

利用三维自适应分裂—合并的 MRI 图像分割算法设计

耿 淼¹, 须文波^{1,2}, 秦向东¹

(1. 无锡太湖学院 物联网工程学院, 江苏 无锡 214000; 2. 江南大学 物联网工程学院, 江苏 无锡 210034)

摘要: 为了在医学图像分割中, 发现均匀几何三维区域的复杂形状, 以提高分割准确率, 提出一种基于 3D 几何特征分裂—合并 (ASM) 的脑部 MRI 图像分割算法; 首先构建简单平行六面体的 12 种 3D 区域分割策略, 体积分割技术将整个体积划分为许多大的均匀三维几何区; 然后, 在体积内定义更多小的均匀区域, 以便在随后的合并步骤中有更大的生存概率; 最后, 进行多级区域合并, 合并阶段只涉及复杂 ASM 树的叶子, 考虑灰度相似性和共同边界区的大小, 将小的区域合并为大邻近区; 相比其他几种 MRI 图像分割算法, 提出的方法在分割过程对噪声具有鲁棒性, 提高了分割性能和准确率; 另外提出的方法不需要训练数据集。

关键词: 医学图像分割; 分裂—合并; 平行六面体; ASM 树; 鲁棒性

Design of MRI Image Segmentation Algorithm Using Three Dimensional Adaptive Split—Merge

Geng Miao¹, Xu Wenbo^{1,2}, Qin Xiangdong¹

(1. College of IoT Engineering, Taihu University of Wuxi, Wuxi 214000, China)

(2. Internet of Things Engineering College, Jiangnan University, Wuxi 210034, China)

Abstract: In order to find the complex shape of the 3D uniform geometry in medical image segmentation and to improve the segmentation accuracy, a MRI image segmentation algorithm based on 3D geometry adaptive split—merge is proposed. Firstly, a simple parallel hexahedron 12 kinds of 3D region segmentation strategy is built, and volume segmentation technology is used to divide the whole volume into many large homogeneous 3D geometric regions. Then, more small homogeneous regions in the volume are defined, so as to have a greater probability of survival in the coming merge step. Finally, a multi—level region merging phase involves only complex ASM tree leaves, concerning gray and size of common boundary areas, merging small regions to adjacent areas. Compared with other MRI image segmentation algorithms, the proposed method is robust to noise in the segmentation process, which improves the performance and accuracy of segmentation. In addition, the proposed method does not require training data sets.

Keywords: medical image segmentation; split—merge; simple parallel hexahedron; ASM tree; robust

0 引言

颅脑核磁共振成像 (magnetic resonance imaging, MRI) 图像分割变成了医学图像处理领域一个非常活跃的研究课题^[1-3]。现有的分割技术一般可以分为 3 类: 基于结构分割^[4-6]、随机分割^[7-8]和混合型分割^[9-11]。

随机 3D 分割技术利用统计学进行分割, 在不考虑 3D 区域结构时, 在离散的像素处使用随机分割。阈值方法、聚类算法和马尔可夫场都属于该方法。例如, 文献 [7] 中提出了一种大脑肿瘤分割方法, 这种算法利用小波聚类算法对 MR 图像进行处理完成图像的分割。首先利用小波变换将图像进行分解; 然后运用改进的 FCM 算法在最高小波级别对概要图像进行分割, 由于在低分辨率图像上进行操作, 因此不但抑制了噪声, 而且降低了计算复杂度; 最后利用反向小波变换将低分

分辨率分割图像映射为一个全分辨率图像。文献 [8] 利用一种基于多分辨率的方法移除噪声, 利用 k 均值算法进行分割。噪声腐蚀的图像中存在两个主要的问题: 即不确定性和歧义性, 这两个因素会导致发生分割错误。因此, 利用多分辨率的噪声消除算法对输入图像进行处理, 该过程是预处理阶段, 然后利用 k 均值算法分割图像中的目标。

混合型分割结合了结构和随机计数特征, 包括区域增长^[9]、分类和合并^[10]。区域增加技术通常需要手动交互, 分裂合并分割算法需要区域图中组织的输入数据。文献 [11] 将自适应马尔可夫随机场和 EM 算法相结合, 进而对一幅医学图像进行分割, 这种新算法称为 WMEM 算法, 该算法根据 3 个分割图像对图像中的每个像素进行划分和分类, 一定程度上解决了 MRI 分割问题, 然而, 分割准确率有待进一步提高。

该文提出一种混合方法, 即自适应集合分裂合并 (Adaptive Split Merge, ASM) 分割算法, 该算法同时应用了区域形状和数据值特征。主要创新点总结如下:

1) 图像体分割的复杂特征提取方法, 该方法根据一定标准, 通过选择一个或多个最优分割策略进行特征提取。

2) 为了进行分割过程, 通过利用空间体积连接和同质性, 找到最大同质性轴。在分裂步骤之后, 应用 3D 区域合并。

收稿日期: 2017-01-11; 修回日期: 2017-02-13。

基金项目: 江苏省高校自然科学基金项目 (14KJB520036)。

作者简介: 耿 淼 (1981—), 女, 江苏无锡人, 讲师, 硕士, 主要从事图像处理、智能控制等方向的研究。

须文波 (1946—), 男, 江苏无锡人, 教授, 博士生导师, 硕士, 主要从事智能计算等方向的研究。

1 3D 几何区域分裂

将整个体积 V_0 划分为 N_s 个子区域 $R_i, i = 1, \dots, N_s (V_0 = \bigcup_{i=1}^{N_s} R_i)$, 当 $m \neq l$ 时, 两个子区域 R_m 和 R_l 不相交 ($R_m \cap R_l = \emptyset$). 自适应 3D 区域分割过程是一种自上而下的方法, 该方法假设整个体积是均匀的。如果不是这种情况, 则将该体积递归地分成多面体直到出现 3D 均匀区域。

使用一般线性方程生成的分割策略如下:

$$x' = \begin{cases} \alpha y' + \beta & \left\{ \alpha, \beta \in \mathbf{R}, \lim_{r \rightarrow \infty} \frac{\alpha}{r} \neq 1 \right\} \\ c_2 & c_2 \in \mathbf{R}^+ \end{cases} \quad (1)$$

式中, c_2 为常数。当表示垂直线时, 参数线方程会遇到一些障碍, 因为参数 α 必须趋于无穷, 所以单独使用 $x' = c_2$ 。如果要分割具有维度 $(x'_{\max} - x'_{\min} + 1) \times (y'_{\max} - y'_{\min} + 1) \times (z'_{\max} - z'_{\min} + 1)$ 的体积区域, 沿着相应的 X', Y' 和 Y' 轴确定中点 x'_m, y'_m 和 z'_m 。接着, 通过改变因子 α 可以产生任意可能的分割策略。通过将适当的线性方程应用到每一个属于分割区域的剖面, 创建几个线性平面, 这几个线性平面会将这个区域划分为几个子区域。

分割结果表示:

使用两种不同的方法表示 N_s 个 3D 区域, R_1, \dots, R_{N_s} , 它们均来自体积分割过程。可将体积描述为树, 如图 2 所示。这个树中的每个内部节点相当于一个非均匀区域, 而叶子相当于均匀区域, 相邻区之间的连接 (父代—子代) 表示策略的连通性。每个中间节点的子代相当于这个节点表示生成的区域。对于每个区域, 只储存两个值, 这两个值用于生成当前区域的策略 id。如果所选的分割策略和等价的子代 id 被分配到每个节点 (区域), 则为了定义每个节点的几何特征, 它将构成足够的信息。这样的路径说明了连续策略, 且该连续策略应用于初始体积以获得一个区域。

2 多级区域合并

区域分割的反过程即为区域合并, 合并步骤对 ASM 方法很重要, 因为在这个步骤会执行最终的区域分裂。两级合并之后即为体积分割方法, 两级合并过程旨在生成许多区域, 并将这些区域降至预期的数目 N_{SM} 。

2.1 使用最小生成树方法^[12]的区域分裂

合并阶段只涉及复杂 ASM 树的叶子, 在合并的第一阶段之前, 必须构造复杂 ASM 树, 以表示 3D 同质区域 (叶子) 的 MST 的关系。MST 表示连接的非循环子图 $G = \{(V, E): |V| = N_s, V = \{1, \dots, N_s\}\}$, 该图生成所有树叶节点 R_1, \dots, R_{N_s} 。

假设 3D 区域 R_i 中的灰度值 f_i 来自高斯分布:

$$P(f_i) = \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(f_i - \mu_i)^2}{2\sigma_i^2}} \quad (2)$$

式中, μ_i 和 σ_i^2 表示区域 R_i 的平均数据值和方差, 利用下式估计高斯分布的参数:

$$\hat{\mu}_i = \frac{1}{n_i} \sum_{k=1}^{n_i} f_i, \quad \hat{\sigma}_i = \frac{1}{n_i} \sum_{k=1}^{n_i} (f_i - \hat{\mu}_i)^2 \quad (3)$$

式中, n_i 为区域 R_i 的像素数。在两个给定的区域 R_i 和 R_j 中, 有如下两个可能的假设:

1) H_0 : 应该合并这两个区域。通过单高斯分布 $N(\mu_{ij}, \sigma_{ij})$ 画出所有像素强度, 并假设来自区域 R_i 和 R_j 的像素灰度级值

都是独立的, 联合概率密度 $P(f_1, \dots, f_{n_i+n_j} | H_0)$ 是每个变量相同方差的多维正态分布。

2) H_1 : 应该合并这两个区域。通过各自的高斯分布 $N(\mu_i, \sigma_i)$ 和 $N(\mu_j, \sigma_j)$ 画出每个区域的像素灰度级值。联合概率密度 $P(f_1, \dots, f_{n_i+n_j} | H_1)$ 是两个不同方差的多维正态分布。

来自区域 R_1, \dots, R_{N_s} 的 R_i 和 R_j 似然率的定义为两个假设下概率密度的比值。

$$r_{R_i, R_j} = \frac{P(f_1, \dots, f_{n_i+n_j} | H_0)}{P(f_1, \dots, f_{n_i+n_j} | H_1)} = \frac{\sigma_{ij}^{n_i+n_j}}{\sigma_i^{n_i} + \sigma_j^{n_j}} \quad (4)$$

r_{R_i, R_j} 的值越低, 则越应合并 R_i 和 R_j 。从根部到叶部距离值大的叶区域从非均匀区域的连续分割中生成。对于 R_i 和 R_j 这两个区域, 从根部到这些区域的距离分别定义为 d_{R_i} 和 d_{R_j} 。因此, 这两个区域之间的距离等于 $D_{R_i, R_j} = \|d_{R_i} - d_{R_j}\|$ 。最有可能合并的区域为具有相同数据值统计且距离 D_{R_i, R_j} 小的区域。

对于 $R_i, R_j \in V$ 这两个区域, 方程 $w(R_i, R_j) \in E$ 用于 MST 构造, 表示这两个区域之间边界的权值, 形式如下:

$$w(R_i, R_j) = w(R_j, R_i) =$$

$$\begin{cases} \frac{\max(e_i, e_j)}{\min(e_i, e_j)} r_{R_i, R_j} D_{R_i, R_j} & |\mu_i - \mu_j| \leq \left(1 - \frac{\sigma_0}{\mu_0^2}\right) * T_m \\ \infty & otherwise \end{cases} \quad (5)$$

式中, e_i 为区域 R_i 的相邻区数。MST 具有边界的最小总权值, 该值为生产树中边界的权值总和。两个区域的合并取决于用户提供的阈值 T_m 。因为样本都是正的, 所以参数 $(1 - \frac{\sigma_{ij}}{\mu_{ij}^2})$ 在 0 (低

一致性) 和 1 (高一一致性) 之间变化。如果参数 $(1 - \frac{\sigma_{ij}}{\mu_{ij}^2}) * T_m$ 很

小, 则可能创建具有更低同质性和标准差较大的区域。在每次迭代中, 选择最小值 $w(L_i, L_j)$ 在 MST 中连接的区域 L_i 和 L_j 进行合并。将产生的区域置于树中, 并将其作为深度为 $d_{R_i \cup R_j} = \min(d_{R_i}, d_{R_j})$ 的新亲代下的子代。在每次迭代中, 当更新 MST 时, 利用式 (3) 估计被合并区域的平均数据值和方差。

2.2 使用局部几何信息的区域合并

第二个合并步骤中生成复杂 ASM 树的叶子 (区域)。需要考虑的不仅有它们的灰度值相似性, 还有区域大小和它们共同边界的大小。其目的是将小的区域合并为大邻近区, 只要满足它们的共同边界具有足够的面积且平均强度足够接近^[13]。两个合并子步骤如下:

1) 假设体积域包含 $N_m > N_{SM}$ 个不同的均匀 3D 区域 R_1, \dots, R_{N_m} 。在每个合并步骤中, 选择具有最低分数 $M(R_i, R_j)$ 的 R_i 和 R_j 这两区域进行合并。

$$i, j = \operatorname{argmin}_{i,j} M(R_i, R_j) = \operatorname{argmin}_{i,j} \left(\frac{S_{R_i}}{S_{R_j}} * \frac{\partial R}{C_{i,j}} \right)$$

$$i, j = [1, N_m], i \neq j, C_{i,j} \neq 0, \bigcup_{k=1}^{N_m} R_k = V_0, C_{i,j} \cap \partial R_i \cap \partial R_j$$

$$|\mu_i - \mu_j| \leq T_D, N_{R_i} \leq \frac{N_m}{N_{SM}}, N_{R_j} \leq \frac{N_m}{N_{SM}} \quad (6)$$

式中, S_{R_i} 为较小区域的大小, S_{R_j} 为较大区域的大小, ∂R 表示较小区域的面积, $C_{i,j}$ 表示共同边界的大小。 N_{R_i} 为这个步骤中生成区域 R_i 所需的判别合并步骤的数目, V_0 为总体积。包含一定数量区域的重复合并步骤, 并将产生坏的合并结果。由于一些区域将显著增大, 为了克服这个问题, 使用不等式 N_{R_i}

$\leq \frac{N_m}{N_{SM}}, N_{R_j} \leq \frac{N_m}{N_{SM}}$, 从而阻止区域 R_i 和 R_j 显著增大。对于给定一个区域, 当它们的平均数据值差异适度 (即低于 T_D), 该方法在具有更大的合并概率。每次迭代中, 自动将阈值 T_D 计算为所有区域之间的最小平均数据值差异。每次迭代都会重新估计被合并区域的平均数据值和方差。

2) 该阶段由以上标准的变异构成, 它用于进一步形成更大的区域。为了移除被大区域完全覆盖的区域 (几乎包含于大区域内), 忽略了尺寸因子 $\frac{S_{R_i}}{S_{R_j}}$ 和式 (3) 中的第二个不等式, 主要考虑 $\frac{\partial R}{C_{i,j}}$ 的大小。

3 实验结果与分析

与本文提出的 ASM 算法比较的算法有文献 [7] 提出的改进 FCM^[7]有、文献 [11] 提出的 WMEM^[11]以及文献 [14] 提出的 GHMRF^[14]算法。

3.1 数据集

ASM 体积分割算法是为 MRI 数据集而创建的。本文分割实验使用麦康奈尔脑成像中心创建的大量已被仿真的大脑 MRI 数据体。参数设置如下:

3 种参考形式 (T_1 、 T_2 和质子密度加权 P_D)、5 个级别的噪声 (0%、1%、3%、5%、7%和 9%) 和 3 个级别的灰度不均匀性 (0%、20%和 40%)。

为了评估 ASM 分割算法的性能, 本文使用噪声为 3%、5%、7%、9%和灰度均匀性分为 0%、20%、40%。噪声百分比表示参考脑部组织图像的高斯白噪声与信号的标准偏差百分率。即噪声百分比乘以参考组织的强度范围即为增加到真实和虚构通道的高斯噪声标准方差^[15]。预处理要考虑体积以移除非大脑组织, 所以只使用内部颅腔。 T_1 —加权引起白质 (White Matter, WM) 的神经连接出现白色, 灰质 (Gray Matter, GM) 神经元的聚集出现灰色, 而脑脊髓液 (Cerebral Spinal Fluid, CSF) 出现黑色。体积为 $161 \times 187 \times 161$ 像素, 其同质性为 1mm 像素。每个体积可分为三类 ($N_{SM} = 3$): 白质 (WM)、灰质 (GM) 和脑脊髓液 (CSF)。因为大脑 MRI 数据体的地面事实只对硬分割有效, 所以 ASM 算法只使用一个组织标签标注每个像素。

3.2 大脑 MRI 分割结果

为了研究该方法的性能, 采用真阳性概率 (True Positive Fraction, TPF) 和假阳性概率 (False Positive Fraction, FPF) 评估实验结果, 其定义如下:

$$TPF = \frac{Volume_{seg}^{+} \cap Volume_{groundtruth}^{+}}{Volume_{groundtruth}^{+}} \times 100\% \tag{7}$$

$$FPF = \frac{Volume_{seg}^{-} \cap Volume_{groundtruth}^{+}}{Volume_{groundtruth}^{+}} \times 100\% \tag{8}$$

式中, 运算符+和-表示像素是否属于特定的组织。很显然, 理想分割的 TPF 值等于 1, FPF 等于 0。混淆矩阵是包含 $n \times n$ 矩阵, 该矩阵包含了实际类标签 l_{ac} 的信息和通过分类 l_{cl} 获得的信息。混淆矩阵的对角线元素为正确分类率, 而非对角线元素为误分类率。

将 ASM 算法分割成 3 个主要的类 (WM、GM 和 CSF), ASM 算法在噪声大脑 MRI 分割中执行得很好。为了在真实病理学上分析 ASM 算法的性能, 本文使用包含了肿瘤的 T_1 大

脑 MRI 数据体。其目标是验证 ASM 算法还可以很好地描述肿瘤, 由于这些数据集中, 只有肿瘤被手动描绘, 而对于 WM、GM 和 CSF 组织, 该数据创建者并没有提供相应的注释。图 1 为紧凑脑瘤的特征真实病理, 其中, (a) 沿着 3 个主轴的体积截面实例; (b) T_1 大脑 MRI 数据集的三维视图; (c) 脑部肿瘤的 3D 视图; (d) ASM 算法获得的肿瘤分割结果, 从图中可以看出, ASM 算法正确分类率可高达 93%。

3.3 比较与分析

由表 1~5 的矩阵可以看出, 在多数情况下, ASM 算法的

表 1 对于 0%非匀质的嘈杂(3%噪音)MRI 数据集(3N0RF), 各算法获得的分类结果之间的混淆矩阵

l_{ac}	l_{cl}					
	ASM			FCM		
	CSF	GM	WM	CSF	GM	WM
CSF	0.965	0.008	0.017	0.915	0.061	0.021
GM	0.016	0.965	0.015	0.071	0.920	0.033
WM	0.013	0.020	0.961	0.008	0.013	0.939

l_{ac}	l_{cl}					
	GHMRF			WMEM		
	CSF	GM	WM	CSF	GM	WM
CSF	0.954	0.023	0.012	0.922	0.031	0.019
GM	0.020	0.958	0.028	0.043	0.934	0.021
WM	0.019	0.013	0.952	0.029	0.028	0.954

表 2 对于 0%非匀质的嘈杂(5%噪音)MRI 数据集(5N0RF), 各算法获得分类结果之间的混淆矩阵

l_{ac}	l_{cl}					
	ASM			FCM		
	CSF	GM	WM	CSF	GM	WM
CSF	0.947	0.022	0.013	0.900	0.019	0.013
GM	0.022	0.951	0.032	0.089	0.916	0.060
WM	0.025	0.020	0.948	0.005	0.005	0.920

l_{ac}	l_{cl}					
	GHMRF			WMEM		
	CSF	GM	WM	CSF	GM	WM
CSF	0.930	0.037	0.048	0.910	0.072	0.031
GM	0.044	0.940	0.011	0.048	0.919	0.031
WM	0.019	0.017	0.935	0.019	0.003	0.930

表 3 对于 0%非匀质的嘈杂(7%噪音)MRI 数据集(7N0RF), 各算法获得的分类结果之间的混淆矩阵

l_{ac}	l_{cl}					
	ASM			FCM		
	CSF	GM	WM	CSF	GM	WM
CSF	0.918	0.060	0.022	0.889	0.076	0.027
GM	0.052	0.930	0.040	0.090	0.897	0.066
WM	0.023	0.003	0.932	0.014	0.021	0.900

l_{ac}	l_{cl}					
	GHMRF			WMEM		
	CSF	GM	WM	CSF	GM	WM
CSF	0.906	0.035	0.009	0.891	0.011	0.060
GM	0.043	0.920	0.063	0.090	0.912	0.024
WM	0.044	0.037	0.921	0.012	0.070	0.909

表 4 对于 20%非匀质的嘈杂(7%噪音)MRI 数据集(7N20RF),

各算法获得的分类结果之间的混淆矩阵

l_{ac}	l_{ci}					
	ASM			FCM		
	CSF	GM	WM	CSF	GM	WM
CSF	0.909	0.059	0.037	0.875	0.080	0.077
GM	0.004	0.912	0.032	0.076	0.871	0.017
WM	0.080	0.022	0.925	0.041	0.042	0.899

l_{ac}	l_{ci}					
	GHMRF			WMEM		
	CSF	GM	WM	CSF	GM	WM
CSF	0.899	0.044	0.022	0.880	0.090	0.052
GM	0.012	0.889	0.036	0.043	0.880	0.016
WM	0.082	0.060	0.937	0.070	0.0230	0.925

表 5 对于 0%非均匀的嘈杂(9%噪音)MRI 数据集(9N0RF), 各算法获得的分类结果之间的混淆矩阵

l_{ac}	l_{ci}					
	ASM			FCM		
	CSF	GM	WM	CSF	GM	WM
CSF	0.889	0.070	0.049	0.873	0.100	0.061
GM	0.054	0.909	0.031	0.110	0.880	0.051
WM	0.050	0.014	0.911	0.010	0.012	0.881

l_{ac}	l_{ci}					
	GHMRF			WMEM		
	CSF	GM	WM	CSF	GM	WM
CSF	0.881	0.066	0.025	0.870	0.092	0.046
GM	0.086	0.899	0.067	0.114	0.886	0.058
WM	0.027	0.028	0.902	0.010	0.016	0.889




图 1 紧凑脑瘤的真实特征病理情况

性能优于其他无监督体积分割技术,特别是在非常嘈杂的数据集中,其鲁棒性得到证明。这是因为体积分割和合并过程充分利用了各个区域的几何形状信息。ASM 算法的主要优势是,对一些外部因素的鲁棒性。很多分割技术只能增加一些组织类型的精度。对于 3% 噪声的情况,ASM 算法的平均分割误差为 3.63%,而次优方法即 GHMRF 为 4.53%。

相比于其他方法,ASM 算法的运行时间大于经典分割合并算法的运行时间。当测试使用区域大小限制来终止分割过程

时,ASM 算法所需执行时间更少。然而 ASM 算法中没用区域大小限制来终止分割过程,其原因如下:

1) 分割方法使用最大同质性轴来生成更小数目的小区域。为了突出这个子过程的重要性及有效性,分类步骤可以生成非常小的区域(甚至包含一个像素)。基于本文的实验,体积分割过程生成的非常小的均匀区域数很少。

2) 当考虑区域大小限制时,产生的复杂 ASM 树会生成更大的 4D 均匀区域。在复杂 ASM 树的创建期间,特别是在边界区域的周围,应该生成更小的区域(甚至考虑一个像素)。分割步骤应该避免将小的均匀区域分配到更大区域来保护这些小的均匀区域,因为这涉及合并步骤不能恢复的细节。

通过从大数据集中皮质和分皮质结构提取诸如体积和形状的信息特征,本文提出的方法可用于形态测定分析。在诊所,这些特征很有可能用于评估机理的条件和脑部手术中的条件。在神经科学研究中,源自实验组和对照组分割的统计可用于识别它们之间的结构差异。在疾病研究中,这样的差异可能导致新的病理生物标记的识别。

4 结语

对于体积分割,本文提出了一种分裂合并方法。为了分割整个体积,利用数据值相似性和几何特征。在分割步骤中,检测了多个分割策略,并激活了最合适的策略。最大同质性轴的选择允许对最优区域分割,该分割过程与基于统计学区域数据值相似性和几何距离的区域合并过程相伴。伴随大量的分割策略的使用,该方法能实现良好的区域分割,适合 MRI 数据集区域的丰富几何形状。使用仿真的临床脑 MRI 体积数据集已经测试了 ASM。MRI 体积上的分割结果表明,相比于其他 3D 分割技术,ASM 提供了更好的分割精度。

参考文献:

[1] 张雷,康宝生,李洪安. 基于 Contourlet 变换和改进 NeighShrink 的图像去噪 [J]. 计算机应用研究, 2014, 31 (4): 1267-1269.

[2] 王志东,汪友生,董路,等. 血管内超声图像初始轮廓提取算法的研究 [J]. 计算机测量与控制, 2014, 22 (5): 1490-1492.

[3] Laishram R, Kumar W K, Gupta A, et al. A Novel MRI Brain Edge Detection Using PSOFM Segmentation and Canny Algorithm [A]. International Conference on Electronic Systems, Signal Processing and Computing Technologies [C]. IEEE, 2014: 398-401.

[4] 凌财进,曾婷,张超,等. 一种改进的基于分水岭的图像分割算法 [J]. 计算机测量与控制, 2016, 24 (6): 214-217.

[5] 张艳. 基于数学形态学的医学图像分割方法研究 [D]. 重庆: 西南大学, 2011.

[6] 张旭梅,范虹,乔柱. 融合全局和局部信息的水平集乳腺 MR 图像分割 [J]. 计算机应用研究, 2015, 32 (1): 307-311.

[7] 李小伟,伍岳庆,姚宇. 基于小波多尺度聚类水平集的医学图像分割 [J]. 计算机应用, 2014, 35 (2): 153-158.

[8] 汪亮,金福江,陈峻严. 基于区域生长和 FCM 模糊聚类的颅内出血 CT 图像分割 [J]. 系统仿真学报, 2014, 26 (2): 231-235.

[9] Javed A, Chai W Y, Thuramaiyer N K, et al. Automated segmentation of brain MR images by combining contourlet transform and K-Means clustering techniques [J]. Theor. Appl. Inf. Technol. 2013, 54 (2): 82-91.

[10] Karuppanagounder S, Kalavathi P. Brain segmentation in magnetic resonance human head scans using multi-seeded region growing

[J]. Imaging Science, 2014, 62 (5): 273-284.

[11] 赵雪梅, 李 玉, 赵泉华. 结合高斯回归模型和隐马尔可夫随机场的模糊聚类图像分割 [J]. 电子与信息学报, 2014, 34 (11): 2730-2736.

[12] 叶 伟, 王远军. 基于 Mumford-Shah 理论的最小生成树图像分割方法 [J]. 计算机辅助设计与图形学学报, 2009, 21 (8): 1127-1133.

[13] Conte D, Damiand G. Remove Noise in Video with 3D Topological

Maps [M]. Structural, Syntactic, and Statistical Pattern Recognition. Springer Berlin Heidelberg, 2014: 213-222.

[14] Li Y, Dou Q, Yu J, et al. Automatic Brain Tumor Segmentation from MR Images via a Multimodal Sparse Coding Based Probabilistic Model [A]. International Workshop on Pattern Recognition in Neuroimaging [C]. IEEE, 2015: 41-44.

[15] 游应德, 李成大. 一种边界梯度组合的图像识别技术与分割方法 [J]. 湘潭大学自然科学报, 2014, 36 (2): 99-103.

(上接第 208 页)

针对相机畸变问题, 可以通过 BP 神经网络进行畸变校正; 针对相机的内外参数的求解问题, 本文利用张正友平面标定法和 Matlab tool box 工具^[15], 求解出相机的全部内外参数。对有无 BP 神经网络校正进行了对比试验, 结果如表 3 所示。

表 3 有无 BP 神经网络校正的误差对比

两种情况	相对误差
不加 BP 神经网络校正	0.0073
加 BP 神经网络校正	0.0046

在此之前伍尤富做过类似的研究, 提出过一种神经网络的摄像机平面模板标定方法^[16], 他采用动态因子的学习算法, 没有采用自适应学习率, 精度较高, 但是速度一般。谭晓波使用摄像机平面标定方法^[17], 其没有使用 BP 神经网络进行校正, 得到的标定相对误差为 0.009 86, 而本文方法, 即经过 BP 神经网络校正后的相对误差为 0.004 6。

可以明显看出, 加 BP 神经网络校正的误差小于不加 BP 神经网络的情况, 同时该方法也更加简洁快速。由于采用的是经过 BP 网络校正后的整幅图像的特征点, 而不是采用图像中心附近畸变较小的特征点, 它有明显的优点: (1) 标定的鲁棒性提高了; (2) 避免了传统标定非线性优化的繁琐性; (3) 标定速度和标定精度提高了。

标定精度提高了, 但是误差并没有完全消除。在本文实验中, 误差产生的原因有很多, 主要包括以下几个部分: (1) 棋盘格标定模板的误差; (2) 标定角点提取的误差; (3) harris 测试点的数目不同, 误差大小可能也不一样; (4) 采集图片数量不同, 误差大小可能也不一样; (5) 标定系统的误差, 采取的标定方法不同误差大小可能也不一样, 由于时间有限, 并没有对现在已有的每一种方法进行实验对比。

3 结论

本文选用 BP 神经网络来校正畸变模型, 采用一种改进的 BP 神经网络, 通过分析工业相机标定与神经网络的关系, 提出了基于三线结构光的 BP 神经网络畸变校正的摄像机标定改进方法。matlab 仿真验证了该方法的准确性和有效性, 在一定误差范围内, 神经网络的相机标定能够有效提高三维测量的精度。该方法有效地利用了神经网络的优点, 动态的进行网络学习, 标定速度和标定精度都有所提高。但是, 在短时间内, 没有办法把该标定技术与图像处理技术融合起来, 这是今后的重点研究内容之一。其次, 本文方法虽然能有效降低图像畸变带来的误差, 但是并不代表没有其它方面的误差, 如镜面反

射、漫反射、光源、图片数目、硬件配置等带来的误差。所以, 各种误差产生的原因及解决办法也是今后的研究内容之一。

参考文献:

[1] 郭海丰. 基于神经网络的摄像机标定方法研究 [D]. 沈阳: 东北大学, 2009.

[2] Chen Xiaobo, Xi Juntong, Jin Ye, et al. Accurate calibration for a camera-projector measurement system based on structured light projection [J]. Optics and Lasers in Engineering, 2009: 1-10.

[3] Zhang Zhengyou. Flexible camera calibration by viewing a plane from unknown orientations [A]. Computer Vision. The Proceedings of the Seventh IEEE International Conference on [C]. 1999: 2-8.

[4] Fuqiang Zhou, Yi Cui, Bin Peng, Yexin Wang. A novel optimization method of camera parameters used for vision measurement [J]. Optics & Laser Technology, 2012: 1-10.

[5] 罗 聪. 基于线结构光的三维重构 [D]. 北京: 中国科学院研究生院 (光电技术研究所), 2015.

[6] 贾 丹. 摄像机现场标定算法研究 [D]. 哈尔滨: 哈尔滨工程大学, 2007.

[7] 刘 艳, 李腾飞. 对张正友相机标定法的改进研究 [J]. 光学技术, 2014, 06: 565-570.

[8] 吉 玲. 双目立体视觉中三维重建关键技术研究 [D]. 天津: 天津理工大学, 2015.

[9] 王 政, 胡志雄. 基于张正友标定算法的内参数线性与非线性解算 [J]. 郑州师范教育, 2013 (2): 68-71.

[10] 岳晓峰, 祁 欢. 基于张正友平面模板法的双目立体视觉系统标定 [J]. 机械工程师, 2014 (2): 1-3.

[11] Zhang Zhengyou. A Flexible New Technique for Camera Calibration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence. 2000 11 (22): 3-22.

[12] 符 红. 结构光投影三维轮廓测量系统的标定 [D]. 杭州: 浙江大学, 2013.

[13] 金伟龙, 周美英. 基于不同 BP 网络层数的双目立体视觉标定研究 [J]. 光学技术, 2015 (1): 2-5.

[14] 于 泓. 摄像机标定算法研究 [D]. 济南: 山东大学, 2006.

[15] 徐世杰, 陕 毅. 摄像机标定算法的 MATLAB 语言实现 [J]. 应用科技, 2004 (7): 1-3.

[16] 伍尤富. 基于神经网络的摄像机平面模板标定方法 [J]. 计算机工程与设计, 2008, 29 (6): 1527-1528.

[17] 谭晓波. 摄像机标定及相关技术研究 [D]. 长沙: 国防科学技术大学, 2004.