

基于内容的医学图像检索研究进展

杨锋, 魏国辉, 曹慧*, 邢蒙蒙, 刘静, 张俊忠

山东中医药大学理工学院, 山东 济南 250355

摘要 基于内容的医学图像检索方法是近年来计算机视觉领域的研究热点,已经广泛应用于计算机辅助诊断的研究中。概述了基于内容的医学图像检索方法的研究进展及意义,介绍了当前主流的医学图像检索算法及其优缺点,旨在引导研究人员快速了解本领域的研究内容。医学图像检索的研究主要分为特征提取和相似性度量两部分。从传统特征提取及近年来兴起的基于深度学习的特征提取入手来介绍医学图像的特征提取方式;而相似性度量部分则详细列举了马氏距离度量、词汇树以及哈希算法。最后概述了医学图像检索领域的相关反馈技术及当前常用的图像检索系统,并讨论了医学图像检索未来可能的研究方向及相关难点。

关键词 机器视觉; 特征提取; 深度学习; 卷积神经网络; 哈希算法; 相关反馈

中图分类号 O436

文献标志码 A

doi: 10.3788/LOP57.060003

Research Progress on Content-Based Medical Image Retrieval

Yang Feng, Wei Guohui, Cao Hui*, Xing Mengmeng, Liu Jing, Zhang Junzhong

*School of Science and Technology, Shandong University of Traditional Chinese Medicine,
Jinan, Shandong 250355, China*

Abstract Content-based medical image retrieval method is a research hotspot in the field of computer vision in recent years, and has been widely used in the research of computer-aided diagnosis. This paper summarizes the research progress and significance of content-based medical image retrieval methods, introduces the current mainstream medical image retrieval algorithms and their advantages and disadvantages, and aims to guide researchers to quickly understand the research content in this field. The research of medical image retrieval is mainly divided into two parts: feature extraction and similarity measurement. This paper introduces the feature extraction method of medical images starting with the extraction of traditional features and the feature extraction based on deep learning emerging in recent years. The similarity measure part enumerates the Mahalanobis distance metric, vocabulary tree, and hash algorithm. Finally, the related feedback technology in the field of medical image retrieval and the commonly used image retrieval system are summarized. The possible research directions and related difficulties in medical image retrieval are discussed.

Key words machine vision; feature extraction; deep learning; convolutional neural network; hash algorithm; related feedback

OCIS codes 150.1135; 170.3880

1 引言

据 2000 全球年报指出,中国是世界上癌症发病率和死亡率最高的国家之一,约 380.4 万例,占全球

癌症发病人数的 20%^[1],且早期筛查病因和诊断病情已被证明可以显著提升癌症患者的存活率。现存医学图像数据主要来源于于密度分辨率较高的电子计算机断层扫描(CT)、磁共振成像(MRI)及 X 射线扫

收稿日期: 2019-08-02; 修回日期: 2019-08-22 录用日期: 2019-08-28

基金项目: 国家自然科学基金(81473708)、山东医药卫生科技发展计划(2018WS206)、2018 年度山东省重点实验室联合开放基金、山东省中医药科技发展计划(2017-016)、山东省研究生导师指导能力提升项目(SDY17119)、山东省研究生教育优质课程建设项目(SDYKC17065)、山东中医药大学优秀青年科学基金(20182K02)

* E-mail: caohui63@163.com

描,这些方法能够很好地区分人体解剖结构的正常或病理表现,因此成为了早期癌症筛查的有效方法。但由于人体各个器官及组织病变的医学图像表现十分复杂,在临床诊断过程中,医生往往会遇到难以确诊的病症。根据循证医学的基本假设,相似病例往往具有相同的诊断方式,因此医生可以参考病理相似病例的诊断方法以辅助其作出正确的临床诊断。医学图像检索的意义在于:从现有的医学图像数据库中检索出与待确诊病例相同或相似的医学图像,医生根据已确诊病例的治疗方案做出相应的临床诊断,此外还能经验少的医生作出临床诊断提供参考性建议,从而减少误诊率。

基于内容的医学图像检索(CBMIR)^[2]以图像的视觉特征为依据,通过从现有医学图像数据库中快速查询病理相似的临床医学图像,成为当前计算机辅助诊断和医学研究的重要手段。CBMIR过程分为以下两步:第一步为特征提取,用于精确地表示出医学图像;第二步是相似性度量,提取特征作为指标在现有医学图像数据库中被快速检索,将具有高度相似性的图像作为检索结果呈现给诊断医生。

相关人员对基于内容的医学图像检索技术研究了近20年,但当前医学图像检索领域仍然面临以下几个问题:1)医学图像多为灰度图像,且在成像过程中会引入噪声、伪影和几何形变的干扰,因此不能直接将现有基于内容的图像检索方法应用到医学图像

检索中;2)医学图像的底层特征与高层语义之间存在着语义鸿沟^[3],若仅通过病理图像的视觉特征进行检索往往难以满足医生的检索需求;3)随着医学图像数据库规模的增大,现有的医学图像检索方法难以满足医生实时检索的需求。

随着深度学习在计算机辅助诊断中得到了一系列成功的应用,研究人员将深度学习应用到了医学图像检索的研究中。本文主要综述深度学习在医学图像检索领域的具体应用,详细内容如下:首先列举了传统特征提取方法以及基于深度学习的特征提取方法;其次,相似性度量方面就马氏距离、词汇树以及哈希算法进行了详细概述;此外,针对语义鸿沟问题,在文章最后介绍了相关反馈(RF)技术的发展及其在医学图像检索中的应用。通过介绍深度学习应用于医学图像检索领域的发展过程,理清深度学习在医学图像检索中的应用方法,为后续医学图像检索的研究指明方向。

2 特征提取

图像的特征提取是指利用计算机提取图像中的有效信息,并将提取出的有效信息以特征向量的形式表示出来,以便更好地应用于图像的分类和识别。图像的特征提取主要分为传统特征提取和基于深度学习的特征提取。图像特征提取的代表方法及发展阶段如表1所示。

表1 图像特征提取的代表方法及发展阶段

Table 1 Representative methods of image feature extraction and their development stages

Time	Representative method	Category
1996	Methods featured by color ^[4] , edge ^[5] , and texture ^[6]	Hand-craft global features
2001	Method featured by GIST (generalized search trees) ^[7]	
2003	BoW (bag of word) ^[8]	
2004	Method featured by SIFT (scale-invariant feature transform) ^[9]	Hand-craft local features
2005	Method featured by HOG (histogram of oriented gradients) ^[10]	
2006	SURF (speeded up robust features) ^[11] ,	
	LBP (local binary pattern) ^[12]	
2007	FV (fisher vector) ^[13]	
2012	VLAD (vector of locally aggregated descriptor) ^[14]	Deep global features
2014	Triangulation embedding ^[15]	
2014	Neural code ^[16]	
2014	MOP-CNN (multiscale orderless pooling-convolutional neural network) ^[17]	
2015	SPoC (sum-pooled convolutional features) ^[18]	
2016	R-MAC (regional maximum activation of convolutions) ^[19] ,	
	CroW (cross weight aggregation code) ^[20]	
2017	Class weighted ^[21]	Deep local features
2018	PWA (progressive web app) ^[22]	

2.1 传统特征提取概述

传统特征提取是专家根据图像特点设计特定的特征提取算法以获取图像特征信息的过程,往往提取图像的 color^[4]、edge^[5]、texture^[6]、GIST^[7] 特征来作为图像的特征表示。传统特征主要分为全局特征和局部特征。全局特征可以直接表示整个图像的全局信息,具有鲁棒性强、受噪声影响小的优点,已经广泛应用于医学图像检索中。方欣等^[23]通过构建不同尺度及方向的 Gabor 滤波器组来提取乳腺超声图像的 GIST 特征用于乳腺肿瘤的良恶性分类。李炎^[24]通过计算整个医学图像相对于 x 和 y 的梯度,提取出医学图像的 HOG^[10] 特征用于图像检索。

医学图像往往具有多样性和复杂性的特点,仅提取其全局特征往往不能很好地表示出医学图像。后来研究人员将特征提取重点转向局部特征提取。其中典型的局部特征提取方法为图像的 SIFT^[9] 特征结合 BoW^[8] 聚合方法。后来还产生了 SURF^[11]、LBP^[12]、FV^[13]、VLAD^[14] 以及 Triangulation embedding^[15] 等更好的特征聚合方法。如 Wei 等^[25]提取了乳腺病理图像的 SIFT 特征并使用 BoW 聚合用于肿瘤的良恶性分类;Filipcuk 等^[26]通过提取细胞图像的 SIFT 特征,包括细胞核的大小及图像中细胞核的分布来表示细胞图像。总之,与传统全局特征提取相比,图像局部特征提取方法能够更好地表示医学图像。与上述直接提取图像的局部特征不同,Avni 等^[27]提取不同分辨率下图像的分块特征,利用 BoW 将提取出的分块特征进行聚合,从而表示出医学图像;Wan 等^[28]改进了图像的 BoW 聚合方法,利用多个加权的 BoW 来聚合图像的分块特征,并在后续的分类过程中取得了不错的效果。

为了更好地表示医学图像,研究人员设计特定算法,实现了医学图像的全局特征和局部特征融合。Tommasi 等^[29]利用支持向量机的交叉检验获得医学图像全局特征及其 SIFT 特征之间的融合系数并融合图像特征,从而更精确地表示出医学图像。Song 等^[30]融合肺部 ROI (region of interest) 的 HOG 和 LBP 特征,从而检索和识别肺部病变。此外,在 ImageCLEF 医学检索任务中,多数采用特征融合方法的小组实现了不错的检索效果。检索的精确度也证明了与单一传统特征表示方法相比,使用特征融合可以获得更好的检索性能。

尽管已有多种医学图像的传统特征提取方法,

但医学成像技术具有多样性,不同医学图像的组织或器官的颜色、纹理和形状往往不同,且相同组织或器官的特征往往在多个维度和形式上也有差异^[31],因此还没有专门适用于医学图像的特征提取方法。此外,传统的特征提取方法不仅耗时耗力且计算量大,因此大规模医学图像检索需要更多自动化、高效、可拓展的特征提取方法。随着 2012 年 ImageNet 挑战中深度学习的出现,从大数据中进行特征的自动提取得以实现,使深度学习成为更有效率的新一代特征提取方式。

2.2 深度特征提取

深度学习是通过模拟人脑分析数据建立起来的模型,通过分析海量数据中的非线性关系,自动学习并生成能够有效表示图像信息的特征,最后根据提取的特征进行准确的分类和预测。到目前为止已经提出了大量的深度学习方法。与传统特征提取方法相比,深度学习不仅能够有效解决类内变异性和类间相似性问题^[32],而且具有更高的特征提取效率。

根据深度学习提取特征的不同思路可将其分为三类:有监督深层网络、无监督深层网络和半监督深层网络。深度学习的分类如表 2 所示。

表 2 深度特征提取方法分类

Table 2 Classification of depth feature extraction methods

Type	Common model
Supervised deep network	Convolutional neural network, deep stacking network, deep-structured
	conditional random fields
	Auto encoders, restricted Boltzmann machines, sparse coding, K-means
Unsupervised deep network	
Semi-supervised deep network	Pre-trained deep neural networks

上述三种类别又都包含医学图像的深度全局特征和深度局部特征,深度全局特征是指通过将整张医学图像输入预训练好的网络并提取其深度全连接特征来表示图像,其通常表示医学图像的全局信息,主要是对医学图像整体语义的描述,图 1 表示利用深度全局特征进行图像检索的流程图。

深度局部特征聚合是指通过提取医学图像的多个深度局部特征,利用传统聚合方法如 BoW, VLAD 等对提取出的局部特征进行聚合,从而更好地表示出医学图像。图 2 表示利用深度全局特征进

行图像检索的流程。

2.2.1 有监督深层网络

有监督深层网络需要大量带有标签的图像来训




图 1 利用深度全局特征进行图像检索的流程

Fig. 1 Flow chart of image retrieval using deep global features

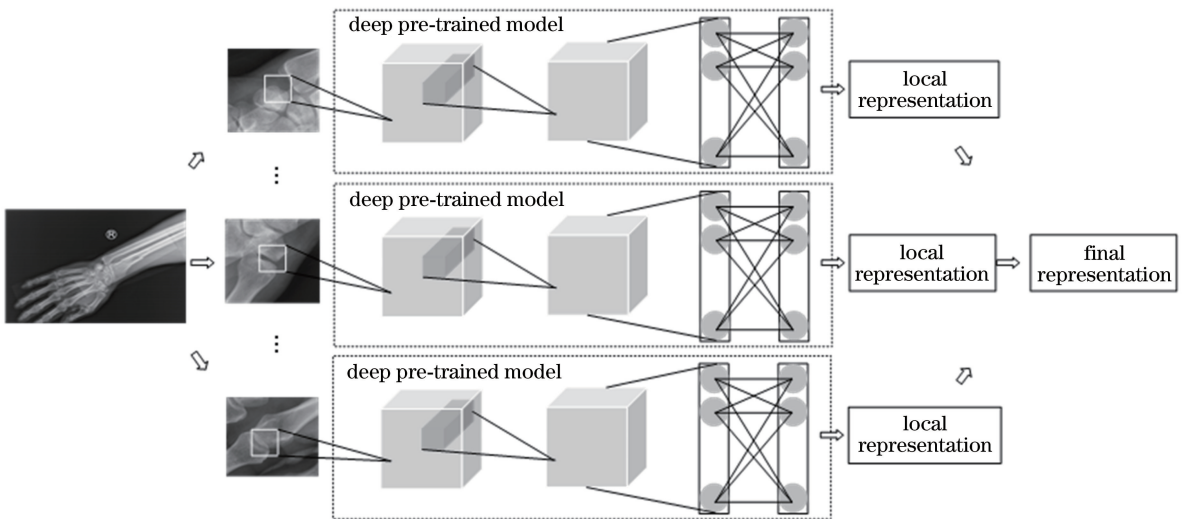


图 2 利用深度局部特征聚合进行图像检索的流程

Fig. 2 Flow chart of image retrieval based on deep local feature aggregation

学图像的深层特征,然后利用池化层压缩输入的特征图以提取图像主要的特征信息。但医学图像的标签来自于医生和专家手动标注,因此带有标签的医学图像数量有限,仅用小型标签数据从头开始训练深度神经网络容易导致过拟合。

研究人员针对上述问题提出了几种解决方法。Bar 等^[34]利用预先训练的 CNN 模型学习了胸部病理学特征,其参数是从诸如 ImageNet 等非医学数据集迁移过来的。李文丰^[35]通过对 ImageNet 中的图像数据集进行迁移来学习脑颅 CT 医学图像的特征。2016 年 Semedod^[36]在 ImageCLEFmed 中 NovaSearch 上使用大量医学图像数据从头开始训练 CNN 模型,并用其处理小型医学图像数据集。Shin 等^[37]提出利用 CNN 学习医学图像深度特征的主要技术,基于迁移学习思想,将自然图像上预先训练的 CNN 模型进行微调后用于医学图像,此外使用预先训练好的 CNN 模型提取特征并将其用作补充信息与传统特征相融合。Wang 等^[38]采用深度

学习框架,利用多级非线性变换获得肺结节的高层语义特征,然后结合其中间特征和顶层视觉信息来实现图像检索。黄刚等^[39]基于 DeepLabV3+ 网络的语义分割方法实现了图像特征的自动提取,并将其应用于后续道路标线分类。张浩等^[40]提出了一个新的学习框架,通过优化 AlexNet 以提高其特征提取能力,其主要思想是利用最大平均池化层替代平均池化层,从而更好地提取医学图像的局部特征,非线性激活函数则被用于全连接层以提取其全局特征,所提出的框架优于用于医学图像检索的公共数据库的最先进方法。实验结果证明,有监督的深层网络在医学图像特征提取中取得了不错的效果,并且大大提高了图像特征提取的效率。

2.2.2 无监督深层网络

虽然有监督的深层网络能够很好地学习并提取医学图像特征,但训练所需数据的标签需要大量的医生或领域专家手工标注,且人为标注往往存在一定的误差。为了克服有监督特征学习的局限性,近

年来出现了很多基于无监督机器学习框架[如自动编码器(AE)^[41]、受限玻尔兹曼机(RBM)^[42]、自编码^[43]、K-means^[44]等]的文献,无监督的深层网络已经被广泛应用到医学图像的特征提取中。

Bengio 等^[45]提出了典型的无监督神经网络 AE,通过将多个 AE 堆叠形成深度自动编码器(SAE),相较于以往的单层 AE,SAE 能够学习到更深层的图像特征,显著提高了图像的特征提取能力。Wang 等^[46]通过构建堆叠的双层 CNN 寻找每个图像块的分层表示,通过从低级网络的响应中推断出高级特征并将该方法用于脑部 MR (magnetic resonance)图像上,实验结果表明无监督深层网络的特征学习对于脑部 MR 配准是有效的。除 AE 外,RBM 也可以构造无监督的深度神经网络,例如 Brosch 等^[47]通过使用多个 RBM 降低大脑图像的维度,并执行流形学习,利用深度网络多方面学习图像特征。杨晓莉等^[48]开发了一种基于深度 RBM 的多模态学习模型,通过从多模态信息中学习联合密度模型,得出缺失的模态。实验结果表明,基于深度 RBM 的多模态学习模型是解决大规模医学图像检索的有效方案。

2.2.3 半监督深层网络

近年来,基于半监督的深度特征学习已成为医学图像检索的主流趋势。以往机器学习方法中,要么完全依赖带有标签的训练集,要么训练样本都没有标注。半监督学习则是依靠已标注的部分训练集和未标注的样本共同训练一个分类器的新型学习方法。且在医学图像数据库中真实存在的往往是“有标识的医学图像数据少、未标识的医学图像数据多”的情况。因此在医学图像特征提取过程中,可以利用已标注的数据信息对深度学习获得的特征进行微调,从而进一步加强图像特征提取性能。本节旨在介绍利用半监督的深层网络进行医学图像特征提取的方法,对利用 ImageNet 预训练模型作为固定特征提取器来提取图像表示的研究方法进行综述。

吴梦麟^[49]提出了基于图的半监督学习框架来学习患者胸部和上肢腕关节 X 光片的语义特征。Bai 等^[50]提出了一种半监督学习方法,通过从标记和未标记的图像数据中训练分割网络,交替更新网络参数和未标记数据的分段。实验评估了短轴心脏 MR 图像分割的方法,并且证明其特征性能优于监督方法。Son 等^[51]提出了一种新的协同方案,将半监督模糊聚类算法应用于牙科射线图像分割,采用 Otsu 方法从 X 射线牙齿图像中去除背景区域,然后

利用模糊 C-均值(FCM)算法去除牙齿结构区域。上述实验证明,基于半监督的深度特征学习在医学图像检索领域取得了不错效果,将成为未来图像特征提取的一大研究热点。

3 相似性度量

医学图像检索的实质可视为计算待查询医学图像与数据库中伴有医生明确语义注释的图像之间的距离。图像通过特征提取后由特征向量表示,通过相似性度量计算待查询医学图像与数据库中所有图像的距离大小并排序,排名越靠前的图像与待查询图像距离越近,最后按照排序的顺序输出图像。当前常用的相似性度量方法主要有欧氏距离、马氏距离、词汇树以及哈希算法等。随着医学图像数据库规模的逐步增大,传统的相似性度量方法满足不了当前医学图像检索的要求,所以本节总结大规模医学图像数据库的检索方法。

3.1 马氏距离

传统相似性度量方法主要采用欧氏距离度量,如李振东等^[52]通过对已提取人脸图像的深度特征进行 K-means 聚类,然后在聚类的簇中进行欧氏距离度量以完成人脸图像的检索任务。由于欧氏距离将样本不同变量之间的差别等同看待,没有考虑总体变异对距离远近的影响,所以在检索中面临很大的局限性。而马氏距离度量通过计算数据之间的协方差而排除变量之间相关性的干扰,因此研究者开始将马氏距离应用于相似性度量的研究中。Xiang 等^[53]用马氏距离代替 K-means 算法中的欧氏距离以改进传统聚类算法,从而度量人脸面部姿势的相似性。魏国辉等^[54]利用相似性度量理论构建距离度量算法,学习了一个马氏距离,根据学到的马氏距离度量提出了新的图像检索方法,并将其应用于肺癌的诊断研究中。Yu 等^[55]提出语义相关的距离度量学习方法,利用用户提供的成对约束来度量两幅图像之间的距离,此方法考虑了图像的语义内容,大大提高了检索的准确率。

近年来随着医学成像技术的进步以及图像规模的不断增大,利用传统相似性度量方法计算数百万个高维特征向量之间的距离不仅大大延长了检索时间,而且计算量很大,难以保证检索的准确率。后来研究者探索了大量的医学图像检索方法。

3.2 词汇树

词汇树最早由 Nister 等^[56]提出,是一种新颖的描述符矢量量化器工具。其基本原理是利用层次

K-means 得到尽可能多的特征,通过分层组织的特征向量集有效地划分特征空间,从而创建映射到整数编码的量化空间。其中,层次 K-means 是指利用普通 K-means 算法将空间中的点聚类得到 K 个聚类中心,然后分别对 K 类样本进行 K-means,不断重复上述过程直至获得想要的聚类中心个数。与普通 K-means 聚类方法相比,层次 K-means 在耗费时间少的同时能够获得更多聚类中心。

当前词汇树已经广泛应用于大规模医学图像检索中。例如,Jiang 等^[57]提出了一种自适应加权策略来处理乳房 X 射线照片的图像检索。通过在词汇树中提取和搜索 SIFT 特征来查询乳房 X 射线照片的 ROI,该词汇树存储先前诊断的乳房摄影 ROI 的所有量化特征。此外,为了充分发挥 SIFT 特征的判别能力,采用词汇树中的上下文信息来细化树节点的权重。然后使用检索到的 ROI 来确定查询 ROI。Wang 等^[58]针对手指静脉图像的识别设计了一个区分性和生成性的词汇树。该方法结合了局部图像块的判别性和其空间布局。这种联合辨识和生成模型不仅在手指静脉图像中取得良好的效果,而且保证了整个系统的检索效率。此外,基于点集匹配策略的方法考虑了局部图像块的几何布局,相较之前仅考虑局部关键点描述的词汇树方法更准确。

基于词汇树的方法通过改变相似性度量策略在大型医疗图像数据库中实现了高效检索,且词汇树采用局部特征描述符,因此可以应用于大多数医学图像。但词汇树仍然有其局限性,比如肺部图像的检索应考虑其全局特征,因此仅使用局部特征并不能很好地表示出肺结节图像。建立分层词汇树的训练阶段通常是耗时的,特别是在处理非常大的图像数据库时。因此需要为大规模医学图像检索开发更高效、更准确的方法。

3.3 哈希算法

为解决医学图像检索过程中耗费时间长及图像维数高的问题,研究者引入了检索速度快、存储空间小的哈希算法。与传统距离度量方法不同,哈希算法是利用哈希函数将图像数据压缩成二进制编码,将特征向量间的相似性度量转换为二进制编码的汉明距离大小问题。哈希算法因其检索的高效性和准确性已被广泛应用到大规模医学图像检索中。

3.3.1 哈希框架

若图像数据库中包含 n 张图像,经特征提取后将其由 d 维特征向量表示为 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\} \subset \mathbf{R}^{d \times n}$ 。对于图像 $\mathbf{x}_i \subset \mathbf{R}^{d \times 1}$,可由哈希函数 $H =$

$\{h_1, h_2, \dots, h_k\}$ 来表示其特征空间,且哈希函数将图像 \mathbf{x}_i 压缩成一个二进制码 $h_k(\mathbf{x}_i)$ 。因此 \mathbf{x}_i 的 k 位编码可表示为

$$\mathbf{y}_i = \{h_1(\mathbf{x}_i), h_2(\mathbf{x}_i), \dots, h_k(\mathbf{x}_i)\}。 \quad (1)$$

为了便于计算,通常将上述哈希函数投影为矩阵 $\mathbf{W} \subset \mathbf{R}^{d \times k}$ 和截距 $\mathbf{b} \subset \mathbf{R}^{k \times 1}$:

$$\mathbf{y}_i = \text{sgn}[f(\mathbf{W}^T \mathbf{x}_i + \mathbf{b})]。 \quad (2)$$

通过哈希函数能够将数据库中所有图像由二进制编码表示。待查询图像 \mathbf{x}_q 可以通过(2)式映射成相应的二进制编码。因此待查询图像与图像数据库间的相似性度量问题转化为二进制代码的汉明距离排序,其检索速度非常快,当前哈希算法已经广泛应用于医学图像检索中。

3.3.2 哈希算法的应用

Zhang 等^[59]提出了高维特征乳腺病理图像的检索方法。首先提取乳腺癌病理图像的 SIFT 特征,利用 BoW 对 SIFT 特征进行聚合,从而完整表示出乳腺病理图像。随后利用哈希算法将乳腺病理图像的高维特征映射为哈希码并将其索引到哈希列表中,从而达到快速检索的目的。Liu 等^[60]将隐层的高维特征映射到二进制代码,以此来优化医学图像检索的相似性度量方案。Yu 等^[61]使用 BoW 算法将提取的肺部病理图像的 SIFT 和 HOG 特征量化为特征向量,利用哈希算法将表示出的高维肺部病理图像特征映射成 10 位哈希码,最后完成对肺部病理图像的检索任务,且极大地缩短了检索时间。Jiang 等^[62]提出了基于哈希的图像检索框架。通过融合乳腺病理图像的 SIFT 和 GIST 特征完整地表示出乳腺病理图像,然后使用无监督哈希算法将高维乳腺病理图像特征压缩为二进制码,并在汉明空间中实现乳腺病理图像的快速检索。

此外,研究人员还提出了将哈希算法应用于不同医学模态图像的检索方法。Rui 等^[63]提取了多模态医学图像的 GIST 特征,采用主成分分析(PCA)降维后,利用迭代量化哈希算法缩小其与哈希码间的误差,并对其进行距离度量,有效缩短了医学图像检索所需的时间。Shi 等^[64]提出了一种新的基于成对深度排序的哈希框架。将目标函数纳入深度学习架构并同时学习图像特征和二进制代码,并将提出的框架应用于骨骼肌和肺癌图像上,达到了 97.49% 的分类准确度。

4 相关反馈

完成相似性度量后,可以有效检索出与待查询

医学图像相似的图像。然而医学图像具有多样性和复杂性,导致检索出的医学图像在视觉上相似但其语义上存在很大差别。为了减少语义鸿沟现象,将相关反馈技术引入 CBMIR 中。

RF 技术过程如下:医生通过对医学图像检索系统输出的检索结果进行判断,将输出图像的相关性反馈给系统,系统根据医生提供的反馈信息进行改进以达到提高检索准确率的目的。RF 技术根据采用检索模型的不同可分为基于距离度量的模型、基于概率统计分类的模型和基于机器学习的模型。

4.1 基于距离度量模型的 RF 技术

基于距离度量模型的 RF 技术实质是权值的调整,主要通过优化相似性度量公式来增强反馈中正例样本的聚拢程度,从而有效将正例和负例样本分开。Holub 等^[65]基于正例样本往往服从单一类型分布的假设,将其在特征分量上标准差的倒数作为该分量的权值,从而达到优化相似性度量公式的目的。此外,吴建鑫等^[66]通过对优化准则的权值进行学习,有效增强了 RF 中正例样本的聚拢程度,达到了更好的检索效果。今后研究方向应充分考虑 RF 中实际样本的分布规律,利用负例样本信息来设计更好的距离度量学习算法,以达到优化距离度量模型的目的。

4.2 基于概率统计分类模型的 RF 技术

基于距离度量模型的 RF 技术主要应用于普通图像数据库中。而医学病理图像结构复杂,基于距离度量模型的 RF 技术往往不能满足医生的检索要求,因此引入概率统计分类模型的 RF 技术。其原理是利用判别学习准则对已经建立的生成模型参数进行优化,从而提高 RF 技术的性能。其中常用模型主要包括高斯混合模型以及贝叶斯网络。

Wu 等^[67]根据医学图像特征服从高斯分布的假设,在确定其分布参数时采用了极大似然估计法,从而有效提高了 RF 技术的性能。Zhou 等^[68]提出了能够优化生成模型参数的贝叶斯网络,为基于概率模型的 RF 技术提供了一个新的思路。Zucker 等^[69]基于贝叶斯规则的 RF 概率框架提出了一种利用全体样本分布特点优化医学图像特征的 RF 技术,该技术不仅解决了医学图像数据库中训练样本少的问题,而且极大地提高了医学图像的检索性能。Greiner 等^[70]结合了生成模型和判别学习的优点,利用正例样本学到的生成模型获得每个特征的似然度并分配不同的权值,从而达到特征选择的目的。实验表明,与传统基于距离度量模型等利用几何方法划分图像类别的 RF 方法相比,基于概率统计分

类模型的 RF 技术在图像检索性能上更加优越。

4.3 基于机器学习模型的 RF 技术

当前研究人员将 RF 看成学习问题,且实验证明将机器学习方法应用于 RF 技术能够获得更好的性能表现。Shyu 等^[71]提出了基于半监督学习的 RF 技术。首先利用分类器完成对样本集中未标记样本的分类,更新分类器后将置信度高的样本加入训练样本集进行重新分类,重复上述过程直至分类器性能满足要求。Tzelepi 等^[72]提出了一种基于深度学习模型的 RF 技术。利用 CNN 自动学习医学图像的深层特征,然后结合医生所反馈的信息重新定义目标函数,从而达到优化检索性能的目的。Gyires-Tóth 等^[73]提出了一种基于 SVM (support vector machine) 的 RF 技术,通过辨别医学图像隐层空间中类内和类间的离散度差异获得包含医学图像判别信息的分类模型,从而达到对未知样本进行分类的目的。Qian 等^[74]提出了结合差分进化算法和 SVM 的 RF 技术,利用前者优良的全局检索能力并结合医学图像数据集训练 SVM,获得了较好的检索效果。

综上,利用 RF 技术对医学图像检索结果的重新排序能够进一步提高检索的性能,得到的输出更能反映查询图像语义信息的检索结果。

5 常用的医学图像检索系统

随着 CBIR (content based image retrieval) 技术在医学领域的研究逐步走向成熟,研究人员研发了许多 CBMIR 系统,但只有少量 CBMIR 系统能够从理论研究走向实际临床应用,因此仍需要对 CBMIR 系统进行进一步的改进和完善。

IRMA (internal relationship management accountability) 系统能够采用多种不同的特征提取方式对输入的检索图像进行特征提取,然后采用多测距离量方式得到相似度大小,再根据相似度结果完成图像输出。同时该系统提供了很好的人机交互,在输入输出两个模块中加入了反馈功能,用户可以通过系统提供的一系列逻辑操作(如并/与/Undo/Redo、回退等)不断优化检索结果。图 3 给出 IRMA 系统结构图。

CBMIR 系统支持多种方式的查询,包括病例检索、图像检索和 ROI 检索等,系统不仅支持对提交的多张医学图像进行检索,同时支持标题、摘要、医学术语等文本查询方式。根据医学图像检索应用对象的不同,将其分为不同种类的医学图像检索系统。表 3 列举了常用的 CBMIR 系统。

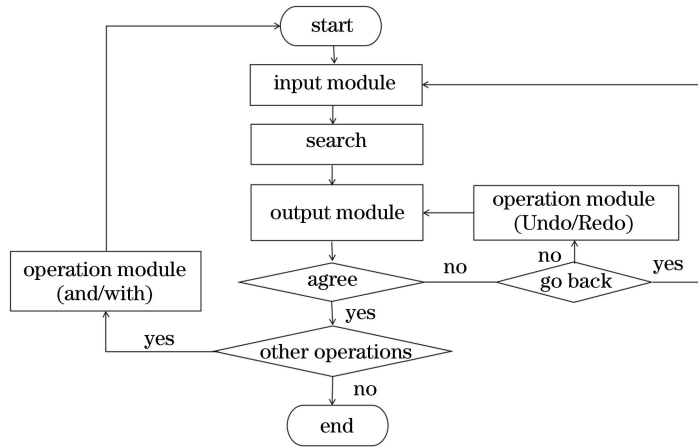


图 3 IRMA 系统结构图

Fig. 3 Diagram of IRMA system structure

表 3 常用的 CBMIR 系统

Table 3 Common CBMIR systems

System name	Application object	Feature extraction	Similarity measure	Related feedback
ASSERT ^[75]	CT image of lung	Labeled area feature	Based on classification	×
NHANES III ^[76]	Spinal X-ray image	Contour shape	Contour matching	×
MRIAGE ^[77]	MRI image of brain	3D Texture	Histogram	×
FICBDS ^[78]	Functional PET	Physiological information	Vector distance	×
IRMA ^[79]	Integrated medical imaging	Multiple feature description	Multiple ranging metric	✓
VisMed ^[80]	Integrated medical imaging	Visual word	Word matching	×
medGIFT ^[81]	Integrated medical imaging	Text and visual features	Multimodal information sorting fusion	×
NovaMedSearch ^[82]	Integrated medical imaging	Text and visual features	Multimodal information sorting fusion	✓
iMedline ^[83]	Clinical case	Text and visual features	Linear weighting of multiple features	✓

由表 3 可见,针对特定应用对象的医学图像检索,往往采用医学图像的相关知识进行特征提取;而针对综合的 CBMIR 系统,通过提取常规医学图像的底层特征(如灰度、纹理和直方图特征等)进行图像表示。此外,带有 RF 的 CBMIR 系统通过用户的反馈信息来改进检索模型,可以获得更好的检索性能。通过列举上述常用的 CBMIR 系统可以得出当前医学图像检索的主要趋势是结合病例的文本信息和图像特征进行检索。

6 展 望

讨论了基于内容的医学图像检索研究进展,主要围绕医学图像特征提取、相似性度量、RF 技术展

开。实现相似病例的医学图像检索,有助于计算机辅助诊断领域的进一步发展,并为深度学习在医疗领域的应用提供了理论和技术支持。现将基于内容的医学图像检索研究的热点及难点总结如下:

1) 寻找更加有效的医学图像特征表示方法,充分利用医学图像的深度特征。医学图像的深度特征包含了许多具有判别能力的图像信息,但由于深度特征本身高维且稀疏,如何挖掘医学图像的更深层特征还是当前图像特征提取面临的一大难题。

2) 探寻更好的特征融合方法。当前的研究主要局限于传统特征的融合,而对于深度特征的融合研究较少。当前深度特征融合面临的主要问题是 CNN 的不同卷积层特征之间的层次复杂,难以找到其中的联

系。此外,现有理论基础对医学图像深度特征的多层融合中应该融合哪些层缺乏合适的指导。

3) 改进哈希算法。医学图像检索算法的高效性对其能否应用到临床中起着至关重要的作用。检索的效率包括图像特征提取的效率及相似性度量的效率。因此未来研究重点应放在哈希算法的改进上,从而进一步增强医学图像检索的实时性。

4) 充分利用 RF 技术。针对当前 RF 技术中面临的无法很好结合医生偏好信息和设置参数过多的问题,考虑利用新的集成学习方法。

5) 建立通用的大规模、高质量医学图像数据库。尽管现有医学图像数据库种类多样,但其所包含医学图像的规模还远远不够,而深度学习需要大量的训练数据,因此如何获得更大、更全面的医学图像数据库是医学图像检索领域所要解决的一大难题。

参 考 文 献

- [1] Smeulders A W M, Worring M, Santini S, et al. Content-based image retrieval at the end of the early years[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(12): 1349-1380.
- [2] Liu Y, Zhang D S, Lu G J, et al. A survey of content-based image retrieval with high-level semantics[J]. *Pattern Recognition*, 2007, 40(1): 262-282.
- [3] Khan S, Yong S P. A comparison of deep learning and hand crafted features in medical image modality classification[C] // 2016 3rd International Conference on Computer and Information Sciences (ICCOINS), August 15-17, 2016, Kuala Lumpur, Malaysia. New York: IEEE, 2016: 633-638.
- [4] Bhattacharyya S, Bhaumik H, De S, et al. Intelligent analysis of multimedia information [M]. Pennsylvania: ICI Global, 2016.
- [5] Jain A K, Vailaya A. Image retrieval using color and shape[J]. *Pattern Recognition*, 1996, 29(8): 1233-1244.
- [6] Manjunath B S, Ma W Y. Texture features for browsing and retrieval of image data [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1996, 18(8): 837-842.
- [7] Lowe D G. Distinctive image features from scale-invariant keypoints [J]. *International Journal of Computer Vision*, 2004, 60(2): 91-110.
- [8] Jegou H, Perronnin F, Douze M, et al. Aggregating local image descriptors into compact codes[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(9): 1704-1716.
- [9] Ojala T, Pietikäinen M, Harwood D. A comparative study of texture measures with classification based on featured distributions[J]. *Pattern Recognition*, 1996, 29(1): 51-59.
- [10] Dalal N, Triggs B. Histograms of oriented gradients for human detection [C] // 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), June 20-25, 2005, San Diego, CA, USA. New York: IEEE, 2005: 8588935.
- [11] Bay H, Tuytelaars T, van Gool L. SURF: speeded up robust features [M] // Leonardis A, Bischof H, Pinz A. *Computer vision-ECCV 2006. Lecture notes in computer science*. Berlin, Heidelberg: Springer, 2006, 3951: 404-417.
- [12] Ramamurthy B. Certain approaches on content based medical image retrieval CBMIR using visual features [D]. India: Anna University, 2014.
- [13] Perronnin F, Sánchez J, Mensink T. Improving the fisher kernel for large-scale image classification[M] // Daniilidis K, Maragos P, Paragios N. *Computer vision-ECCV 2010. Lecture notes in computer science*. Berlin, Heidelberg: Springer, 2010, 6314: 143-156.
- [14] Qayyum A, Anwar S M, Awais M, et al. Medical image retrieval using deep convolutional neural network[J]. *Neurocomputing*, 2017, 266: 8-20.
- [15] Jegou H, Zisserman A. Triangulation embedding and democratic aggregation for image search [C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE, 2014: 3310-3317.
- [16] Babenko A, Slesarev A, Chigorin A, et al. Neural codes for image retrieval [M] // Fleet D, Pajdla T, Schiele B, et al. *Computer vision-ECCV 2014. Lecture notes in computer science*. Cham: Springer, 2014, 8689: 584-599.
- [17] Gong Y C, Wang L W, Guo R Q, et al. Multi-scale orderless pooling of deep convolutional activation features[M] // Fleet D, Pajdla T, Schiele B, et al. *Computer vision-ECCV 2014. Lecture notes in computer science*. Cham: Springer, 2014, 8695: 392-407.
- [18] Yandex A B, Lempitsky V. Aggregating local deep features for image retrieval [C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile.

- New York: IEEE, 2015: 1269-1277.
- [19] Toliás G, Sicre R, Jégou H. Particular object retrieval with integral max-pooling of CNN activations [J/OL]. (2016-02-24) [2019-08-01]. <https://arxiv.xilesou.top/abs/1511.05879>.
- [20] Kalantidis Y, Mellina C, Osindero S. Cross-dimensional weighting for aggregated deep convolutional features [M] // Hua G, Jégou H. Computer vision-ECCV 2016 Workshops. Lecture notes in computer science. Cham: Springer, 2016, 9913: 685-701.
- [21] Jimenez A, Alvarez J, Giro-I-nieto X. Class weighted convolutional features for visual instance search[C] // Proceedings of the British Machine Vision Conference 2017, September 2017, London, UK. England: BMVA Press, 2017: 144.
- [22] Xu J, Shi C, Qi C, et al. Unsupervised part-based weighting aggregation of deep convolutional features for image retrieval [C] // Thirty-Second AAAI Conference on Artificial Intelligence, February 2-7, 2017, New Orleans: AAAI, 2018: 7436-7443.
- [23] Fang X, Yao Y. Content-based Gist-Hash algorithm for ultrasonic image retrieval [J]. Journal of Computer Applications, 2017, 37(z2): 74-76, 81.
方欣, 姚宇. 基于内容的 Gist-Hash 超声图像检索算法[J]. 计算机应用, 2017, 37(z2): 74-76, 81.
- [24] Li Y. Parallel deep solutions for medical image retrieval[J]. Modern Computer, 2018(20): 65-67.
李炎. 医学图像检索的并行深层解决方法[J]. 现代计算机, 2018(20): 65-67.
- [25] Wei C H, Li Y, Huang P J. Mammogram retrieval through machine learning within BI-RADS standards [J]. Journal of Biomedical Informatics, 2011, 44 (4): 607-614.
- [26] Filipczuk P, Fevens T, Krzyzak A, et al. Computer-aided breast cancer diagnosis based on the analysis of cytological images of fine needle biopsies[J]. IEEE Transactions on Medical Imaging, 2013, 32 (12): 2169-2178.
- [27] Avni U, Greenspan H, Konen E, et al. X-ray categorization and retrieval on the organ and pathology level, using patch-based visual words[J]. IEEE Transactions on Medical Imaging, 2011, 30 (3): 733-746.
- [28] Wan Y N, Long F H, Qu L, et al. BlastNeuron for automated comparison, retrieval and clustering of 3D neuron morphologies [J]. Neuroinformatics, 2015, 13(4): 487-499.
- [29] Tommasi T, Orabona F, Caputo B. Discriminative cue integration for medical image annotation [J]. Pattern Recognition Letters, 2008, 29 (15): 1996-2002.
- [30] Song L, Liu X B, Ma L, et al. Using HOG-LBP features and MMP learning to recognize imaging signs of lung lesions [C] // 2012 25th IEEE International Symposium on Computer-Based Medical Systems (CBMS), June 20-22, 2012, Rome, Italy. New York: IEEE, 2012: 12998116.
- [31] Kumar A, Kim J, Cai W D, et al. Content-based medical image retrieval: a survey of applications to multidimensional and multimodality data[J]. Journal of Digital Imaging, 2013, 26(6): 1025-1039.
- [32] Nweke H F, Teh Y W, Al-Garadi M A, et al. Deep learning algorithms for human activity recognition using mobile and wearable sensor networks: state of the art and research challenges[J]. Expert Systems With Applications, 2018, 105: 233-261.
- [33] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 11: 2278-2324.
- [34] Bar Y, Diamant I, Wolf L, et al. Chest pathology detection using deep learning with non-medical training [C] // 2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI), April 16-19, 2015, Brooklyn, NY, USA. New York: IEEE, 2015: 294-297.
- [35] Li W F. Classification of brain CT images based on deep learning [D]. Harbin: Harbin Engineering University, 2017: 356-358.
李文丰. 基于深度学习的脑颅 CT 图分类研究[D]. 哈尔滨: 哈尔滨工程大学, 2017: 356-358.
- [36] Semedod. NovaSearch at image CLEFmed Subfigure classification Task[EB/OL]. (2019-02-10) [2019-08-02]. <https://novasearch.org/publications/>.
- [37] Shin H C, Roth H R, Gao M C, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning [J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1285-1298.
- [38] Wang X F, Lee F, Chen Q. Similarity-preserving hashing based on deep neural networks for large-scale image retrieval[J]. Journal of Visual Communication and Image Representation, 2019, 61: 260-271.
- [39] Huang G, Liu X L. Automatic extraction and classification of road markings based on deep learning [J]. Chinese Journal of Lasers, 2019, 46 (8):

0804002.

黄刚, 刘先林. 基于深度学习的道路标线自动提取与分类方法[J]. 中国激光, 2019, 46(8): 0804002.

- [40] Zhang H, Chen C H. Aurora sequence classification based on deep learning[J]. *Laser & Optoelectronics Progress*, 2018, 55(11): 111504.
张浩, 陈昌红. 基于深度学习的极光序列自动分类方法[J]. 激光与光电子学进展, 2018, 55(11): 111504.
- [41] Gialampoukidis I, Vrochidis S, Kompatsiaris I. Fast visual vocabulary construction for image retrieval using skewed-split k-d trees[M] // Tian Q, Sebe N, Qi G J, et al. *MultiMedia modeling. Lecture notes in computer science*. Cham: Springer, 2016, 9516: 466-477.
- [42] Verma M, Raman B. Local tri-directional patterns: a new texture feature descriptor for image retrieval [J]. *Digital Signal Processing*, 2016, 51: 62-72.
- [43] Wei G, Ma H, Qian W, et al. Similarity measurement of lung masses for medical image retrieval using kernel based semisupervised distance metric[J]. *Medical Physics*, 2016, 43: 6259-6269.
- [44] Coates A, Ng A, Lee H. An analysis of single-layer networks in unsupervised feature learning [C] // *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, April 11-13, 2011, Fort Lauderdale, USA. Cambridge: MIT Press, 2011: 215-223.
- [45] Bengio Y, Courville A C, Vincent P. Unsupervised feature learning and deep learning: a review and new perspectives [J/OL]. (2014-04-23) [2019-08-01]. <https://arxiv.xilesou.top/abs/1206.5538v1>.
- [46] Wang S Y, Kim M, Wu G R, et al. Scalable high performance image registration framework by unsupervised deep feature representations learning [M] // Kevin Zhou S, Greenspan H, Shen D. *Deep learning for medical image analysis*. Pittsburgh: Academic Press, 2017: 245-269.
- [47] Brosch T, Tam R. Manifold learning of brain MRIs by deep learning[M] // Mori K, Sakuma I, Sato Y, et al. *Medical image computing and computer-assisted intervention-MICCAI 2013. Lecture notes in computer science*. Berlin, Heidelberg: Springer, 2013, 8150: 633-640.
- [48] Yang X L, Lin S Z, Lu X F, et al. Multimodal image fusion based on generative adversarial networks [J]. *Laser & Optoelectronics Progress*, 2019, 56(16): 161004.
- 杨晓莉, 蔺素珍, 禄晓飞, 等. 基于生成对抗网络的多模态图像融合[J]. 激光与光电子学进展, 2019, 56(16): 161004.
- [49] Wu M L. Medical image retrieval based on semi-supervised learning[D]. Nanjing: Nanjing University of Science and Technology, 2015: 67-69.
吴梦麟. 基于半监督学习的医学图像检索研究[D]. 南京: 南京理工大学, 2015: 67-69.
- [50] Bai W J, Oktay O, Sinclair M, et al. Semi-supervised learning for network-based cardiac MR image segmentation[M] // Descoteaux M, Maier-Hein L, Franz A, et al. *Medical image computing and computer-assisted intervention-MICCAI 2017. Lecture notes in computer science*. Cham: Springer, 2017, 10434: 253-260.
- [51] Son L H, Tuan T M. A cooperative semi-supervised fuzzy clustering framework for dental X-ray image segmentation [J]. *Expert Systems With Applications*, 2016, 46: 380-393.
- [52] Li Z D, Zhong Y, Zhang B Y, et al. Massive face image retrieval based on depth feature clustering[J]. *Journal of Harbin Institute of Technology*, 2018, 50(11): 101-109.
李振东, 钟勇, 张博言, 等. 基于深度特征聚类的海量人脸图像检索[J]. 哈尔滨工业大学学报, 2018, 50(11): 101-109.
- [53] Xiang S M, Nie F P, Zhang C S. Learning a Mahalanobis distance metric for data clustering and classification [J]. *Pattern Recognition*, 2008, 41(12): 3600-3612.
- [54] Wei G H, Qi S L, Qian W, et al. Image retrieval algorithm of pulmonary nodules based on similarity measurement[J]. *Journal of Northeastern University (Natural Science)*, 2018, 39(9): 1226-1231.
魏国辉, 齐守良, 钱唯, 等. 基于相似性度量的肺结节图像检索算法[J]. 东北大学学报(自然科学版), 2018, 39(9): 1226-1231.
- [55] Yu J, Tao D P, Li J, et al. Semantic preserving distance metric learning and applications [J]. *Information Sciences*, 2014, 281: 674-686.
- [56] Nister D, Stewenius H. Scalable recognition with a vocabulary tree [C] // *2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)*, June 17-22, 2006, New York, NY, USA. New York: IEEE, 2006: 2161-2168.
- [57] Jiang M L, Zhang S T, Li H S, et al. Computer-aided diagnosis of mammographic masses using

- scalable image retrieval [J]. *IEEE Transactions on Biomedical Engineering*, 2015, 62(2): 783-792.
- [58] Wang J J, Xiao J, Lin W Y, et al. Discriminative and generative vocabulary tree: with application to vein image authentication and recognition [J]. *Image and Vision Computing*, 2015, 34: 51-62.
- [59] Zhang X F, Yang L, Liu W, et al. Mining histopathological images via composite hashing and online learning [M] // Golland P, Hata N, Barillot C, et al. *Medical image computing and computer-assisted intervention-MICCAI 2014. Lecture notes in computer science*. Cham: Springer, 2014, 8674: 479-486.
- [60] Liu J J, Zhang S T, Liu W, et al. Scalable mammogram retrieval using Anchor Graph Hashing [C] // 2014 IEEE 11th International Symposium on Biomedical Imaging (ISBI), April 29-May 2, 2014, Beijing, China. New York: IEEE, 2014: 898-901.
- [61] Yu X, Zhang S T, Liu B, et al. Large scale medical image search via unsupervised PCA hashing [C] // 2013 IEEE Conference on Computer Vision and Pattern Recognition Workshops, June 23-28, 2013, Portland, OR, USA. New York: IEEE, 2013: 393-398.
- [62] Jiang M L, Zhang S T, Li H S, et al. Computer-aided diagnosis of mammographic masses using scalable image retrieval [J]. *IEEE Transactions on Biomedical Engineering*, 2015, 62(2): 783-792.
- [63] Rui Y, Huang T. Optimizing learning in image retrieval [C] // *Proceedings IEEE Conference on Computer Vision and Pattern Recognition. CVPR 2000 (Cat. No. PR00662)*, June 15-15, 2000, Hilton Head Island, SC, USA. New York: IEEE, 2000: 6651640.
- [64] Shi X S, Sapkota M, Xing F Y, et al. Pairwise based deep ranking hashing for histopathology image classification and retrieval [J]. *Pattern Recognition*, 2018, 81: 14-22.
- [65] Holub A, Perona P. A discriminative framework for modelling object classes [C] // 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), June 20-25, 2005, San Diego, CA, USA. New York: IEEE, 2005: 8588926.
- [66] Wu J X, Gao B B, Wei X S, et al. Resource-constrained deep learning: challenges and practices [J]. *Scientia Sinica (Informationis)*, 2018, 48(5): 501-510.
- 吴建鑫, 高斌斌, 魏秀参, 等. 资源受限的深度学习: 挑战与实践 [J]. *中国科学: 信息科学*, 2018, 48(5): 501-510.
- [67] Wu H, Lu H, Ma S. The role of sample distribution in relevance feedback for content based image retrieval [C] // *IEEE International Conference on Multimedia and Expo, August 26-29, 2002, Lausanne, Switzerland*. New York: IEEE, 2002: 225-228.
- [68] Zhou Z H, Chen K J, Dai H B. Enhancing relevance feedback in image retrieval using unlabeled data [J]. *ACM Transactions on Information Systems*, 2006, 24(2): 219-244.
- [69] Zucker J D, Chevalere Y. Solving multiple-instance and multiple-part learning problems with decision trees and decision rules. Application to the mutagenesis problem [C] // *Proceedings of the 14th Canadian Conference on Artificial Intelligence, Lecture Notes in Artificial Intelligence*, June 7-9, 2001, Ottawa, Canada. [S. l.: s. n.], 2000: 204-214.
- [70] Greiner R, Su X Y, Shen B, et al. Structural extension to logistic regression: discriminative parameter learning of belief net classifiers [J]. *Machine Learning*, 2005, 59(3): 297-322.
- [71] Shyu C R, Brodley C E, Kak A C, et al. ASSERT: a physician-in-the-loop content-based retrieval system for HRCT image databases [J]. *Computer Vision and Image Understanding*, 1999, 75(1/2): 111-132.
- [72] Tzelepi M, Tefas A. Relevance feedback in deep convolutional neural networks for content based image retrieval [C] // *Proceedings of the 9th Hellenic Conference on Artificial Intelligence - SETN'16*, May 18-20, 2016, Thessaloniki, Greece. New York: ACM, 2016: 27.
- [73] Gyires-Tóth B P, Osváth M, Papp D, et al. Deep learning for plant classification and content-based image retrieval [J]. *Cybernetics and Information Technologies*, 2019, 19(1): 88-100.
- [74] Qian Y, Gao X, Loomes M, et al. Content-based retrieval of 3D medical images [C] // *The Third International Conference on eHealth, Telemedicine, and Social Medicine (eTELEMED 2011)*. [S. l.: s. n.], 2011: 7-12.
- [75] Cai W, Feng D, Fulton R. Content-based retrieval of dynamic PET functional images [J]. *IEEE Transactions on Information Technology in Biomedicine*, 2000, 4(2): 152-158.

- [76] Huang X D, Sun L, Liu S L. A retrieval method of relevance feedback images based on discriminative extreme learning [J]. Journal of Xi'an Jiaotong University, 2016, 50(8): 96-102.
黄晓冬, 孙亮, 刘胜蓝. 一种判别极端学习的相关反馈图像检索方法[J]. 西安交通大学学报, 2016, 50(8): 96-102.
- [77] Yu F, Li Y X, Wei B, et al. Interactive differential evolution for user-oriented image retrieval system[J]. Soft Computing, 2016, 20(2): 449-463.
- [78] Kahn C E Jr, Thao C. GoldMiner: a radiology image search engine [J]. American Journal of Roentgenology, 2007, 188(6): 1475-1478.
- [79] Kalpathy-Cramer J, de Herrera A G S, Demner-Fushman D, et al. Evaluating performance of biomedical image retrieval systems: an overview of the medical image retrieval task at ImageCLEF 2004-2013 [J]. Computerized Medical Imaging and Graphics, 2015, 39: 55-61.
- [80] Lim J H, Chevallet J P. VisMed: a visual vocabulary approach for medical image indexing and retrieval [M]// Lee G G, Yamada A, Meng H, et al. Information retrieval technology. Lecture notes in computer science. Berlin, Heidelberg: Springer, 2005, 3689: 84-96.
- [81] Müller H, Lovis C, Geissbuhler A. The medGIFT project on medical image retrieval [C/OL]. [S.l.: s.n.], (2005-10-01)[2019-08-01]. https://www.researchgate.net/publication/228730403_The_medGIFT_project_on_medical_image_retrieval.
- [82] Mourão A, Martins F, Magalhães J. Multimodal medical information retrieval with unsupervised rank fusion [J]. Computerized Medical Imaging and Graphics, 2015, 39: 35-45.
- [83] Seco de Herrera A G, Schaer R, Markonis D, et al. Comparing fusion techniques for the ImageCLEF 2013 medical case retrieval task [J]. Computerized Medical Imaging and Graphics, 2015, 39: 46-54.