

## 基于卷积神经网络的胃癌癌前病变图像分类方法

张育,赵轶峰,苏卓彬,杨永江

河北北方学院附属第一医院胃肠肿瘤外科,河北 张家口 075000

**【摘要】**通过建立一个以系统和智能方式对胃癌癌前病变进行分类的模型,帮助医生找到敏感点和癌前息肉。在本文方法中,通过设计一种改进的ALexNet架构并使用数据增强、高斯噪声、L2权值衰减和ReLU等技术训练卷积神经网络模型,最后通过利用精度、损失值和混淆矩阵等性能指标对该模型的性能进行评估。在3 677张糜烂、息肉和溃疡等胃病图像上对所提出的模型进行测试,结果表明该模型的分类准确率达到89%。

**【关键词】**胃癌;糜烂;息肉;溃疡;癌前病变;卷积神经网络;图像分类

**【中图分类号】**R318;TP391

**【文献标志码】**A

**【文章编号】**1005-202X(2022)02-0209-06

### Image classification of gastric precancerous lesions based on convolutional neural network

ZHANG Yu, ZHAO Yifeng, SU Zhuobin, YANG Yongjiang

Department of Gastrointestinal Tumor Surgery, the First Affiliated Hospital of Hebei North University, Zhangjiakou 075000, China

**Abstract:** By building a model that can classify gastric precancerous lesions in a systematic and intelligent way, doctors can find sensitive points and precancerous polyps. An improved AlexNet architecture and techniques such as data enhancement, Gaussian noise, L2 weight decay and ReLU are used for training the convolutional neural network model; and the performance of the proposed model is evaluated by analyzing its precision, loss value and confusion matrix. The proposed model is tested on 3 677 images of gastric diseases such as erosion, polyps and ulcers, and the results show that the classification accuracy of the proposed model reaches 89%.

**Keywords:** gastric carcinoma; erosion; polyp; ulcer; precancerous lesion; convolutional neural network; image classification

### 前言

卷积神经网络(Convolutional Neural Network, CNN)是近些年来最流行与最成功的图像分类方法。胃癌被称为全球第4大癌症,并且在所有的癌症中其致死率排名第2。根据癌症进展,胃部病变一般可以分为胃癌癌前病变、早期胃癌和晚期胃癌。通常早期胃癌患者在其接受治疗的5年后生存率超过90%,而晚期胃癌患者通常生存率低于30%。早期胃癌诊断通常会通过检查患者的息肉、糜烂和溃疡等各种癌前病变进行推断,如胃肠息肉通常认为是癌症前兆,因此在早期发现和治疗这些息肉就可以大大降低患癌风险。通常医生使用相关的成像检查设备协助检查患者的胃肠道,以此进行胃肠道疾病诊断。就胃癌诊断而言,建立一个能够帮助医生找到癌前息肉等病理

区域的智能系统是非常必要的,该系统通过对息肉进行分类,并根据息肉类型进行适当标记,可以获得更准确的诊断。近年来,研究人员根据不同类型胃癌癌前病变提出了不同的诊断方法与分类方法。他们使用形状和纹理等不同特征,借助机器视觉和机器学习技术对图像进行分类和标记。很多研究都使用了对息肉的表征非常有效的双树复小波变换方法。文献[1]引入了一种基于纹理和边缘属性的方法,进而通过使用带有提升方法的支持向量机模型取得了较为准确的结果。然而,传统的机器学习方法需要手工制作特征,通常耗时较长且缺乏鲁棒性。如今,基于神经网络的方法在诊断或分类医学图像方面非常有效。在神经网络中有卷积层(convolution)、池化层(pooling)和全连接层(fully connected)的组合,它们通过这些层使用反向传播算法进行训练。文献[2]、[3]使用CNN将多种息肉特征集成到一个息肉检测系统中。文献[4]也使用CNN实现了结肠息肉分类。文献[5]将CNN作为特征提取器,SVM作为分类器,实现了内窥镜下的图像病变检测。表1讨论了基于手工特征的模型,表2讨论了使用CNN的方法。

**【收稿日期】**2021-09-16

**【基金项目】**河北省卫生厅科研基金(20200502)

**【作者简介】**张育,硕士,主要研究方向:胃、结直肠恶性肿瘤,E-mail: wine1226130@163.com

表 1 使用手工特征的常见模型  
Table 1 Common models using manual features

方法	网络模型	准确率/%
CNN	LeNet	67.00
CNN	AlexNet	71.00
CNN	预训练的 AlexNet	76.00
CNN	VGG	78.00
CNN	M-MCN 和 VGG-16	90.58

表 2 使用卷积神经网络的常见模型  
Table 2 Common models using convolutional neural networks

方法	特征	准确率/%
MLP	ART	86.10
MLP-SVM	Histogram	70.50
KNN-SVM	Histogram-texture	95.27
SVM	LBP-LLE	97.00
Weak KNN	Texture, edge, color, HMM	83.30
Boosted SVM	Texture, edge, color, HMM	90.00
SVM	LBP-LDA	91.43

1 提出的方法

本节中首先介绍所用的图像集,然后引入用于胃癌癌前病变的 CNN 模型,最后对实验设置进行介绍。

1.1 图像集

为了训练神经网络模型,使用由文献[6]收集的经相关患者书面许可的胃癌癌前病变图像。本图像集包含两个专业临床医生标记的 3 种胃息肉类型共 1 342 张图像,其中包含 378 张糜烂图像、447 张息肉图像、477 张溃疡图像。原本该图像集的图像尺寸为 460×475,经过对感兴趣区域的裁剪与旋转等图像预处理后,图像集中包含尺寸为 32×32 的 3 677 张图像,其中包括 1 214 张糜烂图像、1 219 张息肉图像和 1 244 张溃疡图像。

1.2 CNN 模型

本文提出的 CNN 模型如图 1 所示。可以看出,其基本架构来源于 AlexNet。然而,由于 AlexNet 保留了全连接层,所以需要更多的参数,这会增加模型的尺寸,且更容易过拟合。为了减少 CNN 的尺寸和提高模型分类的准确性,本文受到 SqueezeNet<sup>[6]</sup>的启发,用 fire 模块(由一个只有 1×1 滤波器组成的压缩卷积层和一个混合了 1×1 和 3×3 卷积滤波器的扩展层组成)替换了 AlexNet 的一些卷积层。目前的神经网络结构包括两种卷积层,即之前 CNN 的卷积层和两个新的 fire 模块。

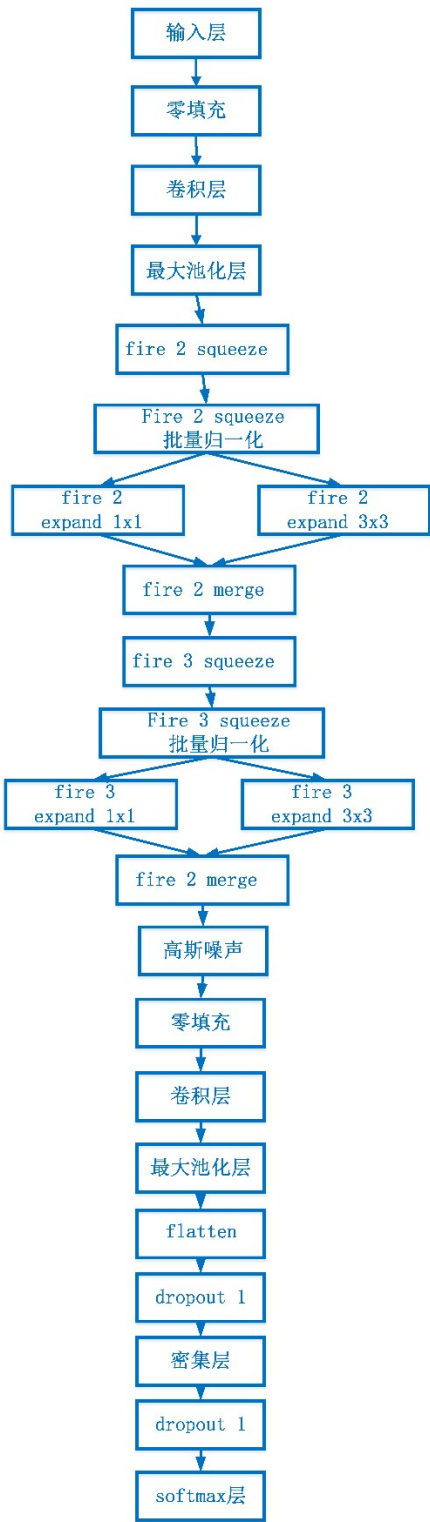


图 1 本文提出的 CNN 模型架构  
Figure 1 Architecture of the proposed CNN model

1.3 训练设置

本文的 CNN 是在 Keras<sup>[7]</sup>框架下实现的,涉及卷积网络的方法是用 Python 编写的,所有实验都是在 Windows 10 上进行的, GPU 为 NVidia GeForce GTX1060 (6 GB)。训练时包含 3 类胃息肉图像的数据集,其中 75% 进行训练,其余 25% 用于测试。损失函数如式(1)所述,以此进行网络参数的更新与迭代。

$$\text{Loss} = \sum_{X_i, I_i \in D} -\log(P(I_i|X_i; (W, b)))$$

(1)

本文采用带有动量<sup>[7]</sup>的随机梯度下降法对损失进行最小优化。在建立了CNN的基本结构后,它可以更新每个训练样本的参数。此外为了通过超参数调优来提高性能,本文使用了如下所述的一些tips:

(1)L2正则化

本文使用权重衰减法惩罚大权重。其中采用的L2正则化可以使得权重很小但不强制它们完全为零。将L2项加入损失函数后,如式(2)所示:

$$\text{Loss\_Function} = \text{Loss} + \frac{\lambda}{2m} \times \sum \|w\|^2$$

(2)

(2)学习率优化

本文的CNN首先以一个基础的学习率开始学习,在随后的每个epoch皆慢慢减少,以此提高模型的准确性,这被称之为阶跃衰减。其计算如式(3)所示:

$$\text{lr} = \text{lr0} * \text{drop}^{\text{floor}(\frac{\text{epoch}}{\text{epoch\_drop}})}$$

(3)

(3)高斯噪声

本文在CNN的密集层之前应用零均值高斯噪声,从而进行数据增强,此操作有助于缓解过拟合,而且可以提高泛化能力。

(4)ReLU

为了避免出现梯度消失,本文采用ReLU函数作为激活函数,如式(4)所示。

$$f(x) = \max(0, x) = \begin{cases} x_i & (\text{if } (x_i > 0)) \\ 0 & (\text{if } (x_i < 0)) \end{cases}$$

(4)

2 实验结果及分析

如上节所述,CNN学习过程中一些重要的超参数是学习率<sup>[8]</sup>、高斯噪声、L2正则化<sup>[9]</sup>和阶跃衰减<sup>[10]</sup>。在本节中,我们将比较和讨论这些参数对最终精度、时间复杂度和损失函数的影响。

2.1 L2正则化的选择

L2是最常见的正则化类型之一<sup>[11]</sup>。本文将式(1)与式(2)结合以得到带有L2正则化损失函数。该参数对精度的影响见表3和图2(1个epoch为整个训练集的全部数据进行一次完整训练<sup>[12]</sup>)。图2a~2d中的L2正则化系数分别为0.1、0.01、0.001、0.000 1,可以看出最佳的L2系数为0.01。

表3 不同的L2正则化系数对分类准确率、损失值和耗时的影响

Table 3 Effects of different L2 regularization coefficients on classification accuracy, loss value and time consumed

指标	L2 范数				
	0.001	0.003	0.01	0.3	0.1
准确率/%	82	83	85	30	50
损失值	0.99	0.96	0.69	1.09	1.06
耗时/h	10.44	10.7	10.34	10.26	10.25

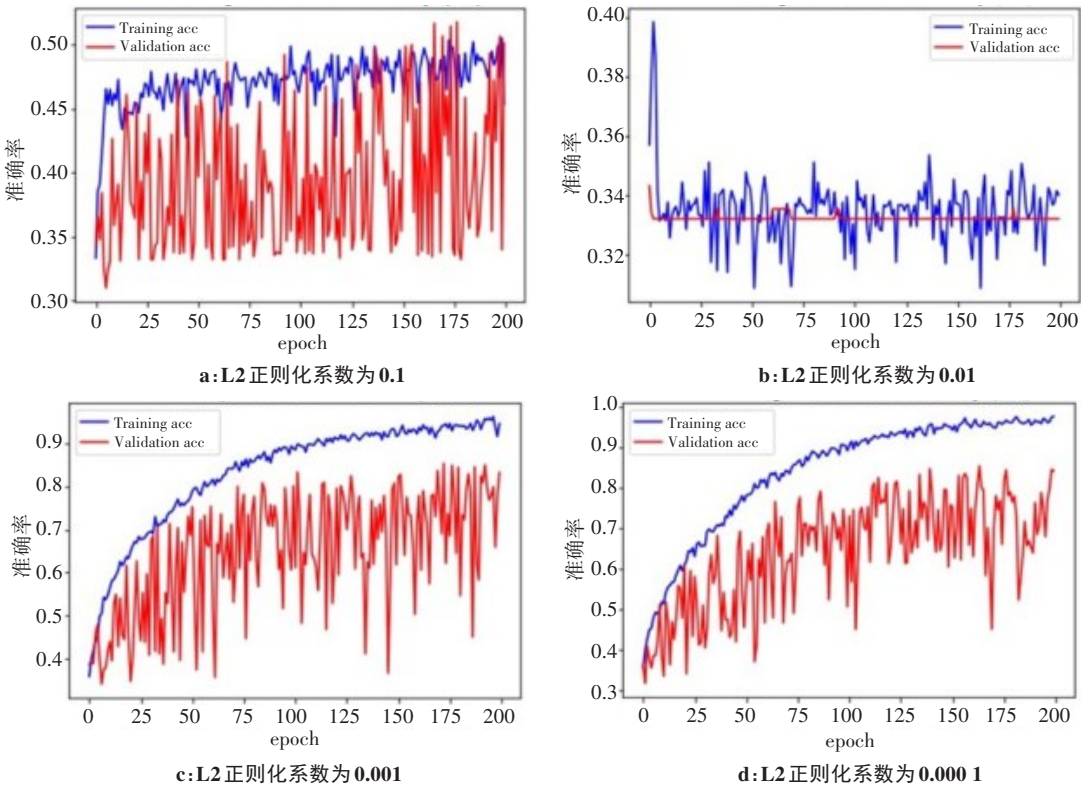


图2 不同的L2正则化系数对分类准确率的影响

Figure 2 Effects of different L2 regularization coefficients on classification accuracy

2.2 学习率的选择

图3与表4为不同学习率对最终准确率的影响。图3a~3d中的基础学习率分别为0.1、0.01、0.001、

0.000 1,可以看出LR=0.001的学习率参数在模型训练过程中效果最好。

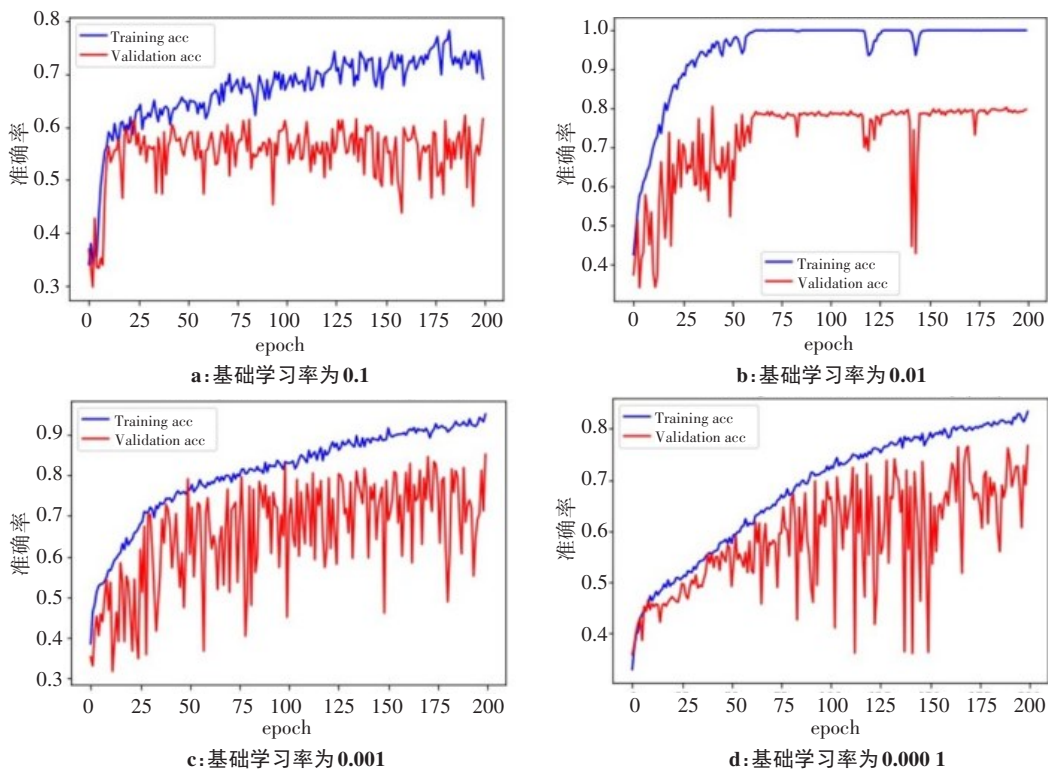


图3 不同的学习率对分类准确率的影响  
Figure 3 Effects of different learning rates on classification accuracy

表4 不同的基础学习率对分类准确率、损失值和耗时的影响  
Table 4 Effects of different basic learning rates on classification accuracy, loss value and time consumed

指标	学习率				
	1	0.0001	0.001	0.01	0.1
准确率/%	79	85	87	84	85
损失值	0.87	0.76	0.64	0.71	0.69
耗时/h	10.27	10.70	10.30	10.12	9.85

2.3 高斯噪声参数的选择

CNN中的高斯噪声定义参考文献[13]和[14]。使用不同的高斯噪声值检验该参数对模型精度和损失函数的影响<sup>[15-16]</sup>,图4给出了结果的对比,图4a~4c中的高斯噪声参数分别为0.1、0.01、0.001。由表5可见高斯噪声参数的最佳值为0.01。

2.4 阶跃衰减

学习速率可以由式(3)所示逐epoch降低。为了应用这个参数,我们定义了一个称为step\_decay的函数,并使用它来更新随机梯度下降函数中的学习率<sup>[17-18]</sup>。图5为该函数,该函数的输入包括初始学习速率、drop的数量和epoch-drop的数量。

图6为本实验的曲线图。图6a~6c中的epoch-drop参数分别为50、100、200。表6为学习率作用后的结果,可以得出本模型中权重损失对应的最佳衰减drop为0.01。

2.5 CNN的重训练

对CNN模型进行训练并定义超参数:epoch为200, L2系数为0.01, 高斯噪声标准差为0.001, dropout为0.1,学习率为0.001与step decay drop为0.1后,分类准确率达到87%。然后每隔200个epoch对模型进行再训练直到第1 000个epoch,模型的精度达到89%,如表7所示,其中超参数:epoch为100,迭代次数为4, L2系数为0.01, 高斯噪声标准差为0.001, dropout为0.1,学习率为0.001与step decay drop为0.1。训练算法如图7所示。

3 小结与展望

随着医学影像学技术的飞速发展,内窥镜图像种类繁多,根据这一问题的敏感性,对不同类型的疾病进行正确诊断和分类是非常重要的<sup>[19]</sup>。内窥镜检查通过观察患者的胃肠道情况,可用于胃癌诊断。早期发现胃癌癌前病变的类型有助于胃癌预防,因

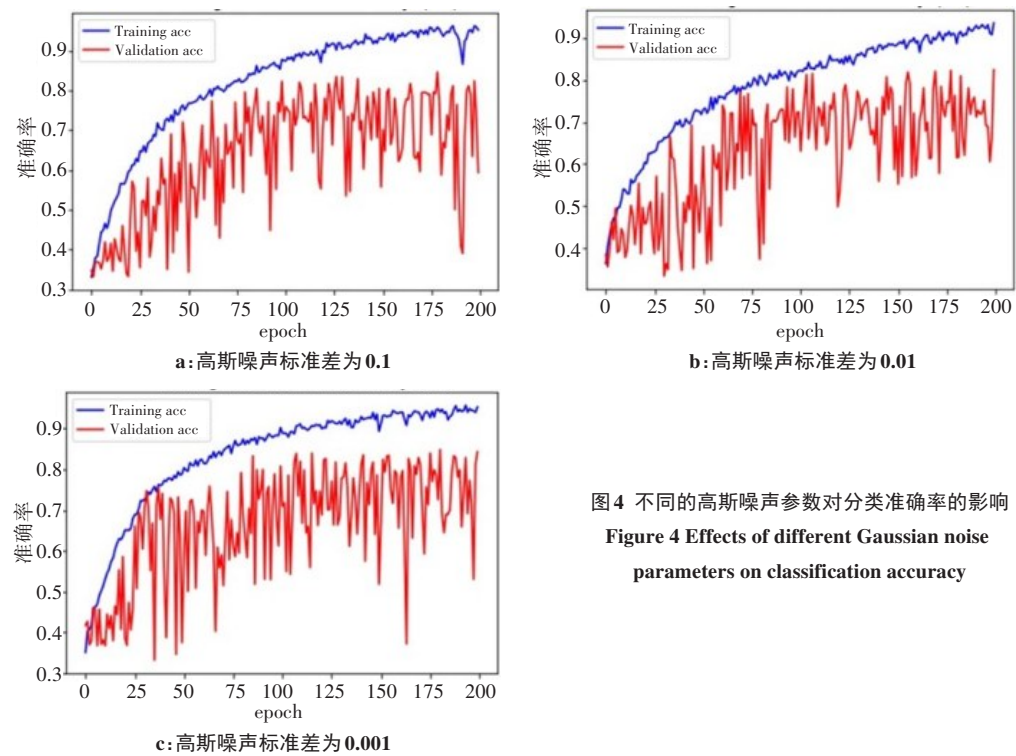


图4 不同的高斯噪声参数对分类准确率的影响

Figure 4 Effects of different Gaussian noise parameters on classification accuracy

表5 不同的高斯噪声标准差选择对分类准确率、损失值和耗时的影响

Table 5 Effects of different Gaussian noise standard deviations on classification accuracy, loss value and time consumed

指标	高斯噪声标准差		
	0.001	0.01	0.1
准确率/%	83	85	59
损失值	0.70	0.65	1.56
耗时/h	9.40	8.17	8.78

```
def step_decay(epoch):
    initial_lrate = 0.001
    drop = 0.1
    epochs_drop = 200
    lrate = initial_lrate * math.pow(drop,
        math.floor((1+epoch)/epochs_drop))
    return lrate
```

图5 定义的阶跃衰减函数

Figure 5 Defined step decay function

此,检测准确性非常重要<sup>[20]</sup>。由于内窥镜操作过程依赖于器材操作者,基于人为因素,出错的概率很

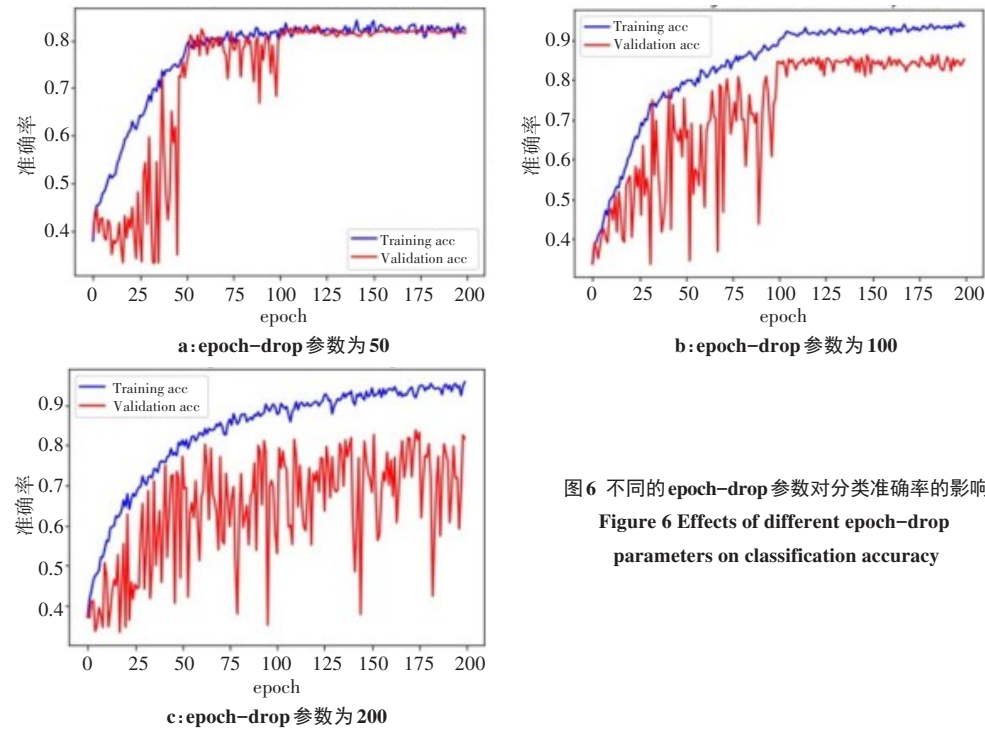


图6 不同的epoch-drop 参数对分类准确率的影响

Figure 6 Effects of different epoch-drop parameters on classification accuracy

表 6 不同的 drop 参数对分类准确率、损失值影响  
Table 6 Effects of different drop parameters on classification accuracy and loss value and time consumed

指标	step decay drop			
	0.05	0.5	0.01	0.1
准确率/%	83	80	78	87
损失值	0.72	0.78	0.91	0.64

表 7 再训练模型的迭代次数对分类准确率、损失值和耗时的影响  
Table 7 Effects of number of iterations for retraining model on classification accuracy, loss value and time consumed

指标	再训练 epoch				
	0-200	200-400	400-600	600-800	800-1 000
准确率/%	85	85	86	87	89
损失值	0.70	0.65	0.63	0.60	0.5
耗时/h	9.38	8.52	9.18	4.53	0.15

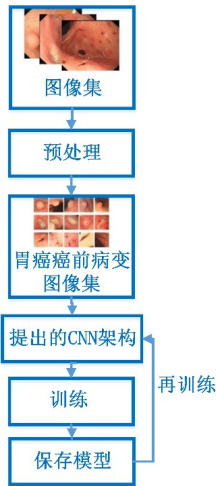


图 7 重训练算法  
Figure 7 Retraining algorithm

高,通过设计基于 CNN 的智能系统,可以更准确地对不同类型的病变和疾病进行分类<sup>[21]</sup>。本文通过设计 CNN 架构并使用数据增强、噪声和权值衰减等技术训练 CNN 模型,最后通过精度、损失值和混淆矩阵等性能指标,证明了本文提出方法的有效性。

【参考文献】

[1] GUIMARÃES P, KELLER A, FEHLMANN T, et al. Deep-learning based detection of gastric precancerous conditions[J]. Gut, 2020, 69 (1): 4-6.  
[2] SHAMIM M, SADATULLAH S, MOHAMMAD S, et al. Automated detection of oral pre-cancerous tongue lesions using deep learning for early diagnosis of oral cavity cancer[J]. Comput J, 2020, 65(1): 91-104.

[3] GUO L, XIAO X, WU C, et al. Real-time automated diagnosis of precancerous lesions and early esophageal squamous cell carcinoma using a deep learning model (with videos)[J]. Gastrointest Endosc, 2020, 91(1): 41-51.  
[4] FU Q, CHEN Y, LI Z, et al. A deep learning algorithm for detection of oral cavity squamous cell carcinoma from photographic images: a retrospective study[J]. Clin Med, 2020, 27: 100558.  
[5] ZHANG Y, LI L, GU J, et al. Cervical precancerous lesion detection based on deep learning of colposcopy images[J]. J Med Imaging Health Inform, 2020, 10(5): 1234-1241.  
[6] ZHANG X, HU W, CHEN F, et al. Gastric precancerous diseases classification using CNN with a concise model[J]. PLoS One, 2017, 12(9): e0185508.  
[7] VIBHA L, HARSHAVARDHAN G M, PRANAW K, et al. Lesion detection using segmentation and classification of mammograms[C]//Conference on Lasted International Multi-conference: Artificial Intelligence & Applications. ACTA Press, 2007: 342-347.  
[8] RAA B, AM A, AS C, et al. Glandular structure-guided classification of microscopic colorectal images using deep learning[J]. Comput Electr Eng, 2019, 85: 106450.  
[9] BHATT J, JOSHI M, SHARMA M. Early detection of lung cancer from CT images: nodule segmentation and classification using deep learning [C]//Tenth International Conference on Machine Vision. 2018: 29.  
[10] 杨荣,陈蓉,高红梅,等. 基于临床数据的胃癌筛查模型研究[J]. 中国医学物理学杂志, 2019, 36(9): 1095-1102.  
YANG R, CHEN Y, GAO H M, et al. Study on screening model of gastric cancer based on clinical data[J]. Chinese Journal of Medical Physics, 2019, 36(9): 1095-1102.  
[11] LI L, KANG D, FENG C, et al. Label-free assessment of premalignant gastric lesions using multimodal nonlinear optical microscopy[J]. IEEE J Sel Top Quantum Electron, 2018, 25(1): 1-6.  
[12] ZHANG Y, WU X, ZHANG C, et al. Dissecting expression profiles of gastric precancerous lesions and early gastric cancer to explore crucial molecules in intestinal-type gastric cancer tumorigenesis[J]. J Pathol, 2020, 251(2): 135-146.  
[13] HU H Y, ZHENG W F, ZHANG X S, et al. Content-based gastric image retrieval using convolutional neural networks[J]. Int J Imaging Syst Technol, 2021, 31(1): 439-449.  
[14] WANG N, CHANG L L. The potential function of IKKα in gastric precancerous lesion via mediating maspin[J]. Tissue Cell, 2020, 65: 101349.  
[15] HUANG R J, PARK S, SHEN J, et al. Pepsinogens and gastrin demonstrate low discrimination for gastric precancerous lesions in a multi-ethnic United States cohort [J]. Clin Gastroenterol Hepatol, 2021. DOI: 10.1016/j.cgh.2021.01.009.  
[16] WANG S, KUANG J, LI G, et al. Gastric precancerous lesions present in ApcMin/+ mice[J]. Biomed Pharmacother, 2020, 121: 109534.  
[17] CHEN X, DAI Y K, ZHANG Y Z, et al. Efficacy of traditional Chinese medicine for gastric precancerous lesion: a meta-analysis of randomized controlled trials[J]. Complement Ther Clin Pract, 2020, 38: 101075.  
[18] ZHANG L Y, ZHANG J, LI D, et al. Bile reflux is an independent risk factor for precancerous gastric lesions and gastric cancer: an observational cross-sectional study [J]. J Dig Dis, 2021, 22(5): 282-290.  
[19] CAI T, ZHANG C, ZENG X, et al. Protective effects of Weipixiao decoction against MNNG-induced gastric precancerous lesions in rats [J]. Biomed Pharmacother, 2019, 120: 109427.  
[20] LAGE J, UEDO N, DINIS-RIBEIRO M, et al. Surveillance of patients with gastric precancerous conditions [J]. Best Pract Res Clin Gastroenterol, 2016, 30(6): 913-922.  
[21] RESENDE C, GOMES C P, MACHADO J C. Review: gastric cancer: basic aspects[J]. Helicobacter, 2020, Suppl 1: e12739. DOI: 10.1111/hel.12739.

(编辑:黄开颜)