

融合多核学习和多源特征的胰腺囊性肿瘤分类方法

武杰¹, 徐真顺¹, 张志伟¹, 田慧¹, 边云²

(1. 上海理工大学健康科学与工程学院, 上海 200093; 2. 长海医院影像科, 上海 200434)

摘要: 胰腺囊性肿瘤的良好分类对于医学决策至关重要, 本文致力于提高胰腺囊性肿瘤的分类准确性, 以辅助医生更精确地制定诊疗方案。基于影像组学技术和 ResNet50 神经网络, 提出了融合多核学习和多源特征的胰腺囊性肿瘤分类方法, 其关键步骤包括特征筛选、核矩阵融合及构建分类模型。首先采用最小绝对收缩与选择算子 (Least absolute shrinkage and selection operator, LASSO) 进行特征筛选, 减少冗余特征, 提高模型的泛化能力; 然后选取经过特征筛选的多源特征, 通过在基础核函数中进行特征映射, 构建多源特征的基础核矩阵, 优化选取核矩阵的权重系数, 并加权相加这些基础核矩阵以形成融合的核矩阵; 最后, 利用支持向量机 (Support vector machine, SVM) 分类器对胰腺浆液性和黏液性囊性肿瘤进行分类。这一过程的关键在于, SVM 可以利用核矩阵在高维空间中内积, 在高维空间中寻找一个超平面来分类数据, 而融合的核矩阵中包含了经过特征映射的多源信息, 可以提供更高维度和更复杂的特征表示。实验结果表明, 该方法在胰腺囊性肿瘤良恶性分类任务中取得了显著的性能提升, 可为医生提供更可靠的辅助信息, 具有显著的临床应用潜力。

关键词: 胰腺囊性肿瘤; 多核学习; 多源特征; 影像组学; 深度学习

中图分类号: O482.53

文献标志码: A

Classification of Pancreatic Cystic Neoplasms by Fusion of Multi-kernel Learning and Multi-source Features

WU Jie¹, XU Zhenshun¹, ZHANG Zhiwei¹, TIAN Hui¹, BIAN Yun²

(1. School of Health Science & Engineering, University of Shanghai for Science & Technology, Shanghai 200093, China;
2. Department of Radiology, Changhai Hospital, Shanghai 200434, China)

Abstract: The classification of pancreatic cystic neoplasms into benign and malignant categories is crucial for medical decision-making. This paper is dedicated to enhancing the accuracy of pancreatic cystic neoplasms classification to assist physicians in formulating more precise diagnostic and therapeutic plans. Utilizing radiomics technology and the ResNet50 neural network, a novel classification method for pancreatic cystic neoplasms is proposed, integrating multi-kernel learning and multi-source feature fusion. The key steps of this method include feature selection, kernel matrix fusion, and the construction of the classification model. Feature selection is performed using the least absolute shrinkage and selection operator (LASSO) to reduce redundant features and improve the model's generalization ability. Subsequently, multi-source features, screened through feature selection, are mapped in basic kernel functions to construct

basic kernel matrices for multi-source features. The weights of these kernel matrices are then optimized and summed up to form a fused kernel matrix. Finally, a support vector machine (SVM) classifier is utilized to categorize pancreatic serous and mucinous cystic tumors. The significance of this process lies in SVM's ability to use the kernel matrix for inner product operations in high-dimensional spaces, thereby finding a hyperplane to classify data in such spaces. The fused kernel matrix, containing multi-source information after feature mapping, provides higher-dimensional and more complex feature representations. Experimental results demonstrate significant performance improvements in the classification task of pancreatic cystic neoplasms, offering more reliable auxiliary information to physicians and holding substantial clinical application potential.

Key words: pancreatic cystic neoplasms; multi-kernel learning; multi-source features; radiomics; deep learning

引 言

胰腺囊性肿瘤(Pancreatic cystic neoplasms, PCN)主要由胰腺浆液性囊性肿瘤(Serous cystic neoplasm, SCN)和胰腺黏液性囊性肿瘤(Mucinous cystic neoplasm, MCN)构成,其中SCN一般为良性,而MCN具有恶变潜能。中国胰腺囊性肿瘤诊断指南^[1]中指出,51.1%的患者缺乏典型的胰腺疾病相关症状,这就为疾病的早期诊断带来了困难。尽管有大量的成像数据以及相应的数据分析,但目前的研究依赖于经验丰富的专业人员的独立判断,传统的分类方法存在主观性强、效率低且误诊率较高的问题。因此,SCN和MCN的术前精确诊断对于临床制定个性化评估方案具有重要意义。

近年来,深度学习技术在许多医学领域中取得了显著进展^[2]。ResNet50^[3]是深度卷积神经网络(Convolutional neural network, CNN)的一种,在大规模图像数据集上表现出色。ResNet50网络因其高度的卷积结构设置,能够使网络学习图像更深层次的特征,特别适用于图像分类任务^[4-5]。目前,由于医学图像数据集规模普遍较小,从而导致了其在深层结构的神经网络中训练结果不够理想。近年来,许多研究表明,迁移学习能够在大规模的数据集上进行预训练,将预训练后的网络权值迁移到ResNet50网络中可以提高训练精度^[6],如Ngonu等^[7]将迁移学习和CNN网络应用在超声内镜的检查图像上,获得了对胰腺黏液性囊性肿瘤和浆液性囊性肿瘤很好的分类效果。

影像组学是一个新兴的研究领域,它专注于从医学影像资料中提取高通量的特征,以发现疾病诊断、预后评估、和治疗反应预测方面的生物学信息。Bian等^[8]利用影像组学提取了181例胰腺癌患者的影像组学特征,使用最小绝对收缩与选择算子(Least absolute shrinkage and selection operator, LASSO)^[9]进行特征去冗余,最后构建影像组学评分模型,评估胰腺癌的诊断效果,最终的分类准确率为71.3%。影像组学在定量评估图像信息中显示着显著优势。

虽然深度学习和影像组学都是利用计算机技术提取医学图像特征,但是二者具有明显的区别。深度学习技术通过深层次的卷积结构学习图像的全局特征,例如平均强度、灰度分布等;而影像组学技术则体现了医学图像的多种类特征,例如强度特征、纹理特征以及滤波变换特征等。怎样有效融合这种来自于同一图像的多源性特征是个难点。多核学习作为先进的核特征映射技术,通过将多源性特征映射到同一特征空间,完成多源特征的融合。Santosh^[4]将核二次判别函数应用在胰腺导管腺癌中,采用SVM和逻辑回归分类器进行分类,获得了比常规方法更高的性能;Wang等^[10]通过在不同肺段上引入大小不同高斯核构成多核学习SVM分类器,和常见的机器学习分类器进行比较,在性能上有所提高。核函数的选择、参数调整以及权重训练都是重大的挑战^[11]。单一核函数不能展现多类型特征的信息,

而过度的参数调整又容易带来过拟合,面对不同来源的特征时,需要更加高效和直观的方法来选择和组合核函数,而不是简单地堆叠更多的核函数^[12]。

本文提出了一个融合多核学习和多源特征的胰腺囊性肿瘤分类模型,该模型将集成PCN的临床特征、影像组学特征以及深度学习特征,实现对PCN的良恶性的鉴别。首先,使用影像组学技术和ResNet50卷积神经网络模型分别提取PCN的影像组学特征和深度学习特征;然后,使用LASSO进行特征筛选,以找出最具分类价值的特征;之后,基于筛选的特征构建融合多核学习和多源特征的SVM分类器,用于MCN和SCN的分类;最后,使用准确率、精确率、召回率和AUC值等评价指标来评估和优化分类器。本文有望为PCN的精确诊断提供新的思路,同时为多核学习算法在医学影像分类中的应用提供重要的推广价值。

1 融合多核学习和多源特征的PCN分类方法

对于PCN的分类,本文构建的融合多核学习和多源特征的分类方法的流程图如图1所示。首先,对PCN的分割图像提取并量化多源特征;然后采用LASSO多源特征做特征筛选,保留对分类变量影响显著的特征;随之,将筛选后的特征通过基础核函数的选择,为多源特征配置合适的核函数,多源特征配置好核函数以后,通过凸优化框架学习多源特征的核权重;最后,选择SVM分类器进行分类。

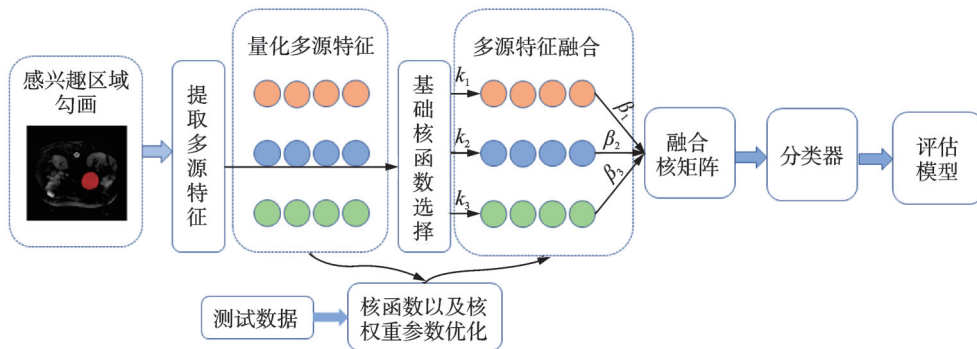


图1 本文方法流程图

Fig.1 Flow chart of the proposed method

1.1 多源特征提取

1.1.1 临床特征提取及评估

临床特征作为临床诊断的第一手资料,对于PCN的定性具有直接意义。两名具有10年以上影像诊断经验的放射科医师对临床特征进行量化评估,他们对肿瘤类型未知。统计学方法使用 T 检验分析临床特征和PCN分类之间的关系。相关临床特征的散点分布图以及 T 检验结果如图2所示,其中“*”表示 $p \leq 0.05$,”**”表示 $p \leq 0.01$,”***”表示 $p \leq 0.001$ 。图中显示性别、位置、形状、囊肿大小、囊壁增厚、T2序列囊液信号、T1序列信号、壁结节、主胰管截断、淋巴结肿大、主导症状、主胰管扩张、胰腺炎、糖类抗原199和癌胚抗原这些临床特征的 p 值非常小($p < 0.05$),这意味着它们可能与PCN之间存在显著关联。年龄、身体质量指数、胰腺实质萎缩、黄疸及糖尿病的 p 值较大($p > 0.05$),说明它们可能与PCN之间的关联性较弱。为了更有利于PCN的分类,本文将临床特征经 T 检验之后,保留 $p < 0.05$ 的特征,构成用于分类的临床特征数据集。




图2 临床特征统计图

Fig.2 Clinical characteristic statistical chart

1.1.2 影像组学特征提取

影像组学特征类型包括20个形状(Shape)特征、18个一阶(First order)特征、24个灰度共生矩阵(Gray level co-occurrence matrix, GLCM)、14个灰度相关矩阵(Gray level dependence matrix, GLDM)、16个灰度游程矩阵(Gray level run length matrix, GLRLM)、16个灰度区域大小矩阵(Gray level size zone matrix, GLSZM)和5个邻域灰度差矩阵(Neighborhood gray tone difference matrix, NGTDM)共7类特征以及小波变换特征。使用3D-slicer软件中的pyradiomics插件对感兴趣区域(Region of interest, ROI)提取影像组学特征,提取出的特征包含113个原始图像纹理特征和744个小波变换特征共857个特征。

1.1.3 深度学习特征提取

本研究基于ResNet50网络来提取深度学习特征,采用python软件包TensorFlow(版本2.1.0)的keras(版本2.3.1)下的ResNet50构建CNN网络。ResNet50由残差模块(Residual module)组成,总共有50层。残差模块包括3个卷积层,分别为标准的卷积层、批量归一化层和激活层,可以实现对输入特征映射的高速和高质量转换,通过避免较浅层特征的丢失,可以更好地提取图像对深层特征,其主要思想是通过残差连接来解决网络过深而出现的梯度消失问题。胰腺在图像中没有固定的形态,结构极为复杂,ResNet50网络因其深度、高度分层和卷积模块的设计,在提取PCN的深度学习特征时,有着明显的优势。迁移学习是一种针对有限训练样本的学习方法,目标是从一个或多个源任务中提取有用的知识,并将其用于新的目标任务中,本质上是知识的迁移和重用。通过迁移学习在大规模ImageNet数据集上进行预训练,将预训练得到的网络权值迁移到ResNet50网络中,减少模型过拟合。对ResNet50网

络随机初始化各层的参数,学习率为0.000 1,衰减率为0.000 1,批数据大小为20,动量为0.9。最终在全连接层FC的输出中提取2 048个深度学习特征。ResNet50提取深度学习特征的网络结构如图3所示。




图3 ResNet50网络结构图

Fig.3 ResNet50 network architecture diagram

1.2 基于LASSO的特征筛选

LASSO的主要原则是通过最小化正则化之后的损失函数实现对回归系数的稀疏化,保留对目标变量的预测具有显著影响的特征。采用LASSO对影像组学特征和深度学习特征分别进行筛选,得到显著影响的影像组学特征和深度学习特征,然后使用10折交叉验证方法来寻找训练集中最优的拟合参数 λ (λ 表示 L_1 正则化的惩罚力度)。LASSO的损失函数为

$$L = \frac{1}{2n} \|X(\mathbf{w}) - \mathbf{y}\|_2^2 + \lambda \|\mathbf{w}\|_1 \quad (1)$$

式中: n 表示样本数, X 表示样本目标向量, \mathbf{w} 表示模型系数向量, \mathbf{y} 表示样本特征矩阵。式(1)右边的第1项为LASSO的均方误差(Mean square error, MSE),第2项为添加了 L_1 正则化的惩罚因子,通过调整 λ 值,控制 L_1 正则化程度,最小化LASSO模型的MSE以确定最佳的系数估计,保留对结果影响较大的特征,其余系数衰减为0。

1.3 多核学习

对于胰腺囊性肿瘤数据具有线性决策特征的数学表达式为

$$f(\mathbf{x}) = a_1x_1 + a_2x_2 + \dots + a_nx_n + a_0 = \langle \mathbf{w}, \mathbf{x} \rangle + b \quad (2)$$

式中: $\mathbf{w} = (a_1, a_2, \dots, a_n)$, $b = a_0$,在此基础上,基于最大边缘的分解方式,获得待优化的数学表达式为

$$\begin{cases} \min \|\mathbf{w}\|^2 \\ y_i \langle \mathbf{w}, \mathbf{x}_i \rangle \geq 1 \quad i = 1, 2, \dots, n \end{cases} \quad (3)$$

式(3)中相关的约束因数都是线性的,因此很容易进行凸优化操作。在方法上,引入松弛算子 ξ_i 对式(3)进行整理,可得

$$\begin{cases} \min \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \\ y_i \langle \mathbf{w}, \mathbf{x}_i \rangle \geq 1 - \xi_i \quad i = 1, 2, \dots, n \end{cases} \quad (4)$$

在式(4)中,参数 \mathbf{w} 通过非线性映射得到,已经不是原始数据空间的权重参数,而是目标空间中的权重参数,因此决策表达式 $f(\mathbf{x}) = \langle \mathbf{w}, \phi(\mathbf{x}) \rangle$ 对于 $\phi(\mathbf{x})$ 还是线性关系的,而对于原始的数据 \mathbf{x} 变成非

线性的关系,这时让 $w = \sum_{i=1}^n a_i \phi(x_i)$,通过非线性映射,将目标函数转化为对 a_i 的优化求解,而不是对 w 求解,对式(4)进一步进行调整可得

$$\begin{cases} \min \sum_{i,j=1}^n a_i a_j \langle \phi(x_i), \phi(x_j) \rangle + C \sum_{i=1}^n \xi_i \\ y_i \sum_{i,j=1}^n a_i a_j \langle \phi(x_i), \phi(x_j) \rangle \geq 1 - \xi_i \quad i, j = 1, 2, \dots, n \end{cases} \quad (5)$$

在式(5)中,令 $k(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle$,就获得了核函数 k 。与此同时,使用这种基于最大边缘分解方式的分类器,就形成了SVM。多核学习(Multi-kernel learning)的形式为基础内核的线性或非线性组合。本文的研究形式为各种基础核函数的凸组合,通过交叉验证选择合适的核函数权重,对基础核函数进行线性组合^[13],即

$$k\phi(x_i, x_j) = \sum_{r=1}^m \sum_{i,j=1}^n \beta_r k_r \langle \phi_r(x_i), \phi_r(x_j) \rangle = \sum_{r=1}^m \sum_{i,j=1}^n \beta_r k_r(x_i, x_j) \quad (6)$$

式中: k_r 代表第 r 个核, β_r 代表第 r 个核权重, m 代表基础和函数的个数。其权重系数的约束条件为

$$\sum_{r=1}^m \beta_r = 1 \quad \beta_r \geq 0 \quad (7)$$

1.4 核函数选择模块

核方法是处理非线性问题的强大工具,而核函数的选取以及权重系数的优化是两个重要环节。当输入空间是欧氏空间或离散集,特征空间是希尔伯特空间时,核函数表示输入空间映射到特征空间得到的向量之间的内积,从而可以避免高维空间的内积运算^[14]。对于含 n 个训练样本的二元分类问题, $\phi(x)$ 表示从原始空间到高维希尔伯特空间的特征映射, $K(x_A, x_B) = \phi(x_A) \phi(x_B)$ 为相应的核函数。表1展示了几种常见的核函数。

表1 基础核函数
Table 1 Basic kernel function

核函数	表达式
线性核函数	$K(x_A, x_B) = \alpha x_A x_B^T + b$
多项式核函数	$K(x_A, x_B) = (\gamma x_A x_B^T + r)^d$
高斯核函数	$K(x_A, x_B) = \exp(-\gamma \ x_A - x_B\ ^2)$
Sigmoid核函数	$K(x_A, x_B) = \tanh(\alpha x_A x_B^T + c)$

单核训练存在着过于依赖核函数的选取以及在异构信息上灵活性差的问题,多核学习能有效解决此类问题^[15]。由于在不同数据上,不同核函数的敏感性不同^[16],因此在PCN的分类问题上,本文基于临床特征、影像组学特征以及深度学习特征,分别在不同的核函数中进行训练,获得基于不同来源的特征向量最适合的核函数。通过 $\phi_i(x)$ 将多源特征映射到相同的希尔伯特特征空间中,使多源特征在空间维度上保持一致,即多源特征经过核特征映射之后将转换成 172×172 的方阵形式,比如临床特征由原来的 172×16 转换成的方阵,影像组学特征由原来的 172×10 转换成 172×172 ,深度学习特征由原来的 172×4 转换成 172×172 。通过绘制核矩阵热力图显示在高维空间中多源特征的数据信息,根据SVM的分类性能为多源特征的核矩阵赋予核权重系数 β_i ,通过加权相加多源特征的核矩阵构成融合了多核学习和多源特征的核矩阵,这样既保留了单核学习过程中不同核函数的优点,又充分利用了多源特征的融合信息。本文通过网络搜索方式优化不同核函数的权重,从而构建最终的融合矩阵。融合多核学习和多源特征的过程如图4所示。

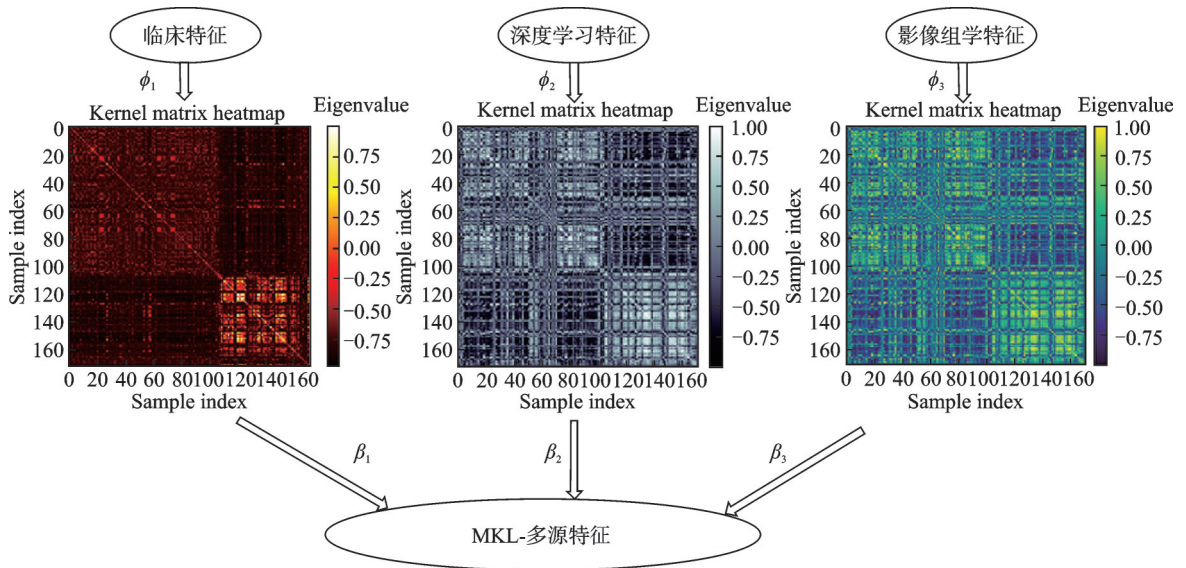


图 4 基于多核学习的多源特征融合过程示意图


Fig.4 Schematic diagram of multi-source feature fusion process based on multi-kernel learning

2 实验材料

2.1 数据集

本研究使用的数据集来自长海医院在 2011 年 3 月至 2021 年 12 月期间接收的 172 例胰腺囊腺肿瘤患者,其中包含 65 个 MCN 病例和 107 个 SCN 病例,所有患者均提供书面知情同意书。经病理学证实的 107 例 SCN 患者包括男性 45 例、女性 62 例,平均年龄 48.7 ± 15.1 岁,65 例 MCN 患者包括男性 23 例、女性 42 例,平均年龄 51.9 ± 12.5 岁。

纳入标准:①T2WI 清晰、无伪影,完整显示肿瘤区域;②诊断资料完整;③未合并黄疸、胰腺炎及糖尿病等。本研究经院医学伦理委员会审核通过(批准号:CHEC2021-163);检查前患者均签署知情同意书。所有的图像分割均由两名具有 10 年放射科诊断经验的放射科医生使用 ITK-snap 软件勾画肿瘤区域,图 5 为 MCN 和 SCN 的 MRI 的 T2WI 影像。从图 5 可以看出,腹腔横断面 T2WI 示 MCN 呈高信号,其边界规则;腹腔横断面 T2WI 示 SCN 呈高信号,其边界不规则。



(a) MCN result (b) SCN result

图 5 MCN 和 SCN 分割图像

Fig.5 Segmented images of MCN and SCN

2.2 评价指标

本文在测试图像上使用准确率(Accuracy)、召回率(Recall)、精确率(Precision)以及 F_1 值(F_1 -score)这四个二分类指标来评价模型的检测性能。各个指标分别定义为

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \tag{8}$$

$$\text{Recall} = \frac{TP}{TP + FN} \tag{9}$$

$$\text{Precision} = \frac{TP}{TP + FP} \tag{10}$$

$$F_1\text{-score} = \frac{2\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (11)$$

式中:TP、FP、TN 和 FN 分别表示真阳性、假阳性、真阴性和假阴性。同时,为了更直观地评估模型性能,引入受试者工作特征(Receiver operating characteristic,ROC)曲线下的面积(Area under the curve of ROC,AUC)。

3 实验结果与讨论

3.1 基于 LASSO 的影像组学特征和深度学习特征筛选结果

对临床特征经过 T 检验分析,保留 16 个临床特征与 PCN 分类之间具有显著性差异($p < 0.05$),排除掉 5 个和 PCN 分类之间没有显著性差异的特征($p > 0.05$);对影像组学特征做标准化处理,然后使用 T 检验从 856 个特征中筛选得到 196 个特征,再使用 LASSO 及 10 折交叉验证方法,当 LASSO 算法的均方误差最小时,参数 $\lambda = 4.94 \times 10^{-2}$,筛选得到 10 个系数不为 0 的影像组学特征;对深度学习特征先标准化处理,在 10 折交叉验证下选择 LASSO 拟合过程中均方误差最小的参数 λ ,此时 $\lambda = 6.55 \times 10^{-2}$,LASSO 筛选得到 4 个系数不为 0 的深度学习特征。影像组学特征的 LASSO 拟合的均方误差图和特征系数图分别如图 6(a)和图 6(b)所示;深度学习特征的 LASSO 拟合的均方误差图和特征系数图分别如图 6(c)和图 6(d)所示。

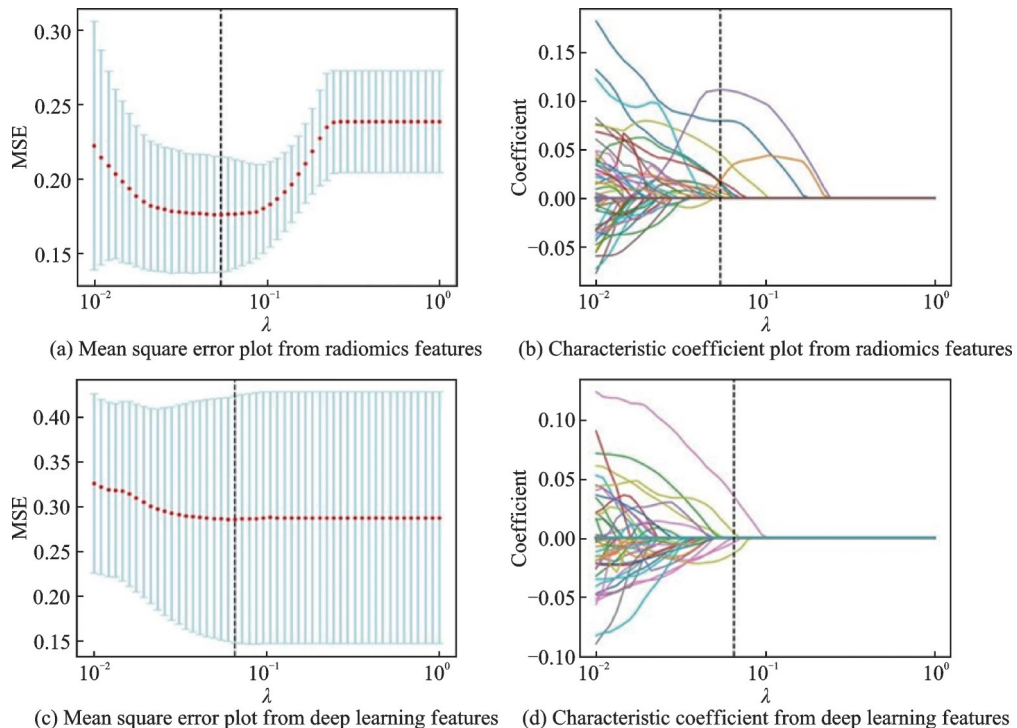


图6 均方误差图以及LASSO筛选的特征系数图

Fig.6 Mean square error plot and characteristic coefficient plot of LASSO screening

3.2 多源特征的核函数参数筛选结果

表2结果显示,不同来源的特征对不同核函数的敏感性不同。因此,在实际应用中,根据不同特征的核适用性选择不同的核函数。通过准确度的比较,临床特征最适合使用 Sigmoid 核函数($\alpha = 0.07$, $c = -1.02$);影像组学特征最适合使用 Sigmoid 核函数($\alpha = 0.12$, $c = -0.2$),深度学习特征最适合使用多项式

表2 核函数参数选择结果

Table 2 Result of kernel function parameter selection

核函数		线性核函数		多项式核函数			高斯核函数	Sigmoid核函数	
不同来源特征	参数	a	b	γ	r	d	γ	α	c
临床特征	调优	-1.02	-3.47	-6.33	6.74	6	0.13	0.07	-1.02
	准确度		0.89		0.87		0.79		0.90
影像组学特征	调优	-0.2	0.2	8.37	-0.61	2	0.13	0.12	-0.2
	准确度		0.9		0.85		0.87		0.92
深度学习特征	调优	-0.2	-5.92	-10	-2.65	9	1.04	79.06	1.43
	准确度		0.79		0.85		0.77		0.83

核函数($\gamma=-10$, $r=-2.65$, $d=9$)。这表明在选择核函数时需要考虑不同来源特征的适应性。

3.3 单核学习分类结果

通过对不同来源特征进行核特征映射,进行单核学习分类结果的比较,结果如表3所示。从表3可知,使用核方法对不同来源特征进行核特征映射后,准确率指标都有所提升。临床特征的准确率提升了2%,影像组学特征的准确率提升了3%,深度学习特征的准确率也提升了3%。这说明使用核方法可以提高分类性能,特别是对于不同来源的特征。从召回率和精确率来看,越高的精确率对MCN的检测精度越高,越高的召回率则代表对SCN的检测敏感度越高。临床特征更趋近于检测MCN,影像组学特征更趋近于检测SCN,而深度学习特征更趋近于检测MCN。经过核方法进行特征映射之后,这种效果得到了加强。

3.4 融合多核学习和多源特征的分类结果

根据综合表4中的二分类评价指标分析,使用多核学习的多源特征的融合模型在PCN的分类任务中表现出较好的性能。各项指标均优于不使用多核学习的情况,其中,准确率提高5%,精确率提高13%,AUC值提高3%。这表明多核学习能够为多源异构数据提供最合适的核函数,并将多源特征有效地映射到合成核空间,使得多源特征保持在同一维度中,从而更好地检测多源特征。

4 结束语

本文基于影像组学和深度学习的方法高通量地提取PCN图像特征,为了避免特征冗余,引起特征空间的维度灾难,从而造成模型过拟合^[17],使用LASSO对影像组学特征和深度学习特征进行筛选,保留对目标变量的预测具有显著影响的特征。这种特征筛选方法可以减少特征维度,提高分类模型的效

表3 基于单核学习在多源特征中的分类性能比较

Table 3 Classification performance comparison of multi-source features based on single kernel learning

特征	准确率	精确率	召回率	AUC
临床特征	0.85	1.00	0.65	0.83
影像组学特征	0.77	0.67	0.75	0.77
深度学习特征	0.63	0.67	0.10	0.53
K-临床特征	0.87	1.00	0.65	0.84
K-影像组学特征	0.79	0.6	0.80	0.79
K-深度学习特征	0.65	1.00	0.05	0.53

表4 融合多核学习和多源特征的分类性能比较

Table 4 Classification performance comparison of fusion of multi-kernel learning and multi-source features

特征	准确率	精确率	召回率	AUC
多源特征	0.88	0.82	0.82	0.87
Sekhar M C ^[4]	0.79	0.37	0.58	0.73
Wang等 ^[10]	0.862	0.868	0.687	0.812
MKL-多源特征	0.92	0.93	0.82	0.90

果和泛化能力。

本文对PCN的临床特征进行评估,通过 T 检验分析临床特征与PCN分类之间的关系,发现性别、位置、形状、囊肿大小、囊壁增厚、T2序列囊液信号、T1序列信号、壁结节、主胰管截断、淋巴结肿大、主导症状、主胰管扩张、胰腺炎、糖类抗原199和癌胚抗原等临床特征与PCN之间存在显著关联。这些临床特征对于PCN的定性具有直接意义。

根据SVM分类结果显示,使用核方法对PCN的多源特征进行核特征映射,可强化SVM对MCN和SCN的分类精度;使用多核学习融合多源特征能够进一步提升SVM的分类效果,多核学习融合多源特征分类MCN和SCN的准确率达0.92,精确率达到0.93,召回率达到0.82,AUC值达到0.90。

针对胰腺囊性肿瘤良恶性分类任务,本文设计了一种融合多核学习和多源特征的分类方法。在特征提取阶段,根据特征的来源不同,分为临床特征、影像组学特征和深度学习特征,在保证检测对象一致性的情况下,利用不同来源的数据之间的差异性进行信息互补,从而得到更加全面的信息描述。引入核方法将不同来源的特征向希尔伯特特征空间映射,获得核特征矩阵,通过多核学习方法将不同来源的特征进行融合,取得了较好的实验结果。此外,性别、身体健康指数以及胰腺囊肿的位置等临床症状和体征对胰腺囊性肿瘤的分类具有关联性,说明本研究的融合多核学习和多源特征的分类模型对于辅助医生制定精确诊疗方案,具有一定的临床价值。

参考文献:

- [1] 李兆申, 金震东, 李汛. 中国胰腺囊性肿瘤诊断指南[J]. 临床肝胆病杂志, 2022, 39(2): 290-298.
LI Zhaoshen, JIN Zhendong, LI Xun. Chinese guidelines for the diagnosis and treatment of pancreatic cystic neoplasm[J]. *Journal of Clinical Hepatology*, 2022, 39(2): 290-298.
- [2] WONG P K, CHAN I N, YAN H M, et al. Deep learning based radiomics for gastrointestinal cancer diagnosis and treatment: A minireview [J]. *World Journal of Gastroenterology*, 2022, 28(45): 6363-6379.
- [3] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [S.l.]: IEEE, 2016: 770-778.
- [4] SEKHAR M C, SANTOSH P R. An efficient novel approach with multi class label classification through machine learning models for pancreatic cancer[J]. *Scalable Computing: Practice and Experience*, 2022, 23(4): 193-210.
- [5] 田慧, 武杰, 边云. 基于DenseNet结合迁移学习的胰腺囊性肿瘤分类方法[J]. 波谱学杂志, 2023, 40(3): 270-279.
TIAN Hui, WU Jie, BIAN Yun. Classification of pancreatic cystic tumors based on DenseNet and transfer learning[J]. *Chinese Journal of Magnetic Resonance*, 2023, 40(3): 270-279.
- [6] 徐佳薇, 武杰, 顾宇翔, 等. 用于烟雾病检测的Faster RCNN改进算法[J]. 数据采集与处理, 2022, 37(6): 1391-1402.
XU Jiawei, WU Jie, GU Yuxiang, et al. Improved Faster RCNN algorithm for moyamoya disease detection[J]. *Journal of Data Acquisition and Processing*, 2022, 37(6): 1391-1402.
- [7] NGUON L S, SEO K, LIM J-H, et al. Deep learning-based differentiation between mucinous cystic neoplasm and serous cystic neoplasm in the pancreas using endoscopic ultrasonography[J]. *Diagnostics*, 2021, 11(6):1052-1062.
- [8] BIAN Y, JIANG H, MA C, et al. CT-based radiomics score for distinguishing between grade 1 and grade 2 nonfunctioning pancreatic neuroendocrine tumors[J]. *American Journal of Roentgenology*, 2020, 215(4): 852-863.
- [9] ROBERT T. Regression shrinkage and selection via the Lasso[J]. *Journal of the Royal Statistical Society*, 1996, 58: 2517-6161.
- [10] WANG X, WANG J, SHAN F, et al. Severity prediction of pulmonary diseases using chest CT scans via cost-sensitive label multi-kernel distribution learning[J]. *Computers in Biology and Medicine*, 2023, 159: 106890.
- [11] CHI Z, WANG Z, WANG B, et al. Multiple kernel subspace learning for clustering and classification[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 35(7): 1-14.
- [12] YAN W, LI Y, YANG M. Towards deeper match for multi-view oriented multiple kernel learning[J]. *Pattern Recognition*,

2023, 134: 1-15.

- [13] ALIOSCHA-PEREZ M, OVENEKE M C, SAHLI H. SVRG-MKL: A fast and scalable multiple kernel learning solution for features combination in multi-class classification problems[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(5): 1710-1723.
- [14] 肖开研, 廉洁. 基于多核支持向量机的句子分类算法[J]. 华东师范大学学报, 2023(6): 85-94.
XIAO Kaiyan, LIAN Jie. Sentence classification algorithm based on multi-kernel support vector machine[J]. Journal of East China Normal University, 2023(6): 85-94.
- [15] 范嘉玮, 祝海江. 基于改进多核学习的多传感数据分类方法研究[J]. 北京化工大学学报, 2020, 47(3): 100-107.
FAN Jiawei, ZHU Haijiang. Classification of internet multisensor data based on improved multi-kernel learning[J]. Journal of Beijing University of Chemical Technology, 2020, 47(3): 100-107.
- [16] WANG J, MIAO Y, LI L, et al. Multi-omics data integration for hepatocellular carcinoma subtyping with multi-kernel learning [J]. Frontiers in Genetics, 2022, 13: 962870.
- [17] 杨一风, 祁章璇, 聂生东. 基于多模态MRI与深度学习的乳腺病变良恶性鉴别[J]. 波谱学杂志, 2022, 39(4): 401-412.
YANG Yifeng, QI Zhangxuan, NIE Shengdong. Differentiation of benign and malignant breast lesions based on multimodal MRI and deep learning[J]. Chinese Journal of Magnetic Resonance, 2022, 39(4): 401-412.

作者简介:



武杰(1976-), 通信作者, 男, 博士, 讲师, 研究方向: 医学影像技术, E-mail: wujie3773@sina.com。



徐真顺(1999-), 男, 硕士研究生, 研究方向: 医学成像与图像处理技术。



张志伟(1999-), 男, 硕士研究生, 研究方向: 医学成像与图像处理技术。



田慧(1999-), 女, 硕士研究生, 研究方向: 医学成像与图像处理技术。



边云(1978-), 女, 博士, 主任医师, 研究方向: 医学影像与核医学。

(编辑:王静)