



DOI: 10.13364/j.issn.1672-6510.20230170

数字出版日期: 2024-04-24; 数字出版网址: <http://link.cnki.net/urlid/12.1355.n.20240416.1645.007>

基于 CSNet 网络的肺炎图像分类研究

刘玉良, 白玉洁

(天津科技大学电子信息与自动化学院, 天津 300222)

摘要: X 射线图像是肺炎疾病诊断的重要影像依据。由于肺部疾病的多样性, 肺炎诊断的准确率有待进一步提高。本文在 ConvNeXt 网络模型的基础上进行改进, 提出一个新的卷积神经网络模型 CSNet, 用于对 X 射线肺炎图像进行四分类。CSNet 网络模型在 ConvNeXt 网络模型的基础上改变了原有的图像预处理部分和池化层, 在卷积块中添加了一个特征通道注意力模块, 以突出特征图中的肺炎信息。在注意力模块的基础上修改激活函数并进行比较, 最终选择 SMU 激活函数。消融实验证明各模块的有效性, 并与 7 个网络进行对比实验证明该网络的有效性。实验结果表明, 与其他网络模型相比, 本文模型的准确率最高, 达到 99.0%, 同时精确率和召回率更高。

关键词: 肺炎; 卷积神经网络; 图像分类; X 射线图像

中图分类号: TP183; R318

文献标志码: A

文章编号: 1672-6510(2024)03-0049-07

Research on Pneumonia Image Classification Based on CSNet Network

LIU Yuliang, BAI Yujie

(College of Electronic Information and Automation, Tianjin University of Science & Technology, Tianjin 300222, China)

Abstract: X-ray images are an important imaging basis for the diagnosis of pneumonia disease. Due to the diversity of lung diseases, the accuracy of pneumonia diagnosis needs to be further improved. Based on the ConvNeXt network model, a new convolutional neural network model CSNet is proposed for four classification of X-ray pneumonia images. Based on the ConvNeXt network model, the CSNet network changed the original image preprocessing part and pooling layer, and added a feature channel attention module to the convolution block to highlight the pneumonia information in the feature map. On the basis of the attention module, the activation function was modified and compared, and finally the SMU activation function was selected. The effectiveness of each module was proved by ablation experiments, and the effectiveness of the network was verified by comparative experiments with 7 networks. Experimental results show that compared with other network models, the proposed model has the highest accuracy of 99.0%, and the precision and recall are higher.

Key words: pneumonia; convolutional neural network; image classification; X-ray image

引文格式:

刘玉良, 白玉洁. 基于 CSNet 网络的肺炎图像分类研究[J]. 天津科技大学学报, 2024, 39(3): 49-55.

LIU Y L, BAI Y J. Research on pneumonia image classification based on CSNet network[J]. Journal of Tianjin university of science & technology, 2024, 39(3): 49-55.

肺炎是一种在全球儿童和老年人中发病率和死亡率均较高的疾病^[1]。在中国, 肺炎是人类第五大死亡原因, 每年约有 250 万例肺炎病例发生, 其中约有 12.5 万人死于肺炎^[2], 对肺炎进行快速准确的诊断并

及时治疗十分重要^[3]。但是, 肺炎也会被误诊为其他类似的肺部疾病, 这可能导致错误的治疗进而引起患者病情的恶化^[4-7]。快速准确地诊断对肺炎的分类和治疗至关重要^[8]。医生通过检查 X 射线图像, 可以诊

收稿日期: 2023-09-12; 修回日期: 2023-12-07

基金项目: 国家自然科学基金资助项目(52378254)

作者简介: 刘玉良(1972—), 男, 河北迁安人, 副教授, ylliu@tust.edu.cn

断肺炎^[9-10]。X 射线图像的解读非常依赖医生的经验,医生可能会因为经验不足或者疲劳造成解读错误。基于深度学习的人工智能(artificial intelligence, AI)辅助诊断的出现,使准确解读肺炎图像成为可能。

基于深度学习的肺炎 AI 辅助诊断研究已经成为研究热点。费宏运等^[11]使用 AlexNet 模型对肺炎图像进行识别分类,测试的准确率达到 80.88%。谢豆等^[12]使用 VGG16 模型诊断肺炎,准确率、精确率、召回率和 F_1 值均为 94% 且正负样本的准确率相差在合理范围内。王琪垚等^[13]设计了一个肺炎图像识别系统,使用的是 GoogleNet 和 ResNet 深度学习模型,精确率分别达到 90.987% 和 73.847%。Chouhan 等^[14]使用基于迁移学习的多个模型集成检测 X 射线肺炎图像,精确率达到 96.39%。Pathak 等^[15]使用了深度迁移技术构建了肺炎图像分类模型,测试准确率为 93.018 9%。Ardakani 等^[16]利用 10 个卷积神经网络对 X 射线肺炎图像进行区分,进而判断该患者是否患肺炎,实验结果表明 ResNet101 效果最好,可以作为辅助工具辅助医生诊断肺炎。Mondal 等^[17]利用 ViT 代替卷积神经网络检测三分类肺炎,准确率为 96%。Krishnan 等^[18]使用预训练的 ViT 在 X 射线图像上检测肺炎,该方法的准确率为 97.6%。洪耿^[19]利用基于 Transformer 和 ResNet 的混合网络 RMT-Net 对 X 射线肺炎图像进行分类研究,测试准确率为 97.65%。

综上所述,分类模型对肺炎诊断准确率很关键,因此本文提出一个新的卷积神经网络模型 CSNet,旨在提高肺炎诊断的准确率。

1 基础知识

1.1 ConvNeXt 网络模型

ConvNeXt 网络模型由 Facebook 团队在 2022 年提出^[20]。该网络是纯卷积模型,其将 Transformer 体系结构合并到卷积中,使性能得以提升。ConvNeXt 网络模型的结构如图 1 所示。首先向网络中输入图像,图像经过预处理部分,该部分采用步长为 4,大小为 4×4 的卷积核,将输入图像的尺寸进行缩放。之后经过 4 个阶段,除第一个阶段外,每个阶段由 ConvNeXt 模块和下采样模块组成。ConvNeXt 模块在开始前加入下采样模块,作用是改变特征图的尺寸,使复杂特征的提取更容易。ConvNeXt 模块主要由深度可分离卷积和层标准化组成,作用是对特征图

进行一系列的升维与降维处理。最后经平均池化、层标准化与全连接(FC)操作后输出诊断结果^[21]。

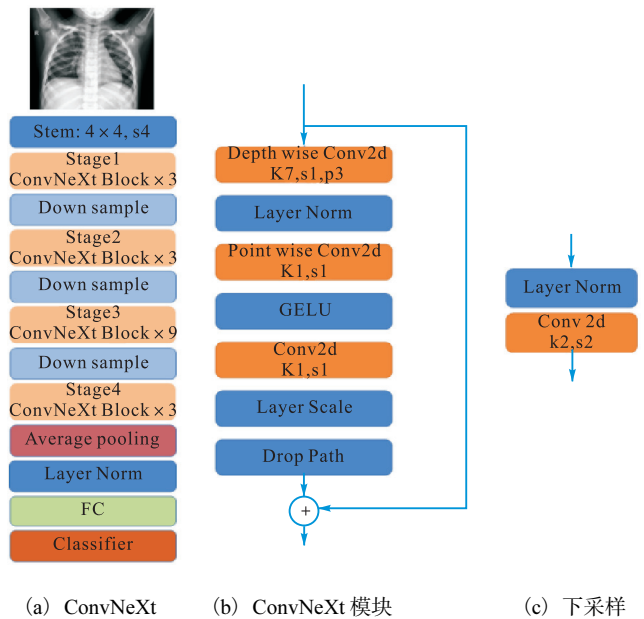


图 1 ConvNeXt 网络模型的结构
Fig. 1 Structure of ConvNeXt model

1.2 注意力模块

引入注意力模块,可以使网络在较多的输入信息中关注与任务有关的重要区域,降低对其他信息的关注,可以解决信息过载问题,提高效率和准确率。常用的注意力模块有挤压-激励注意力模块(squeeze-and-excitation networks, SE)和卷积块注意力模块(convolutional block attention module, CBAM)。

1.2.1 SE 注意力模块

SE 注意力模块主要是获得输入特征层每一个通道的权重,分为挤压和激励两个操作^[22],SE 注意力模块的结构如图 2 所示。




图 2 SE 注意力模块的结构
Fig. 2 Structure of SE attention module

图 2 中 X 为输入特征图,大小为 $[C, H, W]$ 。挤压操作是对输入特征层进行全局平均池化,将每个通道的特征压缩为一个实数,此时的特征图大小为 $[C, 1, 1]$ 。激励操作是通过两个全连接层构建通道之间的相关性,经过 Sigmoid 激活函数,使输出范围变成 $(0,$

1), 即为输入特征层每一个通道的权重, 输出的权重个数和输入的特征图通道数相同, 此时的特征图大小为 $[C, 1, 1]$ 。Scale 操作是将激励生成的权重加权到 X 的每个特征通道, 即每个通道乘以对应的权重得到新的特征图 \tilde{X} , 此时的特征图大小为 $[C, H, W]$ 。

1.2.2 CBAM 注意力模块

CBAM 注意力模块不仅关注每个通道的权重, 还关注每个像素点的权重^[23]。CBAM 注意力模块的结构如图 3 所示。

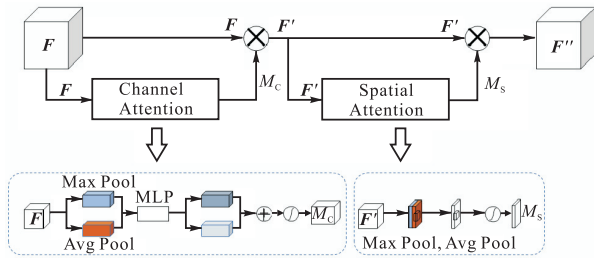


图 3 CBAM 注意力模块的结构

Fig. 3 Structure of CBAM attention module

CBAM 注意力模块^[24]首先经过通道注意力, 之后是空间注意力。先将特征图分别进行最大池化和平均池化, 之后通过共享的全连接层 (MLP) 进行处理, 然后将得到的两个特征相加, 通过 Sigmoid 激活函数得到通道权重。最后, 将权重与特征图相乘得到新的特征图 F' 。

在经过空间注意力模块时, 特征图 F' 在通道维度上进行最大池化和平均池化, 将得到的特征在通道维度上拼接在一起, 之后经过一个 7×7 卷积将通道数调整为 1, 再经过一个 Sigmoid 激活函数得到权重。最后, 将权重与特征图 F' 相乘后得到新的特征图 F'' 。

1.3 激活函数

ReLU 激活函数 [式(1)] 收敛速度快, 可以有效避免梯度消失问题, 但是在输入为负数以及学习率过高等情况下, 有可能会出现神经元坏死现象。

$$f(x) = \max(0, x) \quad (1)$$

LeakyReLU 激活函数 [式(2)] 在输入小于零时引入一个小的斜率, 而不是将负输入直接设为零, 避免了神经元坏死问题, 缺点是效果不稳定。

$$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha x, & x < 0 \end{cases} \quad (2)$$

式中: α 为小于 1 的常数。

PReLU 激活函数 [式(3)] 与 LeakyReLU 激活函数一样, α 是一个可学习的参数。与 LeakyReLU

激活函数相比, 其优点是可以自适应学习不同的负输入值处理方式。

$$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha x, & x < 0 \end{cases} \quad (3)$$

GELU 激活函数 [式(4)] 的优点是它在输入值比较大或比较小的情况下, 梯度不会变得非常小, 避免了梯度消失问题; 其缺点是计算复杂度较高。

$$f(x) = x \cdot \frac{1}{2} \left[1 + \operatorname{erf} \left(\frac{x}{\sqrt{2}} \right) \right] \quad (4)$$

式中: erf 为高斯误差函数。

SMU 激活函数 [式(5)] 具有平滑性, 可以减少梯度爆炸和梯度消失的问题, 从而提高模型的训练准确率。

$$f(x) = \frac{(1+\alpha)x + (1-\alpha)x \cdot \operatorname{erf}[\mu(1-\alpha)x]}{2} \quad (5)$$

式中: α 、 μ 为常数。

2 数据集与方法

2.1 实验数据集

选用正常图像、病毒性肺炎图像、细菌性肺炎图像和新冠感染图像 [图(4)] 进行后续研究。




图 4 X 射线图像

Fig. 4 X-ray image

数据集来自 Kaggle 公开数据集, 4 种 X 射线图像共 14 733 张, 具体数量见表 1。

表 1 数据集
Tab. 1 Datasets

类别	数量/张
正常图像	3 687
病毒性肺炎图像	3 656
细菌性肺炎图像	3 737
新冠感染图像	3 653

2.2 数据处理

为满足模型对大量图像数据的需求,减少模型进行训练以及测试所需时间,对图像数据进行处理,把图像数据值转成 RGB 值储存,并对数据进行归一化处理,处理后的数据大小为 224×224 。

2.3 CSNet 网络的构建

本文提出的 CSNet 网络的结构图如图 5 所示。

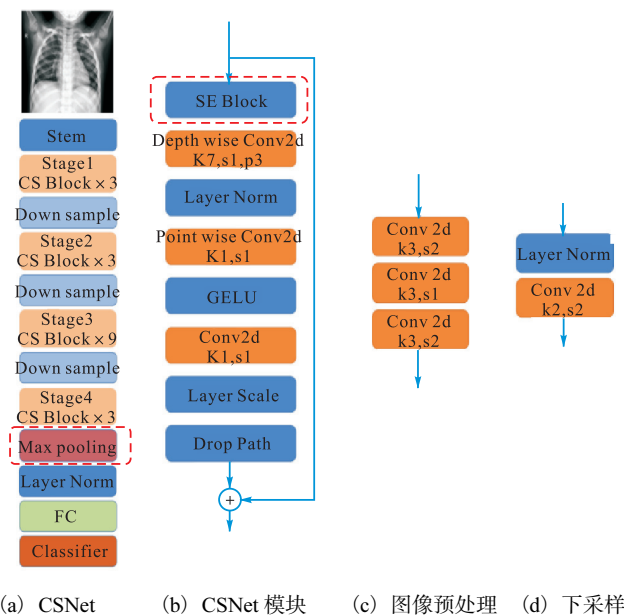


图 5 CSNet 网络的结构图
Fig. 5 Structure diagram of CSNet

本文使用该网络作为骨干网络,首先输入图像,用 3 个 3×3 的卷积核代替原有图像预处理部分〔图 5(c)〕,每个小卷积核都能学习到一些不同的特征。这样可以在不改变网络感受野的前提下,减少参数量,还可以引入更多的非线性函数,提高神经网络对模型的表达能力。接着是 4 个阶段,除第一个阶段外,每个阶段由 CSNet 模块〔图 5(b)〕和下采样〔图(d)〕组成。将 SE 注意力模块〔图 5(b)中的红色虚线框部分〕添加到卷积块中,从而增加网络对肺炎图像信息的关注,使模型性能增加。通过对 ReLU、PReLU、GELU、LeakyReLU 和 SMU 激活函数效果进行比较,最终在 SE 注意力模块中选取了 SMU 激活函数用以避免神经元死亡。为了更加关注肺炎图

像区域以获得更好的分类结果,把最后一个平均池化层改为最大池化层〔图 5(a)中的红色虚线框部分〕,平均池化容易使图像模糊,但最大池化能很好地保留纹理特征,避免较多的冗余信息介入,使神经网络更专注于重要信息,还可以减少参数量。上述改进可以使 CSNet 网络在进行肺炎图像分类时的准确率得到提升。

3 结果与分析

3.1 环境与训练参数

使用 PyTorch 深度学习框架搭建肺炎图像分类模型,使用 NVIDIA GTX 3090 GPU 进行训练,实验中所有模型输入尺寸均为 $224 \times 224 \times 3$,选用 Adam 优化器,学习率设置为 0.000 1,批大小设置为 32,迭代次数为 35 次。

3.2 评价指标

在分类任务中,主要有以下评价指标^[25]:准确率、精确率和召回率。

准确率(A)表示的是识别正确的个数在总样本中所占的比例。

$$A = \frac{N_{TN} + N_{TP}}{N_{TN} + N_{TP} + N_{FN} + N_{FP}} \quad (5)$$

式中: N_{TN} 为预测结果为负样本,实际为负样本的样本数目; N_{TP} 为预测结果为正样本,实际也为正样本的样本数目; N_{FP} 为预测结果为正样本,实际为负样本的样本数目; N_{FN} 为预测结果为负样本,实际为正样本的样本数目。

精确率(P)表示的是实际正样本在识别为正样本中所占的比例。

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (6)$$

召回率(R)表示的是识别正确的正样本在总正样本中所占的比例。

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (7)$$

3.3 实验结果

3.3.1 消融实验

本节研究网络中不同模块对肺炎图像分类的影响,以证明模块的有效性。用模块一代表 3×3 卷积核,用模块二代表 SE 注意力模块,用模块三代表 SMU 激活函数,用模块四代表最大池化层。消融实验结果见表 2。与 ConvNeXt 网络模型相比,每个模块的改进都使模型效果有一定的提升。各个模块组

合之后,模型的准确率从 97.0% 提升到 99.0%, 提高了 2.0%。

表 2 消融实验结果

Tab. 2 Results of ablation experiment

网络模型	准确率/%
ConvNeXt	97.0
ConvNeXt + 模块一	98.2
ConvNeXt + 模块二	98.7
ConvNeXt + 模块三	98.8
ConvNeXt + 模块四	97.3
CSNet	99.0

模块一可以减少参数量,使网络所需的存储空间更小,计算更有效率,每次只需要移动 9 个参数,更小的卷积核可以使计算速度更快。在此基础上还可以引入更多的非线性因素,提高神经网络对模型的表达能力。模块二将模型的注意力集中在关键信息上,使用全局信息来强调关键特征、抑制无用特征,显著提高模型的性能。模块三通过其特有的平滑性减少了 ReLU 激活函数在训练过程中的神经元死亡问题,提高网络的性能。模块四通过选择每个池化窗口的最大值,保留最重要的特征,有效降低平均池化的均值偏移问题,保留纹理特征。

不同注意力模块的对比结果见表 3,不同激活函数的对比结果见表 4。激活函数的修改是在原始网络加入 SE 注意力模块上进行对比。通过对表 3、表 4 的实验结果进行对比,最终选取了 SE 注意力模块和 SMU 激活函数。

表 3 不同注意力模块的对比结果

Tab. 3 Comparison results of different attention modules

注意力模块	准确率/%
SE	98.7
CBAM	98.6

表 4 不同激活函数的对比结果

Tab. 4 Comparison results of different activation functions

激活函数	准确率/%
ReLU	98.7
LeakyReLU	98.7
PReLU	98.8
GELU	98.7
SMU	98.8

CSNet 网络的损失曲线如图 6 所示。从图 6 可以看出:在训练初期,随着迭代次数的增加,损失曲线不断衰减;迭代达到 30 次后,CSNet 网络损失值收敛,基本保持在 0.028。损失曲线的趋势和幅度都较好,验证了 CSNet 网络的稳定性。





图 6 CSNet 网络的损失曲线


Fig. 6 Loss curve of CSNet network

3.3.2 对比实验

ConvNeXt 与 CSNet 的混淆矩阵如图 7 所示。



(a) ConvNeXt



(b) CSNet

图 7 ConvNeXt 与 CSNet 的混淆矩阵

Fig. 7 Confusion matrix of ConvNeXt and CSNet

由混淆矩阵可以看出,ConvNeXt 网络模型将 42 张图像错分,而 CSNet 网络错分图像数量为 14 张。CSNet 网络错分数量少可能是因为添加了注意力模块,网络能更加关注肺炎图像的重要区域。新冠感染图像被错分的原因可能是 X 射线图像中没出现典型的小斑片或磨玻璃影。细菌性肺炎图像和病毒性肺炎

图像被错分为正常图像的原因可能是病灶区域太小,不易被发现。正常图像被错分的原因可能是 X 射线图像质量不好,存在模糊位置被认为是病灶区域。总体来看,CSNet 网络对各个类别的肺炎图像判断比较准确。

为了进一步验证方法的有效性,比较了 CSNet 网络与 AlexNet、VGG16、ResNet34、ConvNeXt、MobileViT、Swim transformer 和 CMT 这 7 个网络对肺炎图像的认识,不同网络的性能对比结果见表 5。

表 5 不同网络的性能对比结果

Tab. 5 Performance comparison results of different networks

网络名称	图像类别	准确率/%	精确率/%	召回率/%
AlexNet	新冠感染	92.3	85.4	89.3
	细菌性肺炎		75.9	96.0
	正常		92.2	68.8
	病毒性肺炎		95.3	93.7
VGG16	新冠感染	91.5	87.5	86.3
	细菌性肺炎		85.2	87.7
	正常		83.9	85.1
	病毒性肺炎		97.4	94.5
ResNet34	新冠感染	94.4	99.7	97.5
	细菌性肺炎		98.1	98.9
	正常		97.3	97.8
	病毒性肺炎		99.2	100.0
ConvNeXt	新冠感染	97.0	100.0	96.4
	细菌性肺炎		96.5	97.3
	正常		93.8	97.8
	病毒性肺炎		99.2	97.5
MobileViT	新冠感染	93.4	92.5	90.8
	细菌性肺炎		95.0	95.3
	正常		87.5	92.3
	病毒性肺炎		99.3	95.3
Swim transformer	新冠感染	97.0	96.2	96.1
	细菌性肺炎		98.9	98.5
	正常		93.9	95.8
	病毒性肺炎		99.3	97.8
CMT	新冠感染	93.3	92.9	90.8
	细菌性肺炎		95.5	93.0
	正常		89.1	90.9
	病毒性肺炎		95.9	98.6
CSNet	新冠感染	99.0	99.7	98.4
	细菌性肺炎		99.5	98.9
	正常		97.8	98.9
	病毒性肺炎		99.2	100.0

由表 5 可知:在精确率方面,Swim transformer 对病毒性肺炎图像的识别精确率略高,ConvNeXt 对新冠感染图像的识别精确率略高,但是总体来看,CSNet 网络在各个图像类别都有更高的精确率和召回率。

4 结 语

为了提高肺炎图像诊断的准确率,本文提出 CSNet 网络对肺炎的 X 射线图像进行分类。应用多个 3×3 的卷积核、SE 注意力模块、SMU 激活函数、最大池化提高分类的准确率。

实验结果表明,本文提出的 CSNet 网络结构对 X 射线肺炎图像分类识别效果更好,准确率达到 99.0%,在诊断肺炎方面具有优越性,应该可以辅助医生进行肺炎诊断,减轻医生面对大量肺炎图像解读时的压力。

参考文献:

- [1] 熊丰,何迪,刘玉杰,等. 基于改进 VGG19 卷积神经网络的肺炎图像分类[J]. 光子学报, 2021, 50(10): 1010001.
- [2] 邓棋,雷印杰,田锋. 用于肺炎图像分类的优化卷积神经网络方法[J]. 计算机应用, 2020, 40(1): 71-76.
- [3] KALLANDER K, BURGESS D H, QAZI S A. Early identification and treatment of pneumonia: a call to action[J]. The lancet global health, 2016, 4(1): e12-e13.
- [4] GRAVES R S. Users' guides to the medical literature: a manual for evidence-based clinical practice[J]. Journal of the medical library association, 2002, 90(4): 483.
- [5] LIU N, WAN L H, ZHANG Y, et al. Exploiting convolutional neural networks with deeply local description for remote sensing image classification[J]. IEEE Access, 2018, 6: 11215-11228.
- [6] ZU Z Y, JIANG M D, XU P P, et al. Coronavirus disease 2019 (COVID-19): a perspective from China[J]. Radiology, 2020, 296(2): E15-E25.
- [7] YARI Y, NGUYEN T V, NGUYEN H. Accuracy improvement in detection of COVID-19 in chest radiography[C]//IEEE. Proceedings of 14th International Conference on Signal Processing and Communication Systems (ICSPCS). Adelaide: IEEE, 2020: 1-6.
- [8] ORTIZ-TORO C, GARCIA-PEDRERO A, LILLO-SAAVEDRA M, et al. Automatic detection of pneumonia in chest X-ray images using textural features[J]. Computers in biology and medicine, 2022, 145: 105466.
- [9] WEST C P, MONTORI V M, SAMPATHKUMAR P. COVID-19 testing: the threat of false-negative results[J]. Mayo clinic proceedings, 2020, 95(6): 1127-1129.

- [10] ALHARBI A H, HOSNI M H A. Pneumonia transfer learning deep learning model from segmented X-rays[J]. *Healthcare*, 2022, 10(6): 987.
- [11] 费宏运, 陈庚, 迟兆瑞, 等. 基于 AlexNet 的新冠肺炎 CT 图像识别的可行性分析[J]. *信息与电脑(理论版)*, 2021, 33(4): 137-140.
- [12] 谢豆, 郑菲, 陈涛, 等. 基于 CNN 的 COVID-19 医学影像远程诊断算法与实现[J]. *电脑知识与技术*, 2021, 17(23): 137-139.
- [13] 王琪垚, 王健庆. 基于深度学习的新冠肺炎 CT 图像识别研究[J]. *信息与电脑(理论版)*, 2020, 32(17): 62-64.
- [14] CHOUHAN V, SINGH S K, KHAMPARIA A, et al. A novel transfer learning based approach for pneumonia detection in chest X-ray images[J]. *Applied sciences*, 2020, 10(2): 559.
- [15] PATHAK Y, SHUKLA P K, TIWARI A, et al. Deep transfer learning based classification model for COVID-19 disease[J]. *IRBM*, 2022, 43(2): 87-92.
- [16] ARDAKANI A A, KANAFI A R, ACHARYA U R, et al. Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: results of 10 convolutional neural networks[J]. *Computers in biology and medicine*, 2020, 121: 103795.
- [17] MONDAL A K, BHATTACHARJEE A, SINGLA P, et al. xViTCOS: explainable vision transformer based COVID-19 screening using radiography[J]. *IEEE Journal of translational engineering in health and medicine*, 2021, 10: 1-10.
- [18] KRISHNAN K S, KRISHNAN K S. Vision transformer based COVID-19 detection using chest X-rays[EB/OL]. (2021-10-09) [2023-09-01]. <https://arxiv.dosf.top/abs/2110.04458>.
- [19] 洪耿. 基于深度学习的新冠肺炎 X/CT 图像识别方法研究[D]. 天津: 天津科技大学, 2022.
- [20] LIU Z, MAO H Z, WU C Y, et al. A ConvNet for the 2020s[EB/OL]. (2022-03-02) [2023-09-01]. <https://arxiv.org/pdf/2201.03545.pdf>.
- [21] 李建威, 吕晓琪, 谷宇. 基于改进 ConvNeXt 的皮肤镜图像分类方法[J]. *计算机工程*, 2023, 49(10): 239-246.
- [22] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. *IEEE Transactions on pattern analysis and machine intelligence*, 2019, 42(8): 2011-2023.
- [23] 崔雪松. 基于注意力机制 + DenesNet 的肺部 X 光图像分类算法[D]. 哈尔滨: 哈尔滨理工大学, 2021.
- [24] WOO S, PARK J, LEE JY, et al. CBAM: convolutional block attention module[EB/OL]. (2018-07-18) [2023-09-01]. <https://arxiv.org/pdf/1807.06521v2.pdf>.
- [25] 薄靖宇. 基于深度学习的肺炎医学影像自动识别与检测技术研究[D]. 北京: 北京交通大学, 2021.

责任编辑: 周建军

(上接第 48 页)

- 2020, 48(2): 12-14.
- [10] 沈靖轩, 肖维毅, 黄海群, 等. 不同压纹对卷烟用滤嘴棒原纸及滤嘴棒性能的影响[J]. *中国造纸*, 2014, 33(1): 34-36.
- [11] 曾万怡. 纸质滤棒对部分卷烟主流烟气释放物的影响研究[D]. 昆明: 昆明理工大学, 2014.
- [12] 殷沛沛, 王理珉, 董高峰, 等. 功能性烟支用纸的开发及应用[J]. *中国造纸*, 2014, 33(9): 56-61.

责任编辑: 周建军