

DOI:10.19651/j.cnki.emt.2005441

基于多特征选择的膝关节骨关节炎 SVM 分级研究*

刘志鹏¹ 李修寒¹ 冯锐¹ 姚庆强² 王伟¹ 吴小玲¹

(1. 南京医科大学 生物医学工程学系 南京 210000; 2. 南京市第一医院 南京 210000)

摘要: 骨关节炎是中老年人群最常见的关节疾病,该疾病及其并发症占据了全球 10% 的医疗问题。其中膝关节骨关节炎最为严重,致残风险极高。尽早发现并介入治疗对于缓解其症状,减少其危害有着至关重要的意义。首先收集了大量膝关节 DR 影像数据,对获得的数据进行多种纹理特征和融合特征的提取,将提取的特征向量进行各种组合作为输入训练 SVM 模型,使用网格搜索法进行了参数寻优。训练完成的模型在测试集上的准确率最高可以达到 84.29%,具有良好的智能分类诊断性能。使用训练完的 SVM 模型,可以有效的对膝关节骨性关节炎进行分级,辅助医生进行诊断,对膝关节骨性关节炎的早期诊断,尽早介入治疗有着重要意义。

关键词: SVM; 纹理特征; 融合特征; 特征选择

中图分类号: R318.5 文献标识码: A 国家标准学科分类代码: 310.61

Classification of knee osteoarthritis by SVM based on multi-feature selection

Liu Zhipeng¹ Li Xiuhuan¹ Feng Rui¹ Yao Qingqiang² Wang Wei¹ Wu Xiaoling¹

(1. Department of Biomedical Engineering, Nanjing Medical University, Nanjing 210000, China;
2. Nanjing First Hospital, Nanjing 210000, China)

Abstract: Osteoarthritis is the most common joint disease in middle-aged and elderly people. The disease and its complications account for 10 per cent of global medical problems. Among them, osteoarthritis of the knee is the most serious and the risk of disability is very high. Early detection and interventional treatment is of great significance to relieve the symptoms and reduce the harm. Firstly, a large number of knee joint DR image data were collected. Various texture features and fusion features were extracted from the obtained data. Then, various combinations of extracted feature vectors were used as input to the training support vector machine model. We use the grid search method to optimize the parameters. The highest accuracy of the trained model on the test set can reach 84.29%, which has good intelligent classification and diagnosis performance. Using the trained SVM model can effectively grade knee osteoarthritis and assist doctors in diagnosis, which is of great significance for early diagnosis and early intervention treatment of knee osteoarthritis.

Keywords: SVM; texture feature; fusion feature; feature selection

0 引言

骨关节炎(OA)是中老年人群最常见的关节疾病,在 65 岁以上人群中,发病率高达 50%,OA 危害严重,除导致关节疼痛、畸形外,还会造成活动功能障碍,进而诱发更多的心血管事件,造成许多致残的隐患^[1]。膝、髌、踝、手和脊柱都是骨关节炎入侵的部位,其中膝关节患病情况最为严重。尽管全膝关节置换手术是最有效的严重关节炎治疗手

段,但是对于早期骨关节炎合理的基础和药物治疗也有着十分有效的作用,尽早发现并介入治疗对于避免骨关节炎恶化从而严重影响个人生活有着十分重要的意义。

针对于膝关节骨关节炎的分级诊断主要通过 DR 影像数据进行,医生根据 Kellgren & Lawrence 分级指南^[2-3],对于膝关节骨关节炎严重程度进行主观的分级,经验的丰富与否对于最终的诊断起着决定性作用。人工进行膝关节分级会大大增加医生的负担,同时主观的判断会受到多种因

收稿日期:2020-11-27

* 基金项目:国家重点研发计划(2017YFB1303203)、江苏省研究生研究与实践创新计划(JX12413673)资助

素的影响。

DR 影像对于医生有着最直观的判断依据,众多分级指南也是依据 DR 影像而定,但是在机器分类上并没有太多的深入研究。相对而言,由于 MRI 成像所能提供的高组织对比度使得其成像可以清晰的显示软骨形态,吸引了更多学者的注意。李志刚等^[4]发现相对于对照组,病变组股骨内侧髁、外侧髁负重区与非负重区的 T2 值有所增高。此外 MRI 的 T2 成像图在纹理上也会有所变化,王姗^[5]通过 T2 值联合 MRI 图像的纹理分析将机器学习引入到膝关节 OA 的分类诊断,取得了不错的效果。

本文将膝关节 OA 分类依据重回影像,利用 DR 影像数据对其进行多种纹理特征及融合特征的提取,对于提取的单一特征进行组合^[6],通过机器学习的方法将提取到的特征训练一个最优的支持向量机模型,通过该模型可以实现膝关节骨关节炎的自动分级,对于辅助医生的诊断,减轻医生负担,为膝关节骨关节炎诊断进入常规体检,增加人们对膝关节保护的重视有着重大意义。

本文的主要研究思路总结如下:

- 1) 从医院采集获取下肢 DR 影像数据,邀请经验丰富的医生根据 Kellgren&Lawrence 分级指南标注好的膝关节骨关节炎等级。
- 2) 将原始数据进行预处理,截取 $1\ 500 \times 1\ 500$ pixel 的膝关节部分影像实现图像归一化并去除冗余信息。
- 3) 对膝关节部分影像纹理特征,融合特征以及膝关节间隙距离特征进行提取。
- 4) 对提取完成的 5 组特征向量进行组合,输入训练支持向量机模型,对每个组合进行参数寻优。
- 5) 对训练完成的模型进行性能的评估。

1 图像预处理和纹理特征提取

根据膝关节骨关节炎 Kellgren&Lawrence 分级指南可知,由膝关节 DR 影像对膝关节骨关节炎进行分级主要参考的特征有膝关节间隙的大小和骨赘的严重程度,这些特征都在图像的纹理特征值上有一定的表现特点,因此本文将膝关节 DR 影像的纹理特征作为膝关节骨关节炎主要的分类依据。

目前,对于图像全局纹理特征的描述主要有灰度共生矩阵(gray-level cooccurrence matrix, GLCM)的纹理分析法和 Tamura 纹理特征等,对于图像的局部纹理特征的描述有局部二值模式^[7](LBP 算子),尺度不变特征转化^[8](sift 算子),定向梯度直方图^[9](HOG 算子)等,其中 sift 算子和 HOG 算子对图像边缘敏感,更利于感知物体的轮廓。本文将基于以上方法对膝关节影像数据进行特征向量的提取,作为输入进行支持向量机模型的训练。

灰度共生矩阵是通过统计像素及其邻域的灰度属性形成的,通常包含 0° 、 45° 、 90° 、 135° 四个方向上的 4 组矩阵,通过计算可以得到 4 组灰度共生矩阵的每组 14 个统计特性

从而对图像的纹理进行描述,其中 4 个关键特征对比度、自相关、能量和同质性在用于图像分类中有着较好的表现,常被用于图像的分类识别。对比度(Contrast)反映了整幅图像中像素和它相邻像素之间的反差,对比度的大小与图像的细致程度呈正相关;相关性(Correlation)反映了 GLCM 中元素在行列上的相似程度;能量(Energy)即为角二阶矩,计算的是 GLCM 中每个元素的平方和,反映图像灰度分布的均匀性和纹理的粗细度;同质性(Homogeneity)反映了图像的纹理的清晰度和规则度。上述 4 个特征可由如下公式计算得到:

$$Con = \sum_{i,j} |i-j|^2 p(i,j) \quad (1)$$

$$Cor = \frac{\sum_i \sum_j (ij) p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2)$$

$$Eng = \sum_i \sum_j p(i,j)^2 \quad (3)$$

$$Hom = \sum_{i,j} \frac{p(i,j)}{1+|i-j|} \quad (4)$$

通过计算得到一组 GLCM 纹理特征记为 $OG = [Con, Cor, Eng, Hom]$ 。

Tamura 特征是对图像的纹理特征描述的另一套体系,在 Tamura 纹理特征的描述中,主要包括 6 项指标,粗糙度、对比度、方向度、线性度、规则度和粗略度。粗糙度(F_{crs})反映了图像纹理特征中的粒度;对比度(F_{con})是统计像素灰度的分布情况后计算得到,反映了图像灰度的动态范围,量机分化程度,边缘的锐度和图像重复的周期;方向度(F_{dir})反映了纹理沿某些方向发散或集中的程度,具体计算公式如下:

$$F_{crs} = \frac{1}{m \times n} \sum_m^{i=1} \sum_n^{j=1} S_{best}(i,j) \quad (5)$$

$$F_{con} = \frac{\sigma}{\alpha_4^n} \quad (6)$$

$$F_{dir} = \sum_p \sum_{\Phi \in W_p} (\Phi - \Phi_p)^2 H_D(\Phi) \quad (7)$$

后 3 个特征与前 3 个特征高度相关,线性度、规则度和粗略度分别由如下公式计算得到:

$$F_{lin} = \sum_i \sum_j P_{Dd}(i,j) \cos \left[(i-j) \frac{2\pi}{n} \right] / \sum_i \sum_j P_{Dd}(i,j) \quad (8)$$

$$F_{reg} = 1 - r(\sigma_{crs} + \sigma_{con} + \sigma_{dir} + \sigma_{lin}) \quad (9)$$

$$F_{rgh} = F_{crs} + F_{con} \quad (10)$$

弥补了前 3 个特征对于精细纹理特征辨别的不足。

此时又得到一组图像的 Tamura 纹理特征 $OT = [F_{crs}, F_{con}, F_{dir}, F_{lin}, F_{reg}, F_{rgh}]$ 。

局部二值模式(LBP 算子)不同于以上两种方法,是一种对于图像局部纹理特征的提取方法,该方法可以注重于关键的局部信息^[10],具有光照不变性和旋转不变性的特征,可以减少患者拍 CT 影像时个人姿势不同以及射线计

量造成的图像对比度不同对于分类的影响。该算子在 3×3 的窗口中,以中心像素为阈值,周围 8 个像素与之比较,大于中心像素取 1,小于中心像素取 0,组成一个 8 位二进制数据作为中心像素的 LBP 值,以此来反映该区域的纹理信息。每个像素的 LBP 值可由如下公式计算得到:

$$LBP(x_c, y_c) = \sum_{p=0}^{p-1} 2^p s(i_p - i_c) \quad (11)$$

式中: (x_c, y_c) 表示中心像素; i_c 表示中心像素的灰度值; i_n 表示周围像素的灰度值; $s(x)$ 表示一个符号函数,即:

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (12)$$

对经过 LBP 算子处理后的图像继续提取 GLCM 纹理特征和 Tamura 纹理特征可将两种纹理特征提取方法进行融合,实现局部纹理和整体纹理特征的融合^[11]。融合后的特征向量可以记为 LG,LT。

K-means 聚类对于给定的样本集,按照样本之间的距离大小,将样本集划分为 K 簇。本文将原图像二值化后使用 K-means 聚类将影像数据中数值为 1 的像素点分为两簇,此两簇即为膝关节上的股骨和膝关节下方的胫骨腓骨,计算聚类中心间的距离记为 Dir。其中簇中心计算方式如下:

$$\mu_i = \frac{1}{|C_i|} \sum_{x \in C_i} x \quad (13)$$

2 支持向量机

支持向量机(support vector machine, SVM)自 1995 年提出后便在小样本、非线性、高维度模式识别中表现出巨大的优势,基于统计学习理论,通过核函数的方法将低维不可分的数据映射到高维空间,从而寻找最优超平面作为决策函数,对样本进行分类。目前 SVM 在信号的和图像的分类上已经取得广泛的应用^[12]。在对膝关节多组特征向量的提取完成后需要解决的问题便是对于多维特征向量的分类问题。SVM 模型将会是一个很好地选择。

2.1 支持向量机的构建

对于给定训练样本集的数据 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$, $y_i \in \{-1, +1\}$, 其中 $x_i (i = 1, 2, \dots, m)$ 表示特征向量,此处即为第二部分所述的由图像提取的各种纹理特征 $x_i = [OG, OT, LG, LT, Dir]$; y_i 表示类别标签。

SVM 的分类思想便是基于以上给定的训练样本寻找一个超平面可以将不同类别标签的样本区分开。这样的超平面可以用如下的线性方程表示,即:

$$w^T x + b = 0 \quad (14)$$

式中: $w = (w_1, w_2, \dots, w_d)$ 为法向量; b 为位移项。

若超平面将样本正确分类,此时应满足以下限制条件: $y_i(w^T x_i + b) - 1 \geq 0, i = 1, 2, \dots, m$ (15)

两个距离超平面距离最近的并且类别标签不同的样本称为支持向量,两个支持向量超平面的距离和记为:

$$\gamma = \frac{2}{\|w\|} \quad (16)$$

SVM 的训练目标便是寻找最大间隔 γ 。

于是,SVM 的训练便是一个凸二次规划求最优解的问题,具体的数学表达形式如下所示:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (17)$$

$$s.t. y_i(w^T x_i + b) - 1 \geq 0, i = 1, 2, \dots, m$$

该问题的求解可以通过拉格朗日乘子法将其转换为“对偶问题”,直接使用 SMO 算法高效求解。

2.2 核函数选择与参数寻优

在实际应用中,用于训练的特征向量在自身维度下并非线性可分,此时核函数的使用便是 SVM 模型的核心所在,通过向高维映射,使得所选特征向量线性可分。通过一个非线性函数 $\Phi(x)$ 实现特征向量 $x_i \in R^N$ 向更高维度的欧几里得特征空间的 F 的映射。此时,使用 $\Phi(x_i) \cdot \Phi(x_j)$ 代替原本的 $x_i \cdot x_j$ 可以将 R^N 空间的最优化问题转换为 F 空间的最优化问题。SVM 中,核函数可表达如下:

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (18)$$

此外使用的训练和测试样本很难做到完全的线性可分,即便实现了线性可分,也很难确定不是由于过拟合导致的,因此,将引入软间隔的概念,以此来提高模型训练的效率和减少过拟合情况的发生。此时,优化的限制条件可转换为:

$$c l_{0/1}(y_i(w^T x_i + b) - 1) \geq 0 \quad (19)$$

其中, $l_{0/1}(x)$ 为 0/1 的损失函数。

核函数和软间隔的使用为 SVM 的训练引入了两个新的优化参数,核函数参数 g 和惩罚常数 c 。

SVM 的训练集中体现在核函数和损失函数的选择和优化,即选定核函数和损失函数后 c 和 g 的参数寻优,常用的方法有网格搜索法^[13],粒子群算法^[14]和遗传算法^[15]。网格搜索法给定参数寻优范围,对参数进行地毯式扫描,尽管效率低于粒子群算法和遗传算法,但优于不会陷入局部最优解,因此此处选择网格搜索法进行参数寻优。

3 实验部分

3.1 数据采集

实验所用的原始数据来自南京市第一人民医院骨科,获得的数据有下肢单肢、下肢双肢、下肢正位、下肢侧位的 DR 影像,图 1 所示为部分收集到的影像数据。膝关节 DR 影像数据由 5 位专业医生根据 Kellgreb&Lawrence 分级指南进行评级,分为 0~4 级。膝关节骨关节炎最终评级取 5 位医生评级的众数,并且只有当 4 位医生评级相同才将其定为有效数据。经过以上筛选之后共剩余膝关节骨关节炎 0 级数据 5 例、1 级数据 12 例、2 级数据 65 例、3 级数据 150 例、4 级数据 223 例。首先对影像数据进行初步的筛选,支持向量机训练仅使用膝关节正位影像数据,并截取

膝关节部分 $1\ 500 \times 1\ 500$ pixel 的影像,以此对数据进行归一化处理并减少其他冗余信息对支持向量机训练的干扰,

处理完成后的图像如图 2 所示,分别为归一化后的 0~4 级膝关节 DR 影像数据。



图 1 下肢 DR 影像原始数据



图 2 截取并归一化后的膝关节影像数据

3.2 数据分类

本文将以上数据分成两类,0级,1级,2级为一类,这类数据采集来自正常人或者膝关节骨关节炎早期的患者,此类人群的膝关节骨关节炎对生活的影响较小,对他们的治疗策略主要以引起他们对膝关节保护的重视为主,同时也可以使用非药物疗法,例如物理疗法,关节功能训练,有氧锻炼,减少不合理运动,避免不良姿势,避免长时间跑、跳、蹲等来减缓甚至遏制膝关节骨关节炎向3级,4级发展的趋势;将3级,4级膝关节骨关节炎数据分为另一类,这类患者通常已经进入膝关节骨关节炎后期了,通常伴随着关节疼痛及压痛、关节僵硬、关节肿大、骨摩擦音、关节无力活动障碍等症状的出现,此类患者生活已经受到膝关节骨关节炎的影响了,骨关节的危害在此类人群中最为显著,对于此类患者医生的干预已经必不可少,药物辅必要的物理治疗显得至关重要,严重的甚至要进行全膝关节置换术这一手术治疗才能有所效果。

3.3 数据增强

通过上述方法进行分类后,得到正类数据 82 例,负类数据 373 例。数据极不均匀,因此,对正类数据进行数据增强,通过图像翻转,图像旋转等方法将正类数据增强至原来的 4 倍,最终得到正类数据 328 例。

3.4 特征提取

对于每一幅膝关节数据将提取 5 组特征。两组是直接对图像提取的 GLCM 纹理特征和 Tamura 纹理特征,其中 GLCM 纹理特征将提取 0° 、 45° 、 90° 、 135° 四个方向上对比度、自相关、能量和同质性 4 类特征,得到 16 维特征向量,Tamura 纹理特征提取粗糙度、对比度、方向度、线性

度、规则度和粗略度 6 类特征,得到 6 维特征向量;两组是融合特征,在图像经过 LBP 算子计算后,对新的图像在提取 GLCM 纹理特征和 Tamura 纹理特征又得到 16 维特征向量和 6 维特征向量,图 3 所示为原图和经过 LBP 算子运算后的图像;最后一组是对图像进行 K-means 聚类,将膝关节上方的股骨和下方的尺桡骨分为两簇,之后计算聚类中心的距离,作为膝关节图像的最后的一组一维特征,图 4 所示为 K-means 聚类中簇划分效果以及聚类中心的寻找效果。

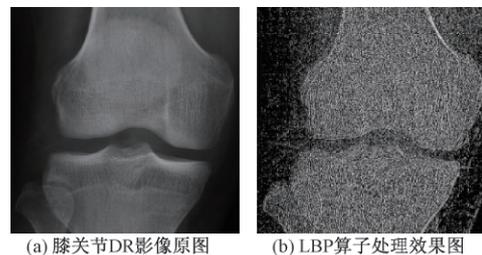


图 3 LBP 算子处理效果图

3.5 支持向量机

通过上述步骤,累计得到 701 例分为两类的膝关节影像数据,提取了 5 组共计 44 维特征向量,按 8 : 2 将数据分为训练集和验证集。对于 SVM 模型的构建与训练,采用台湾大学林智仁教授设计的 MATLAB 工具包 libsvm^[16],选用的核函数为 RBF 核,通过网格搜索法对惩罚参数 c 和核参数 g 进行地毯式搜索,搜索范围为 $[2^{-10}, 2^{10}]$,采用交叉验证法的 10 折交叉验证,选择使得交叉验证平均成功率最高的 c 和 g 。最后在确定 c 和 g 后,在验证集上评估所构建的模型。

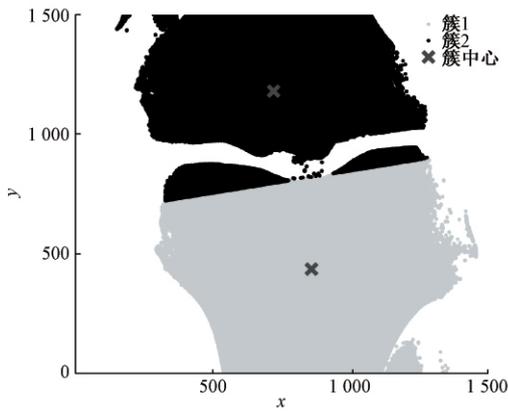


图 4 K-means 聚类效果

3.6 分类特征选择

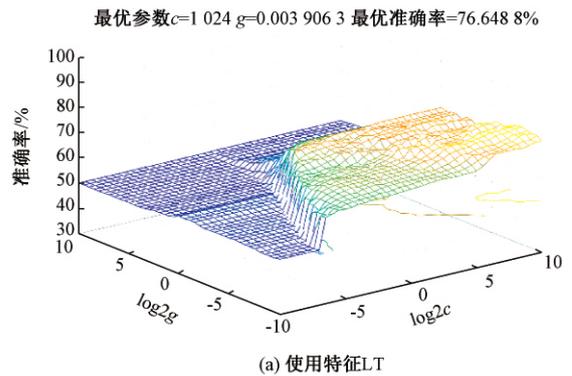
在特征提取中,一共提取获得了 5 组特征共计 45 维特征向量,虽然人为可以理解每种纹理特征参数对应表示图像的何种特征,然而,并不能确定 SVM 分类时对于哪组或哪几组特征敏感,并且,SVM 模型的训练样本并非维度越高越好,倘若维度过高会产生休斯效应^[17-18],反而降低了 SVM 模型的性能,因此特征的选择在 SVM 模型的构建中也是必不可少的^[19],本文将测试不同的特征组合下所训练出的 SVM 的分类的准确率。其中 K-means 聚类中心距离对应膝关节的间隙大小,本文将此作为公共的特征向量。

3.7 测试结果展示与分析

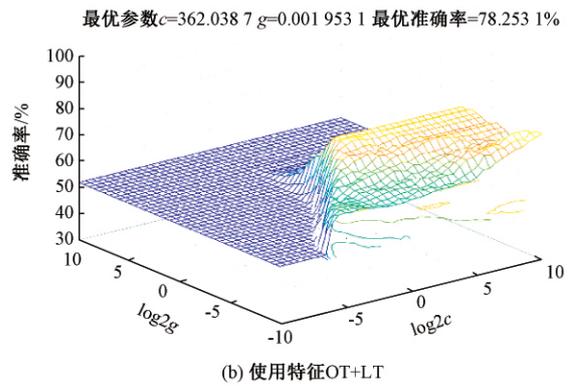
本文对 5 组特征, GLCM 纹理特征(OG)、Tamura 纹理特征(OT)、LBP 算子和 GLCM 融合纹理特征(LG)、LBP 算子和 Tamura 融合纹理特征(LT)进行组合,其中 K-means 聚类中心距离作为公共特征,分别输入支持向量机模型进行惩罚参数 c 和核参数 g 的搜索。在对 4 组特征进行组合时,一共获得 15 组组合情况,图 5 所示为 4 组组合情况下对惩罚参数 c 和核参数 g 搜索的 3D 图像。

在选取不同特征组合时,网格搜索到的最优的惩罚参数 c 和核参数 g 下,对于数据分类的准确率如表 1 所示。

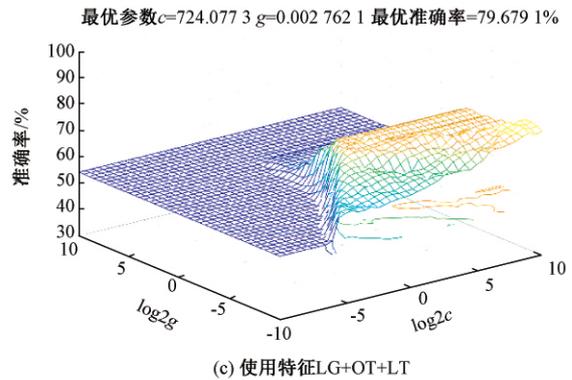
从实验结果的图表可知,使用 Tamura 纹理特征和 LBP 算子与 Tamura 纹理特征的融合特征作为 SVM 的输入特征参数时,所得到 SVM 模型效果最好,在测试集数据的分类上准确率可以达到 84.2857%。对比于 GLCM 纹理特征,SVM 模型在膝关节骨关节炎的分类上对 Tamura 纹理特征更为敏感,所训练得到的模型在测试集上具有更好的准确率。随着输出的特征参数增加时,所训练得到的模型并没有完全随之增长,对于特征的选择在 SVM 模型的训练上是有必要的。相比于单一的特征,两类纹理特征与 LBP 算子的融合特征在 SVM 模型的训练上具有更高的敏感性,所训练的得到的 SVM 相比于用非融合特征具有更高的准确率。



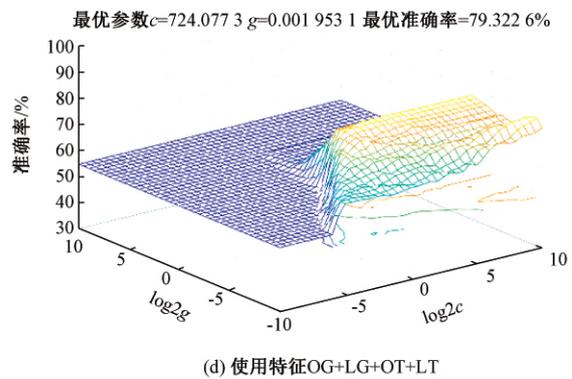
(a) 使用特征LT



(b) 使用特征OT+LT



(c) 使用特征LG+OT+LT



(d) 使用特征OG+LG+OT+LT

图 5 网格搜索法使用不同特征向量输入训练 SVM 的参数 c, g 寻优 3D 图

表 1 膝关节影像数据特征选择及分类结果

特征选择	参数 c	参数 g	测试集正确率/%
OG	1.414 2	0.007 8	62.857(88/140)
LG	1.024	0.007 8	72.857(102/140)
OT	1	0.062 5	75(105/140)
LT	1.024	0.003 9	78.571(110/140)
OG+LG	1.024	0.003 9	70.714(99/140)
OG+OT	45.254 8	0.007 8	72.857(102/140)
OG+LT	1.024	0.007 8	76.429(107/140)
LG+OT	0.5	0.044 2	72.143(101/140)
LG+LT	1.024	0.002 0	72.857(102/140)
OT+LT	362.038 7	0.002 0	84.286(118/140)
OG+LG+OT	2.828 4	0.176 8	70.714(99/140)
OG+LG+LT	724.077 3	0.003 9	76.429(107/140)
OG+OT+LT	724.077 3	0.002 0	77.857(109/140)
LG+OT+LT	724.077 3	0.002 8	81.429(114/140)
OG+LG+OT+LT	724.077 3	0.002 0	76.429(107/140)

4 结 论

通过标注好的膝关节影像数据可以提取其各种纹理特征,可以选择支持向量机敏感的纹理特征进行 SVM 模型的训练,训练完成的 SVM 可以对未标注的膝关节影像数据进行自动分类,目前实验表明,SVM 对于融合 LBP 的 Tamura 纹理特征敏感度最高,通过 Tamura 纹理特征和 LBP 算子 Tamura 的融合特征的组合训练得到的 SVM 模型拥有最高的测试集分类准确率,高达 84.2857%。通过该方法可以实现膝关节骨性关节炎的自动分类评级,对于经验不足新医生的诊断有一定的参考指示意义,同时可以通过此方法将膝关节诊断纳入日常体检中,自动诊断分级的应用可以给医生带来极大的便利,同时也可以增加患者对于膝关节保护的重视性。本文仅使用了 SVM 的二分类模型,后续随着更多数据的收集,可以训练 5 级膝关节骨性关节炎的自动分级模型,对于精准医疗有着重要意义。

参考文献

- [1] MCALINDON T E, BANNURU R R. Latest advances in the management of knee OA[J]. Nature reviews. Rheumatology, 2018, 14(2):73-74.
- [2] KOLASINSKI S L, NEOGI T, HOCHBERG M C, et al. 2019 American College of rheumatology/arthritis foundation guideline for the management of osteoarthritis of the hand, hip, and knee[J]. Arthritis & Rheumatology, 2020, 72(2):220-233.
- [3] BANNURU R R, OSANI M C, VAYSIBROT E E, et al. OARSI guidelines for the non-surgical management of knee, hip, and polyarticular osteoarthritis [J]. Osteoarthritis and Cartilage, 2019, 27(11), DOI: 10.1016/j.joca.2019.06.011.
- [4] 李志刚, 文戈, 杜立新, 等. T2* mapping 辅助 MRI 技术对差异性膝关节骨性关节炎软骨损伤程度的诊断价值[J]. 分子影像学杂志, 2020, 43(2):242-246.

- [5] 王姗. T2 mapping 联合纹理分析在膝关节骨性关节炎中的应用[D]. 郑州:郑州大学, 2017.
- [6] 史庆军, 郭晓振, 刘德胜. 基于特征量融合和支持向量机的轴承故障诊断[J]. 电子测量与仪器学报, 2019, 33(10):104-111.
- [7] SONG K C, YAN Y H, CHEN W H, et al. Research and perspective on local binary pattern [J]. Acta Automatica Sinica, 2013, 39(6):730-744.
- [8] LINDBERGER T. Scale invariant feature transform[J]. Scholarpedia, 2012, 7(5):2012-2021.
- [9] SURHONE L M, TENNOE M T, HENSSONOW S F, et al. Histogram of oriented gradients[J]. Betascript Publishing, 2016, 12(4):1368-1371.
- [10] 贾磊, 鲁旭涛, 孙运强. 基于改进的局部二值模式算法的表情识别[J]. 国外电子测量技术, 2018, 37(10):35-39.
- [11] 景军锋, 张缓缓, 李鹏飞, 等. LBP 和 Tamura 纹理特征方法融合的织物疵点分类算法[J]. 计算机工程与应用, 2012, 48(23):155-160.
- [12] 杨成财, 余慧庄, 龙郝明. 基于 SVM 和能量最小化的 PolSAR 图像分类方法[J]. 电子测量技术, 2020, 43(3):146-152.
- [13] 刘祥楼, 贾东旭, 李辉, 等. 说话人识别中支持向量机核函数参数优化研究[J]. 科学技术与工程, 2010, 10(7):1669-1673.
- [14] KENNEDY J, EBERHAR T R. Particle swarm optimization [J]. Proceedings of IEEE International Conference on Neurac, 2011, DOI: 10.1007/978-0-387-30164-8_630.
- [15] SYARIF I, PRUGELBENNETT A, WILLS G. SVM parameter optimization using grid search and genetic algorithm to improve classification performance [J]. TELKOMNIKA, 2016, DOI: 10.12928/telkomnika.v14i4.3956.
- [16] CHANG C C, LIN C J. LIBSVM: A library for support vector machines [J]. ACM Transactions on Intelligent Systems and Technology, 2011, DOI: 10.1145/1961189.1961199.
- [17] 张加辉, 陈峰, 薛星, 等. 基于支持向量机的 MRI 影像组学方法鉴别不同病理分型原发性肝癌的价值[J]. 中华放射学杂志, 2018, 52(5):333-337.
- [18] PAL M, FOODY G M. Feature selection for classification of hyperspectral data by SVM [J]. IEEE Transactions on Geoenvironment & Remote Sensing, 2010, 48(5):2297-2307.
- [19] ZHANG X, YAN L F, HU Y CH, et al. Optimizing a machine learning based glioma grading system using multi-parametric MRI histogram and texture features [J]. Oncotarget, 2017, 8(29):47816-47830.

作者简介

刘志鹏, 硕士在读, 主要研究方向为人工智能机器学习在医学问题中的应用。

E-mail: lzp625346483@outlook.com

吴小玲(通信作者), 教授, 主要研究方向为磁定位技术、医疗仪器设备等。

E-mail: bmewxl@163.com