

基于改进的高斯混合模型脑 MR 图像分割

顾升华¹ 杨建伟¹

摘要

MR 图像中常含有偏移场以及噪声现象,传统的高斯混合模型无法得到正确的分类.在高斯混合模型目标函数中加入偏移场估计与噪声去除,完善其分类效果,使分类结果较好地克服偏移场和噪声影响.实验表明,该算法在得到较准确的分类结果的同时还能很好地估计偏移场.

关键词

高斯混合模型;偏移场;去噪

中图分类号 TP391.41

文献标志码 A

0 引言

Introduction

脑部疾病是当前威胁人类身体健康的主要疾病之一.利用脑影像检查技术,定性和定量的分析脑功能,对有效诊断脑疾病有重要帮助.核磁共振成像(Magnetic Resonance Imaging, MRI)以其非介入性、非损伤性、很少受目标物体运动的影响等特点,已被广泛运用于医学图像拍摄.目前,MR 图像在临床医学上起着越来越重要的作用,特别是脑核磁共振成像技术可以提供脑功能信息、解剖信息等,利于有效地诊断.然而,由于人体解剖结构的复杂性、软组织的不规则性以及成像质量受到多种因素的影响,在 MR 图像中经常会出现偏移场现象以及受到噪声的影响,使得脑图像分割很难得到较好的结果^[1-3].偏移场主要与反射频率、静态噪声场等因素有关,几乎每张图像都存在或强或弱的偏移场,有时可以使图像灰度增幅高达 30%,导致图像分析错误;其次,由于机器自身等因素的影响,使得脑图像中经常含有噪声,降低分割精度;另外,脑图像中存在大量的非脑组织与背景,该类信息在整个图像中占据较大的比例,影响分割精度.虽然噪声、非脑组织对分割具有影响,但医学图像分割的主要影响因素是偏移场而不是噪声.

对于给定的观测图像,如何准确地得到真实图像是目前研究的热点. Collewet 等^[2-3]提出一种基于物理影响的模型测量电磁线圈的干扰,以达到求解偏移场的目的,此方法能够处理由电磁干扰产生的偏移场,但对于其它形式的偏移场无能为力. Tincher 等^[4-5]在频率场上分析偏移场,发现该类信息主要分布在低频部分,并在低频域上分离出偏移场,然而该方法忽略了边界信息的影响,导致在边界处易出错.而且当成像仪器中使用定相电磁线圈列时,偏移场会导致不同区域间的灰度差异较大,此时基于低频信息的方法不能得到较好的分割结果.

相对于 MR 图像来说,偏移场往往都比较光滑,许多学者提出多种模型分离真实图像 X 与偏移场 B ,如基于多项式的模型^[6-7];基于离散正余弦变换的模型^[8];基于薄板样条的模型^[9]等.这些方法的精确度由自由度确定,随着自由度的增加,导致计算复杂度的增加,且易陷入局部最优.还有一些模型假设在图像 X 中含有有限个组织,每个组织内部是同质的,利用这一性质将聚类模型引入到偏移场的计

收稿日期 2009-09-14

资助项目 国家自然科学基金(60973157);江苏省高校自然科学基金(08KJB520004)

作者简介

顾升华,男,主要研究图像处理、小波分析. gushenghuamath@163.com

算中. 上述方法大多为先进行灰度不均匀校正, 然后进行后继分割, 但将这两者结合起来的方法很少见到公开报道.

设观察得到的图像为 Y , 真实图像为 X , 偏移场为 B , 噪声为 N , 则有下式成立^[1]:

$$Y = X \cdot B + N. \quad (1)$$

噪声也是影响图像准确分类的一个重要因素, 传统高斯混合模型(简称 GMM 模型)仅依据图像的灰度信息, 而忽略了像素间的空间位置关系, 所以分割模型是不完整的. 一个完整的分割模型应该在充分考虑灰度信息的同时, 考虑像素的空间信息对分割的影响. 文献[10]指出, 同时考虑空间信息与灰度信息的分割算法, 与先进行空间滤波再进行图像灰度分割相比更具优越性.

本文将去偏移场和去噪声引入先验的邻域约束信息, 放入高斯混合模型框架中, 提出改进的算法——加入区域信息的高斯混合模型(简称 GB-GMM 模型)算法. 该算法能够去除偏移场和噪声对图像分类的影响, 同时还能得到偏移场.

1 高斯混合模型及其 EM 算法

Gaussian mixed mode and EM algorithm

高斯混合模型是单一高斯概率密度函数的延伸, 它能够平滑地近似任意形状的密度分布. 设 X 是 d 维随机变量, 若为其中的一个采样, 其高斯混合分布的密度函数为

$$P(x_i | \theta) = \sum_{j=1}^K a_j p(x_i | u_j, \Sigma_j) = \sum_{j=1}^K a_j \frac{1}{\sqrt{(2\pi)^d |\Sigma_j|}} \exp\left(-\frac{1}{2}(x_i - \mu_j)\Sigma_j^{-1}(x_i - \mu_j)\right),$$

其中: K 是混合成分的个数; $\theta = \{a_j, u_j, \Sigma_j\}_{j=1}^K$ 为参数集; a_j 是混合成分系数, 且 $\sum_{j=1}^K a_j = 1$. 若 $\{x_1, x_2, \dots, x_n\}$ 是 X 的一组样本集, 参数 θ 的最大似然估计为

$$\theta_{ML} = \arg \max_{\theta} L(\theta | x_1, \dots, x_n) = \arg \max_{\theta} \sum_{i=1}^n \log(x_i | \theta). \quad (2)$$

EM 算法是一种从“不完全数据”中求解模型分布参数的极大似然估计的方法, 它通过迭代来获得 θ_{ML} . 给出参数集 θ 的当前估计, 则每一次迭代可按照以下两个步骤来对参数集进行重新估计.

步骤 1 计算期望(E-Step)

$$\omega_{ij} = \frac{a_j p(x_i | u_j, \Sigma_j)}{\sum_{l=1}^K a_l p(x_i | u_l, \Sigma_l)}, \quad j = 1, \dots, K; \quad i = 1, \dots, n. \quad (3)$$

其中 ω_{ij} 表示样本 x_i 由成分 j 产生的概率, 即由第 j 个高斯分布产生的后验概率, 即 $p(j | x_i)$.

步骤 2 最大化期望(M-Step)

$$a_j = \frac{1}{n} \sum_{i=1}^n \omega_{ij}, \quad (4)$$

$$u_j = \frac{\sum_{i=1}^n \omega_{ij} x_i}{\sum_{i=1}^n \omega_{ij}}, \quad (5)$$

$$\Sigma_j = \frac{\sum_{i=1}^n \omega_{ij} (x_i - u_j)^2}{\sum_{i=1}^n \omega_{ij}}. \quad (6)$$

该方法虽然可以很好的完成图像分割的任务, 但它在分割过程中假设像素与像素之间是相互独立的, 因此其分类只取决于图像的直方图, 使得该算法对含有偏移场和噪声的图像无法得到准确的分割结果. 本文根据偏移场和噪声的特点, 提出一种改进的分割模型, 使得该方法在分割过程中去除偏移场和噪声的影响, 得到准确的分类结果, 同时还能得到偏移场, 对分割图像进行恢复.

2 改进的各向异性高斯混合模型

Improved anisotropic Gaussian mixed mode

2.1 去偏移场高斯混合模型(BGMM)

因为灰度图像中含有偏移场现象, 使得传统的基于分类的方法不能得到较为精确的结果, 因此需要在分割过程中去除偏移场, 使得分割结果更加精确. 本文将偏移场的去除放入到高斯混合模型框架内, 使去偏移场和分割同时进行, 这样最终得到准确分割结果的同时还能估计出图像的偏移场.

偏移场现象可以被认为是一个光滑的附加场, 大小与图像相同, 该场与图像信息相乘(如式(1)), 得到含有偏移场的图像. 因此在知道图像含偏移场的情况下, 只有很好的估计出真实图像, 才能得到偏移场, 从而对图像进行恢复. 本文采用 EM 算法求出均值信息, 然后对真实图像进行估计, 从而求出图像中的偏移场.

对于灰度不均匀现象的作用过程可以写成 $Y =$

$\mathbf{X} \cdot \mathbf{B}$, 据此对图像进行 log 转换:

$$\log(\mathbf{Y}) = \log(\mathbf{X} \cdot \mathbf{B}) = \log(\mathbf{X}) + \log(\mathbf{B}), \quad (7)$$

记为

$$\mathbf{Y}' = \mathbf{X}' + \mathbf{B}', \quad (8)$$

将乘性场转变为加性场, 这样可以通过 \mathbf{Y}' 和 \mathbf{X}' 的线性关系估计出 \mathbf{B}' . 用式(5)求出的均值估计出真实图像 \mathbf{X}' , 这样即可求出偏移场

$$\mathbf{B}' = \frac{\sum_{j=1}^K (\mathbf{Y}' - u_j) H_j \otimes \mathbf{W}}{\sum_{j=1}^K H_j \otimes \mathbf{W}}, \quad (9)$$

其中: u_j 是将 \mathbf{Y}' 代入式(5)、(8)中求得的第 j 类的均值; H_j 是第 j 类的符号函数, 当前点属于第 j 类其值为 1 否则为 0, 其表达式为

$$H_j(x) = \begin{cases} 1, & x \in s_j, \\ 0, & x \notin s_j; \end{cases}$$

\otimes 是卷积; \mathbf{W} 为低通滤波器.

在利用 EM 算法的每次迭代中, 通过式(6)得到分类结果, 利用式(9)估计出偏移场, 对图像进行恢复, 再将恢复后的图像引入下一次的分类中, 这样可以有效地避免偏移场现象对分类结果的影响. 因此针对含有偏移场现象的图像, 该模型分类结果较传统的 GMM 模型相比更加精确.

2.2 分类结果的优化

除了偏移场, 噪声也是影响分类结果的一个重要因素. 2.1 仅仅考虑了灰度信息, 但是没有考虑像素的空间位置信息, 因此分类结果会对噪声敏感. 当图像具有强噪声的时候, 该算法往往会将噪声点分割出来, 本文利用结构信息对分割结果进行优化, 在消除噪声点对分割结果影响的同时能保留角点信息.

本文引入结构张量信息构造各向异性邻域. 该信息已经被广泛地应用于局部相关性估计等方面, 如指纹图像的方向场估计和图像增强^[12]. 它具有高精度性, 即对图像内容如边缘与角点位置定位准确.

结构张量定义为^[13]

$$\mathbf{J} = \begin{bmatrix} \mathbf{I}_x^2 & \mathbf{I}_x \mathbf{I}_y \\ \mathbf{I}_x \mathbf{I}_y & \mathbf{I}_y^2 \end{bmatrix}, \quad (10)$$

\mathbf{J} 为一半正定矩阵, 用于描述线形结构方向信息, 其特征值为

$$\lambda_1 = \mathbf{I}_x^2 + \mathbf{I}_y^2, \quad \lambda_2 = 0,$$

对应的特征向量为

$$\boldsymbol{\mu}_1 = [\cos \theta \quad \sin \theta]^T, \quad \boldsymbol{\mu}_2 = [-\sin \theta \quad \cos \theta]^T,$$

其中: $\cos \theta = \mathbf{I}_x / \sqrt{\mathbf{I}_x^2 + \mathbf{I}_y^2}$; $\sin \theta = \mathbf{I}_y / \sqrt{\mathbf{I}_x^2 + \mathbf{I}_y^2}$.

此时的 $\boldsymbol{\mu}_1, \boldsymbol{\mu}_2$ 分别为法线和切线方向上的向量; λ_1, λ_2 为对应的特征值. 利用结构信息构造邻域范围

$$N_i = \{x_j \mid x_j \in \Omega_j, j \neq i\},$$

其中: Ω_j 为以 x_i 为圆心的椭圆, 其长轴长为 r , 短轴长为 $r \exp(-C(\lambda_1 - \lambda_2)^2)$; r, C 为常量. 设点 x_i 的坐标为 (a_i, b_i) , x_j 的坐标为 (a_j, b_j) , 若满足如下方程

$$\frac{((a_j - a_i) \cos \theta + (b_j - b_i) \sin \theta)^2}{r^2} + \frac{(-(a_j - a_i) \sin \theta + (b_j - b_i) \cos \theta)^2}{(r \exp(-C(\lambda_1 - \lambda_2)^2))^2} \leq 1, \quad (11)$$

则说明点 x_j 属于邻域 N_i .

根据 Hamersley-Clifford 定理, MRF 可以等效地用 Gibbs 随机场表示^[14]

$$P(x) = \frac{\exp(-U(x))}{\sum_{x \in X} \exp(-U(x))}, \quad (12)$$

其中, $U(x)$ 是能量函数, 其表达式为

$$U(x) = \sum_{c \in C} V_c(x),$$

$V_c(x)$ 为 c 上的势函数. 本文设为

$$V(x_i - x_j) = \beta(1 - \delta(x_i - x_j)),$$

β 为常量; δ 为 dirac 函数.

加入区域信息, 得到概率密度函数

$$P^{(q+1)}(x_i \theta_k^{(q)}) = \frac{p(x_i \mid \theta_k^{(q)}) P^{(q)}(x_i \mid x_j, j \in N_i)}{\sum_{s=1}^K p(x_i \mid \theta_s^{(q)}) P^{(q)}(x_i \mid x_j, j \in N_i)}, \quad (13)$$

其中, $P^{(q)}(x_i \mid x_j, j \in N_i)$ 使用式(12)计算.

当点位于图像内部区域时, 能量较小、方向一致性较差; 位于目标边缘时, 方向一致性较好; 角点区域局部能量较大, 方向一致性较弱. 用特征值表示为当点处于目标内部区域时 $\lambda_1 \approx \lambda_2 \approx 0$; 处于目标边界区域时 $\lambda_1 \gg \lambda_2 \approx 0$; 处于角点区域时 $\lambda_1 \geq \lambda_2 > 0$. 因此, 当点属于目标内部时, $r \exp(-C(\lambda_1 - \lambda_2)^2)$ 接近于 r , 此时, 等价于各向同性 Gibbs 场; 而当点属于目标边界时, $r \exp(-C(\lambda_1 - \lambda_2)^2)$ 较小, 此时为各向异性 Gibbs 场. 然而对于角点, 则是一种特殊情况, 用 Gibbs 理论很容易将其归为噪声, 定义下式来判断当前点是否为角点:

$$S = \frac{\det(\mathbf{J})}{\text{tr}(\mathbf{J})} = \frac{\lambda_1 \cdot \lambda_2}{\lambda_1 + \lambda_2}. \quad (14)$$

显然, $S(\text{角点}) \gg S(\text{边缘}) \approx S(\text{内部区域}) \approx 0$. 为了将角点信息融入到模型中, 本文令此时的

$P^{(q)}(x_i = K | x_j, j \in N_i) = P^{(q)}(x_i = K)$, 即保持角点区域信息不变.

2.3 GBGMM 算法

为了使得高斯混合模型在分类过程中去除偏移场以及噪声的影响, 本文将偏移场和噪声的去除放入 EM 算法的迭代中, 得到本文算法 (GBGMM 算法).

- 1) 对图像进行 \log 变换, 再进行初始分类, 求得初始参数 $\theta^{(0)}$, 设定初始偏移场 $B^{(0)}$.
- 2) 求得新的图像信息 $X' = Y' - B'$.
- 3) 用改进的 GMM 算法对图像进行分类.
- 4) 利用式(9)计算得到 B' .
- 5) 判断是否收敛, 如不收敛转 2), 否则输出结果, 算法结束.

3 试验结果和分析

Results and analysis

本文试验是在 PG2.0/1G 内存的微机上用 Matlab 实现的.

图 1a 为真实的脑 MR 侧面图像, 大小为 192×248 , 图中有较明显的偏移场, 分别使用 GMM 算法和本文算法对其分类. 图 1b 是传统 GMM 算法在类别为 4 类的分类结果, 可以看出, 传统 GMM 算法的分类结果因受偏移场的影响与准确的分类结果相差很大. 图 1c 是本文算法的分类结果, 因为本文算法将分类和去除偏移场同时进行, 有效地避免了偏移场的干扰, 因此得到了准确的分类结果. 图 1d 是本文




图 1 含偏移场的脑 MR 图像分类结果

Fig. 1 Segmentation results of the brain MR image having bias

方法得到的偏移场, 图 1e 是去除偏移场后的恢复图像, 从结果中可以看出, 本文方法可以有效地减少偏移场对图像分类的干扰, 还可以利用估计得到的偏移场对图像进行恢复.

图 2a 为真实的人脑 MR 图像, 大小为 256×256 , 图中具有较明显的偏移场和噪声; 图 2b-2d 分别为 GMM 算法、BGMM 算法、本文算法的分类结果, 可以看出 BGMM 算法可以有效地降低偏移场的影响, 其效果优于 GMM 算法, 但无法去除噪声的干扰, 分割结果不准确; 而本文算法能够有效地去除偏移场和噪声的影响, 分割效果较为准确. 图 2e 为本文算法估计出的偏移场, 这是本文方法的另一大优点: 即将分割与偏移场的估计相结合, 在得到分类结果的同时能估计出图像中的偏移场.




图 2 3T 脑 MR 图像分类结果

Fig. 2 Segmentation results of the 3T brain MR image

4 总结

Conclusion

本文将偏移场信息融入到 GMM 框架内, 有效地解决了强度不均匀现象对分类结果的影响, 还将改进的小邻域去噪引入 GMM 算法的迭代过程中, 在每次分类后都对分类结果进行优化. 实验表明本算法可以有效地抑制噪声的影响.

参考文献

References

- [1] Sled J G, Zijdenbos A P, Evans A C. A nonparametric method for automatic correction of intensity nonuniformity in MRI data [J]. IEEE Trans Med Imag, 1998, 17(1): 87-97
- [2] Collewet G, Davenel A, Toussaint C, et al. Correction of intensity nonuniformity in spin-echo T1-weighted images [J]. Magn Reson Imag, 2002, 20(4): 365-373

- [3] Tincher M, Meyer C R, Gupta R, et al. Polynomial modeling and reduction of RF body coil spatial inhomogeneity in MRI [J]. IEEE Trans Med Imag, 1993, 12(2) :361-365
- [4] Cohen S M, DuBois R M, Zeineh M M. Rapid and effective correction of RF inhomogeneity for high field magnetic resonance imaging [J]. Hum Brain Mapp, 2000, 10(4) :204-211
- [5] Han C, Hatsukami T S, Yuan C. A multi-scale method for automatic correction of intensity nonuniformity in MR images [J]. J Magn Reson Imag, 2001, 13(3) :428-436
- [6] Leemput K V, Maes F, Vandermeulen D. Automated model-based bias field correction of MR images of the brain [J]. IEEE Trans Med Imag, 1999, 18(10) :885-896
- [7] Styner M, Brechbuhler C, Szekeley G. Parametric estimate of intensity inhomogeneities applied to MRI [J]. IEEE Trans Med Imag, 2000, 19(3) :153-165
- [8] Salvado O, Hillenbrand C, Zhang S. MR signal inhomogeneity correction for visual and computerized atherosclerosis lesion assessment [C] // Proceeding of 2004 IEEE International Symposium on Biomedical Imaging, 2004 :1143-1146
- [9] Liew A W C, Yan H. An adaptive spatial fuzzy clustering algorithm for 3-D MR image segmentation [J]. IEEE Trans Med Imag, 2003, 22(9) :1063-1075
- [10] Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via EM algorithm [J]. J of Royal Statist Soc, Series B, 1977, 39(1) :1-38
- [11] Redner J A, Walker A K. Mixture density, maximum likelihood and the EM algorithm [J]. SIAM Review, 1984, 26(2) :195-239
- [12] Perona P, Malik J. Scale-space and edge detection using anisotropic diffusion [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990, 12(7) :629
- [13] 陈允杰. 脑核磁共振图像与虚拟人脑图像分割技术研究 [D]. 南京:南京理工大学, 2008
CHEN Yunjie. Study on brain nuclear magnetic resonance images and virtual brain segmentation technology [D]. Nanjing: Nanjing University of Technology, 2008
- [14] 冯衍秋, 陈武凡, 梁斌, 等. 基于 Gibbs 随机场与模糊 C 均值聚类的图像分割新算法 [J]. 电子学报, 2004, 32(4) :645-647
FENG Yanqiu, CHEN Wufan, LIANG Bin, et al. A new algorithm for image segmentation based on Gibbs randomness field and fuzzy C average value clustering [J]. Journal of Electronics, 2004, 32(4) :645-647

The brain MR image segmentation based on an improved Gaussian mixed mode

GU Shenghua¹ YANG Jianwei¹

¹ School of Math & Physics, Nanjing University of Information Science & Technology, Nanjing 210044

Abstract The conventional GMM mode can't get the precise classification results of magnetic resonance images, which are disturbed by bias field and noises. In order to overcome these limitations, bias field estimation and noise removal are incorporated in GMM mode in this paper. The new mode can reduce the effect of bias field and noise so as to get better classification results. Experiments on the segmentation of magnetic resonance images show that this mode has better effect in image segmentation and is able to have the bias field well estimated at the same time.

Key words Gaussian mixed mode; bias field; noise removal