

基于循环卷积神经网络的甲状腺恶性结节检测

郑斌¹, 杨晨¹, 马小萍², 刘立波^{1*}

¹宁夏大学信息工程学院, 宁夏 银川 750021;

²银川市第一人民医院医技科, 宁夏 银川 750002

摘要 针对过拟合及甲状腺恶性结节细粒度分类(恶性分为恶性与高度恶化)的问题,提出一种基于循环卷积神经网络的分类方法。将 Xception 网络与长短时记忆网络(LSTM)作为互不干扰的两部分,分别对甲状腺结节样本进行特征提取得到两个权重矩阵;通过 Merge 算法融合为单个权重矩阵,将单个权重矩阵导入卷积神经网络(CNN)进行特征提取与池化;采用 L2 正则化的 Softmax 函数作为分类器,完成循环卷积神经网络的训练与测试。实验结果表明,甲状腺恶性结节细粒度分类的准确率为 87.00%,并有较好的特征提取能力。

关键词 图像处理;神经网络;超声图像;甲状腺;图像分类预测

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP56.241003

Malignant Thyroid Nodule Detection Based on Circular Convolutional Neural Network

Zheng Bin¹, Yang Chen¹, Ma Xiaoping², Liu Libo^{1*}

¹ School of Information Engineering, Ningxia University, Yinchuan, Ningxia 750021, China;

² Medical Technologic Departments, Yinchuan People's Hospital, Yinchuan, Ningxia 750002, China

Abstract In this study, a classification method is proposed based on a circular convolutional neural network (CNN) to deal with the issues of over-fitting and fine-grained classification of the malignant and highly deteriorated thyroid nodules. First, the Xception network and long short-term memory network (LSTM) are used as two non-interference parts. Next, the features of thyroid nodule samples are separately extracted to obtain two weight matrices, which are subsequently merged into a single weight matrix using the Merge algorithm. Further, the single weight matrix is imported into the CNN for feature extraction and pooling. Finally, the Softmax function of L2 regularization is used as a classifier to complete the training and testing of the circular CNN. Our experimental results denote that the accuracy of the fine-grained classification of malignant thyroid nodules is 87.00%, denoting a good feature-extraction capability.

Key words image processing; neural network; ultrasound image; thyroid; image classification prediction

OCIS codes 100.4996; 100.2000; 100.3008

1 引言

甲状腺结节是严重危害人类健康的疾病之一,及时发现甲状腺结节并进行有效分类诊断与治疗,有利于降低甲状腺癌症的发病率。

对于被诊断为不确定或疑似恶性肿瘤的患者,甲状腺结节评估作为排除甲状腺癌症的主要方式,

通常采取细针穿刺^[1]活检(FNA)或手术的方式来准确诊断结节性质,该方式需消耗大量的人力、物力。因此,各放射科专家根据甲状腺超声图像中结节区域表现出的若干类特征,如回声、钙化、边缘、结节纵横比等,参考乳腺 BI-RADS (breast imaging reporting and data system) 分级评估标准制定甲状腺 TI-RADS (thyroid imaging reporting and data

收稿日期: 2019-04-08; 修回日期: 2019-05-18; 录用日期: 2019-06-06

基金项目: 国家自然科学基金(61862050)、赛尔网络下一代互联网技术创新项目(NGH20180709)、西部一流大学科研创新项目(ZKZD2017005)

* E-mail: liulib@163.com

system)分级评估标准^[2-3]。该评估标准根据结节临床特征进行结节级别分类,从而避免资源大量浪费。虽然多数研究者采用该评估标准展开探究讨论^[4-6],但该方法存在评估周期长、完全依赖主治医师的个人主观经验等问题。

主要用于图像识别等,且在图像识别领域取得较大成功^[7]的深度学习方法,通过向医疗领域的渗透,为甲状腺结节分类提供了新思路。基于神经网络与机器学习的甲状腺超声图像分类,解决了评估周期长与完全依赖医生主观因素的问题。当前研究采用神经网络与机器学习等对甲状腺良恶性结节展开分类研究。江涛^[8]对图像去噪、计算边界紧致度等信息的65个纹理学特征进行研究,并利用离差标准化变换对特征值进行处理,然后分别采用人工神经网络(ANN)和支持向量积(SVM)2组分类模型进行验证。Ma等^[9]采用非侵入性和自动化与留一交叉验证(LOOCV)的分类方法区分良性和恶性甲状腺结节。Keramidas等^[10]采用结合原始KNN(K-Nearest neighbor)方法的甲状腺结节探测器(TND)对甲状腺良恶性结节进行评估分析。其中,结节分割需要手动初始化点,存在工作量大、特征信息易丢失的问题。网络模型中各参数计算过程复杂,研究人员未考虑利用甲状腺结节超声图像中的图像特征之间的关系近似还原病症临床表现之间的关系,而且缺乏对恶性甲状腺结节进一步细化(细粒度)的分类研究。甲状腺结节超声图像自身具有复杂性和多变性,这也为实现高效能的甲状腺结节检测提出了较为严峻的挑战。

本文针对这些问题,参考刘鑫童等^[11]的融合学习思想,提出基于Xception^[12]与长短时记忆网络(LSTM)^[13]模型的循环卷积神经网络(CNN),对甲状腺恶性结节进行细粒度(将恶性结节细化分类为初步恶性、高度恶化)分类研究。在循环卷积神经网络中使用ReLU_s激活函数来增强网络收敛能力;采用L2正则化以防止出现过拟合。该网络在提取甲状腺结节样本特征的基础上,能研究特征之间的关联关系,并能近似还原甲状腺结节临床病理特征间的关系,提高了对甲状腺结节分类的泛化能力。通过实验验证,该模型在进行恶性结节细粒度分类时准确率达到87.00%,这表明该方法具有更强的特征提取能力和更高的分类准确率。

2 方法模型

循环卷积网络模型实现了甲状腺超声图像恶性

结节检测,流程如图1所示。因卷积神经网络是图像识别检测领域优秀的深度学习模型^[14],所以在网络中采用卷积神经网络。在该网络模型初始化之前,首先对原始甲状腺超声图像进行去噪、增强、旋转及裁剪等处理;接着分别进入Xception、LSTM模型提取图像特征之间的关联关系;然后两支网络输出权重矩阵进入CNN-Fusion网络(该网络的构建用于特征融合,即对权重矩阵的shape张量做逐元素相乘来进行融合学习);最后,通过Softmax分类器实现甲状腺恶性结节分类检测。

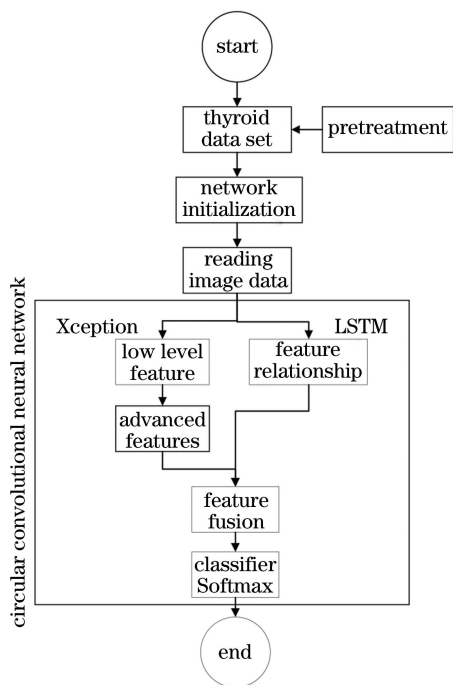


图1 循环卷积网络模型的实验流程

Fig. 1 Experimental procedure of circular CNN

2.1 图像处理方法

由于超声成像设备的限制,超声图像的分辨率效果较差,需要先对图像进行处理。首先,对图像进行噪声去除和图像增强,图2(b)为使用中值滤波去除噪声后的甲状腺图像,能够观察到图2(b)比图2(a)甲状腺原始图像平滑,噪声得到控制。然后,对甲状腺超声图像结节区域进行提取与图像增强,如图2(c)所示,利用数据扩充增加样本数量,提取的方法有旋转、反转、对比度调整、色度、亮度调整、裁剪等^[15]。最后,对所有样本进行归一化处理。

2.2 基于循环卷积神经网络的甲状腺结节检测方法

本文网络模型由Xception、LSTM与CNN-Fusion构成。创新点在于引入循环网络功能,该网络可根据甲状腺结节超声图像中的图像特征之间的




图2 甲状腺超声图像。(a)原始图像;(b)去除噪声图像;(c)感兴趣区域

Fig. 2 Ultrasound images of thyroid. (a) Original image; (b) noise-removal image; (c) region of interest

关系近似还原病症临床表现之间的关系,并搭建特征融合网络 CNN-Fusion。循环卷积神经网络模型如图3所示。经L2正则化等调整,使其适合甲状腺恶性结节细粒度分类,能发挥出最佳效能。首先将样本数据分别输入Xception网络与LSTM(两者工作互不干扰);进而将两者计算得到的两个权重矩阵同时输入CNN-Fusion的Merge层,由该层对特征进行融合处理,合并为单个权重矩阵;接着将合并后的权重矩阵进行卷积运算;最后由输出层输出种属概率最大的类别,完成分类预测。

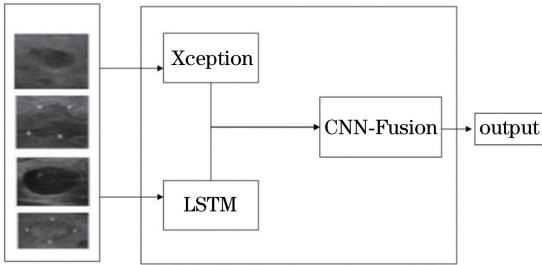


图3 循环神经网络基本原理图

Fig. 3 Basic principle of circular CNN

2.2.1 Xception 与 LSTM

Xception 是一种卷积神经网络,采用可分离卷积,并与局部连接和权值共享相结合。首先,样本通过卷积层的三维(3D)滤波器进行卷积运算,产生特征映射图;然后,对特征映射图局部区域进行加权平均求和,增加偏置;继而通过一个非线性激活函数并在池化层进行特征融合得到新的特征映射图;最终,特征映射图由输出层输出。该网络不仅能减少参数数量,而且降低了过拟合发生的概率。其优势在于甲状腺超声图像样本在卷积层中先是通过卷积处理得到低级特征,然后再通过连续卷积得到样本的高级特征,能进行有效的特征提取。

LSTM 核心为遗忘门、输入门、输出门。遗忘门读取上层单元的输出与当前单元的输入,输出在0到1间的数值给每个神经元,并由神经元决定取舍内容;输入门经激活函数生成一个向量,以备更新网络数据;输出门将 Sigmoid 层输出信息通过激活

函数处理,输出最终信息。该网络作为一种时间递归神经网络,常用于实验语句连接与挖掘样本特征间的关联等,而在本研究中则用于实现甲状腺超声图像样本特征与特征之间的关联,继而还原出病症临床表现之间的关系。

2.2.2 卷积神经网络融合网络

构建甲状腺超声图像特征融合网络 CNN-Fusion,该网络基本原理如图4所示,由 Merge 层、卷积层(Conv1~Conv4)、池化层(Pool1~Pool4)、全连接层(FC)、输出层等组成。由图4可以看出,融合网络 CNN-Fusion 结构先由两个权重矩阵到单个权重矩阵,再由多层卷积与池化得到甲状腺超声图像的高级特征,最后根据特定的超声图像分类器输出检测结果。其中,Merge 层设定卷积核大小为 5×5 ,即滑动窗口每次将 5×5 的图像区域与卷积核进行非线性运算,输入为 Xception 与 LSTM 的输出权重矩阵。

卷积操作中的卷积核大小均设置为 5×5 ,即滑动窗口每次将 5×5 的图像区域与卷积核进行非线性运算,因此 Conv 层的输入 y_j^k 为

$$y_j^k = \sum_{i \in \mathbf{Z}^+} x_i^{k-1} * w_{ij}^k + b_j^k, \quad (1)$$

式中, w_{ij}^k 为卷积核, x_i^{k-1} 为甲状腺超声输入特征图, b_j^k 为偏置, i 和 j 分别为第 i 个输入和第 j 个神经元, k 为卷积层数, \mathbf{Z}^+ 为正整数。卷积核进行卷积操作后,需要通过激活函数输出特征图,因此 Conv 的输出为

$$\mathbf{Y}_j^k = f(y_j^k), \quad (2)$$

式中, $f(\cdot)$ 为激活函数 ReLUs, \mathbf{Y}_j^k 为特征矩阵。特征图通过 max-pooling 层(特征映射层),对经过卷积层后得到的特征进行下采样,缩小了输入数据规模,得到局部最优值^[16],在 max-pooling 层表示为

$$x_j^k = f[\alpha_j^k p(\mathbf{Y}_j^{k-1}) + b_j^k], \quad (3)$$

式中, $p(\cdot)$ 为 max-pooling 函数, α_j^k 为权重系数,池化在一定程度上降低了计算复杂度。

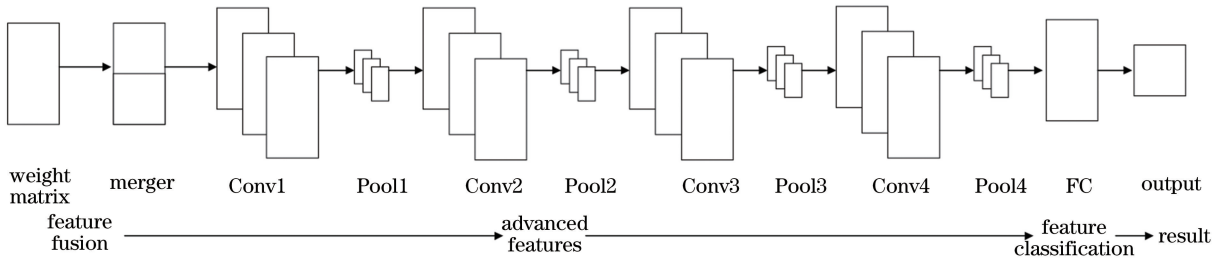


图 4 CNN-Fusion 结构图

Fig. 4 Structure of CNN-Fusion

2.2.3 激活函数优化选择

卷积层中对卷积核进行卷积操作后,需要通过一个激活函数输出特征图,而且激活函数可以有效提高网络的特征学习能力。常用的激活函数有 Sigmoid 函数和 ReLUs 函数。其中 Sigmoid 函数,为

$$S(x) = \frac{1}{1 + \exp(-x)}, \quad (4)$$

ReLUs 函数为

$$f(x) = \max(0, x), \quad (5)$$

式中, x 为神经元输入。图 5 为激活函数曲线图。由图可见,与 Sigmoid 相比,ReLUs 具有梯度不饱和的优点:当 $x > 0$ 时, $R(x) = x$; 当 $x < 0$, 则将 $R(x)$ 数值置为 0,使其能够减轻梯度弥散。ReLUs 函数能简化计算过程,更适合使用在这深度网络模型中,因此,卷积层的激活函数采用 ReLUs。

Softmax 函数值变动,容易使模型趋于过拟合。针对样本中噪声点对 Softmax 损失函数的不良影响,引入 L2 正则化,获取压缩系数,将模型参数缩小化,一定程度上能够避免过拟合现象的发生。

引入 L2 正则化后,Softmax 函数表示为

$$H(\theta) = J(\theta) + \lambda_1 \|\theta\|_2^2, \quad (6)$$

式中, $H(\theta)$ 为引入正则化后的 Softmax, $\|\theta\|_2$ 为 L2 范数的规则项^[17], λ_1 为可调的衰减系数。本文通过调整 λ_1 的值,对大数值权重进行类似“削弱”作用的措施,有助于提高甲状腺结节分类模型测试的关联特性。将 L2 正则化引入 Softmax 中,可使网络模型在对甲状腺超声图像进行分类时有效提高分类效果。

3 实验与结果分析

为实现甲状腺恶性结节检测,在甲状腺超声图像数据集中构建循环卷积神经网络进行实验。训练初始,学习率设置为 0.1,在 500 次迭代后学习率降为 0.01,实验在 Tensorflow 环境下进行。

3.1 图像数据采集

实验采用本地合作医院提供的 967 名匿名患者的甲状腺超声图像和 Romero 课题组^[18]提出的甲状腺超声图像数据库。其中,本地数据含有阴性甲状腺超声图像 719 张,阳性甲状腺超声图像 367 张,共 1086 张;Romero 课题组提出的甲状腺超声图像数据库中,357 张标记为阳性数据、71 张标记为阴性数据,共 428 张。实验采用的甲状腺超声图像分级均依据医生指导,并结合 TI-RADS 评估标准进行。

甲状腺超声图像按照图像处理方式处理完之后分为 3 组数据,如表 1 所示,分别为正常-结节数据组(分类 I)、良性结节-恶性结节数据组(分类 II)、结节初步恶化-结节高度恶化数据组(本组即为对恶性结节细粒度分类的数据组,分类 III)。其中,数据分组依据合作医院主任医师的指导与 TI-RADS 评估标准相结合的方式,将 TI-RADS 评估标准中




图 5 激活函数图。(a) Sigmoid;(b) ReLUs

Fig. 5 Activation function plots. (a) Sigmoid; (b) ReLUs

2.2.4 引入 L2 正则化优化

本文采用 Softmax^[17]进行优化处理。因为 Softmax 较为敏感,样本中噪声点极易引起

表 1 甲状腺分类的图像张数

Table 1 Image numbers of thyroid classification

Datasource	Classification I		Classification II		Classification III	
	Normal	Nodule	Benign	Malignant	Malignant	Highly deteriorated
Local	2157	1101	609	492	288	288
Romero		213	714	580	580	
Total	2157	1101	822	1206	868	868
Test	648	330	246	361	260	260

包含若干个 TI-RADS 等级的恶性结节,根据其恶化程度分为 2 类(恶性程度相对较低、恶性程度较高及癌变)即为恶性结节细粒度的指标。

表 1 分为 4 行,第 1 行是本地甲状腺超声图像;第 2 行是 Romero 公开的数据集中的图像数据;第 3 行是本地和 Romero 公开数据同一类型的数据的总计(即实验测试集使用的数据);第 4 行是测试集数据情况。

3.2 评价指标

选择适当的实验评价指标对于检验实验方法的性能具有重要意义。本文采用准确率与 Loss 函数值作为甲状腺超声图像恶性结节检测的实验指标。在检测结果中,将正确检测为高度恶化结节图像、错误检测为高度恶化结节图像、正确检测为初步恶化图像、错误检测为初步恶化图像分别定义为真阳性(T_P)、假阴性(F_N)、真阴性(T_N)、假阳性(F_P),则检测准确率 A_{cc} 为

$$A_{cc} = \frac{1}{n} \sum_{m=1}^n \frac{T_P + T_N}{T_P + F_N + T_N + F_P} \times 100\%, \quad (7)$$

式中, n 为样本数量, m 为样本编号。

Loss 函数值展示了网络的收敛性能,当网络 Loss 函数值稳定时的数值越小,代表网络数据集中数据拟合效果更好、收敛能力更强。

$$l(\theta) = \prod_{m=1}^n f\{y^{(m)} | h_{\theta}[x^{(m)}]\}, \quad (8)$$

式中, l 为 Loss 函数值, $x^{(m)}$ 为第 i 个样本,其对应的标签为 $y^{(m)}$ 。

3.3 结果分析

首先,在 CNN 基础上引入序列并使网络产生一定的记忆效应,使前后输入产生一定的关系,进而获得甲状腺结节超声图像中图像特征之间的关系,最终近似还原病症临床表现之间的关系。为验证本文网络模型分类效果更佳,实验中采用江涛、Ma 等、Keramidas 等研究甲状腺良恶性结节分类时提出的方法及残差网络(ResNet)^[19] 方法进行比较,如表 2 所示。本文方法的分类准确率比江涛、Ma 等、

Keramidas 的方法准确率分别高 6.06 个百分点、17.83 个百分点、7.7 个百分点、28.80 个百分点,比 ResNet 分类方法高 1.9 个百分点。由表 2 得出本文方法分类效果最佳,原因是引入了时间序列,在提取图像特征的同时建立了图像特征间的关联关系,一定程度上还原了甲状腺结节临床病理特征之间的关系,即将临床病理特征间关系以图像特征间的关联关系的形式复现,充分考虑图像特征间的差异与联系,提高了分类器的适应能力。

表 2 良恶分类结果对比

Table 2 Comparison of classification results for good and malignancy

Method	Accuracy / %
ANN ^[8]	88.24
SVM ^[8]	76.47
LOOCV ^[9]	86.60
TND ^[10]	65.50
ResNet ^[19]	92.40
Proposed method	94.30

网络模型中引入循环网络特点,分类预测能力得到显著提高。传统 CNN 只提取甲状腺超声图像的图像特征,本文方法在此基础上引入时间序列,使网络具有一定的记忆功能,在提取图像特征下,整理得到图像特征间的关联,从而还原了甲状腺结节临床病理特征之间的关系,实现了高准确分类预测。

其次,为验证本文循环 CNN 对分类预测难度较高的甲状腺恶性结节细粒度分类效果,制作 3 组数据集分别进行实验。实验结果为:正常甲状腺超声图像与结节甲状腺超声图像的分类(classification I)准确率高达 99.70%;甲状腺良恶性结节分类的(classification II)准确率突破 90%,达到 94.30%;甲状腺恶性结节细粒度分类(初步恶化与高度恶化,classification III)的准确率高达 87.00%。实验结果表明,本文网络预测模型对较高难度的甲状腺恶性结节细粒度分类效果优越。CNN-Fusion 网络将甲状腺超声图像特征与特征间联系等信息高度融合,相比只掌握图像特征无特征间关系的传统 CNN,

CNN-Fusion 的构建与使用增强了网络分类预测能力与网络稳健性。

图 6 为本文实验准确率的变化曲线、Loss 值与训练神经网络迭代次数曲线,3 组实验随迭代次数的增加,准确率呈上升趋势,迭代次数在 500 次左右趋于平稳,分类 I 准确率最高,分类 II 次之,分类 III 最低。通过观察 Loss 值与迭代次数的变化曲线,得出该模型收敛速度较快。在训练迭代 500 次后,所有实验的 Loss 值均降到 0.3 以下,训练继续进行,Loss 值维持在 0.1~0.2 之间,分类器适应能力较好,收敛速度与收敛能力较好。同时该网络模型采用参数共享与局部感知,可以降低网络复杂度;引入 L2 正则化可以有效避免网络训练过拟合,获取最佳的提取特征能力。

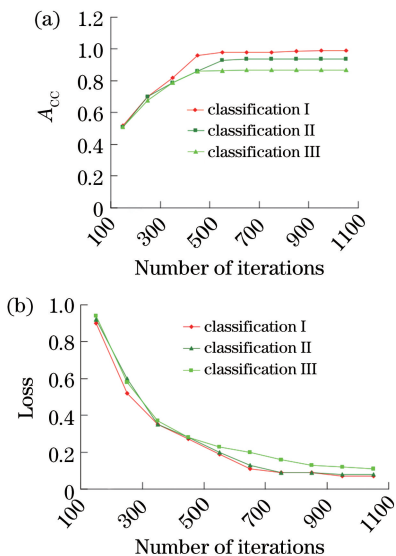


图 6 实验数据图。(a)准确率;(b) Loss 值

Fig. 6 Experimental data. (a) Accuracy rate;
(b) Loss value

最后,为验证该分类模型的优化效果,相同条件下,在引入 L2 正则化基础上对 ReLUs 激活函数与 Sigmoid 激活函数进行对比实验。由于训练迭代次数在 1000 次左右后,Loss 曲线趋于平缓,因此这里主要分析 1000 次迭代的两种激活函数情况。图 7 为甲状腺恶性结节细粒度分类实验的对比结果,由该图得出,采用 ReLUs 函数作为非线性激活函数的 Loss 值下降更快,ReLUs 下降到 0.12 并趋于稳定,而采用 Sigmoid 函数作为激活函数的 Loss 值下降到 0.3,因此,将 ReLUs 函数作为激活函数的收敛效果更好。本文网络通过引入 L2 正则化与 ReLUs 激活函数,从而使网络模型提取图像特征能力、图像特征间的关联联系能力均有所提高。




图 7 函数 ReLUs 与 Sigmoid 的 Loss 曲线

Fig. 7 Loss curves of ReLUs and Sigmoid functions

通过以上实验分析可得,本文方法对甲状腺超声图像分类具有明显优势。该网络模型通过卷积提取甲状腺超声图像样本中的图像特征;利用引入网络的传播特点,学习并整理甲状腺超声图像中图像特征间的关联关系,在一定程度上复现甲状腺结节临床病理特征之间的关系;CNN-Fusion 将图像特征与特征间的关联关系中两个权重矩阵融合为单个权重矩阵,得到图像特性及其关系,并进一步提取高级特征,如图 8 所示。另外,该实验中由于图像样本数量小,通过图像扩充方法适度增广样本数量,并针对实验中小样本数据集易使分类网络产生过拟合的问题,采用 L2 正则化与 Softmax 优化该网络模型增强网络性能,全面学习图像特征与深度理解图像特征之间的联系,从而使甲状腺恶性结节与高度恶性结节分类准确率高达 87.00%,实现了高精度的恶性结节细粒度分类。

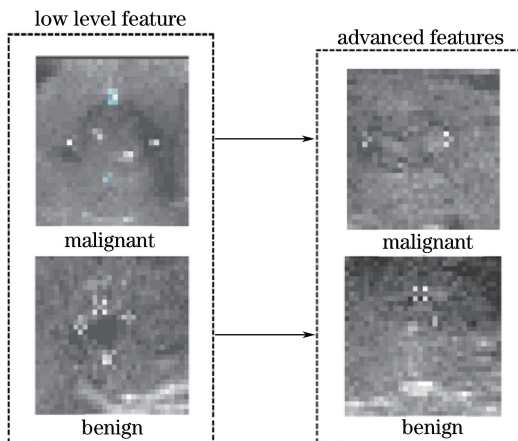


图 8 甲状腺超声图像特征图

Fig. 8 Feature maps of ultrasound image of thyroid

4 结 论

针对甲状腺恶性结节细粒度分类,提出由 Xception、LSTM 和 CNN-Fusion 组成,并采用 Merge 算法融合图像特征的循环卷积神经网络。该模型结合 TI-RADS 评估标准,实现了高精度的甲

状腺恶性结节细粒度分类,提高了对甲状腺结节分类的泛化能力。充分使用卷积神经网络的特征提取能力与 LSTM 获取特征间浅层与深层的语义联系的能力,以及 CNN-Fusion 网络的特征与特征间关联关系,通过在数据集上对该网络的评估测试进行比较,证明本文方法能有效实现甲状腺恶性结节细粒度分类,并获得较高的分类准确率。本文网络中 L2 正则化能有效防止循环卷积神经网络出现过拟合,同时网络参数共享与局部感知降低了网络复杂度,提高了网络稳定性;ReLU 作为激活函数,能够有效提高网络的收敛能力,更好地适应恶性结节细粒度分类的复杂性,因此本文网络模型具有较高的分类准确率,能够帮助医生辅助诊断,具有实际应用价值。

参 考 文 献

- [1] Galbraith J D, Swann N, Cox B, *et al.* The Bethesda classification for thyroid fine needle aspiration: a predictor or an alarmist?[J]. *The American Surgeon*, 2018, 84(1): 161-164.
- [2] Kwak J Y, Han K H, Yoon J H, *et al.* Thyroid imaging reporting and data system for US features of nodules: a step in establishing better stratification of cancer risk[J]. *Radiology*, 2011, 260(3): 892-899.
- [3] de Macedo B M, Izquierdo R F, Golbert L, *et al.* Reliability of thyroid imaging reporting and data system (TI-RADS), and ultrasonographic classification of the American thyroid association (ATA) in differentiating benign from malignant thyroid nodules [J]. *Archives of Endocrinology and Metabolism*, 2018, 62(2): 131-138.
- [4] Wang H, Yang Y, Peng B, *et al.* A thyroid nodule classification method based on TI-RADS [J]. *Proceedings of SPIE*, 2017, 10420: 1042041.
- [5] Cheng S P, Lee J J, Lin J L, *et al.* Characterization of thyroid nodules using the proposed thyroid imaging reporting and data system (TI-RADS) [J]. *Head & Neck*, 2013, 35(4): 541-547.
- [6] Russ G. Risk stratification of thyroid nodules on ultrasonography with the French TI-RADS: description and reflections [J]. *Ultrasonography*, 2016, 35(1): 25-38.
- [7] Lai W H, Zhou M R, Wang Y, *et al.* Application of counterfeit liquor recognition based on deep learning and laser induced fluorescence [J]. *Laser & Optoelectronics Progress*, 2018, 55(4): 043001. 来文豪, 周孟然, 王亚, 等. 深度学习与激光诱导荧光
- 光在假酒识别中的应用[J]. *激光与光电子学进展*, 2018, 55(4): 043001.
- [8] Jiang T. Computer aided diagnosis of thyroid nodules based on ultrasound images [D]. Nanchang: Nanchang University, 2017. 江涛. 基于超声图像的甲状腺结节计算机辅助诊断研究[D]. 南昌: 南昌大学, 2017.
- [9] Ma J M, Luo S, Dighe M, *et al.* Differential diagnosis of thyroid nodules with ultrasound elastography based on support vector machines[C]// 2010 IEEE International Ultrasonics Symposium, October 11-14, 2010, San Diego, CA, USA. New York: IEEE, 2010: 1372-1375.
- [10] Keramidis E G, Maroulis D, Iakovidis D K. TND: a thyroid nodule detection system for analysis of ultrasound images and videos [J]. *Journal of Medical Systems*, 2012, 36(3): 1271-1281.
- [11] Liu X T, Ma X P, Liu L B. Thyroid nodule detection method based on median filter and residual network [J]. *Computer Engineering and Applications*, 2019, 55(13): 254-259. 刘鑫童, 马小萍, 刘立波. 基于中值滤波和残差网络的甲状腺结节检测[J]. *计算机工程与应用*, 2019, 55(13): 254-259.
- [12] Chollet F. Xception: deep learning with depthwise separable convolutions[C]// *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)*, July 21-26, 2017, Honolulu, Hawaii. New York: IEEE, 2017: 1251-1258.
- [13] Hochreiter S, Schmidhuber J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [14] Liu F, Liu P Y, Zhang J N, *et al.* Joint detection of RGB-D images based on double flow convolutional neural network [J]. *Laser & Optoelectronics Progress*, 2018, 55(2): 021503. 刘帆, 刘鹏远, 张峻宁, 等. 基于双流卷积神经网络的 RGB-D 图像联合检测[J]. *激光与光电子学进展*, 2018, 55(2): 021503.
- [15] Chi J N, Walia E, Babyn P, *et al.* Thyroid nodule classification in ultrasound images by fine-tuning deep convolutional neural network [J]. *Journal of Digital Imaging*, 2017, 30(4): 477-486.
- [16] Xu Y, Sun M S. Convolution neural network image defogging based on multi-feature fusion [J]. *Laser & Optoelectronics Progress*, 2018, 55(3): 031012. 徐岩, 孙美双. 基于多特征融合的卷积神经网络图像去雾算法[J]. *激光与光电子学进展*, 2018, 55(3):

- 031012.
- [17] Liu X T, Liu L B, Zhang P. Cross-dataset image classification based on multi-convolutional neural network [J]. *Computer Engineering and Design*, 2018, 39(11): 257-262.
刘鑫童, 刘立波, 张鹏. 基于多重卷积神经网络跨数据集图像分类[J]. *计算机工程与设计*, 2018, 39(11): 257-262.
- [18] Pedraza L, Vargas C, Narváez F, *et al.* An open access thyroid ultrasound image data-base [J]. *Proceedings of SPIE*, 2015, 9287: 92870W.
- [19] 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)*, June 26-July 1, 2016, Las Vegas, Nevada. New York: IEEE, 2016: 770-778.