

文章编号: 2095-4980(2018)02-0307-06

基于自组织神经网络的多模态 MRI 图像分割

王 磊

(安康学院 电子与信息工程学院, 陕西 安康 725099)

摘 要: 磁共振成像(MRI)是一项重要的医学成像技术, 在人体组织器官的诊断治疗方面被广泛应用。在脑肿瘤的临床诊断应用中, 如何实现脑肿瘤图像的有效自动分割是一个研究的难点和重点。利用多个自组织神经网络(SOM)构造一个并行自组织神经网络(CSOM), 将肿瘤图像的分割问题转化为并行自组织神经网络的分类问题。实验表明, 并行自组织神经网络的应用, 有效提高了分割精确度, 有利于自动分割的实现。

关键词: 图像分割; 多模态; 自组织神经网络; 并行模型

中图分类号: TN911.73

文献标志码: A

doi: 10.11805/TKYDA201802.0307

Multimodal MRI image segmentation based on SOM network

WANG Lei

(College of Electronics and Information Engineering, Ankang University, Ankang Shaanxi 725099, China)

Abstract: Magnetic Resonance Imaging(MRI) is a distinctly important technology of medical imaging, which is widely used in the diagnosis and treatment of tissues and organs of the human body. In the clinical diagnosis of brain tumor, it is a challenge for how to achieve effective automatic brain image segmentation. Multiple Self-Organizing feature Maps(SOM) are utilized to create a Concurrent Self-Organizing Map(CSOM) for the whole segmentation process to realize the brain tumor image segmentation. The results show that CSOM model used in the brain tumor image segmentation is effective and successful in this design, improving the precision and reducing the segmentation duration triumphantly, makes a progressive step to the automated segmentation.

Keywords: image segmentation; multimodal; Self-Organizing feature Map; concurrent model

多模态磁共振成像(MRI)图像是利用不同的 MRI 脉冲序列对人体进行磁共振成像的, 由于成像条件不同, 因此所得图像有一定区别, 这样的一组图像被称为多模态 MRI 图像。常用的脉冲序列有自由感应衰减序列(Free Induction Decay, FID)、自旋回波序列(Spin-Echo, SE)、梯度回波序列(Gradient Recalled Echo, GRE)等, 每一种脉冲序列都有相对应的临床应用。不同模态的 MRI 图像对病灶的显示有不同侧重, 鉴于单模态的 MRI 图像显示的信息较少, 医生大多需要对多模态 MRI 图像进行提取分割与分析比较, 才能对患者的病灶区域有更为细致的了解^[1]。医学图像分割是图像分析处理中的关键技术, 根据图像内区域的相似性以及特异性, 将感兴趣的相关部分分离出来, 是一切后续工作的主要前提。分割效果的好坏程度直接影响到信息处理工作以及最终的诊断结论。研究医学图像的分割技术对临床诊断具有重大意义。在医学图像分割过程中, 人工分割费时费力且主观性较大, 因此自动分割技术和少量人工干预的半自动分割技术成为图像分割领域的重要研究分支。医学图像大多存在对比度较低、组织特性不同以及不同组织边界之间存在模糊性等问题, 这都给研究带来了困难。另外, 由于医学图像往往是三维图像或者图像中仅存在灰度信息, 对计算机运算的要求非常高。

由于脑肿瘤 MRI 图像的特点是低对比度和高噪声, 这严重影响了图像分割的精确度, 目前的图像分割方法应用于这一场合多存在一定局限, 如模糊 C-均值聚类算法只利用了灰度之间相关性, 而没能充分利用图像的空间信息, 导致其抗噪性能很差^[2]; 蚁群算法用于脑部 MRI 图像的自动分割, 对于没有噪声的图像, 分割结果的平均正确提取率等指标较为理想, 但对于含有噪声的图像, 则分割精确度明显下降, 分割成绩较差^[3]。

本文将自组织神经网络(SOM)引入到脑肿瘤图像分割的问题中, 利用多个自组织神经网络构造一个并行自组

织神经网络(CSOM), 将肿瘤图像的分割问题转化为并行自组织神经网络的分类问题。CSOM 模型的应用, 能有效提高图像分割的精确度, 更加便于自动分割的实现^[4]。

1 自组织神经网络

人工神经网络理论是基于生物神经系统提出的, 有强大的学习训练能力, 其中 SOM 采用无导师无监督的学习方式, 能够更有效地研究自动化分割脑肿瘤的方法, 并且人工神经网络有良好的并行运算能力, 能够减少运算时间。

CSOM 是在 SOM 神经网络的基础上研究出的一种新模型^[5], CSOM 神经网络的实现是基于多个并发的 SOM 神经网络系统, 每一个 SOM 神经网络系统都经过训练与识别过程并提供一个最理想的结果模式, 对整体利用胜者为王(Winner-Take-All)的竞争原则, 从每一个小的 SOM 神经网络中选取一个最好的结果。V. E. Neagoe 与 A. D. Ropot 已经测试了 2 个重要应用 CSOM 模型: 人脸识别以及多光谱卫星图像分类。实验证明, 利用 CSOM 方法比利用 SOM 神经网络识别的正确率要高, 与此同时, CSOM 与 SOM 相比, 训练时间大大减少^[6]。

SOM 神经网络在训练阶段, 由于获胜神经元的位置不确定, 在随机输入训练样本之后, 输出层中的获胜神经元也不确定, 根据 Kohonen 算法的原理可知, 获胜神经元及其周围的神经元可以对权值系数做不同程度的调整, 调整程度视离获胜神经元的距离而定。按照一定的学习规则调整权系数, 利用多数样本训练权值系数, 在不断调整适应的过程中达到一种对输入模式可以进行识别的层次, 在输出层中培养各神经元成为对某种特定类型敏感神经元, 如果 2 个给定的类型是相似的, 则对 2 个类型敏感神经元也会位置相近, 在工作阶段会利用训练阶段的结果对输入的样本进行识别, 然后分类。

本文中 SOM 神经网络结构分 2 层, 由输入层与输出层组成, 输入层有 n 个节点, 节点个数由输入模式的维数决定, 输出层呈二维阵列分布, 输入层的神经元和输出层的每个神经元都通过权值相互连接, 实现输入层与输出层的全互连, 将收集到的各种信息传送到输出层的神经元中, SOM 的二维拓扑结构如图 1 所示。

SOM 神经网络训练算法流程如下:

1) 权值初始化。对 n 个输入结点到 m 个输出结点的权向量进行归一化处理并赋值最小的随机数, 设置邻域半径的初始值。在此阶段得到 $\hat{W}_j (j=1,2,\dots,m)$, 设置初始学习率 η 初值以及初始邻域半径 $N_{j^*}(0)$ 。

2) 接收输入 t 时刻的输入模式。从训练样本集中随机选取一个输入模式进行归一化处理, 输入层的神经元数目为 n , 得到 $\hat{X}^p (p=1,2,\dots,n)$ 。

3) 计算归一化输入矢量与归一化连接权矢量的欧氏距离:

$$d_j = \left\{ \sum_{i=1}^n [x_i(t) - w_{ij}(t)]^2 \right\}^{1/2} \quad (j = 1, 2, \dots, m) \quad (1)$$

4) 选取优胜节点, 找出最小距离。计算输入节点与权向量的点积, 从中找到点积最大的获胜节点。

$$j^* = \arg \min_{1 \leq j \leq m} d_j \quad (2)$$

5) 更新邻域半径和优胜节点中的权值。训练过程中 $N_{j^*}(t)$ 如图 2 所示, 会随着训练时间收缩。

对优胜邻域 $N_{j^*}(t)$ 内的所有节点调整权值,

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t) [x_i(t) - w_{ij}(t)], i = 1, 2, \dots, n; j \in N_{j^*}(t) \quad (3)$$

式中 $\eta(t)$ 是训练时间 t 的递减函数。

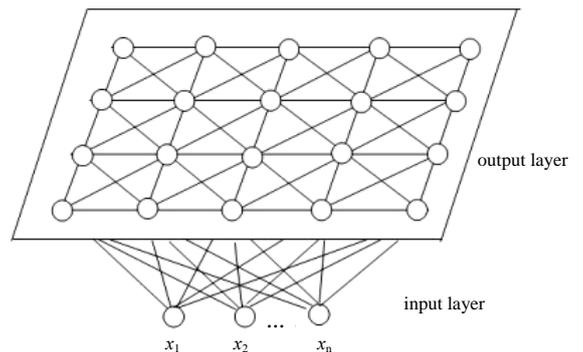


Fig.1 Two-dimensional array of self organizing feature diagram
图 1 自组织神经网络的二维阵列表示

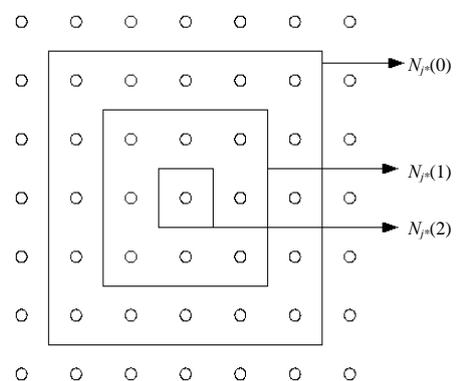


Fig.2 Change law of $N_{j^*}(t)$
图 2 $N_{j^*}(t)$ 变化规律

6) 若还有剩余输入样本集, 令 $t=t+1$, 再返回到步骤 2)继续。学习率在初始时可以设置为接近 1 的常数, 之后随着训练次数逐渐减小。

通过上述过程, 各个 SOM 神经网络训练之后可以得到训练过的权值系数。CSOM 神经网络的实现基于每一个被训练过的 SOM 网络, 从每一个小的 SOM 神经网络中选取一个最好的结果。

基于 CSOM 模型对多模态 MRI 脑肿瘤图像进行分割时的流程如图 3 所示, 提前设定前景及背景像素图像的初始值, 将训练图像样本集输入系统, 训练各个 SOM 神经网络中的权值系数, 在多个并行的 SOM 神经网络中使用胜者为王的学习规则, 训练得到 CSOM 神经网络, 最后在识别阶段, 将测试图像输入系统之中, 会得到一系列的最终分割轮廓图像。

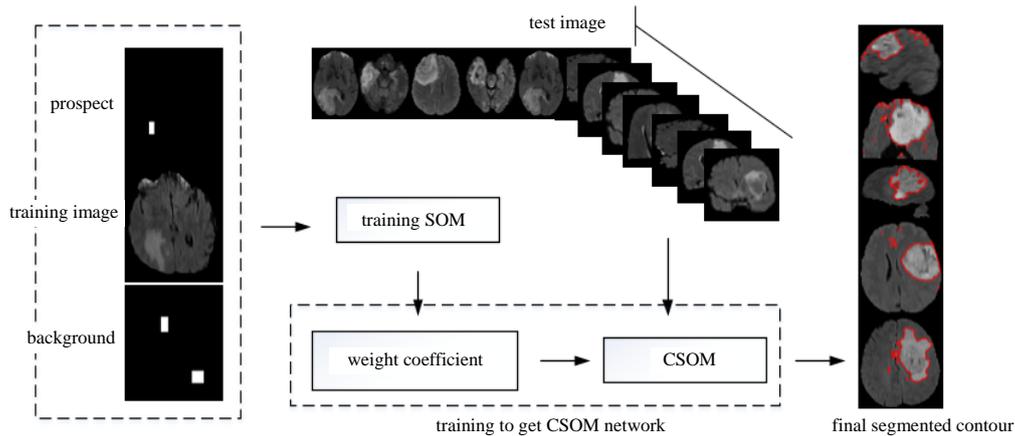


Fig.3 Segmentation process for MRI brain images with CSOM network
图 3 CSOM 网络分割 MRI 脑肿瘤图像的流程

2 实验与分析

本文以自组织神经网络为理论工具, 研究结合多模态 MRI 图像的脑肿瘤检测、分割的方法, 完成肿瘤检测与分割等任务, 图像数据样本集选用 Flair 以及 T2 模态的 MRI 图像, Flair 模态图像中包含着最大限度的病变组织信息, 由此利用 Flair 图像作为分割的基础。因为病变的组织在 Flair 和 T2 中都是亮信号, 利用 T2 模态的分割结果可以更准确地确定肿瘤在 Flair 图像中的区域, 最后结合自组织神经网络算法达到多模态分割的目的。

原始数据来自多模态 MRI 数据集, 利用 ITK-SNAP 软件将 3D 图像读入, 可以观察病变组织的大体位置等信息, 利用软件分别得到 3D 图像中横断面(Axial)、冠状面(Coronal)、矢状面(Sagittal)的脑部切片, 还可以利用软件调节 3D 图像的对比度, 以求得到更好的分割效果。利用 MATLAB 软件的命令行操作, 将图像信号转化为数字信号, 将图像读入转化为矩阵形式, 对图像进行处理, 编写程序分割出脑肿瘤的病变区域, 并利用命令行交互式操作的功能检验此次分割图像的功效。

本文选取了基于边缘检测的算法(边缘算子)、基于区域的分割方法以及可形变模型中的 CV 模型(Active Contours Without Edges)这 3 种基本的分割方法与自组织神经网络算法相对比分析。根据算法原理, 在 MATLAB 软件中对图像样本集进行图像分割, 最后与标准分割图像对比分析, 证明自组织神经网络在多模态 MRI 图像分割中的优越性。

用边缘检测进行分割时, 主要利用 Roberts 边缘算子; 利用基于区域的方法时主要选取阈值分割; 主动轮廓模型中选取 CV 模型对脑肿瘤进行病变区域的提取, 将 3 种方法得到的分割结果与利用 CSOM 模型得到的分割结果进行比较分析, 最后的评价环节是基于 BRATS^[7-8], 如图 4 所示。

区域 T_1 是标准分割的真正的病变区域(蓝线所围区域), T_0 是剩余的正常区域, P_1 是根据算法分割出的预测的病变区域(红线所围区域), P_0 则是根据算法分割预测出的正常区域, P_1 与 T_1

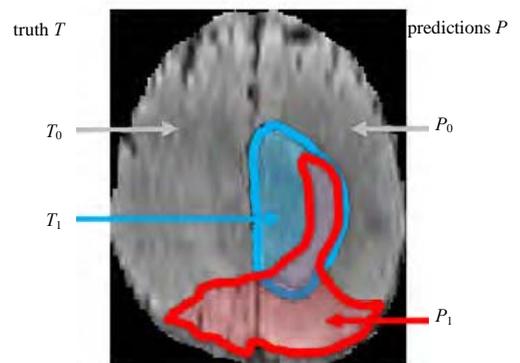


Fig.4 Standard evaluation figure
图 4 标准评价图

有相互重叠的区域,用逻辑运算式可表示为 $P_1 \wedge T_1$ 。利用公式可分别测出分割成绩(Dice score)、敏感性(Sensitivity)、特异性(Specificity)3个参数数值的大小,计算公式如下:

$$Dice(P, T) = \frac{|P_1 \wedge T_1|}{(|P_1| + |T_1|)/2} \quad (4)$$

$$Sens(P, T) = |P_1 \wedge T_1| / |T_1| \quad (5)$$

$$Spec(P, T) = |P_0 \wedge T_0| / |T_0| \quad (6)$$

分割结果如图 5 所示。

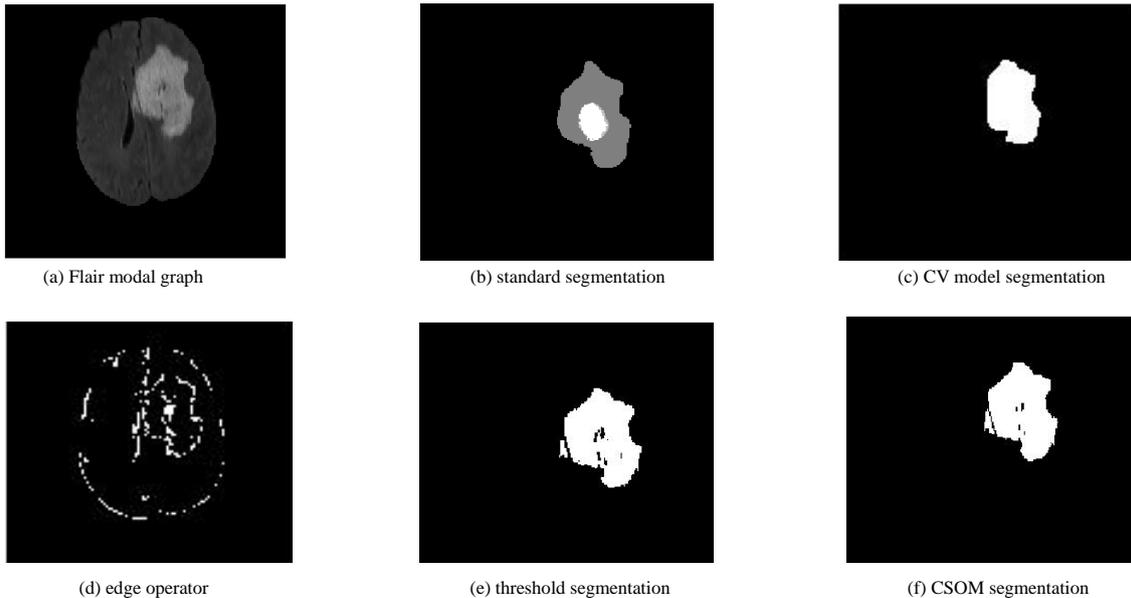


Fig.5 Segmentation results 1 of different algorithms
图 5 不同算法的分割结果比较 1

观察以上图像分割的直观结果可知,利用边缘算子的脑肿瘤分割结果不是很理想,由于边缘算子是提取边缘的算法,直接对原始 Flair 模态图进行分割会产生 2 条轮廓线,其结果与人工操作所得的标准分割结果相差过大。将标准分割结果与另外几种算法的分割结果进行比较可知,基于 CSOM 模型分割结果以及阈值分割结果中的主要病变区域与标准分割结果较为匹配,而基于 CV 模型的分割结果图中的病变区域轮廓则不是特别理想,但是阈值分割的结果图中存在较多的不相干像素点,分割正确率明显低于 CSOM 模型。

鉴于边缘检测的分割效果较差,后文中不再比较这一算法的分割效果,只针对自组织神经网络、CV 模型以及阈值分割等算法进行进一步的参数评估比较。

为此,本文进一步进行另外几组图像的对比,以说明 CSOM 模型分割的效果,其中一组如图 6 所示,对比结果仍然支持以上结论,基于 CV 模型的分割结果的病变区域轮廓不理想;阈值分割的结果虽然轮廓与标准分割较为一致,但是存在较多的不相干点,分割正确率低;只有基于 CSOM 模型分割的结果与标准分割结果最为匹配,分割效果最佳。

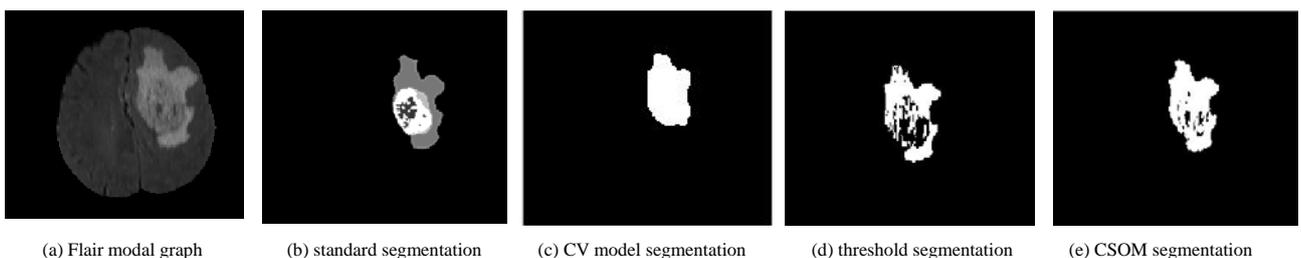


Fig.6 Segmentation results 2 of different algorithms
图 6 不同算法的分割结果比较 2

整个评估过程共采用 6 组图像,为进一步比较,本文针对评价标准中的 3 个参数进行分析,以上 3 种算法的 Dice 参数如图 7 所示。

几种算法的 Sens 参数、Spec 参数、分割时间如表 1、表 2、表 3 所示。

根据上述图表可以得知 3 种算法分割结果的分割成绩 (Dice score)、敏感性(Sensitivity)、特异性(Specificity)、分割时间等参数的大小,明显可以看出基于自组织神经网络的分割结果有明显优势,无论分割成绩、分割速度还是敏感性都更加理想,准确率更高。

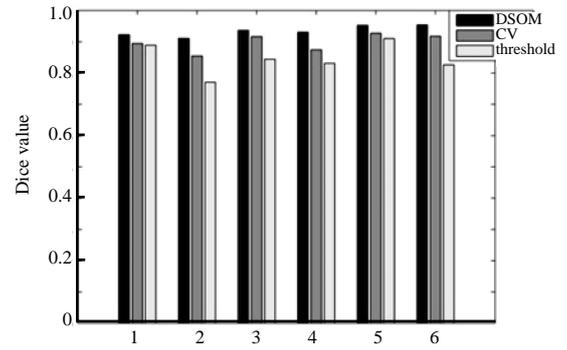


Fig.7 Comparison of Dice parameters
图 7 Dice 参数比较

表 1 3 种算法的 Sens Value

Table1 Sens Values of three kinds of algorithm

algorithm	1	2	3	4	5	6
CSOM	0.859 54	0.836 90	0.883 73	0.873 18	0.921 05	0.933 80
CV	0.838 08	0.859 38	0.887 43	0.829 38	0.890 32	0.926 81
threshold	0.801 75	0.627 09	0.752 06	0.735 10	0.858 62	0.810 60

表 2 3 种算法的 Spec Value

Table2 Spec Values of three kinds of algorithm

algorithm	1	2	3	4	5	6
CSOM	0.999 82	1.000 00	0.999 68	0.999 70	0.999 05	0.998 21
CV	0.997 44	0.988 29	0.995 31	0.993 63	0.997 44	0.992 60
threshold	0.999 65	1.000 00	0.990 36	0.989 21	0.982 18	0.960 12

表 3 3 种算法的分割时间对比(单位: s)

Table3 Segmentation time of three kinds of algorithm(unit:s)

algorithm	1	2	3	4	5	6
CSOM	19.982 41	21.745 67	22.959 57	23.295 93	20.254 95	25.548 21
CV	29.349 25	34.284 27	38.897 31	36.771 46	31.554 72	39.624 75
threshold	38.796 32	51.746 28	44.296 35	52.309 27	49.375 49	60.635 17

3 结论

根据上述分析,自组织神经网络具有明显的优越性,在学习训练方面有强大的自学习能力,且 CSOM 模型的并行能力大大减少了分割时间,提高了实时性,有助于实现病变区域的全自动分割或者半自动分割。同时,基于自组织神经网络的多模态 MRI 图像脑肿瘤分割结果的正确率也比较高。在今后的研究中,可以考虑改进算法或者改变输入的 MRI 模态图,充分利用各个模态的成像表征,结合自组织神经网络实现脑肿瘤图像的全自动分割,并进一步提高准确性。

参考文献:

[1] 万俊,聂生东,王远军. 基于 MRI 的脑肿瘤分割技术研究进展[J]. 中国医学物理学杂志, 2013,30(4):52-57. (WAN Jun, NIE Shengdong,WANG Yuanjun. The research progress of brain tumor segmentation technology based on MRI[J]. Chinese Journal of Medical Physics, 2013,30(4):52-57.)

[2] 余黎煌,钟华,张石. 结合马尔可夫随机场与模糊 C-均值聚类的脑 MRI 图像分割[J]. 中国图象图形学报, 2012,17(12): 1554-1560. (SHE Lihuang,ZHONG Hua,ZHANG Shi. Fuzzy C-means clustering algorithm combined with Markov random field for brain MR image segmentation[J]. Journal of Image and Graphics, 2012,17(12):1554-1560.)

[3] 吴骏,孙明明,肖志涛,等. 联合蚁群算法和 PCNN 的脑部 MRI 图像分割方法[J]. 光电子·激光, 2014,25(3):614-619. (WU Jun,SUN Mingming,XIAO Zhitao,et al. Ant colony optimization combined with PCNN for brain MRI image segmentation[J]. Journal of Optoelectronics · Laser, 2014,25(3):614-619.)

[4] CHAN T F,VESE L A. Active contours without edges[J]. IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society, 2001,10(2):266-277.

[5] HAYKIN S S. Neural networks and learning machines[M]. Prentice Hall, 2008:425-474.