

基于模糊贝叶斯网络的星形细胞瘤恶性分级的研究

林春漪^{1,2)} 尹俊勋¹⁾ 马丽红¹⁾ 陈健宇³⁾

¹⁾(华南理工大学电子与信息学院, 广州 510640) ²⁾(中山大学生物医学工程系, 广州 510080)

³⁾(中山大学第二附属医院, 广州 510120)

摘要 针对医学影像诊断的复杂性和不确定性,首次提出将模糊贝叶斯网络应用于星形细胞瘤恶性程度的诊断,通过采用条件高斯模型对连续输入进行模糊化处理,利用专家知识和数据,并通过机器学习,建立了星形细胞瘤恶性程度分级的概率模型。两个建模实验结果证明了这种方法的有效性,其中融合了低层视觉特征和中层语义的概率模型比仅仅使用低层视觉特征的模型有更高的识别率,使用60个测试样本,可达81.67%的识别率。该模型解决了贝叶斯网络连续输入的问题,为医生尤其是年轻医生提供了一个针对星形细胞瘤分级的较客观的定量诊断参考,为恶性程度预测提供新的辅助手段。

关键词 模糊贝叶斯网络 星形细胞瘤 诊断模型 机器学习

中图分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2007)04-0661-05

Classification of Astrocytoma Malignant Degrees Based on Fuzzy Bayesian Networks

LIN Chun-yi^{1,2)}, YIN Jun-xun¹⁾, MA Li-hong¹⁾, CHEN Jian-yu³⁾

¹⁾(College of Electronic and Information Engineering, South China University of Technology, Guangzhou 510640)

²⁾(Department of Biomedical Engineering SUN Yat-sen University, Guangzhou 510080) ³⁾(SUN Yat-sen Memorial Hospital, Guangzhou 510120)

Abstract In order to deal with the complexity and uncertainty in medical diagnosis, this paper proposed a new method based on fuzzy Bayesian networks, and applied it to the classification of astrocytoma malignant degrees. Introducing a fuzzy procedure with conditional Gaussian models, aiming to transform a continuous variable into a discrete one, probability model of the classification of the degree of malignancy was established, through machine learning and with expert knowledge and sample data. Two modeling experiments demonstrate the validity of this method. Thereinto, the model fusing low-level image features and high-level semantics outperforms the one with only low-level image features. Using 60 test samples, an accuracy of 81.67% is achieved. This model provides a more objective quantitative reference and novel assistant ways for doctors to predict astrocytoma malignant level.

Keywords fuzzy Bayesian networks, astrocytoma, diagnosis model, machine learning

1 引言

神经胶质瘤是最常见的原发性脑肿瘤,约占颅内肿瘤的40%~50%,而星形细胞瘤为胶质瘤中最常见的一类肿瘤(约占40%),传统的柯氏

(Kernohan)分类法将星形细胞瘤分为I~IV级, I和II级呈良性, III和IV级呈恶性^[1]。脑肿瘤的治疗依赖于肿瘤的恶性程度,判断星形细胞瘤恶性程度对制订肿瘤的治疗方案、评估预后具有重要意义。现有的诊断方法主要是医生根据磁共振影像和临床症状做出定性的诊断,带有一定的主观性,因此借助

基金项目:国家自然科学基金项目(60472063);广东省自然科学基金项目(04020074/CN200402)

收稿日期:2005-10-09;改回日期:2005-12-22

第一作者简介:林春漪(1964~),女,讲师。2006年于华南理工大学获电路与系统专业博士学位。主要研究方向为医学图像处理、医学图像检索、模式识别。E-mail: linchy@mail.sysu.edu.cn

计算机设计一个星形细胞瘤恶性程度分级的诊断模型,采用定量分析的方法为年轻医生提供一个客观的诊断参考是很有意义的。

虽然出现了基于规则的医学专家系统^[2,3]可以解决这些问题,但这些专家系统采用了“if 条件 then 结论”的形式,缺乏对诊断过程的清晰直观的知识表达,对系统的不确定性、数据的不完整性和复杂性不能很好地解决,不能自动更新它的知识规则,系统的知识容量不会超过设计者的设计能力。而结合概率理论和图论的贝叶斯网络能很好地解决这些难题,它可将复杂系统分解成简单系统的组合,而概率理论将保证整个系统的一致性,巧妙地将专家知识和数据有效地结合起来,直观定量地表达了系统中各个因素以及它们之间的关联程度,除了依靠专家知识以外,还可以利用训练数据扩充自身的知识和网络推理能力。另一方面,医学诊断经常需要综合考虑来源于不同模态或设备的影像以及不同类型的临床数据,需要贝叶斯网络这样的智能处理工具。近年来涌现了不少医学贝叶斯网络模型^[4,5],最典型的例子是肺癌的诊断,针对可能导致肺癌的多种因素、症状和后果,建立了一个医学贝叶斯网络。但这些模型采用了离散贝叶斯网络,缺乏处理连续输入的能力,而且至今未见对星形细胞瘤恶性程度分级的模型。如果贝叶斯网络能与把连续数据分成离散集合的模糊方法结合起来,就能有效地处理连续输入的问题,同时由于模糊概念的引入,对整个诊断过程的知识表达更合理。因此本文结合医学影像诊断的实际情况,提出了利用模糊贝叶斯网络对星形细胞瘤恶性程度分级建模,实现其恶性程度的预测,实验结果显示,这种方法是有效的,其中融合了中层语义和底层特征的模型取得了 81.67% 的正确诊断率,接近专家的诊断水平。

2 模糊贝叶斯网络

2.1 贝叶斯网络模型

贝叶斯网络(BN)是指结合概率理论和图论的一种不确定性知识的表达和推理的模型,由有向无环图(DAG)和条件概率矩阵(CPM)组成,如式(1)所示:

$$BN = \langle DAG, CPM \rangle \quad (1)$$

DAG 中每个节点对应有有限集 X 中的随机变量 X_1, X_2, \dots, X_n , 每个变量有一组状态,各变量之间的弧表示事件发生的直接相关,通过条件概率矩阵表达

与相连节点的相关程度。

贝叶斯网络采用概率计算来表达不确定性,这就是条件概率。在贝叶斯网络中,当融合多个信息源时,应用了扩展的贝叶斯规则。如果 e 是多传感器测量的向量, H_i 是假设 H 的一个 S 状态的集合,则有

$$P(H_i | e) = \frac{P(e | H_i)P(H_i)}{\sum_{i=1}^s P(e | H_i)P(H_i)} \quad (2)$$

式(2)中的概率 $P(H_i)$ 被称为先验概率, $P(H_i | e)$ 是状态 i 在给定测量向量 e 的结果后的后验概率。在贝叶斯网络中假定了每个节点是在给定父节点条件下相互独立的,因此有 $P(e) = \prod_{k=1}^N P(e_k | H_i)$ 。其中 N 是信息源的数目。

图 1 表达了一个用来诊断心肌梗塞的离散贝叶斯网络^[4],输入节点代表症状,相当于观察值,每个节点有两个状态,“MI”是输出节点(MI—是,MI—非),后验概率 $P(MI | e)$ 表明了对诊断结论的肯定程度。




图 1 一个典型的医学贝叶斯网络
Fig. 1 A typical medical Bayesian network

2.2 模糊贝叶斯网络

离散的贝叶斯网络中每个节点是离散的,一般通过量化、分类^[6]的方法解决连续输入问题,但这些处理方法是硬处理,而医学影像特征的描述具有模糊性,使用模糊方法将连续输入分成离散集合更合理。我们认识到,概率是随机事件发生的不确定性的一种度量,而模糊是关于事件本身描述的不确定性,可以使用概率来描述模糊度。因此提出通过引入离散隐变量,采用含有条件高斯(CG)密度函数的贝叶斯网络实现连续输入的模糊化处理,并称之为模糊贝叶斯网络。

这类网络中,先引入离散隐变量对连续变量软量化,两个变量之间的映射是由 CG 概率分布决定,即给定离散隐变量的条件下,连续变量的条件分布被假定是多变量高斯分布。这里并非使用传统的模

糊逻辑公式实现连续变量和模糊离散变量之间的映射,而是采用了 CG 模型,即 CG 模型等同于模糊集。因此可以定义模糊贝叶斯网络模型 FBN 如下:

$$FBN = (X, Y, \hat{Y}, L, P) \quad (3)$$

其中, X 表示离散变量, \hat{Y} 表示连续变量; Y 是软量化 \hat{Y} 所定义的离散隐变量,称为模糊变量。 P 是条件概率分布的集合: $P = P_X \cup P_Y \cup P_{\hat{Y}}$, $P_X = \{P(X | \Gamma_x^+), X \in X\}$, $P_Y = \{P(Y | \Gamma_y^+), Y \in Y\}$, $P_{\hat{Y}} = \{P(\hat{Y} | Y), \hat{Y} \in \hat{Y}\}$, $L \subset V \times V$, V 是变量集, Γ_x^+ 表示变量 V 的离散父变量。

一方面,模糊贝叶斯网络可以实现模糊逻辑的功能,对连续输入软量化,更恰当地表达医学诊断特征,同时解决了连续输入的问题;另一方面,同时继承了概率方法的灵活性。

3 影像诊断的模糊贝叶斯网络表达

3.1 模糊贝叶斯网络结构的设计与参数学习

模型(图 2 所示)的结构是根据放射科的专家知识和贝叶斯网络的一般知识设计的。




图 2 基于模糊贝叶斯网络的星形细胞瘤恶性程度诊断模型

Fig.2 A fuzzy Bayesian network-based diagnosis model of astrocytoma malignant degree

其中,节点“恶性程度”是输出节点,状态是两种病症诊断类别,1—良性;2—恶性;

方框为离散节点,圆形为连续节点;“模糊隐变量”是相应连续变量的软量化,相当于计算获得的中层语义;

“图像中层语义特征”包括“部位”、“形状是否分叶”、“边界是否清晰”、“坏死”、“水肿”、“囊变”等特征,由医生判断给出;

“图像低层视觉特征”包括“T1 肿瘤/正常的灰度对比度”、“肿瘤 T1 均匀度”、“T2 肿瘤/正常的灰度对比度”、“肿瘤 T2 均匀度”、“肿瘤 T1 增强均匀

度”、“肿瘤 T1 增强的明显程度”等低层特征,通过图像处理技术直接从相应图像提取,是用连续量表达的特征矢量。

网络的学习采用了机器学习的方法,使用 EM (expectation maximum) 技术对网络进行机器学习训练^[7],得到一个用概率矩阵表达的模型。

3.2 星形细胞瘤恶性分级的模糊贝叶斯网络推理

网络训练后,输入测试样本,提取特征,即可通过概率推理得出相应的“良性”和“恶性”的概率,推理流程图如图 3 所示。

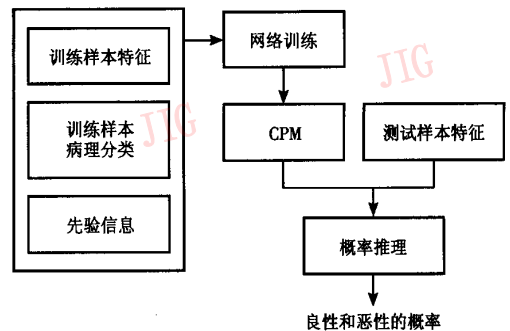


图 3 星形细胞瘤恶性分级的模糊贝叶斯网络推理流程图

Fig.3 A fuzzy Bayesian network-based inference flow of astrocytoma malignant level

4 实验结果

4.1 融合了中层图像语义和低层图像特征的诊断模型

数据来源是 Philips 1.5 Tesla MR 扫描仪(采用标准正交头线圈)产生的 MRI 图像(256×256 大小),本实验中,采取了统计训练样本数目来评估先验概率,即节点“恶性程度”的每个状态的先验概率均为 50%;选用了 70 个训练样本(其中 35 个良性星形细胞瘤,35 个恶性星形细胞瘤,共 210 幅图像),60 个测试样本(包括 30 个良性以及 30 个恶性星形细胞瘤);选取决策阈值为 0.5,实验结果如表 1。

表 1 诊断星形细胞瘤恶性程度的测试结果

Tab.1 Benign vs. malignant of astrocytoma classification results

样 本	样本总数	正确分类数目	正确率(%)
训练样本	70	70	100
测试样本	60	49	81.67

表 1 的分级正确率是输出结果与病理分级结果比较而得到的,可以看出,训练后的模型对训练样本的识别率达 100%,对测试样本的识别率达 81.67%,取得了令人满意的诊断结果。

举例说明推理结果:图 4 是一个恶性级别为 III 级的星形细胞瘤样本,根据图像特征的输入,网络输出为:“良性”的概率为 0.0026;“恶性”的概率为 0.9974,最后诊断为恶性。

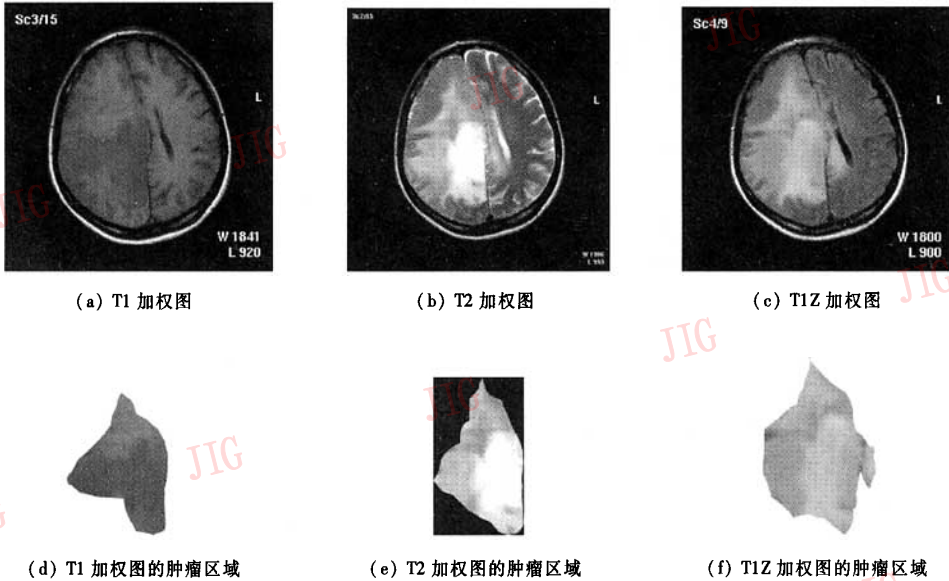


图 4 一个恶性级别为 III 级的星形细胞瘤样本
Fig. 4 A malignant astrocytoma sample of level III

4.2 只使用图像低层特征的诊断模型

下面的实验是在图 2 的基础上,只使用图像低层特征,同样选取了决策阈值为 0.5,实验结果如表 2 所示。可以看出,只使用图像低层特征的诊断模型识别率低于结合中层图像语义特征和低层图像特征的诊断模型。

表 2 只使用图像低层特征的测试结果

Tab.2 Benign vs. malignant of astrocytoma classification results with alone low-level features

样 本	样本总数	正确分类数目	正确率(%)
训练样本	70	59	84
测试样本	60	47	78.33

5 讨 论

本文首次提出将模糊贝叶斯网络应用于星形细胞瘤恶性程度的诊断,建立一个恶性分级的可计算的概率模型,以概率的形式定量地预测恶性程度。

两个建模实验证明了这种方法的有效性,其中结合中层语义和低层视觉特征的诊断模型取得令人满意的诊断结果,正确诊断率达到 81.67%。将模糊理论和贝叶斯网络结合起来,解决了连续输入问题,更合理、定量地推理了诊断结论以及实现了诊断过程的知识表达,很好地解决了医学诊断中的不确定性和模糊性,尤其是为年轻医生的分级诊断提供客观的参考和新的计算机辅助手段。

实验结果表明,结合图像中层语义和低层特征的诊断模型优于只使用图像低层特征的诊断模型。与其他分类模型(比如神经网络、支持向量机)比较,该诊断模型具有以下优势:

(1)由于将模糊和贝叶斯网络结合起来,有效地处理了连续输入的问题,更合理地实现了诊断过程的知识表达;

(2)充分考虑了医学专家知识和利用了样本数据进行机器学习,因而在样本量有限的情况下也能得到满意的结果,避免了单独使用其中任何一种的弊端,更灵活而且可解释;

(3)避免了数据过拟合的问题;

(4)每个节点具有明确的语义,更好地表达了整个诊断过程的知识结构,从微观上描述了每个节点的概率变化,而且也从宏观上描述了推理产生诊断结论的分析;

(5)这种设计思想可以推广到其他病症的诊断,具有可推广性;

(6)能将不同模态的图像特征和不同类型、不同层次的数据融合起来,适合于多模态医学影像的诊断,很好地解决了影像诊断的复杂性问题。

利用机器学习的自动计算学习算法是依赖于样本的,样本量是否足够也与样本分布和所解决的识别问题有关,因此样本的选择非常重要。本实验采用的70个训练样本尽量覆盖了星形细胞瘤的典型病例。由于MRI不是分子级成像,从MRI得到的信息不能完全可靠地得出诊断结论,而病理检查的结果才是金标准,依据MRI的诊断只是手术前的预测,对手术方案的制订有指导作用,81.67%的识别率已接近有多年经验的影像科医生的正确诊断率。虽然融合图像中层语义和低层视觉特征的模型识别率比仅仅使用低层视觉特征的模型只提高了3.34%,但从测试训练样本的分级结果可知,前者比后者更好地拟合了训练样本,相信增加样本量可以进一步改善识别率。因为采集样本的客观困难,所以把增加样本量以及进一步优化分级模型作为下一阶段的工作目标,并且考虑通过进一步筛选图像特征和增加与诊断密切相关的图像特征以及临床数据,筛选训练样本,改善特征提取精度,进一步提高

识别率。因此下一阶段的工作是提高图像特征提取的自动化程度,采用更多的训练数据扩充模型自身的知识和网络推理能力,针对模型的优化做深入研究,进一步提高识别率,同时在临床应用中进一步完善。

参考文献(References)

- 1 Zhang Xue-lin. Medical Imageology [M]. Beijing: People's Medical Publishing House, 2001, 59. [张雪林著. 医学影像学[M]. 北京:人民卫生出版社,2001:59.]
- 2 Apte Chidan, Weiss Sholom. Data mining with decision trees and decision rules [J]. Future Generation Computer Systems, 1997, 13(2-3): 197~210.
- 3 YE Chen-zhou, YANG Jie, GENG Dao-ying, et al. Fuzzy Rules to Predict Degree of Malignancy in Brain Glioma [EB/OL], <http://www.paper.edu.cn>, 2005-04-18.
- 4 Daniel Nikovski. Constructing Bayesian networks for medical diagnosis from incomplete and partially correct statistics [J]. IEEE Transactions on Knowledge and Engineering, 2000, 12(4): 509~516.
- 5 Basilio Sierra, Iñaki Inza, Pedro Larrañaga, et al. Medical Bayes Networks [A]. In: Lecture Notes in Computer Science [M]. Berlin Heidelberg: Springer-Verlag, 2000: 4~14.
- 6 Jiebo Luo, Andreas E Savakis, Amit Singhal. A Bayesian network-based framework for semantic image understanding [J]. Pattern Recognition, 2005, 38(6): 919~934.
- 7 David Heckerman. A tutorial on learning with Bayesian network [R]. TR MSD-TR-95-06, Redmond, WA, USA: Microsoft Research Advanced Technology Division, Microsoft Corporation, 1995.