

基于哈希理论和线性近邻传递反馈的乳腺X线 图像肿块检索方法*

李艳凤¹⁾ 陈后金^{1)†} 曹霖¹⁾ 韩振中¹⁾ 程琳²⁾

1)(北京交通大学电子信息工程学院, 北京 100044)

2)(北京大学人民医院乳腺中心, 北京 100044)

(2014年4月17日收到; 2014年6月14日收到修改稿)

在乳腺X线图像肿块检测中存在较高的假阳性率, 通过基于内容的肿块检索, 将待判定肿块与已确诊肿块进行相似性分析, 可有效降低假阳性率. 本文提出了一种结合可区分锚点图哈希和线性近邻传递的乳腺图像肿块检索方法. 针对传统锚点图哈希在相似度定义中没有考虑病理相关性的问题, 引入病理类别至锚点图哈希图像相似度计算, 提出了可区分锚点图哈希以重新表示图像. 利用线性近邻传递作为相关反馈技术, 基于图像底层特征表达与图像高层语义间的学习机制, 实现交互式肿块图像检索. 采用北京大学人民医院乳腺中心提供的临床图像作为实验数据, 实验结果表明, 引入病理类别的可区分锚点图哈希图像表达在肿块相似性分析上优于传统锚点图哈希. 相比于现有方法, 本文提出的方法在肿块检索性能上得到明显提高.

关键词: 乳腺X线图像, 肿块检索, 相关反馈, 哈希理论

PACS: 87.57.N-, 42.30.Va, 07.05.Pj

DOI: 10.7498/aps.63.208701

1 引言

乳腺癌是女性最常见的恶性肿瘤之一^[1], 近50年来全世界范围内妇女乳腺癌的发病率和死亡率呈逐渐上升趋势^[2]. 随着我国经济的发展和人们生活方式的改变, 我国已成为乳腺癌发病率增长速度最快的国家之一, 且呈年轻化趋势^[3]. 在对乳腺癌发病原因和预防尚未完全清楚的情况下, 对乳腺癌的早期检测和诊断是提高患者治愈率和降低死亡率的关键^[4]. 在众多乳腺摄影技术中^[5-9], 乳腺钼靶X线摄影术是临床上最常用的乳腺癌疾病筛查手段之一. 筛查过程造成乳腺X线图像大量增加, 放射科医生阅片工作量繁重. 同时相比于西方女性, 我国女性多为致密型腺体乳房^[10], 腺体组织相互叠加, 产生类似病变的特征或将病变掩盖, 病变的检测难度进一步增大. 为减轻医生工作量且提高检测精度, 计算机辅助检测 (computer-aided

detection, CAD) 被引入到乳腺癌的检测中.

肿块是乳腺癌的主要表现形式之一, 现有CAD系统在提高肿块检测率的同时会产生较高的假阳性. 为提高CAD系统性能, 同时为医生提供视觉相似临床相关的可视结果, 基于内容的图像检索 (content-based Image retrieval, CBIR) 在乳腺图像肿块检测中的应用逐渐受到人们的重视. 在CBIR中, 首先构建一个大量且分布广泛的已确诊感兴趣区域 (region of interest, ROI) 参考图像库, 这些ROI包含肿块ROI和疑似肿块的正常组织ROI. 然后从参考图像库中检索到与待判定ROI最相似的ROI, 并将结果返回显示给放射科医师, 为医生提供辅助检测结果或增加医生对当前病例诊断结果的可信度. 计算机返回的检索结果通常与人类视觉存在一定的差异, 因此Rui等^[11]将相关反馈机制集成到CBIR中, 提出带有相关反馈机制的检索系统. 在该系统中, 放射科医生对计算机检

* 国家自然科学基金 (批准号: 61271305, 61201363) 和高等学校博士学科点专项科研基金 (批准号: 20110009110001) 资助的课题.

† 通讯作者. E-mail: hjchen@bjtu.edu.cn

索到的图像进行标记, 与待判定ROI相关和不相关的图像反馈给计算机, 实现对检索结果的交互式修正, 该检索系统的结构如图1所示.

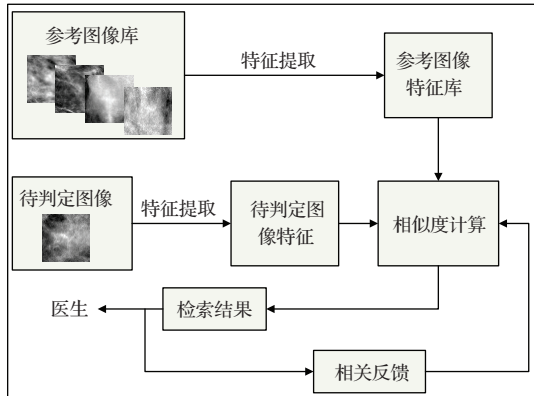


图1 带有相关反馈的乳腺图像检索系统流程

目前, 基于内容的肿块检索方法主要有: Alto等^[12]首先对肿块进行精确分割, 然后提取形状、边缘锐度和纹理特征对良性及恶性肿块ROI进行检索. 然而在致密型乳腺X线图像中, 很难得到准确的肿块边缘. Li等^[13]使用相关系数对疑似肿块ROI和肿块ROI进行检索, 该方法首先对ROI进行高斯金字塔分解, 得到分辨率最低层的图像最大相关系数, 然后使用位置映射和局部搜索, 得到分辨率最高层的最大图像相关系数, 将其作为图像间的相似度进行检索. Siyahjani等^[14]首先对ROI进行多级小波分解, 计算每级小波分解子带的灰度共生矩阵, 从灰度共生矩阵中提取纹理特征以计算图像间的相似度, 从而对肿块和疑似肿块ROI进行检索. Georgia等^[15]比较了几种基于熵的相似度测度在肿块和疑似肿块ROI中的检索性能, 包括联合熵、条件熵、互信息、归一化互信息、平均KL散度(Kullback-leibler divergence, KLD)、最大KL散度、Jensen散度(Jensen divergence, JD)和代数几何平均散度(arithmetic geometric mean divergence, AGMD). 文献^[15]指出, 相比于其他熵测度, 互信息和KLD的检索性能较好. Liu等^[16]使用锚点图哈希(anchor graph hashing, AGH)作为图像新的表达方式, 然后使用AGH表达的汉明(Hamming)距离对肿块和疑似ROI进行检索, 获得了较好的检索性能.

乳腺图像肿块检索需保证检索到的图像与待判定ROI既有视觉相似性, 又具有病理相关性^[17]. 目前基于AGH的图像表达在肿块检索中有较好的性能, 但传统AGH^[16]在肿块检索中存在以下两个

问题: 1) 在定义ROI间的相似度时, AGH没有考虑ROI间的病理相关性; 2) 传统AGH检索方法没有使用相关反馈机制, 不能实现医生与计算机的交互. 为解决上述问题, 本文在AGH的基础上, 提出可区分AGH (discriminating AGH, DAGH) 以重新表示图像, 相比于传统AGH, DAGH将图像的病理类别信息引入到ROI相似度计算, 可同时考虑到视觉相似性和病理相关性. 然后将线性近邻传递(linear neighborhood propagation, LNP)作为相关反馈技术, 并与DAGH图像表达结合, 实现交互式肿块图像检索. 本文提出方法无须对ROI内的肿块进行边缘分割, 基于整个ROI即可实现检索.

本文组织安排如下: 第2节主要介绍了DAGH图像表达的基本思想, 第3节介绍了LNP反馈的相关概念, 第4节给出了实验数据和本文方法的实现过程, 第5节对实验结果进行了分析, 第6节为本文的结论.

2 基于DAGH的图像表达

2.1 AGH图像表达

设参考图像库中每个图像的表达向量为 $\{\mathbf{x}_i \in \mathbb{R}^d, i = 1, 2, \dots, n\}$, d 为图像表达向量的长度, n 为参考图像的个数, 这样每个图像被描述为多维特征空间中的一个“点”. AGH的目标是寻找到一种新的图像表达方式, 使得输入空间中相似的图像向量在AGH中具有相似的表达形式^[18]. 令 \mathbf{A}_{ij} 为输入空间图像对 $(\mathbf{x}_i, \mathbf{x}_j)$ 的相似度, 图像的AGH表达由矩阵 \mathbf{Y} 描述, 其满足如下条件:

$$\min_{\mathbf{Y}} \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \|\mathbf{y}_i - \mathbf{y}_j\|^2 \mathbf{A}_{ij} = \text{tr}(\mathbf{Y}^T \mathbf{L} \mathbf{Y}),$$

$$\text{s.t. } \mathbf{Y} \in \{1, -1\}^{n \times r}, \mathbf{E}^T \mathbf{Y} = 0, \mathbf{Y}^T \mathbf{Y} = n\mathbf{I}, \quad (1)$$

其中 \mathbf{y}_i 是 \mathbf{Y} 的第 i 行, 为图像向量 \mathbf{x}_i 的AGH表达, 长度为 r ; \mathbf{A} 是 $n \times n$ 的相似度矩阵, $\mathbf{E} = [1, \dots, 1]^T \in \mathbb{R}^n$, \mathbf{I} 为 $r \times r$ 维的单位矩阵, \mathbf{L} 是图拉普拉斯(graph Laplacian)矩阵, 定义为 $\mathbf{L} = \mathbf{B} - \mathbf{A}$, $\mathbf{B} = \text{diag}(\mathbf{A}\mathbf{E})$. (1) 式是一个NP-hard (non-deterministic polynomial) 问题, 为使(1)式可解, 可通过放宽 \mathbf{Y} 的数值约束条件对其进行谱放松^[19], 允许 \mathbf{Y} 的取值为整个实数空间, 即 $\mathbf{Y} \in \mathbb{R}^{n \times r}$. 此时 \mathbf{Y} 的解为矩阵 \mathbf{L} 的前 r 个最小特征值对应的 r 个特征向量(需要首先去除特征值0)^[18].

上述求解过程虽然在概念上可行,但其计算代价太大,尤其当图像个数 n 很大时.

为解决计算代价问题, AGH 使用图像向量量子集来近似整个图像向量结构. 对 n 个图像向量进

$$\mathbf{Z}_{ij} = \begin{cases} \frac{\exp(-d^2(\mathbf{x}_i, \mathbf{u}_j)/\beta)}{\sum_{j' \in \langle i \rangle} \exp(-d^2(\mathbf{x}_i, \mathbf{u}_{j'})/\beta)} & (\forall j \in \langle i \rangle) \\ 0 & (\text{其他}) \end{cases}, \quad (2)$$

其中 β 为范围调节参数, $\langle i \rangle$ 为 \mathbf{U} 中与 \mathbf{x}_i 距离最近的前 γ 个锚点向量的集合索引, 这里提到的距离是函数 $d(\cdot)$, 一般为欧氏距离. γ 的取值应小于 m , 根据大量实验, 本文取 $\gamma = 15$. 由于选取距离最近的前 γ 个锚点, \mathbf{Z} 矩阵的每行仅有 γ 个数值不为零, 且每行相加为 1. 根据图像向量和锚点向量间的随机游走, 计算输入空间相似度矩阵 \mathbf{A} 的近似矩阵 $\hat{\mathbf{A}} = \mathbf{Z}\mathbf{A}^{-1}\mathbf{Z}^T$, 其中 $\mathbf{A} = \text{diag}(\mathbf{Z}^T\mathbf{E})$.

近似矩阵 $\hat{\mathbf{A}}$ 具有如下性质:

- 1) $\hat{\mathbf{A}}$ 是非负且稀疏的矩阵 (因为 \mathbf{Z} 是稀疏矩阵);
- 2) $\hat{\mathbf{A}}$ 是低秩矩阵 (最大值为 m);
- 3) $\hat{\mathbf{A}}$ 中每行相加为 1, 每列相加也为 1, 因此矩阵 $\hat{\mathbf{A}}$ 的图拉普拉斯矩阵为 $\mathbf{L} = \mathbf{I} - \hat{\mathbf{A}}$.

AGH 表达 \mathbf{Y} 为图拉普拉斯矩阵 \mathbf{L} 的前 r 个最小特征值对应的特征向量, 即矩阵 $\hat{\mathbf{A}}$ 的前 r 个最大特征值 (这里需要去除矩阵 $\hat{\mathbf{A}}$ 中数值为 1 的特征值, 其与 \mathbf{L} 的特征值 0 相对应) 对应的特征向量.

通过上述转化, AGH 表达 \mathbf{Y} 为矩阵 $\hat{\mathbf{A}}$ 的前 r 个特征向量, 利用 $\hat{\mathbf{A}}$ 的低秩特性, 通过求解一个较小矩阵 $\mathbf{M} = \mathbf{A}^{-1/2}\mathbf{Z}^T\mathbf{Z}\mathbf{A}^{-1/2}$ 的特征向量, 可以得到 \mathbf{Y} 的解. 设 \mathbf{M} 的前 r 个最大特征值和特征向量为 $\{(\sigma_k, \mathbf{v}_k), k = 1, 2, \dots, r\}$, 其中 $1 > \sigma_1 \geq \dots \geq \sigma_r > 0$. 前 r 个特征值和特征向量按列组成矩阵 $\mathbf{\Sigma} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r) \in \mathbb{R}^{r \times r}$ 和 $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_r] \in \mathbb{R}^{m \times r}$, 则 \mathbf{Y} 的解为

$$\mathbf{Y} = n^{1/2}\mathbf{Z}\mathbf{A}^{-1/2}\mathbf{V}\mathbf{\Sigma}^{-1/2} = \mathbf{Z}\mathbf{S}, \quad (3)$$

其中 $\mathbf{S} = n^{1/2}\mathbf{A}^{-1/2}\mathbf{V}\mathbf{\Sigma}^{-1/2} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_r] \in \mathbb{R}^{m \times r}$, $\mathbf{s}_k = (n/\sigma_k)^{1/2}\mathbf{A}^{-1/2}\mathbf{v}_k$.

求解图像 AGH 表达可看作首先对图像向量 \mathbf{x}_i 进行非线性变换到 \mathbf{Z}_i , 然后将 \mathbf{Z}_i 线性投影到 \mathbf{S} . 得到参考图像库每个图像的 AGH 表达 \mathbf{y}_i 后, 待判定图像的 AGH 表达可通过类似的方法得到, 待判定

行 K 均值聚类, 得到 m ($m < n$) 个聚类中心向量 $\mathbf{U} = \{\mathbf{u}_j \in \mathbb{R}^d, j = 1, 2, \dots, m\}$, 称这 m 个聚类中心向量为锚点向量. 定义 n 个图像向量和 m 个锚点向量间的相似度 \mathbf{Z} :

图像向量 \mathbf{x}_q 的 AGH 表达第 k 位 $\mathbf{h}_q(k)$ 计算如下:

$$\mathbf{h}_q(k) = \mathbf{s}_k^T \mathbf{z}_q \quad (k = 1, 2, \dots, r). \quad (4)$$

\mathbf{z}_q 是待判定图像向量 \mathbf{x}_q 与锚点向量的相似度, 计算如下:

$$z_q(j) = \frac{\delta_j \exp(-d^2(\mathbf{x}_q, \mathbf{u}_j)/\beta)}{\sum_{j'=1}^m \delta_{j'} \exp(-d^2(\mathbf{x}_q, \mathbf{u}_{j'})/\beta)}, \quad (5)$$

其中 $j = 1, 2, \dots, m$, 当 \mathbf{u}_j 是 \mathbf{U} 中 \mathbf{x}_q 的前 γ 个邻时, $\delta_j = 1$, 否则, $\delta_j = 0$.

计算图像 AGH 表达的一般过程如下:

输入 参考图像库中 n 个图像向量 $\{\mathbf{x}_i \in \mathbb{R}^d, i = 1, 2, \dots, n\}$ 和任意一个待判定的图像向量 \mathbf{x}_q ;

步骤 1 对 n 个图像向量 $\{\mathbf{x}_i \in \mathbb{R}^d, i = 1, 2, \dots, n\}$ 进行 K 均值聚类, 得到 m 个锚点向量集合 $\mathbf{U} = \{\mathbf{u}_i \in \mathbb{R}^d, i = 1, 2, \dots, m\}$;

步骤 2 使用 (2) 式计算 n 个图像向量和 m 个锚点向量的相似度 \mathbf{Z} ;

步骤 3 计算矩阵 $\mathbf{M} = \mathbf{A}^{-1/2}\mathbf{Z}^T\mathbf{Z}\mathbf{A}^{-1/2}$ 的前 r 个最大特征值和特征向量 $\{(\mathbf{v}_k, \sigma_k), k = 1, 2, \dots, r\}$;

步骤 4 通过 (3) 式计算 \mathbf{Y} , 将 $\text{sgn}(\mathbf{Y})$ 作为参考图像库的 AGH 表达, 其中 sgn 为符号函数;

步骤 5 通过 (4) 式计算 $\mathbf{h}_q(k)$, 将 $\text{sgn}(\mathbf{h}_q)$ 作为待判定图像 \mathbf{x}_q 的 AGH 表达;

输出 参考图像库的 AGH 表达 $\text{sgn}(\mathbf{Y})$ 和待判定图像的 AGH 表达 $\text{sgn}(\mathbf{h}_q)$.

2.2 DAGH 图像表达

乳腺图像肿块检索不仅要求视觉上的相似性, 同时要求病理上的相关性, 但在定义图像相似度时, 传统的 AGH 没有考虑病理相关性. 本文根据病理类别信息已知和未知的两种情形, 对 AGH 中的相似度进行修正. 图像类别信息已知时, ROI 对可分为具有相同类别的 ROI 对和具有不同类别的

ROI对, 修正后的相似度应保证相同类别的ROI对相似度大于不同类别的ROI对相似度. 在图像类别信息未知的情况下, 无法确定两个ROI对是否属于相同的病理类别, 此时ROI对的相似度应介于相同类别ROI对相似度与不同类别ROI对相似度之间. 基于上述思想, 本文引入病理类别信息到图像相似度计算, 提出DAGH用于图像表达, 其与传统

AGH在计算过程中的主要区别为: 1) 参考库图像向量与锚点向量的相似度计算; 2) 待判定图像向量和锚点向量的相似度计算.

AGH使用(2)式定义参考库图像向量与锚点向量间的相似度, 锚点向量和参考图像向量的病理类别信息是已知的. 通过增加相同类别ROI对的相似度, DAGH对(2)式进行修正, 得到

$$Z_{ij} = \begin{cases} \frac{D_{ij}}{\sum_{j' \in \langle i \rangle} D_{ij'}} & (\forall j \in \langle i \rangle) \\ 0 & (\text{其他}) \end{cases}, \quad (6)$$

$$D_{ij} = \begin{cases} \exp(-d^2(\mathbf{x}_i, \mathbf{u}_j)/\beta) + b & (\forall j \in \langle i \rangle, \text{且} \mathbf{x}_i, \mathbf{u}_j \text{同类}) \\ \exp(-d^2(\mathbf{x}_i, \mathbf{u}_j)/\beta) & (\forall j \in \langle i \rangle, \text{且} \mathbf{x}_i, \mathbf{u}_j \text{不同类}), \\ 0 & (\text{其他}) \end{cases}, \quad (7)$$

(7)式表示修正后锚点向量和参考图像向量之间的相似度, b 表示相同类别ROI对的相似度增加量, 取值为0—1之间, 修正后的相似度确保相同类别ROI对相似度大于不同类别ROI对相似度. 根据大量实验, 本文取 $b = 1$.

AGH使用(5)式定义待判定图像向量与锚点向量的相似度, 锚点向量病理类别已知, 但待判定图像病理类别是未知的, 不能确定锚点向量和待判定图像是否属于相同类别. 设置此时的ROI相似度为相同类别ROI相似度与不同类别ROI相似度的平均值, DAGH对(5)式进行修正:

$$z_q(j) = \frac{\delta_j [\exp(-d^2(\mathbf{x}_q, \mathbf{u}_j)/\beta) + b/2]}{\sum_{j'=1}^m \delta_{j'} [\exp(-d^2(\mathbf{x}_q, \mathbf{u}_{j'})/\beta) + b/2]}, \quad (8)$$

(8)式中相似度的增加量为 $b/2$, 确保类别信息未知ROI对相似度小于ROI属于同类时的相似度, 大于ROI属于不同类的相似度.

3 LNP 反馈技术

LNP^[20]是一种利用少量的已标记图像标签, 通过标签传递, 得到大量未标记图像标签的半监督学习方法, 其与图像检索中的相关反馈机制一致^[21]. 利用LNP对肿块检索进行相关反馈时, 首先构建参考图像库DAGH表达的权重矩阵, 然后由用户标记出与待判定ROI相关和不相关的图像,

结合标记的图像标签和DAGH权重矩阵, 对整个参考库图像标签信息进行更新. 最后对更新后的标签信息进行排序, 得到本次反馈后与待判定ROI最相似的ROI.

3.1 权重矩阵构建

LNP首先构建每个图像的权重向量, 然后对权重向量进行组合, 得到整个参考图像库的权重矩阵. LNP假设每个图像可由其近邻的线性组合进行重建, 设第 i 个图像的表达向量为 \mathbf{a}_i , 其权重向量为重建误差最小化时对应的权重值, 即

$$\begin{aligned} \mathbf{w}_{ii_j} &= \arg \min_{\mathbf{w}_{ii_j}} \sum_i \|\mathbf{a}_i - \sum_{i_j \in \langle i \rangle} \mathbf{w}_{ii_j} \mathbf{a}_{i_j}\|^2, \\ \text{s.t.} \quad & \sum_{i_j \in \langle i \rangle} \mathbf{w}_{ii_j} = 1, \quad \mathbf{w}_{ii_j} \geq 0, \end{aligned} \quad (9)$$

其中 $\langle i \rangle$ 为 \mathbf{a}_i 的近邻集合, 近邻的定义与(2)式相同; \mathbf{a}_{i_j} 为 \mathbf{a}_i 的第 j 个近邻, \mathbf{w}_{ii_j} 为 \mathbf{a}_{i_j} 在重建 \mathbf{a}_i 时的权重, 可通过标准的二次规划问题对(9)式进行求解.

每个图像对应一个重建权重向量 \mathbf{w} , 组合所有图像的重建权重向量, 得到参考图像库的权重矩阵 \mathbf{W} 为

$$W(i, j) = \mathbf{w}_{ij}. \quad (10)$$

3.2 标签更新

构建权重矩阵后, 用户标记出与待判定ROI相关和不相关的图像, 将标记信息定义为图像的原始

标签. 根据图像原始标签, 迭代更新得到整个参考库图像的最终标签信息. 每次更新时, 图像的新标签由图像的原始标签和其近邻的更新后标签决定. k 次更新后, 第 i 个图像的标签为

$$f_i^k = \alpha \sum_{i_j \in \langle i \rangle} w_{ii_j} f_{i_j}^{k-1} + (1 - \alpha)t_i, \quad (11)$$

其中 α 为近邻标签影响因子, 取值为0到1之间, 本文假设近邻标签和图像原始标签的影响相同, 将 α 设置为0.5; $\mathbf{t} = [t_1, t_2, \dots, t_n]^T$ 为图像的原始标签, 当用户标记图像 i 与待判定图像相关时, $t_i = 1$, 当标记图像 i 与待判定图像不相关时, $t_i = -1$, 没有标记图像 i 时, $t_i = 0$; 设用户标记的图像总数为 l , 则 \mathbf{t} 中仅有 l 个数值不为0; $\mathbf{f}^k = [f_1^k, f_2^k, \dots, f_n^k]^T$ 为第 k 次迭代更新后参考图像库的标签. 没有更新时, $\mathbf{f}^0 = \mathbf{t}$. (11) 式可重写为

$$\mathbf{f}^k = \alpha \mathbf{W} \mathbf{f}^{k-1} + (1 - \alpha)\mathbf{t}. \quad (12)$$

若几次连续更新后, 参考图像库的标签信息 \mathbf{f}^k 不再改变, 此时的标签值即为参考库图像最终的标签. 文献 [20] 指出, (12) 式会收敛到一个固定值 \mathbf{f}^* , 为

$$\mathbf{f}^* = (1 - \alpha)(\mathbf{I} - \alpha \mathbf{W})^{-1} \mathbf{t}. \quad (13)$$

对更新后的标签值进行排序, 标签值最大的前 N 幅图像即为本次反馈后的检索结果.

4 实验仿真

4.1 实验数据

本文选取的实验数据为北京大学人民医院乳腺中心(The Breast Center of Peking University People's Hospital, BCPKUPH)提供的乳腺图像. 参考图像库中, 疑似肿块ROI 284幅, 肿块ROI 284幅, 共568幅ROI; 测试图像库中, 疑似肿块ROI 144幅, 肿块ROI 144幅, 共288幅ROI. 每幅ROI的大小为 50×50 , 分辨率为 $448 \mu\text{m}/\text{pixel}$, 疑似肿块ROI为使用形态学方法检测到的正常组织区域. 本文提出的检索方法无须对ROI中的肿块进行边缘分割.

4.2 肿块检索方法实现

LNP根据图像的DAGH表达构建权重矩阵, 本文将 \mathbf{Y} 作为图像的DAGH表达, 这样 \mathbf{Y} 的取值为整个实数空间. 本文涉及的参数主要包

括: DAGH中的范围调节参数 β , 锚点向量个数 m , DAGH表达的长度 r 和 K 均值聚类的初始化参数. 本文将 β 的取值范围设置在6—16之间, m 的范围为60—110, r 的范围为24—48, K 均值聚类的初始化参数采用多次随机初始化, 在参考图像库上使用5折交叉验证(5-fold cross validation), 将平均检索正确率最高时对应的参数值作为参数的优化值. 然后使用优化值在测试库图像上进行测试, 得到检索结果.

结合DAGH表达和LNP反馈的乳腺图像肿块检索方法具体过程如下:

步骤1 将参考图像库中 50×50 的ROI排列为2500维的列向量, 作为图像的表达向量, 应用DAGH, 计算每个图像的DAGH表达 \mathbf{Y} ;

步骤2 对待判定图像进行相同的处理, 将其排列为2500维的列向量, 计算其DAGH表达 \mathbf{h}_q ;

步骤3 计算参考图像库与待判定图像DAGH表达的欧氏距离, 返回参考图像库中距离最近的前 N 幅图像; 初始化相关图像集合 \mathbf{Q}_r 为空, 不相关图像集合 \mathbf{Q}_{ir} 为空;

步骤4 用户对 N 幅返回图像进行标记, 得到与待判定图像相关的图像集合 $\mathbf{Q}_r^{\text{new}}$ 和不相关的图像集合 $\mathbf{Q}_{ir}^{\text{new}}$, 更新 $\mathbf{Q}_r = \mathbf{Q}_r \cup \mathbf{Q}_r^{\text{new}}$, $\mathbf{Q}_{ir} = \mathbf{Q}_{ir} \cup \mathbf{Q}_{ir}^{\text{new}}$; 根据 \mathbf{Q}_r , \mathbf{Q}_{ir} 和参考库图像的DAGH表达, 使用LNP算法得到更新后的图像标签;

步骤5 对更新后的标签进行排序, 将标签值最大的前 N 幅图像返回给用户;

步骤6 重复步骤4和5, 进行多次反馈, 得到满意的结果.

反馈次数增加, 系统的检索性能会提高, 但同时检索时间也会增加, 一般2到3次是用户可以接受的反馈次数. 在进行多次反馈时, 步骤5会返回两个结果: 结果一为参考库所有图像中标签值最大的前 N 幅图像, 即本次反馈得到的检索结果; 结果二为用户未标记的参考库图像中标签值最大的前 N 幅图像, 为下一次需要用户进行标记的图像, 这样避免了同一幅图像在多次反馈中的重复标记.

5 结果分析与讨论

5.1 评价指标

使用两个指标对本文提出的检索方法进行评价. 首先作为检索系统, 使用查准率和查全率曲线

进行评价. 对于待判定图像, 查准率 (precision, P) 为一次检索过程中系统返回的相关图像个数与返回图像总数之比. 查全率 (recall, R) 为一次检索过程中, 系统返回的相关图像个数与参考图像库中所有相关图像 (包括返回的和没返回的) 个数之比, 计算如下:

$$P = T_r / N,$$

$$R = T_r / T_t, \quad (14)$$

T_r 为一次检索中系统返回的相关图像数目, N 为系统返回的图像总数, T_t 为参考图像库中与待判定图像相关的图像总数. 图像相关性定义如下: 若返回图像与待判定图像同属肿块 ROI 或疑似肿块的正常组织 ROI, 认为这两幅图像相关, 否则认为不相关. 其次该系统也可作为肿块检测辅助系统, 使用受试者工作特征 (receiver operating characteristic, ROC) 曲线下面积评价其性能. 在返回的 N 幅图像中, 计算待判定 ROI 属于肿块的概率, 通过改变决策阈值, 绘制 ROC 曲线.

5.2 结果比较

比较本文提出的 DAGH 图像表达方式与其他肿块检索方法图像表达方式的检索性能. 选取用于比较的图像表达方式包括: 相关系数 [13]、小波 [14]、互信息 [15]、KLD [15] 和传统 AGH [16]. 在未加 LNP 反馈的情况下, 几种图像表达方式的 $P-R$ 曲线如图 2 所示.

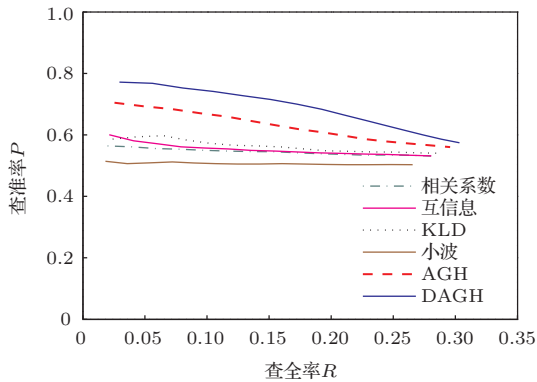


图2 (网刊彩色) 无反馈时不同图像表达方式的 $P-R$ 曲线比较

由图 2 可以看出, 本文提出的 DAGH 和传统 AGH 表达在检索性能上优于其他图像表达方式. 同时由于 DAGH 表达在计算图像相似度时包含了图像的病理类别, 其检索性能较传统 AGH 有明显提高. 在 $N = 20$ 时, 使用 DAGH 表达进行检索得

到的 $P-R$ 为 76.79%—5.60%, AGH 得到的 $P-R$ 为 69.32%—4.88%, 相比于 AGH, DAGH 的查准率 P 提高了 10.78%, 查全率 R 提高了 14.75%.

由于测试图像数量较多, 本文随机从测试图像库中选择 30 幅正常组织 ROI 和 30 幅肿块组织 ROI 用于评价相关反馈对于检索性能的影响. 相关系数、互信息和 KLD 基于两幅图像像素关系进行检索, 无法直接与 LNP 相关反馈结合, 这里仅给出基于小波、传统 AGH 和本文提出的 DAGH 在不同反馈次数下的 $P-R$ 曲线, 如图 3 所示.




图3 (网刊彩色) 加入 LNP 反馈后不同图像表达方式的 $P-R$ 曲线比较

由图 3 可得加入反馈后, 三种图像表达方式的检索性能均有所提高, 且随着反馈次数的增加, 检索性能也随之增加. 相比于小波和传统 AGH 图像表达, 在相同的反馈次数下, 本文提出的 DAGH 图像表达具有更好的检索性能. 在 1 次反馈 $N = 20$ 的情况下, 小波表达得到的 $P-R$ 为 66.08%—4.65%, AGH 表达得到的 $P-R$ 为 81.50%—5.74%, DAGH 表达得到的 $P-R$ 为 89.42%—6.30%.

图 4 和图 5 为不同反馈次数下, 本文方法在肿块 ROI 和正常组织 ROI 上的检索结果示例. 对于正常组织 ROI, 在没有反馈时, 本文方法检索到 6 幅不相关图像 (肿块 ROI), 经过 1 次反馈, 检索到的不相关图像减少到 2 幅, 经过 2 次反馈, 不相关图像减少到 0 幅. 对于肿块 ROI, 在没有反馈时, 本文方法检索到 2 幅不相关图像 (正常组织 ROI), 经过 1 次反馈, 不相关图像减少到 1 幅, 经过 2 次反馈, 不相关图像减少到 0 幅.

下面对本文方法在肿块辅助检测上的性能进行评价. 图 6 给出了未加 LNP 反馈的情况下, DAGH 和其他几种图像表达方式在不同返回图像个数 N 下的 ROC 曲线下面积比较结果. 由图 6 可






图4 (网刊彩色) 正常组织 ROI 的检索结果, 其中图像右下角的数字为病理类别, “1”表示正常组织, “2”表示肿块; 在每个子图中, 左上角图像为待判定图像, 其余 19 幅图像为检索返回图像, 红色框中的图像为与待判定图像不相关的图像 (a) 无反馈; (b) 1 次反馈; (c) 2 次反馈






图5 (网刊彩色) 肿块 ROI 的检索结果, 其中图像右下角的数字为病理类别, “1”表示正常组织, “2”表示肿块; 在每个子图中, 左上角图像为待判定图像, 其余 19 幅图像为检索返回图像, 红色框中的图像为与待判定图像不相关的图像 (a) 无反馈; (b) 1 次反馈; (c) 2 次反馈

以看出, 未加 LNP 反馈时, 本文提出的 DAGH 和传统 AGH 表达的平均 ROC 曲线下面积大于其他图像表达方式. 在 N 取值在 10—50 之间, DAGH 表达的 ROC 曲线下面积与传统 AGH 差别不大, 在 N 取值在 60—150 之间时, DAGH 图像表达的 ROC 曲线下面积均明显大于传统 AGH. 在 $N = 80, 100$ 和 120 时, DAGH 的 ROC 曲线下面积为 0.8793, 0.8795 和 0.8698, 相比于 AGH 的 0.8534, 0.8311, 和 0.8135, DAGH 的 ROC 曲线下面积提高了 3%, 6%

和 7%.

结合 LNP 反馈后, 在随机选取的 60 幅图像上测试, 比较基于小波、传统 AGH 和本文提出的 DAGH 图像表达在不同反馈次数, 不同返回图像个数 N 下的 ROC 曲线下面积, 如表 1 所示.

由表 1 可得随着反馈次数的增加, 小波、AGH 和 DAGH 表达的 ROC 曲线下面积也随之增加, 表明加入反馈后, 三种图像表达形式在肿块辅助检测性能均有所提高.

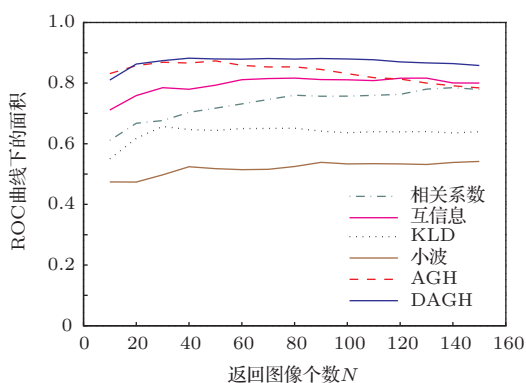


图6 (网刊彩色) 无反馈时不同图像表达方式的ROC曲线下面积比较

综合肿块检索和肿块辅助检测结果可得, 在肿

块辅助检测性能上DAGH与AGH基本相同, 在肿块检索性能上DAGH明显优于AGH. 其原因可能为: 对于检索性能而言, 在一次检索中返回相关图像越多, 其检索精度越高. 对于辅助检测性能而言, 当待查肿块ROI比待查正常组织ROI检索到更多肿块ROI时, ROC曲线下的面积会增大, 进一步增加二者检索到的ROI差值, ROC曲线下的面积变化不大. 本文实验中对于一些待查ROI, 传统AGH比DAGH检索到更少的相关图像, 但没有对区分肿块和正常组织造成影响, 因而AGH与DAGH具有相似的肿块辅助检测性能, 但DAGH的检索性能明显优于传统AGH.

表1 加入LNP反馈后不同图像表达的ROC曲线下的面积

	小波			AGH			DAGH		
	无反馈	1次反馈	2次反馈	无反馈	1次反馈	2次反馈	无反馈	1次反馈	2次反馈
$N = 10$	0.4267	0.9467	0.9889	0.9000	0.9911	1.0000	0.9078	0.9867	1.0000
$N = 40$	0.5644	0.7689	0.8889	0.9411	0.9889	1.0000	0.9433	0.9944	1.0000
$N = 70$	0.5489	0.6644	0.8111	0.9444	0.9789	1.0000	0.9367	0.9900	1.0000
$N = 100$	0.5433	0.6278	0.7911	0.9311	0.9689	0.9989	0.9389	0.9933	1.0000

6 结 论

本文提出了一种结合DAGH图像表达与LNP反馈的乳腺图像肿块检索方法. 针对传统AGH图像表达在计算图像相似度时没有考虑病理相关性的问题, 将图像病理类别引入到相似度计算, 提出了DAGH以重新表达图像. 结合DAGH表达与LNP反馈, 实现了交互式肿块检索. 与传统AGH、小波等方法进行实验对比, 结果表明, 在无须分割肿块边缘的情况下, 本文方法在肿块检索性能上优于传统AGH和其他现有方法.

参考文献

[1] Xiao X, Song H, Wang Z J, Wang L 2014 *Chin. Phys. B* **23** 074101
 [2] Liu J 2012 *Ph. D. Dissertation* (Wuhan: Wuhan University of Science and Technology) (in Chinese) [刘俊 2012 博士学位论文 (武汉: 武汉大学)]
 [3] Li Y F, Chen H J, Yang N, Zhang S J 2013 *Acta Auto. Sin.* **39** 1265 (in Chinese) [李艳凤, 陈后金, 杨娜, 张胜君 2013 自动化学报 **39** 1265]

[4] Xiao X, Xu L, Li Q W 2013 *Chin. Phys. B* **22** 094101
 [5] Xu X H, Li H 2008 *Acta Phys. Sin.* **57** 4623 (in Chinese) [徐晓辉, 李晖 2008 物理学报 **57** 4623]
 [6] Xiao X, Xu L, Liu B Y 2013 *Acta Phys. Sin.* **62** 044105 (in Chinese) [肖夏, 徐立, 刘冰雨 2013 物理学报 **62** 044105]
 [7] Moon W K, Lo C M, Chang J M, Huang C S, Chen J H, Chang R F 2013 *J. Digit. Imaging* **26** 1091
 [8] Huang Y H, Chang Y C, Huang C S, Wu T J, Chen J H, Chang R F 2013 *Comput. Meth. Prog. Biol.* **112** 508
 [9] Yao C, Chen H J, Yang Y Y, Li Y F, Han Z Z, Zhang S J 2013 *Acta Phys. Sin.* **62** 088702 (in Chinese) [姚物, 陈后金, Yang Yong-Yi, 李艳凤, 韩振中, 张胜君 2013 物理学报 **62** 088702]
 [10] Maskarinec G, Meng L, Ursin G 2001 *Int. J. Epidemiol.* **30** 959
 [11] Rui Y, Huang T S, Ortega M, Mehrotra S 1998 *IEEE Trans. Circ. Syst. Vid.* **8** 644
 [12] Alto H, Rangayyan R M, Desautels J E L 2005 *J. Electronic Imaging* **14** 023016
 [13] Li Y, Wei C H 2011 *Proceedings of International Conference on Multimedia Technology* Hangzhou, China, July 26–28, 2011 p550
 [14] Siyahjani F, Ghaffari A, Fatemizadeh E 2011 *Proceedings of the 1st Middle East Conference on Biomedical Engineering* Sharjah, United Arab Emirates, February 21–24, 2011 p63

- [15] Tourassi G D, Harrawood B, Singh S, Lo J Y, Floyd C E 2006 *Med. Phys.* **34** 140
- [16] Liu J, Zhang S, Liu W, Zhang X, Metaxas D N, Scalable Mammogram Retrieval Using Anchor Graph Hashing, http://www.research.rutgers.edu/~shaoting/paper/IS-BI14_mammogram_agh.pdf [2014-4-10]
- [17] Jiang L 2009 *Ph. D. Dissertation* (Wuhan: Huazhong University of Science and Technology) (in Chinese) [姜雯 2009 博士学位论文 (武汉: 华中科技大学)]
- [18] Liu W, Wang J, Kumar S, Chang S F 2011 *Proceedings of the 28th International Conference on Machine Learning* Bellevue, USA, June 28–July 2, 2011 p1
- [19] Shi J, Malik J 2000 *IEEE Trans. Pattern Anal.* **22** 888
- [20] Wang F, Zhang C 2008 *IEEE Trans. Knowl. Data En.* **20** 55
- [21] Huang C B, Jin Z 2011 *Information and Control* **40** 289 (in Chinese) [黄传波, 金忠 2011 信息与控制 **40** 289]

Mass retrieval in mammogram based on hashing theory and linear neighborhood propagation*

Li Yan-Feng¹⁾ Chen Hou-Jin^{1)†} Cao Lin¹⁾ Han Zhen-Zhong¹⁾ Cheng Lin²⁾

1) (School of Electronic and Information Engineering, Beijing Jiaotong University, Beijing 100044, China)

2) (Center for Breast, Peking University People's Hospital, Beijing 100044, China)

(Received 17 April 2014; revised manuscript received 14 June 2014)

Abstract

Mass detection in mammograms usually has high false positive (FP) rate. Content based mass retrieval can effectively reduce the FP rate by comparing the image which is to be determined with mass images which have already been diagnosed. In this paper, a method combining discriminating anchor graph hashing (DAGH) and linear neighborhood propagation (LNP) is proposed for mammogram mass retrieval. Original AGH image representation does not consider pathological relevance in defining image similarity. To solve this problem, DAGH is put forward as a new image representation, which introduces the pathological class into image similarity. Furthermore, LNP is employed as a relevance feedback technique. Finally, interactive retrieval for mammogram masses is implemented based on the learning strategy between the underlying features and high-level semantic for images. Mammograms provided by the Breast Center of Peking University People's Hospital (BCPKUPH) are used to test the proposed method. Experimental results show that the DAGH image representation introducing pathological class is superior to original AGH in analyzing the similarity of mass images. Compared with existing methods, the proposed method shows obvious improvement in mass retrieval performance.

Keywords: mammogram, mass retrieval, relevance feedback, Hashing theory

PACS: 87.57.N-, 42.30.Va, 07.05.Pj

DOI: 10.7498/aps.63.208701

* Project supported by the National Natural Science Foundation of China (Grant Nos. 61271305, 61201363) and the Specialized Research Fund for the Doctoral Program of Higher Education of China (Grant No. 20110009110001).

† Corresponding author. E-mail: hjchen@bjtu.edu.cn