{pq} = 1$ 。

最后,为提高相似度测量的准确性,将颜色距

离、空间距离和 U 值距离加权融合作为超像素的距离度量准则。根据相似度度量,形成融合模型^[18],表达式为

$$\Delta = \lambda \cdot d_U(p, C_k) + (1 - \lambda) \cdot d(p, C_k), \quad (31)$$

式中: Δ 为距离度量参数, Δ 越小,像素间相似度越大; λ 为控制参数, λ 越大, U 值对相似度度量的影响越大,反之影响越小。利用该公式定义的距离度量方法,对图像像素进行聚类。

3.4 第二次合并

尽管碎片经过第一次合并就能较好地贴合物体的边缘,但加权融合聚类后会导致图像过分割,期间产生了一些碎片,这些碎片需用上述合并碎片的方式再次进行合并,最终完成图像超像素分割。

4 分析与讨论

为了证明本文方法的有效性,实验选用 3 组来

自 Berkeley 自然图像库的图片比较本方法在各环节中相对 SLIC 的优势。算法运行的系统环境为 Windows7,软件环境为 MATLAB R2016b。

参数设置如下: λ 设为 0.8,以提高内部活动项 U 值对分割的影响; m 设为 1, n 设为 20,以增强对形状的控制; α 设置为 2,使超像素形状更加规则;分割数设为 300,以避免过、欠分割现象。

如图 2 所示:对于第一幅图中的建筑物,本文方法得到的边缘轮廓明显,但正中下方的右边建筑物窗沿欠分割,可通过加权融合聚类过程,分割出窗沿的细节,而 SLIC 方法得到的物体边缘不突出,细节有所缺失;在第二幅图中,本文方法得到的大雁边缘清晰,很好地保留了脚部细节,而 SLIC 方法得到的羽翼和脚部细节比较模糊;在第三幅图中,SLIC 方法得到的树枝轮廓不明显,细节损失严重,而本文方法在划分阶段已经可以分割出丰富的细节,符合视觉效果。



图 2 算法各环节下的结果对比。(a)本文算法划分结果;(b)本文算法划分后第一次合并结果;(c)本文算法聚类结果;(d)SLIC 算法聚类结果

Fig. 2 Comparison results of division and clustering for two algorithms. (a) Division results of the proposed algorithm; (b) first merging results after division by the proposed algorithm; (c) clustering results of the proposed algorithm; (d) clustering results of SLIC

为了进一步验证本文方法的有效性,将本文方法的分割结果与 SNIC^[10]、CAS^[8]、SLIC^[7] 和

SCoW^[19]算法分割结果进行对比实验。不同算法的分割结果如图 3 所示。




图 3 算法对比结果。(a)SLIC 算法分割结果;(b)SNIC 算法分割结果;(c)CAS 算法分割结果;
(d)SCoW 算法分割结果;(e)本文提出算法分割结果

Fig. 3 Comparison results for different algorithms. (a) SLIC; (b) SNIC; (c) CAS; (d) SCoW; (e) our algorithm

从主观角度分析:SLIC 分割的边缘轮廓欠缺,细节损失严重;CAS 和 SNIC 分割的细节保留不完整,大雁的尾翼和树木的边缘遗失,CAS 分割的超像素边缘杂乱,超像素块大小不均匀;SCoW 边界基本保留,但细节信息有一定缺失。而本文算法与其他算法相比,能够更完整地保留物体边缘,细节信

息更丰富,对形状的把控更到位,视觉效果更好。

为了更加客观地对上述各种方法进行评价,采用 BR (boundary recall)、UE (under-segmentation error) 和 ASA (achievable segmentation accuracy) 这三个指标来比较各方法的优劣。比较结果如表 1 所示。

表 1 各算法指标对比
Table 1 Index comparison

Algorithm	Building			Bird			Tree		
	BR	UE	ASA	BR	UE	ASA	BR	UE	ASA
SLIC	0.7696	0.2204	0.7620	0.9484	0.0324	0.8747	0.9056	0.0272	0.8220
SNIC	0.6613	0.3105	0.6431	0.9316	0.0411	0.8605	0.9298	0.0284	0.8464
CAS	0.7702	0.0235	0.9322	0.8703	0.0141	0.9066	0.9118	0.0322	0.8634
SCoW	0.9328	0.0285	0.7037	0.7284	0.1495	0.6490	0.8117	0.1346	0.7703
Proposed	0.9763	0.1353	0.8513	0.9682	0.1186	0.9265	0.9438	0.0273	0.8711

从表 1 可看出,本文方法的 BR 值优于其他算法,ASA 值在后两幅图中优于其他算法,UE 值处

于中间位置。各算法的时间对比如表 2 所示,从表 2 可以看出,本文算法分割时间相对较长,这主要

是因为引入 PC-MSPCNN 模型消耗了较多时间。但是总体来说,时间在可承受范围之内。

表 2 各算法时间对比

Table 2 Running time comparison unit: s

Running time	SLIC	SNIC	CAS	SCoW	Proposed
Building	0.9547	0.3945	0.4411	0.4973	1.1965
Bird	0.7937	0.2894	0.3681	0.7804	1.1209
Tree	0.7825	0.2454	0.3818	0.4716	1.1264

综合主客观两个方面的评价结果,本文方法能够较完整地保留边界,能较好地提取物体的细节特征,优于其他几种分割算法。

5 结 论

针对超像素分割方法所存在的边缘贴合度差的问题,利用 PCNN 高度符合人眼视觉的特性,提出了一种基于 PC-MSPCNN 模型和 SLIC 的彩色图像分割方法。利用像素对应的神经元输出 Y 值进行区域划分,从分割结果中可以看出,物体边缘得到很好地保留。利用内部活动项 U 的紧密联结性增加聚类限定条件,提取分割细节,利用相似性准则多次合并碎片,进一步提高边缘贴合度。实验结果表明,本文分割方法符合人眼视觉系统,能较好地划分物体边缘,提取丰富的图像细节,但耗时较长。关于时间的消耗问题有待在后续研究中加以解决。

参 考 文 献

- [1] Ren X F, Malik J. Learning a classification model for segmentation[C]//Proceedings Ninth IEEE International Conference on Computer Vision, October 13-16, 2003, Nice, France. New York: IEEE Press, 2003: 10-17.
- [2] Luo X G, Lü J R, Peng Z M. Recent research progress of superpixel segmentation and evaluation [J]. Laser & Optoelectronics Progress, 2019, 56(9): 090005.
罗学刚, 吕俊瑞, 彭真明. 超像素分割及评价的最新研究进展[J]. 激光与光电子学进展, 2019, 56(9): 090005.
- [3] Gong Y J, Zhou Y C. Differential evolutionary superpixel segmentation[J]. IEEE Transactions on Image Processing, 2018, 27(3): 1390-1404.
- [4] Nakamura K, Hong B W. Fast-convergence superpixel algorithm via an approximate optimization [J]. Journal of Electronic Imaging, 2016, 25(5): 053035.
- [5] Peng J T, Shen J B, Yao A, et al. Superpixel optimization using higher order energy[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2016, 26(5): 917-927.
- [6] Chen J S, Li Z Q, Huang B. Linear spectral clustering superpixel[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3317-3330.
- [7] Achanta R, Shaji A, Smith K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274-2282.
- [8] Xiao X L, Zhou Y C, Gong Y J. Content-adaptive superpixel segmentation [J]. IEEE Transactions on Image Processing, 2018, 27(6): 2883-2896.
- [9] Giraud R, Ta V T, Papadakis N. Robust superpixels using color and contour features along linear path[J]. Computer Vision and Image Understanding, 2018, 170: 1-13.
- [10] Achanta R, Süsstrunk S. Superpixels and polygons using simple non-iterative clustering[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 4895-4904.
- [11] Eckhorn R, Reitboeck H J, Arndt M, et al. Feature linking via synchronization among distributed assemblies: simulations of results from cat visual cortex[J]. Neural Computation, 1990, 2(3): 293-307.
- [12] Du X Y, Zhong J. Insulator image segmentation based on improved unit-linking pulse-coupled neural network [J]. Laser & Optoelectronics Progress, 2019, 56(15): 151005.
杜小燕, 钟俊. 基于改进型 UL-PCNN 的绝缘子图像分割[J]. 激光与光电子学进展, 2019, 56(15): 151005.
- [13] Wang J, Wu X S. Medical image fusion based on improved guided filtering and dual-channel pulse coupled neural networks[J]. Laser & Optoelectronics Progress, 2019, 56(15): 151004.
王建, 吴锡生. 基于改进的引导滤波和双通道脉冲耦合神经网络的医学图像融合[J]. 激光与光电子学进展, 2019, 56(15): 151004.
- [14] Wang Y, Yang Y C, Dang J W, et al. Image fusion based on fuzzy logic combined with adaptive pulse coupled neural network in nonsubsampled contourlet transform domain [J]. Laser & Optoelectronics Progress, 2019, 56(10): 101006.
王艳, 杨艳春, 党建武, 等. 非下采样 Contourlet 变换域内结合模糊逻辑和自适应脉冲耦合神经网络的图像融合[J]. 激光与光电子学进展, 2019, 56(10): 101006.

- [15] Chen Y L, Park S K, Ma Y D, et al. A new automatic parameter setting method of a simplified PCNN for image segmentation[J]. IEEE Transactions on Neural Networks, 2011, 22 (6): 880-892.
- [16] Lian J, Yang Z, Sun WH, et al. An image segmentation method of a modified SPCNN based on human visual system in medical images[J]. Neurocomputing, 2019, 333: 292-306.
- [17] Ma Y D, Li L, Zhan K. Pulse-coupled neural networks and digital image processing[M]. Beijing: Science Press, 2008: 8-22.
- 马义德, 李廉, 绽琨. 脉冲耦合神经网络与数字图像处理[M]. 北京: 科学出版社, 2008: 8-22.
- [18] Yao J, Odobez J M. Multi-layer background subtraction based on color and texture [C] // 2007 IEEE Conference on Computer Vision and Pattern Recognition, June 17-22, 2007, Minneapolis, MN, USA. New York: IEEE Press, 2007: 1-8.
- [19] Hu Z W, Zou Q, Li Q Q. Watershed superpixel [C] // 2015 IEEE International Conference on Image Processing (ICIP), September 27-30, 2015, Quebec City, Canada. New York: IEEE Press, 2015: 349-353.