

## 基于深度学习的儿童肺炎检测模型建立及应用

董芳芬<sup>1,2</sup>, 陈群<sup>3</sup>, 李诺兮<sup>2</sup>, 徐本华<sup>1,2</sup>, 李小波<sup>1,2,4</sup>

1. 福建医科大学附属协和医院放疗科/福建省肿瘤智能影像与精准放疗重点实验室/福建省消化、血液系统与乳腺恶性肿瘤放射治疗临床医学研究中心, 福建 福州 350001; 2. 福建医科大学医学影像学院, 福建 福州 350004; 3. 西北工业大学计算机学院, 陕西 西安 710072; 4. 清华大学工程物理系, 北京 100084

**【摘要】目的:**基于深度学习根据儿童胸部X光正位数字影像构建肺炎自动判别模型,辅助临床诊断,提高影像诊断效率。**方法:**首先通过选取公开数据集5856张儿童胸片(肺炎4273张,正常1583张),分为训练集、验证集和测试集,基于Resnet-50神经网络构建儿童肺炎自动判别模型,利用验证集选取最优模型,在测试集上做内部独立验证。进一步收集6家医疗单位共611张儿童胸片(肺炎300张,正常311张)进行外部验证,并根据验证结果对模型进行微调后再次测试,使模型更贴合临床使用。**结果:**基于深度学习技术和公开数据集数据构建儿童肺炎自动判别模型,准确率为98.48%,精确率为99.54%,召回率为98.81%,F1-score为98.86%,AUC为0.999。外部验证初始结果准确率为59.90%,选用部分外部验证数据微调模型后,独立测试准确度提升至85.00%。**结论:**基于深度学习根据公开数据集构建肺炎自动判别模型具有可行性,准确率达98.48%,在实际临床使用时应根据具体使用条件选取适量数据集对模型进行微调。

**【关键词】**儿童;肺炎;深度学习;神经网络

**【中图分类号】**R318;R445.4

**【文献标志码】**A

**【文章编号】**1005-202X(2022)12-1579-06

## Establishment and application of a deep learning-based model for pneumonia detection in children

DONG Fangfen<sup>1,2</sup>, CHEN Qun<sup>3</sup>, LI Nuoxi<sup>2</sup>, XU Benhua<sup>1,2</sup>, LI Xiaobo<sup>1,2,4</sup>

1. Department of Radiation Oncology, Fujian Medical University Union Hospital/Fujian Key Laboratory of Intelligent Imaging and Precision Radiotherapy for Tumors/Clinical Research Center for Radiology and Radiotherapy for Digestive, Hematological and Breast Malignancies of Fujian Province, Fuzhou 350001, China; 2. School of Medical Imaging, Fujian Medical University, Fuzhou 350004, China; 3. School of Computer Science, Northwestern Polytechnical University, Xi'an 710072, China; 4. Department of Engineering Physics, Tsinghua University, Beijing 100084, China

**Abstract: Objective** To construct a deep learning-based model for automatically detecting pneumonia according to the digital ortho-images of children's chest X-ray for assisting clinical diagnosis and improving the efficiency of image diagnosis. **Methods** A total of 5 856 pediatric chest radiographs, including 4 273 chest radiographs of pneumonia and 1 583 normal chest radiographs, were selected from the public data set and divided into training set, verification set and test set. A model for the automated pediatric pneumonia detection was constructed based on Resnet-50. The validation set was used for selecting the optimal model, and the test set for carrying out internal independent validation. In addition, 611 pediatric chest radiographs, including 300 chest radiographs of pneumonia and 311 normal chest radiographs, were further collected from 6 medical units for external validation, and the model was fine-tuned according to validation results and then tested again to make it more suitable for clinical application. **Results** An automated detection model for pediatric pneumonia was successfully constructed using deep learning technology and public data set. The accuracy, precision, recall, F1-score and AUC of the model were 98.48%, 99.54%, 98.81%, 98.86% and 0.999, respectively. After fine-tuning the model with some external validation data, the accuracy of the independent test was improved from 59.90% (preliminary external validation) to 85.00% (independent test). **Conclusion** It is feasible to construct an automated pneumonia detection model using deep learning and public data set,

**【收稿日期】**2022-06-08

**【基金项目】**福建省科技厅(高校产学研)项目(2020Y4010)

**【作者简介】**董芳芬,硕士研究生,技师,主要研究方向:医学物理与智能影像,E-mail: 944866709@qq.com

**【通信作者】**李小波,副主任医师,主要研究方向:医学物理与智能影像,E-mail: lixiaobo2004@126.com;徐本华,主任医师,主要研究方向:肿瘤智能影像与精准放疗,E-mail: benhuaxu@163.com

and the accuracy of the model can reach 98.48%. In practice, the model should be fine-tuned by selecting the appropriate data set according to the specific conditions.

**Keywords:** children; pneumonia; deep learning; neural network

## 前言

肺炎是儿童常见死亡原因之一,且儿童肺炎的症状和体征在早期不明显,易与其他疾病混淆<sup>[1]</sup>。在儿童肺炎的诊断领域,胸部X射线因其无痛、无创、辐射剂量低的优势,被作为儿童肺炎辅助诊断的重要手段,并且大部分临床治疗方式选择依赖影像检查结果<sup>[2]</sup>。然而,由于医疗资源分配不平衡,各医疗单位儿科和放射科医生的医学影像诊断经验及知识储备不同。且因儿童自主控制能力有限,在投照时难以自觉配合医生的指示,与成人相比,儿童胸片的成像质量相对较差。这些影响因素对目前人工诊断儿童肺炎结果的可靠性和稳定性造成干扰。随着计算机技术的发展,人工智能的深入,深度学习等技术在医疗领域的应用越来越多<sup>[3-6]</sup>。本研究利用公开数据库下载的儿童胸片数据,基于Resnet-50神经网络构建儿童肺炎自动判别模型,并收集6家医院儿童胸片数据做独立外部验证,优化模型,辅助影像医生快速、大批量的阅片,在节约人力的同时及早正确诊断有利于儿童肺炎早期诊断,减少漏诊、误诊,降低儿童肺炎病死率。

## 1 资料与方法

### 1.1 数据集

数据集包括两部分:(1)Kaggle网站<sup>[7]</sup>下载的来自广州市妇女儿童医学中心所提供的肺炎和正常两个类别的胸部X光影像数据(命名为chest\_Xray),共5856张,其中肺炎4273张,正常1583张。在本研究中,随机将数据分为训练集(命名为chest\_Xray\_train)、验证集(命名为chest\_Xray\_val)和测试集(命名为chest\_Xray\_test),其中5232张图像作为模型的训练集,包括3883张肺炎及1349张正常;295张作为验证集,包括170张肺炎和125张正常,验证集用于选取最佳的训练模型;最后剩余的329张作为独立内部测试集,包括220张肺炎和109张正常,用于测试模型的性能;3个数据集相互独立。(2)从福建医科大学附属协和医院(标记为A)、泰兴市人民医院(标记为B)、东山县医院(标记为C)、厦门大学附属中山医院(标记为D)、杭州市妇产医院(标记为E)、南平市第一医院(标记为F)共6所医院收集611张胸片(命名为hosp\_all)作为独立外部验证集,其中正常311张,A~F分别45、50、50、56、60、50张;肺炎

300张,A~F分别48、50、50、48、54、50张。所有胸片来源无重复个体。

### 1.2 评价指标

儿童肺炎检测模型建立的评估基于模型训练-验证-内部及外部测试等方案。首先在训练数据集上训练基本模型,用验证集选择最佳模型,确定超参数,利用内部测试集来评估建立模型的整体性能,进一步使用外部数据进行测试。基于外部测试集的测试结果,评估并采取方案对模型进行微调,使模型更适合实际使用的数据集。本研究基于实际诊断结果和模型预测结果,定义模型预测为肺炎且实际诊断也为肺炎表示为True Positive(TP),模型预测为肺炎而实际诊断为正常表示为False Positives(FP),模型预测为正常而实际诊断为肺炎表示为False Negatives(FN),模型预测为正常且实际诊断也为正常表示为True Negative(TN)。

根据参数TP、FP、FN、TN计算模型评价指标:准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1-score和受试者工作曲线(ROC)下面积AUC。Accuracy为预测正确样本占全部样本的比例,通常准确率越高,模型性能越好;Precision为预测为肺炎的样本中实际诊断为肺炎的比例;Recall为实际为肺炎的样本中,被模型预测正确的肺炎比例;F1-score为在不同模型或不同的两组精度和召回率之间做选择时,综合考虑的值;AUC为ROC曲线覆盖的面积。计算公式如下:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (1)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

### 1.3 模型构建及内部验证方法及流程

**1.3.1 图像标签** 利用Python代码遍历文件将chest\_Xray中诊断为正常的胸片图像命名为CX-0-0001到CX-0-1583,诊断为肺炎的胸片图像命名为CX-1-0001到CX-0-4273,并生成包括每张图像文件名和实际诊断结果(正常标记为0,肺炎标记为1)的标签csv文件。

**1.3.2 图像预处理与数据增强** 针对数据集中图像尺寸不统一,对图像大小进行随机裁剪,采用默认参数

(0.08, 1), 并缩放到统一的 224×224 大小(RandomResizedCrop), 同时在训练过程中对图片进行随机水平翻转。增强训练数据的多样性。

1.3.3 模型训练 基于 Ubuntu 16 系统, Pytorch 深度

学习框架, Resnet-50 神经网络模型<sup>[8]</sup>(图 1), batch size=64, learning rate=0.005, epoch=64。利用 chest\_Xray\_train 数据训练模型, 用 chest\_Xray\_val 数据选出最佳模型。




图1 Resnet-50网络结构图(共包含 49 个卷积层, 1 个全连接层)  
Figure 1 Structure of Resnet-50 containing 49 convolutional layers and 1 fully connected layer

1.3.4 内部验证 通过验证集选出的最佳模型, 应用于独立测试集 chest\_Xray\_test, 作为判断神经网络模型的性能标准。

1.4 外部验证及模型微调

基于上述模型对收集的 6 家医疗单位共 611 张胸片进行独立外部验证。根据验证结果, 将 611 张胸片

(hosp\_all)分为两部分, 一部分命名为 hosp\_val(30 张肺炎和 30 张正常胸片), 另一部分命名为 hosp\_test(270 张肺炎和 281 张正常胸片), 分别用 hosp\_val 和 hosp\_test 作为验证集对模型进行微调, 并用另一部分作为测试集测试模型。训练及测试所用数据及流程如图 2 所示。

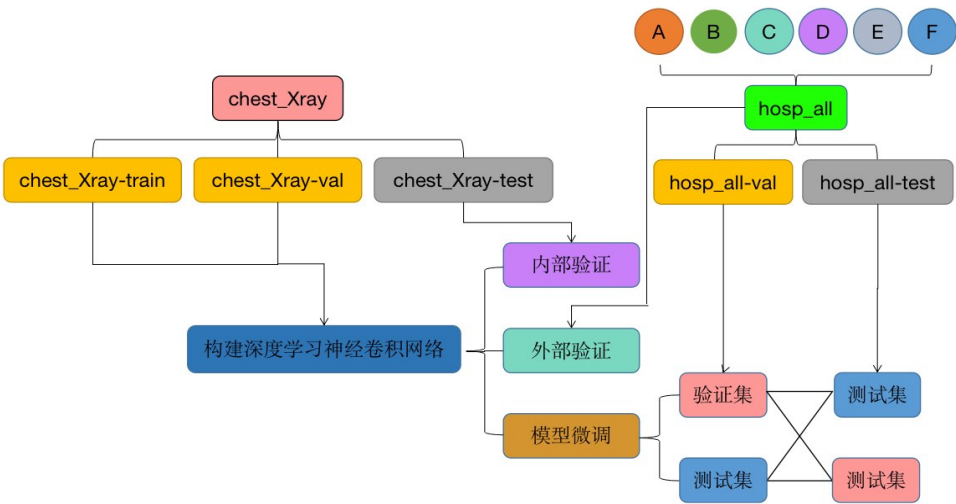


图2 训练及测试所用数据及流程图  
Figure 2 Data used for training and testing and the flowchart

2 结果

2.1 模型准确度

利用 chest\_Xray\_train 训练模型, 用 chest\_Xray\_val 选取最佳模型(图 3), 利用 chest\_Xray-test 做内部独立测试。测试结果准确率为 98.48%, 精确率为 99.54%, 召回率为 98.81%, F1-score 为 98.86%, AUC 为 0.999。

2.2 外部测试及模型微调结果

利用 hosp\_all 作为外部独立测试, 准确率为 59.90%,

精确率为 84.81%, 召回率为 22.33%, F1-score 为 35.36%, AUC 为 0.649。基于 hosp\_all 的测试结果, 进一步将 hosp\_all 分为 hosp\_val 和 hosp\_test, 分别作为验证集对原有模型基于迁移学习的方法微调, 将 batchsize 和 learning\_rate, 分别调到 32 和 0.000 5 后, 在 hosp\_test 和 hosp\_val 测试准确率分别为 76.04% 和 85.00%, 精确率分别为 83.17% 和 92.00%, 召回率分别为 64.07% 和 76.67%, F1-score 分别为 72.38% 和 83.64%, AUC 分别为 0.826 和 0.878。具体结果如表 1 所示。






图3 模型训练准确度  
Figure 3 Accuracy of model training

### 3 讨论

深度学习是目前先进的机器学习方法,在许多模式识别的应用中,深度学习给医疗领域带来革命性的变化<sup>[9-10]</sup>。在一些病灶的检测和分类研究中,深度学习优于传统放射科医生,尤其在检测效率上<sup>[11-12]</sup>。新兴的神经卷积网络在肺炎诊断、乳腺癌诊断、肺结节检测和前列腺癌定位等得到广泛应用,为放射科医生和临床医生提供有效的诊疗参考<sup>[13-17]</sup>。肺炎的诊断一直是放射科医生和临床医生关注的问题,尤其是儿童肺炎。近年来,随着深度学习的应

表 1 模型训练结果  
Table 1 Results of model training

| 数据集             | Accuracy/% | F1-score/% | Precision/% | Recall/% | AUC   |
|-----------------|------------|------------|-------------|----------|-------|
| chest_Xray_test | 98.48      | 98.86      | 99.54       | 98.81    | 0.999 |
| hosp_all        | 59.90      | 35.36      | 84.81       | 22.33    | 0.649 |
| hosp_test       | 76.04      | 72.38      | 83.17       | 64.07    | 0.826 |
| hosp_val        | 85.00      | 83.64      | 92.00       | 76.67    | 0.878 |

chest\_Xray\_test:用 chest\_Xray\_train 训练,用 chest\_Xray\_val 选择最佳模型,在 chest\_Xray\_test 上做独立内部测试的结果;hosp\_all:基于 chest\_Xray 构建的模型,在 hosp\_all 上做独立外部测试的结果;hosp\_test:基于 chest\_Xray 构建的模型,hosp\_val(30+30)验证微调,在 hosp\_test 上测试的结果;hosp\_val:基于 chest\_Xray 构建的模型,用 hosp\_test 验证微调,在 hosp\_val(30+30)上测试的结果

用,对肺炎深度学习的研究也逐渐增多,研究者们利用不同的数据集、运行环境、算法、评价指标进行实验。其中 Chest X-ray Images 数据集进行的研究较多,李新等<sup>[18-19]</sup>对深度学习在肺炎检测中的研究综述中对比几种算法模型,包括迁移学习、改进 AlexNet+SVM、Teacher and student Module、ResNet+空洞卷积和 Inception,其中准确性最高的是利用 Inception V3+RF 模型,准确率达 96.77%。周进凡等<sup>[20]</sup>提出利用卷积神经网络对胸部 X 光影像数据进行分析,利用改进的 VGG 卷积神经网络可以得到 98.50% 的准确性,但其图像预处理的方法和卷积神经网络的构建均较繁杂,且存在梯度消失和梯度爆炸问题。

本研究也是基于 Chest X-ray Image 数据集,利用 Pytorch 深度学习框架,搭建 Resnet-50 神经网络模型,模型的准确率达 98.48%,AUC 达 0.999,相比一般深度学习模型如 CheXNet、Densenet121 准确率高,且研究采用的 Pytorch 深度学习框架具有简洁、快速和易用的特点。数据训练前采用数据增强方式,提高数据特征的多样性,尽量增加训练的难度,导致训练集准确率有所下降,但提高了模型的泛化能力,提升

了测试集的准确率。模型构建是采用 Resnet-50 神经网络模型,能很好地解决上述提到 VGG 卷积神经网络在模型层数加深后带来精度下降的问题。Resnet 中提出跳跃链接方式,可从某一层网络层获取激活,然后迅速反馈给另一层,甚至是神经网络的更深层,因此可以训练更深度的学习网络。

在深度学习的发展和应用过程中存在一个关键问题,即在推广应用过程中其适用性受到训练数据的限制。针对这类问题,本研究收集 6 家医疗中心不同的儿童肺炎和正常的胸部 X 片,对模型进行外部验证。由结果可知,初步外部验证的准确率仅为 59.90%。分析其原因,可能为外部验证的胸部 X 片与训练使用的数据具有较大差异,其差异来源主要为:各单位摄片设备的摄片参数略有差异;各单位诊断肺炎的标准略有不同;收集的儿童胸片年龄范围略有不同。基于这样的异质性,本研究在对数据预处理的基础上,利用外部数据再次对模型进行训练和选择。通过将外部验证数据集分为两部分,分别作为验证集对原模型进行训练和选择,通过对原有模型重新训练后,提高测试的准确率。通过微调后,模型的准确率达到 85.00%,提升了 25.10%。由此可

见,当训练模型与所使用环境不一致时,在投入临床使用过程中,还应该使用具体环境下所收集的数据作为验证数据对模型进行微调,提高模型的准确率。

尽管本研究所提出的深度学习算法模型在儿童肺炎诊断上具有一定应用价值,但还存在一定缺陷。模型的准确性依赖于训练的数据集,为了使模型具有更好的泛化功能,还应该增加数据的多样性,并且尽可能使测试数据和训练数据在大小、图像灰度等特征具有一致性。因此,对图像数据进行恰当的预处理是必要的,包括图像的大小、灰度、空间分辨率、密度分辨率等的归一化。另外,在对已有数据的预处理基础上,增加数据本身的样本量十分重要,但这受到数据安全问题的限制,导致数据共享及传输困难,涉及到患者信息等敏感问题,有待解决。最后,本研究未进一步评估人工诊断与模型预测在误诊率、诊断时间等方面的临床使用效果,对模型的应用和推广还有待深入。

深度学习的快速发展使得其不仅在儿童肺炎诊断中具有应用价值,在新冠疫情常态化防控期间新冠肺炎的诊断、治疗以及预测等研究和应用也已经日渐成熟,并且在其他医学领域疾病的早诊早治方面能较好地辅助临床医生工作,减轻工作负担,提高诊疗工作的效率和精确度,推动智能医学的发展<sup>[21-24]</sup>。值得注意的是,在人工智能快速发展的过程中,数据安全问题也应该纳入考虑。针对数据安全问题,未来可以采用数据脱敏技术、数据安全沙箱、数据隐私计算等进行保障,以便增加训练的样本量<sup>[25]</sup>。虽然深度学习取得了不错的成果,但在实际使用时仍有出错的可能,因此预估模型在什么情况下出错也十分重要<sup>[26]</sup>,尤其在医学领域,预测失误可能会带来严重后果。此外,深度学习分类模型的训练大多是基于标注的训练集进行参数调整而得到与真实标签尽可能一致的判别效果,基于这样的情况,模型容易过拟合。因此,将来还需要关注基于风险分析<sup>[27]</sup>的图像分类自适应深度学习方法,进而提高模型的准确性<sup>[28]</sup>。

## 4 结 论

本研究提出基于卷积神经网络对儿童肺炎进行诊断,简便快捷,准确率可达98.48%。针对与训练集不同来源的外部验证数据,经过微调模型,准确率可从59.90%提升至85.00%。因此,针对临床应用,可以基于已有模型进行改进,并不断增加样本量进行训练,以提高临床应用的准确性,并且在将来的发展过程中,应增加对数据安全及深度学习风险预测的研究。

致谢:感谢复旦大学周林祥及泰兴市人民医院

王继民、东山县医院王玉成、厦门大学附属中山医院方镇源、杭州市妇产医院刘日敏、南平市第一医院黄洪磊(排名不分先后)对本研究的支持。

## 【参考文献】

- [1] Mathur S, Fuchs A, Bielicki J, et al. Antibiotic use for community-acquired pneumonia in neonates and children: WHO evidence review [J]. Paediatr Int Child Health, 2018, 11(38): S66-S75.
- [2] Wang X, Peng Y, Lu L, et al. ChestX-ray8: hospital-scale chest X-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 2097-2106.
- [3] Xiang Y, Zhao L, Liu Z, et al. Implementation of artificial intelligence in medicine: status analysis and development suggestions [J]. Artif Intell Med, 2020, 102: 101780.
- [4] Egger J, Gsaxner C, Pepe A, et al. Medical deep learning-a systematic meta-review [J]. Comput Meth Prog Bio, 2022, 221: 106874.
- [5] Tran KA, Kondrashova O, Bradley A, et al. Deep learning in cancer diagnosis, prognosis and treatment selection [J]. Genome Med, 2021, 13(1): 152.
- [6] 李湘元, 张金宝, 刘鹏华, 等. 深度学习在医学影像领域的应用现状与展望 [J]. 临床放射学杂志, 2021, 40(12): 2423-2429.
- [6] Li XY, Zhang JB, Liu PH, et al. Application status and prospect of deep learning in medical imaging [J]. Journal of Clinical Radiology, 2021, 40(12): 2423-2429.
- [7] Kaggle. Chest X-ray images (Pneumonia) [EB/OL]. <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>.
- [8] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 770-778.
- [9] Nogales A, García-Tejedor ÁJ, Monge D, et al. A survey of deep learning models in medical therapeutic areas [J]. Artif Intell Med, 2021, 112(12): 102020.
- [10] Schaefferkoetter J, Yan J, Moon S, et al. Deep learning for whole-body medical image generation [J]. Eur J Nucl Med Mol Imaging, 2021, 48(12): 3817-3826.
- [11] Chan HP, Samala RK, Hadjiiski LM, et al. Deep learning in medical image analysis [J]. Adv Exp Med Biol, 2020, 1213: 3-21.
- [12] Rudie JD, Duda J, Duong MT, et al. Brain MRI deep learning and bayesian inference system augments radiology resident performance [J]. J Digit Imaging, 2021, 34(4): 1049-1058.
- [13] Gao J, Jiang Q, Zhou B, et al. Convolutional neural networks for computer-aided detection or diagnosis in medical image analysis: an overview [J]. Math Biosci Eng, 2019, 16(6): 6536-6561.
- [14] 董婷, 魏琬, 叶晓丹, 等. 基于空洞空间卷积池化金字塔结构和注意力机制的全卷积残差网络磨玻璃肺结节分割方法 [J]. 生物医学工程学杂志, 2022, 39(3): 441-451.
- [14] Dong T, Wei L, Ye XD, et al. Segmentation of ground glass pulmonary nodules using full convolution residual network based on atrous spatial pyramid pooling structure and attention mechanism [J]. Journal of Biomedical Engineering, 2022, 39(3): 441-451.
- [15] Wong PK, Yan T, Wang H, et al. Automatic detection of multiple types of pneumonia: open dataset and a multi-scale attention network [J]. Biomed Signal Proces, 2022, 73: 103415.
- [16] Angayarkanni SP. Hybrid convolution neural network in classification of cancer in histopathology images [J]. J Digit Imaging, 2022, 35(2): 248-257.
- [17] Abbasi AA, Hussain L, Awan IA, et al. Detecting prostate cancer using deep learning convolution neural network with transfer learning approach [J]. Cogn Neurodyn, 2020, 14(4): 523-533.
- [18] 李新, 陈帆, 郝海江, 等. 深度学习在肺炎检测中的研究综述 [J]. 桂林理工大学学报, 2020, 40(4): 859-866.
- [18] Li X, Chen F, Hao HJ, et al. Review of deep learning in pneumonia detection [J]. Journal of Guilin University of Technology, 2020, 40(4): 859-866.
- [19] 何新宇, 张晓龙. 基于深度神经网络的肺炎图像识别模型 [J]. 计算机应用, 2019, 39(6): 1680-1684.
- [19] He XY, Zhang XL. Pneumonia image recognition model based on deep

- neural network[J]. Journal of Computer Applications, 2019, 39(6): 1680-1684.
- [20] 周进凡, 刘宇红, 张荣芬, 等. 基于卷积神经网络的肺炎检测系统[J]. 现代电子技术, 2019, 42(23): 35-39.
- Zhou JF, Liu YH, Zhang RF, et al. Pneumonia detection system based on convolutional neural network[J]. Modern Electronics Technique, 2019, 42(23): 35-39.
- [21] Wu X, Hui H, Niu M, et al. Deep learning-based multi-view fusion model for screening 2019 novel coronavirus pneumonia: a multicentre study[J]. Eur J Radiol, 2020, 128: 109041.
- [22] Yang Y, Zhou D, Zhang X, et al. D3AI-CoV: a deep learning platform for predicting drug targets and for virtual screening against COVID-19[J]. Brief Bioinform, 2022, 23(3): 1-16.
- [23] Abdel-Basset M, Chang V, Hawash H, et al. FSS-2019-nCov: a deep learning architecture for semi-supervised few-shot segmentation of COVID-19 infection[J]. Knowl Based Syst, 2021, 212: 106647.
- [24] Kivrak M, Guldogan E, Colak C. Prediction of death status on the course of treatment in SARS-COV-2 patients with deep learning and machine learning methods[J]. Comput Meth Prog Biomed, 2021, 201: 105951.
- [25] 魏明月, 陈敏, 胥婷, 等. 临床科研场景下医疗数据安全开放共享平台设计[J]. 中国数字医学, 2021, 16(7): 27-32.
- Wei MY, Chen M, Xu T, et al. Design and exploration of medical data security opening sharing platform for clinical research scenarios[J]. China Digital Medicine, 2021, 16(7): 27-32.
- [26] Glikson E, Woolley AW. Human trust in artificial intelligence: review of empirical research[J]. Acad Manag Ann, 2020, 14(2): 627-660.
- [27] Hendrycks D, Gimpel K. A baseline for detecting misclassified and out-of-distribution examples in neural networks[J]. arXiv preprint arXiv, 2016, 1610.02136: 1-12.
- [28] Stamp M, Alazab M, Shalaginov A. Malware analysis using artificial intelligence and deep learning[M]. Berlin/Heidelberg: Springer, 2021, 223-246.

(编辑:陈丽霞)