S 计算机科学 COMPUTER SCIENCE

结合深度学习与改进的极限学习机的集成学习胸腺瘤CT图像预测方法

徐坤财, 冯宝, 陈业航, 刘昱, 周皓阳, 陈相猛

引用本文

徐坤财, 冯宝, 陈业航, 刘昱, 周皓阳, 陈相猛结合深度学习与改进的极限学习机的集成学习胸腺瘤CT图 像预测方法[J]. 计算机科学, 2022, 49(11A): 211200097-6. XU Kun-cai, FENG Bao, CHEN Ye-hang, LIU Yu, ZHOU Hao-yang, CHEN Xiang-meng. Thymoma CT Image Prediction Method Based on Deep Learning and Improved Extreme Learning Machine Ensemble Learning [J]. Computer Science, 2022, 49(11A): 211200097-6.

相似文章推荐(请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

基于机器学习的剩余使用寿命预测实证研究

Empirical Research on Remaining Useful Life Prediction Based on Machine Learning 计算机科学, 2022, 49(11A): 211100285-9. https://doi.org/10.11896/jsjkx.211100285

基于通道拆分CLAHE和自适应阈值残差网络的变工况故障诊断

Fault Diagnosis Based on Channel Splitting CLAHE and Adaptive Threshold Residual NetworkUnder Variable Operating Conditions 计算机科学, 2022, 49(11A): 211100122-7. https://doi.org/10.11896/jsjkx.211100122

R-YOLOv5:自动切割的旋转的文本检测模型

R-YOLOv5:Auto-cutting,Rotated Text Detection Model 计算机科学, 2022, 49(11A): 210900185-6. https://doi.org/10.11896/jsjkx.210900185

基于注意力机制的手写体数字识别

Handwritten Digit Recognition Based on Attention Mechanism 计算机科学, 2022, 49(11A): 211100009-5. https://doi.org/10.11896/jsjkx.211100009

多字体印刷体维-哈-柯文关键词图像识别

Multi-font Printed Uyghur-Kazakh-Kirghiz Keyword Image Recognition 计算机科学, 2022, 49(11A): 211100038-6. https://doi.org/10.11896/jsjkx.211100038



结合深度学习与改进的极限学习机的集成学习胸腺瘤 CT 图像预测方法

徐坤财¹ 冯 宝² 陈业航² 刘 昱² 周皓阳² 陈相猛³
1 桂林电子科技大学电子工程与自动化学院 广西 桂林 541004
2 桂林航天工业学院电子信息与自动化学院 广西 桂林 541004
3 江门市中心医院医学影像智能计算及应用实验室 广东 江门 529000 (xkc1009@163.com)

摘 要 针对胸腺瘤患者术前危险程度的预测问题,提出了结合深度学习与改进的极限学习机的集成学习计算机辅助分析方法。首先,将胸腺瘤 CT 图像通过小波多尺度变换到不同的尺度下并计算小波能量图,以增加图像信息的丰富性和多样性;其次,利用小波能量图训练卷积神经网络模型,并利用卷积核提取小波能量图中与任务相关的特异性深度特征;最后,基于改进的 极限学习机为基分类器训练具有差异性的子模型并构建集成学习分类模型,以提高模型的稳定性和预测精度。多中心实验结 果表明,所提方法有较好的泛化性能和稳定性,3 个验证集的 AUC 分别为 0.833,0.771,0.784。

关键词:胸腺瘤;小波变换;卷积神经网络;极限学习机;集成学习

中图法分类号 TN911.73-34; TP391.41

Thymoma CT Image Prediction Method Based on Deep Learning and Improved Extreme Learning Machine Ensemble Learning

XU Kun-cai¹, FENG Bao², CHEN Ye-hang², LIU Yu², ZHOU Hao-yang² and CHEN Xiang-meng³

1 School of Electronic Engineering and Automation, Guilin University of Electronic Technology, Guilin, Guangxi 541004, China

2 School of Electronic Information and Automation, Guilin University of Aerospace Technology, Guilin, Guangxi 541004, China

3 Medical Image Intelligent Computing and Application Laboratory, Jiangmen Central Hospital, Jiangmen, Guangdong 529000, China

Abstract To predict the risk of thymoma patients before operation, a computer-aided analysis method combining deep learning and extreme learning machine ensemble learning is proposed. Firstly, the CT image of thymoma is transformed to different scales by wavelet multi-scale transform, and the wavelet energy map is calculated to improve the richness and diversity of image information. Secondly, the convolution neural network model is trained by wavelet energy map, and the specific depth features related to tasks in wavelet energy map are extracted by convolution kernel. Finally, the differentiated training subsets are trained based on the improved limit learning machine, and ensemble learning is constructed to improve the stability and prediction accuracy of the model. Based on multicenter experiments, the results show that the proposed method has good generalization performance and stability. The *AUCs* of the three verification sets are 0.833,0.771 and 0.784 respectively.

Keywords Thymoma, Wavelet transform, Convolutional neural network, Extreme learning machine, Ensemble learning

胸腺瘤的发病率在纵隔肿瘤中排在第三位,是成年人中 常见的前纵膈原发肿瘤。在临床中,针对不同危险程度的胸 腺瘤有不同的治疗方案。低风险的胸腺瘤主要采用手术切 除,而高风险胸腺瘤需要先放疗或化疗后再手术切除^[1]。目 前,放射科医生通常使用电子计算机断层扫描(Computed Tomography,CT)影像采用经验性、观察性等具有主观因素 的指标(如周围浸润、毛刺征等)进行诊断评估^[2]。然而,临床 中不同危险程度的肿瘤影像表现不乏相似性,且低风险与高 风险两类胸腺瘤之间的 CT 影像表现多有重叠,导致难以准 确区分^[3]。因此,提出一种客观、量化的指标对胸腺瘤的危险 程度进行诊断评估具有重要的临床意义。 提高模型的泛化性能而得到众多领域的关注,是机器学习中 一种新的学习模式^[4]。Ding 等^[5]提出一种无监督和不需要 训练的差异性随机子空间选择算法,该算法利用多核最大均 值差异来衡量子空间的差异性,虽然能保证基分类器的差异 性,但是在大多数情况不能保证集成后的预测精度,并且在多 中心情况下模型稳定性较差。文献[6]在同一数据上重复训 练多个子模型,未考虑基分类器的差异性,导致基分类器的冗 余度较高、集成后的模型稳定性较差。由于胸腺瘤的 CT 图 像存在伪影,组织有重叠的现象,且不同危险程度的胸腺瘤组 织结构复杂、样本差异性大等特点导致预测模型的预测精度 较低。

集成学习目前在机器学习中应用较为广泛,因其能显著

深度学习方法具有较强的学习特征的能力,能从数据中

基金项目:国家自然科学基金项目(81960324);广西自然科学基金面上项目(粤桂联合基金项目)(2021GXNSFAA075037) This work was supported by the National Natural Science Foundation of China(81960324) and General Project of Guangxi Natural Science Foundation(Guangdong Guangxi Joint Fund Project)(2021GXNSFAA075037). 通信作者:陈业航(1535601070@qq. com)

挖掘与任务相关的特异性深度特征,备受研究人员的关注^[7]。 在医学领域中,深度学习在疾病的检测、诊断、预后等方面已 有广泛应用^[8+9]。Muhammed 等^[10]使用基于 CNN 的迁移学 习 ResNet34 模型提取异常脑部 MR 图像的深度特征并进行 自动分类,取得了良好的结果。Ye 等^[11]使用预训练 Res-Net50 模型检测磨玻璃肺结节,准确率达到 0.87。因此,应用 深度学习方法提取胸腺瘤 CT 图像的特异性深度特征有助于 提高胸腺瘤危险程度的预测准确性。

为了完成对胸腺瘤患者术前危险程度的预测,本文提出 了结合深度学习与改进的极限学习机集成学习的计算机辅助 分析方法。首先,采用小波变换将图像分解到不同尺度下并 计算小波能量图;其次,基于深度学习模型以卷积滤波器为特 征提取器提取小波能量图中具有鲁棒性的深度特征;最后,采 用 bootstrap 自助法从训练集中重采样出训练子集,并基于改 进的极限学习机训练具有差异性的子模型作为基分类器,采 用算术平均的策略构建集成学习分类模型以提升模型的泛化 性能。多中心试验结果表明,本文所提方法具有良好的预测 精度和稳定性。

1 结合深度学习与改进的极限学习机集成学习的 胸腺瘤 CT 图像预测方法

近年来,随着胸腺瘤的检出率逐步增加,临床中对胸腺瘤 的诊断受到广泛关注。胸腺肿瘤的密度变化以及周围的浸润 程度能反映肿瘤的危险程度,针对不同危险程度的胸腺瘤有 不同的诊断方案,而肿瘤的精确分割成为临床诊断的关键。 然而实际中由于肿瘤的组织结构复杂、病灶边界模糊、个体形 态差异大等问题给临床医生对肿瘤分割带来极大的困难,从

而导致临床诊断效果不佳。针对上述问题,本文提出结合深 度学习与改进的极限学习机集成学习对胸腺瘤的危险程度进 行预测,该方法无须精确分割肿瘤病灶,只需对肿瘤病灶进行 框选。1)首先,采用小波变换将图像分解到不同尺度下;然 后,将不同尺度下的图像信息映射到不同的卷积层中,以卷积 滤波器作为特征提取器提取小波能量图中与任务相关的特异 性深度特征,以丰富图像特征的多样性。2)本文采用 Bagging 集成建模方法构建集成学习分类模型。首先,使用 bootstrap 自助法对训练集重采样出具有差异性的训练子集;然后,在传 统的极限学习机中引入 L₁ 范数对网络进行稀疏化约束,并将 改进的极限学习作为基分类器训练具有差异性的子模型,以 降低网络的过拟合现象,同时提高模型的稳定性;最后,采 用算术平均的策略构建集成学习分类模型。该集成学习 分类模型具有较好的预测精度和稳定性。图 1(a)为经典 的胸腺瘤 CT 图像,图 1(b)为胸腺瘤可视化分割结果。本 文算法的流程图如图2所示。





(a)胸腺瘤 CT 图像

(b)可视化分割结果

图 1 胸腺瘤 CT 图像 Fig. 1 CT image of thymoma



图 2 本文算法结构流程图

Fig. 2 Flow chart of the proposed algorithm

1.1 基于小波变换下的卷积神经网络深度特征提取

图像的深度特征中包含图像不同维度下的信息,该信息 的丰富性与多样性能提高预测模型的预测精度和鲁棒性。为 了得到图像不同维度下更丰富的深度特征,将胸腺瘤图像采 用小波多尺度变换,得到图像不同尺度下的能量成分信 息^[12],对不同尺度下的图像能量信息计算小波能量图。利用 小波能量图训练卷积神经网络(Convolutional Neural Network,CNN)模型,以卷积核作为特征提取器提取小波能量图 中与任务相关的特异性深度特征。其小波能量可定义为:

$$E_{W}(x,y) = E_{A}(x,y) + E_{H}(x,y) + E_{V}(x,y) + E_{D}(x,y)$$
(1)

其中, $E_A(x,y)$, $E_H(x,y)$, $E_V(x,y)$ 和 $E_D(x,y)$ 分别表示小 波的细节能量、小波水平能量、小波垂直能量和小波对角 能量。

$$\begin{cases} E_A(x,y) = \sum_{r,s \in \mathbb{Z}} [D_A(x,y)]^2 K(x-r,y-s) \\ E_H(x,y) = \sum_{r,s \in \mathbb{Z}} [D_H(x,y)]^2 K(x-r,y-s) \\ E_V(x,y) = \sum_{r,s \in \mathbb{Z}} [D_V(x,y)]^2 K(x-r,y-s) \\ E_D(x,y) = \sum_{r,s \in \mathbb{Z}} [D_D(x,y)]^2 K(x-r,y-s) \end{cases}$$
(2)

其中, $D_A(x,y)$, $D_H(x,y)$, $D_V(x,y)$ 和 $D_D(x,y)$ 分别是低频 小波系数、水平高频小波系数、垂直高频小波系数和对角高频 小波系数,r和s分别是领域Z内的像素的横坐标和纵坐标, $K(\cdot)$ 是高斯核函数^[13]。

图 3 给出了小波变换后的结果,图 3(a)是胸腺瘤 CT 图 像,图 3(b)为小波多尺度变换后的结果。从图中可以看出小 波能量图可以明显提高图像的质量,同时为提取图像不同尺 度下更丰富的深度特征提供了保障。为了满足后续深度学习 模型的输入要求,将小波多尺度变换后的胸腺瘤图像合并为 三通道,图 3(c)为三通道合并后的结果。



(a)胸腺瘤 CT 图像 (b)小波变换后 CT 图像 (c)三通道合并
 图 3 胸腺瘤 CT 图像小波变换预处理

Fig. 3 Wavelet transform preprocessing of thymoma CT image

本文研究基于 DenseNet 网络^[14]提取图像的深度特征,特征提取流程如图 4 所示,图像通过网络中的第 c 层卷积层中的第 l 个卷积滤波器映射之后得到图像对应卷积层下的不同卷积滤波器的深度特征,在 DenseNet 网络中图像共经过了 11264 个卷积滤波器,对所有卷积层中的

深度特征累加得到图像通过整个卷积神经网络中的深度 特征。图像通过不同卷积层的卷积滤波器映射之后,可表 示为:

$$a_{i,j} = g(\sum_{m=0}^{\infty} \sum_{n=0}^{\infty} w_{m,n} x_{i+m,i+n} + w_b)$$
(3)

其中,wm.n和wb分别为卷积层第m 行第n 列的值和偏置项, xi,j表示图像的第i 行第j 列元素。图像通过卷积层映射之 后得到卷积滤波器对图像有响应的区域,然后经过池化层对 图像有响应区域的深度特征进行统计^[15]。经过多个卷积滤 波器之后可以将 K×K 个 D 维的图像矢量特征进行拼接,其 表达式如下:

$$J_{d} = \sum_{i}^{K} \sum_{j}^{K} \frac{M_{i,j,d}}{K^{2}}$$
(4)

其中,*M_{i,j,d}*表示提取特征的第*i*行第*j*列元素的多个提取层, *K*表示图像的初始维度,其参数范围为[1,*d*]。



图 4 DenseNet 特征提取流程图

Fig. 4 Flow chart of Densenet feature extraction

图 5 是图像经 DenseNet 网络不同卷积层的卷积滤波器 响应之后的特征图,从图中可以看出,卷积神经网络中浅层中 具有图像的共有特征(如形状特征、颜色特征,纹理特征等), 中间层的特征则更加丰富,深层的特征则更加抽象。



(a)Conv2_1



(b)Conv3_15

(c)Conv5_16

图 5 深度学习卷积核可视化



为了使模型的预测性能更高、计算复杂度更低,需要选择 与任务具有相关性的特征。首先,采用统计学中的U检验^[16] 对 DenseNet 提取的11264个深度特征进行特征选择;然后, 使用 mRMR 算法对U检验后的结果进行降维处理,以提高 特征与任务之间的相关性,去除特征之间的冗余性。

1.2 基于改进的极限学习机的集成学习分类算法

如图 6 所示,胸腺瘤患者术前危险程度的预测问题包含



3个步骤:1)训练子样本的获取;2)子模型的构建;3)构建集

图 6 改进的极限学习机集成学习模型的构建

Fig. 6 Construction of integrated learning model of improved extreme learning machine

1.2.1 训练子样本的获取

训练子样本采用 bootstrap 抽样模拟出符合原始数据特 征的子样本,从而提供足够的样本进行统计分析,估计样本总 体。假设原始数据 $X = (x_1, x_2, \dots, x_N)$ 符合总体分布为 F 的 随机样本,从 F 中随机抽取样本 $X^* = (x_1^*, x_2^*, \dots, x_N^*)$ 构造 统计量,可以得到第 I 个自助样本的均值 $\overline{M(x_l^*)}$ 和方差 $S(x_l^*),即:$

$$\overline{M(x_I^*)} = \frac{1}{N} \sum_{I=1}^{N} M(x_I^*)$$
(5)

$$S(x_{I}^{*}) = \frac{1}{N} \sum_{I=1}^{N} (M(x_{I}^{*}) - \overline{M(x_{I}^{*})})^{2}$$
(6)

其中, $M(x_l^*)$ 为第 I个自助样本,独立重复 Q次采样,计算多 次采样的均值 $\overline{M(x^*)}$ 和方差 $S(x^*)$,即:

$$\overline{M(x^*)} = \frac{1}{Q} \sum_{I=1}^{Q} \overline{M(x_I^*)}$$
(7)

$$S(x^*) = \frac{1}{Q} \sum_{l=1}^{Q} (\overline{M(x_l^*)} - \overline{M(x^*)})^2$$
(8)

当重采样次数 Q 越大,则采样的子集的均值和方差越接 近总体样本的均值和方差。然而在采样过程中,每个数据每 次被随机独立采样的概率相同,因此每个新样本之间相互独 立,样本之间存在差异性,则构建的每个基分类器的预测输出 空间也存在差异性。

1.2.2 基分类器的构建

集成学习中基分类器的选择众多,可以根据数据之间是 否存在依赖关系选择"同质"分类器和"异质"分类器。本文选 择以改进的极限学习机作为基分类器构建集成学习分类模型。

极限学习机(Extreme Learning Machine, ELM)在 2006 年由 Huang 等^[17]提出,该网络作为一种单隐层的前馈神经 网络,不仅结构简单,而且在学习速度和预测精度方面有着优 秀的表现。网络中随机给定输入层与隐含层之间的连接权值 和激活函数的偏置,因此,可根据式(9)对网络求解。

$$H\beta = T' \tag{9}$$

其中,H 为隐含层的输出矩阵,T 为目标输出。通过计算可得 出隐含层的输出 H,因此只需要确定β就可以得出网络的解。 为使训练过程中期望损失最小,通过求解式(10)线性方程最 小二乘的解来确定隐含层与输出层之间的权重矩阵β。

$$\min \parallel \boldsymbol{H}\boldsymbol{\beta} - T' \parallel \tag{10}$$

式(10)解为 $\beta = H^{-1}T'$ 。一般情况下隐含层神经元个数 小于训练样本数,此时矩阵 *H*不可逆,因此引入广义逆矩阵 进行求解,则 $H^{-1} = H^+$,其 $H^+ = (H^TH)^{-1}H^T$ 。

然而在实际的情况中,传统的极限学习机的解通常存在 不适定的情况,当输入矩阵 X 不是列满秩或者某些列之间存 在很强的线性关系时,此时会出现 X^TX 的行列式结果为 0, 此时(X^TX)⁻¹产生很大的误差,导致网络稳定性差。为避免 此现象的出现,在式(10)中引入 L₁ 范数对隐含层与输出层之 间的权值进行稀疏化约束,可得到稀疏网络模型,正则化下的 约束求解如下:

$$\min \| \boldsymbol{H}\boldsymbol{\beta} - \boldsymbol{T}' \| + \lambda \| \boldsymbol{\beta} \|_{1}$$
(11)

将式(11)转化为:

$$\hat{\boldsymbol{\beta}} = (\boldsymbol{H}^T \boldsymbol{H} + \frac{1}{\lambda} \mathbf{I})^{-1} \boldsymbol{H}^T T'$$
(12)

其中, $c = \frac{1}{\lambda}$ 为正则化系数,设置参数 c = 0.0001, I 为单位矩阵,通过引入 L₁ 正则化的约束后可得到正则化的极限学习机(Regularized Extreme Learning Machine, R-ELM)模型,将正则化的极限学习机作为基分类器构建集成学习模型。

对已训练好的子模型的输出子空间采用算术平均的策略 构建集成学习,其集成学习模型表达式可表示为:

$$H(x) = \frac{1}{N} \sum_{n=1}^{N} h_n(x)$$
(13)

其中,N表示子模型的数量,h_n(x)表示第n个子模型的预测 输出。在集成学习中基分类器个数合理的选择是取得良好集 成效果的前提,基分类器的数量可根据集成的错误率来确定。 由于基分类器之间相互独立,则集成错误率为:

$$P(H(x) \neq f(x)) = \sum_{K=1}^{\frac{N}{2}} (1 - \varepsilon)^{K} \varepsilon^{N-K}$$

$$\leq \exp\left(-\frac{1}{2}N\left(1-2\varepsilon\right)^{2}\right) \tag{14}$$

其中, ε 为基分类器的错误率, f(x)为实际值。将该集成学习 分类模型应用于胸腺瘤危险程度的诊断中,该集成学习模型既 保留了 ELM 预测能力强、学习速度快的优点,同时又避免了 ELM 稳定性差的缺点。本文的集成学习算法的具体步骤如下:

(1)将深度学习模型提取的深度特征采用 U 检验以及 mRMR 算法对训练集进行特征选择与降维处理;

(2)采用 bootstrap 自助法从训练集中随机有放回地重采 样出训练子集;

(3)确定基分类器的激活函数和隐含层节点数,将重采样 的训练子集基于改进的极限学习机训练具有差异性的子 模型;

(4)重复步骤(2)和步骤(3)的操作,构建 N 子模型;

(5)将构建的 N 子模型预测的结果采用算术平均的策略 聚合作为最终的预测结果,同时将集成学习模型应用于内部 验证集和外部验证集的预测。

2 实验结果

2.1 实验数据

本文研究中使用的数据分别来源于江门市中心医院 149 例胸腺瘤 CT 影像数据,其中高危病例 87 例,低危病例 62 例;广州市第一人民医院 40 例胸腺瘤 CT 影像数据,其中高 危病例 19 例,低危病例 21 例;粤北人民医院 54 例胸腺瘤 CT 影像数据,其中高危病例 31 例,低危病例 23 例。本文研究采 用江门市中心医院的 CT 影像数据作为模型的训练集和内部 验证集,其中 149 例按照病理时间划分为训练集 100 例,在训 练集中包含高危病例 58 例、低危病例 42 例,在内部验证集 49 例中包含高危病例 29 例、低危病例 20 例。其他数据作为 模型的外部验证集。

2.2 实验仪器

胸腺瘤 CT 影像数据的获取是采用 Siemens Somatom16 排 CT 以及 Siemens 双源 Flash CT、Toshiba Aquilion 64 排 CT 和 GE Discovery 750 HD 64 排 CT。采用螺旋 CT 容积扫 描技术,扫描参数为:管电压 120 KVp;自动管电流技术 (50~150 mAs);螺距:0.75-1.0;矩阵:512×512;FOV: 320×320 mm。扫描范围为双侧肺尖至肾上腺水平。患者取 仰卧位,双手上举,于深吸气末屏气状态开始扫描。CT 增强 扫描保持与平扫相同的体位、范围和方向。使用双筒高压注 射器经肘前静脉团注非离子型碘对比剂,总量约 60~80 ml, 流速 2.0~3.0 ml/s,注药后分别于 30~35 s(动脉期),60~ 70 s(静脉期)扫描。多平面重组图像(Multiplnar Reconstruction,MPR)横断位 3.0 mm,20%~30%重叠;冠状位和矢状 位重组层厚 3.0 mm。

2.3 深度学习模型参数设置

在深度学习模型的训练过程中,模型的各个参数设置为: 网络初始学习率 lr = 0.0001,模型每轮训练输入的样本量 $batch_size = 16 张 3 通道 224 \times 224$ 的图片,训练轮数 epoch =150 轮,优化器动量 momentum = 0.7,衰减因子 decay =0.00001。选择随机梯度下降算法优化模型,采用交叉熵损 失函数来反映期望值与目标值之间的损失。损失函数的数学 表达式如下:

$$L_{s} = \frac{1}{N} \sum_{i=1}^{N} - \left[y_{i} \cdot \log(p_{i}) + (1 - y_{i}) \cdot \log(1 - p_{i}) \right] \quad (15)$$

其中,yi 表示样本 i 的标签,正类为 1,负类为 0; pi 为样本 i 预测为正的概率。

2.4 分类性能评价指标

本文采用准确率(Accuracy)、灵敏度(Sensitivity)、特异 度(Specificity)、阳性预测值(Positive Predictive Value, PPV)、 阴性预测值(Negative Predictive Value, NPV)以及 ROC 曲线下 的面积(Area Under Curve, AUC)来评价分类结果。

$$\begin{cases}
Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \\
Sensitivity = \frac{TP}{TP + FN} \\
Specificity = \frac{TN}{TN + FP} \\
PPV = \frac{TP}{TP + FP} \\
NPV = \frac{TN}{TN + FN}
\end{cases}$$
(16)

其中,TP和FP分别表示正确分类为胸腺瘤低危的病例数和 错误分类为胸腺瘤高危病例数,TN和FN分别表示正确分 类为胸腺瘤高危病例数和错误分类为胸腺瘤低危病例数, Accuracy, Sensitivity, Specificity, PPV, NPV 越接近于1, 表示分类结果越好。

2.5 不同分类器的性能比较

为了验证所提算法的准确性和泛化性能,选择 DenseNet 端对端的方法、随机森林(Random Forest, RF)和极限学习机 算法(Extreme Learning Machine, ELM)以及依赖于临床医生 经验的专家模型与本文方法进行对比分析,实验结果如表1 所列,图7给出了4个数据集在不同分类器上的ROC曲线。 图 7(a) 一图 7(d) 分别表示训练集、内部验证集、外部验证集 1 和外部验证集2,由表1和图7可知,本文方法在训练集、内 部验证集、外部验证集 1、外部验证集 2 上的 AUC 分别为 0.918,0.833,0.771,0.784.

|--|

l Comparison of classification performance of differen	nt classifiers
--	----------------

Table 1 Comparison of classification performance of different classifiers									
数据集	分类器	AUC	Sensitivity	Specificity	Accuracy	PPV	NPV		
训练集	本文方法	0.918	0.897	0.786	0.850	0.853	0.846		
	RF	0.769	0.707	0.786	0.740	0.820	0.660		
	ELM	0.877	0.776	0.833	0.800	0.865	0.729		
	DenseNet 端对端	0.521	0.793	0.381	0.620	0.639	0.571		
	专家模型	0.685	0.552	0.738	0.630	0.744	0.544		
内部验证集	本文方法	0.833	0.650	0.931	0.816	0.867	0.794		
	RF	0.720	0.900	0.483	0.653	0.545	0.875		
	ELM	0.750	0.700	0.793	0.755	0.700	0.793		
	DenseNet 端对端	0.528	0.931	0.350	0.694	0.675	0.779		
	专家模型	0.729	0.655	0.600	0.633	0.704	0.546		
外部 验证集 1	本文方法	0.771	0.871	0.609	0.759	0.750	0.778		
	RF	0.706	0.839	0.565	0.722	0.722	0.722		
	ELM	0.711	0.783	0.645	0.704	0.621	0.800		
	DenseNet 端对端	0.555	0.435	0.710	0.593	0.562	0.629		
	专家模型	0.641	0.419	0.870	0.611	0.813	0.526		
外部 验证集 2	本文方法	0.784	0.789	0.762	0.775	0.750	0.800		
	RF	0.693	0.789	0.571	0.675	0.625	0.750		
	ELM	0.712	0.619	0.895	0.750	0.867	0.680		
	DenseNet 端对端	0.526	0.579	0.714	0.650	0.647	0.652		
	专家模型	0.734	0.316	0.905	0.625	0.750	0.594		



图 7 不同分类器的 ROC 对比曲线

Fig. 7 ROC comparison curves of different classifiers

根据实验结果分析可知,使用不同的分类模型,预测结果 相差较大。极限学习机分类器虽然学习速度快,但是稳定性 差,不宜于多中心验证;随机森林分类算法的表现更加依赖于 两类之间的相互独立,而本研究中不同危险程度的胸腺瘤 CT 表现为多重叠,两类之间存在相关性,因此随机森林的分 类准确率较低;DenseNet端对端的模型是在卷积神经网络的 最后一层直接输出预测结果,模型灵活性较低,并且全连接层 中可能存在特征的冗余,导致结果较差;依赖于临床医生经验 的专家模型受主观因素影响较大,存在费时费力、再现性低等 问题。相比其他几个分类模型,本文提出改进的极限学习机 的集成学习综合了多个子模型的性能,因此能提高模型的分 类性能。该模型在多中心验证中能表现出良好的预测精度和 稳定性。

结束语 针对胸腺瘤术前危险程度的预测问题,本文提 出结合深度学习与改进的极限学习机集成学习的计算机辅助 分析方法。首先,将图像通过小波多尺度变换并计算小波能 量图以挖掘图像信息的丰富性;其次,采用卷积神经网络提取 小波能量图中与任务相关的特异性深度特征;最后,采用 bootstrap 自助法对训练集重采样出训练子集,并基于改进的 极限学习机为基分类器训练具有差异性的子模型,采用算术 平均的策略构建集成学习分类模型以提高模型的稳定性。多 中心实验结果表明,本文所提方法具有较好的预测精度和泛 化性能。

参考文献

- [1] YU S,LIU D Z,XU G Q. New progress in the treatment of thymic tumors [J]. Chinese Journal of Practical Surgery, 2009, 29(S1):160-161.
- [2] HAN Y P,ZHANG Y P,WANG D,et al. Value of energy spectrum CT imaging in differential diagnosis of invasivethymoma and mediastinal lymphoma[J]. Chinese Journal of Medical Imaging,2016,24(6):464-467.
- [3] PANDEY S J.MANNAN N.YADAV R. Diagnostic accuracy of multidetector computed tomography scan in mediastinal masses assuming histopathological findings as gold standard [J]. Polish Journal of Radiology, 2018, 83: e234-e242.
- [4] WANG S H,QIN B. Bayesian network structure learning based on integrated learning and feedback strategy [J]. Journal of Computer Science, 2021, 44(6):1051-1063.
- [5] DING Y, WANG M L, ZHANG D Q. Differential stochastic subspace integration [J]. Computer Science and Exploration, 2018, 12(9): 1434-1443.
- [6] SHAO L S, MA H, WEN T X. Research on classifier integration model of limit learning machine[J]. Computer Engineering and Application, 2016, 52(13):121-125.
- [7] LI H Y, BI D Y, YANG Y, et al. Research on visual tracking algorithm based on depth feature expression and learning [J].

Journal of Electronics and Information, 2015, 37(9): 2033-2039.

- [8] SONG Y,HOU B G,CAI Z P. Network intrusion detection method based on deep learning feature extraction[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition),2021,49(2):115-120.
- [9] SHI J, WANG L L, WANG S S et al. Application of deep learning in medical imaging [J] Chinese Journal of Image and Graphics, 2020, 25(10): 1953-1981.
- [10] MUHAMMED T.ULAS B B.ÖZAL Y.RAJENDRA A. Application of Deep Transfer Learning for Automated Brain Abnormality Classification Using MR Images[J]. Cognitive Systems Research, 2018, 54(MAY): 176-188.
- [11] YE W, GU W, GUO X, et al. Detection of pulmonary groundglass opacity based on deep learning computer artificial intelligence[J]. Biomedical Engineering Online, 2019, 18(1):6.
- [12] TIAN F,LI Y,WANG J. Retinal vessel segmentation based on multi-scale wavelet transform fusion [J]. Journal of Optics, 2021,41(4):82-92.
- [13] GESISSBUHLER A, POLETTI P A, MULLER H, et al. Nearaffine-invariant texture learning for lung tissue analysis using isotropic wavelet frames[J]. IEEE Transactions on Information Technology in Biomedicine: A Publication of the IEEE Engineering in Medicine and Biology Society, 2012, 16(4): 665-675.
- [14] GAO H,ZHUANG L,VAN DER M L,et al. Densely Connected Convolutional Networks [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017:2261-2269.
- [15] ZHENG C L, PANG M. Spatiotemporal weighted attitude motion feature extraction algorithm based on convolutional neural network [J] Journal of Applied Science, 2021, 39(4):594-604.
- [16] FENG B.CHEN X M.CHEN Y H.et al. Solitary solid pulmonary nodules: a CT-based deep learning nomogram helps differentiate tuberculosis granulomas from lung adenocarcinomas [J]. European Radiology, 2020, 30(12):6497-6507.
- [17] HUANG G B,ZHU Q Y,SIEW C K. Extreme learning machine: Theory and applications [J]. Neurocomputing, 2006, 70(1/2/3):489-501.



XU Kun-cai, born in 1997, postgraduate. His main research interests include application of machine learning in medical images and so on.



CHEN Ye-hang, born in 1993, master. His main research interests include machine learning technology and its application in biomedical signal processing.