

基于 ResNet34 的肺炎医学图像分类方法研究

孙贵苗¹ 刘腾岳² 许梦珂¹ 高梦雪¹ 赵艳婷³ 刘新奎³

(¹郑州大学公共卫生学院 郑州 450001 ²郑州大学电气与信息工程学院 郑州 450001 ³郑州大学第一附属医院 郑州 450052)

〔摘要〕 **目的/意义** 针对胸部 X 光片肺炎诊断效率低、主观性强等问题，提出基于 ResNet34 的深度学习分类方法，以提高诊断效率、降低误诊率。**方法/过程** 设计混合全局-局部特征增强模块（HGFE），采用双分支结构提取局部特征与全局上下文：局部分支以空洞卷积扩大感受野，全局分支以坐标注意力机制建立长程依赖，再经 SE 模块融合特征。**结果/结论** 在 ChestX-ray2017 数据集上，模型精确率达 98.16%，F1 分数 0.9758，AUC 值 0.9896；在 COVID-19 Radiography 数据集上准确率达 96.94%，优于 VGG16、ResNet50 等模型。该方法有效提升了肺炎分类性能，具有良好的泛化能力和临床实用价值。

〔关键词〕 ResNet34-HGFE，肺炎，医学图像分类

〔中图分类号〕： R183 〔文献标识码〕： A

Automated Pneumonia Detection from Chest X-rays Using a ResNet-34 Architecture

Sun Guimiao¹, Liu Tengyue², Zhang Jiayu¹, Zhao Yanting³, Yang Linpeng³, Liu Xinkui³

¹School of Public Health, Zhengzhou University, Zhengzhou 450001, China; ²School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, ³The First Affiliated Hospital of Zhengzhou University, Zhengzhou 450052, China

〔 Abstract 〕 **Objective/Significance** To address the low efficiency and strong subjectivity of pneumonia diagnosis from chest X-rays, a deep learning classification method based on ResNet34 is proposed to improve diagnostic efficiency and reduce misdiagnosis. **Method/Process** A Hybrid Global-Local Feature Enhancement module (HGFE) was designed, in which two parallel branches extract local features and global context: the local branch employs dilated convolution to enlarge the receptive field, the global branch introduces coordinate attention to model long-range dependencies, and an SE module is used for feature fusion. **Results/Conclusions** On the ChestX-ray2017 dataset, the model achieved a precision of 98.16%, an F1-score of 0.9758 and an AUC of 0.9896; on the COVID-19 Radiography dataset, it reached an accuracy of 96.94%, outperforming VGG16 and ResNet50. The proposed method

effectively improves pneumonia classification, with good generalization and clinical application value.

Keywords: ResNet34-HGFE, Pneumonia, Medical image classification

1 引言

肺炎是由细菌、病毒等病原体引起的肺部感染性疾病，在全球范围内发病率高、疾病负担重^[1]，X光片成本低且易于获取，成为诊断肺炎疾病最常见的分析方法。胸部X光检查因成本低、获取便捷，已成为肺炎筛查和诊断的重要影像学手段。然而，传统人工阅片过程耗时较长，诊断结果易受医师经验和主观判断影响。开发一种能自动、准确地检测肺炎的计算机辅助诊断系统，具有重要的临床价值和社会意义。基于此，深度学习技术展现出显著的临床应用潜力。通过卷积神经网络（Convolutional Neural Network, CNN）等算法对胸片进行自动化特征提取与病理识别，计算机辅助诊断系统（Computer-Aided Diagnosis, CAD）^[2, 3]不仅能够实现肺炎的快速初筛，其检测敏感度与特异度更可达到资深放射科医师水平。该技术路径有效弥补了人工分析的效率缺陷，并为医疗资源匮乏地区提供了可及的精准诊断支持。

本研究聚焦于深度学习在肺炎医学影像分类中的应用，提出了一种基于ResNet34架构的改进型分类模型ResNet34-HGFE。为解决传统卷积神经网络在复杂病变特征提取中存在的局限性，本文提出了HGFE模块。该模块通过双分支结构，增强了肺炎病灶的局部和全局的特征信息，实现了对病变区域的精准定位。实验结果表明，本研究所提出的方法在ChestX-ray2017数据集以及COVID-19 Radiography数据集上显著提升肺炎识别准确率。

2 相关研究情况

医学影像分类的早期研究主要采用分形理论方法，通过计算图像的分数布朗运动特征来提取分形维数，并构建归一化的特征向量进行影像分析和分类^[4]。近年来，计算机视觉技术快速发展，深度学习在医学图像诊断中表现突出^[5-7]。常川等^[8]基于ResNet-50构建人类蛋白质图谱28类分类模型，准确率突破91%，验证其在小样本医学场景中的有效性；王杰等^[9]在甲状腺结节检测中进一步比较ResNet101/152与轻量级网络，证实深层ResNet在精度上最优；赵姗姗等^[10]则在阿尔茨海默病MRI分类中通过改进Swin-Transformer取得领先性能，提示Transformer与CNN融合或为趋势。此外，近年来随着大模型的爆发，视觉语言模型（Vision Language Models, VLMs）在医学图像任务中展现出了巨大潜力。相关研究表明，通过对齐胸部X光图像与放射科医生的文本诊断报告，

VLM 能够在零样本或少样本学习中取得优异的分类与病灶定位效果^[11, 12]。尽管 VLM 具备强大的跨模态理解能力，但其对计算资源和庞大配对数据的极高要求，限制了其在某些计算资源受限环境中的实时部署。因此，在当前阶段，探索高效、轻量且具备强表征能力的纯视觉 CNN 仍具有不可替代的现实意义。Zhuang 等人基于 1420 张舌象图像，开发结合 ResNet34 和视觉问答技术的系统，实现舌象分类，准确率达 89.46%，优于 VGG16 等模型^[13]。加纳研究者通过分析 1200 张乳腺 X 光图像，开发基于 ResNet18 和 ResNet34 的深度学习方法，训练测试后，ResNet18 取得 92% 的准确率^[14]。上述研究表明，ResNet 系列在医学图像细粒度分类任务中具备强鲁棒性与扩展性，为本研究以 ResNet34 为核心架构、聚焦肺炎影像多类别判别提供了直接的方法学依据。

3 研究方法 with 实验设计

3.1 研究方法

3.1.1 ResNet 网络简述

卷积神经网络（CNN）^[15-18]在图像分类领域取得了巨大成就，其强大的特征提取能力使其成为处理数据的首选工具。然而随着网络深度的增加，模型的准确率在达到饱和后会迅速下降。为解决这一关键问题，何凯明等人于 2015 年提出了残差网络（Residual Network, ResNet）^[19]。ResNet 以残差学习（Residual Learning）框架为核心创新，如图 1 所示。其残差块通过恒等快捷连接将输入 x 与若干权重层的输出 $F(x)$ 逐元素相加，最终得到该块的输出，整个过程如公式（1）所示。该恒等映射零参数、零计算增量。

$$y = F(x) + x \tag{1}$$

ResNet34 的网络深度为 34 个含参数的层（33 个卷积层和 1 个全连接层），其整体架构遵循现代卷积神经网络的通用设计范式，并由一系列堆叠的残差块构成。




图 1 残差结构

3.1.2 混合全局-局部特征增强模块

胸部 X 射线肺炎病灶自动识别的核心难点在于：一是病灶形态高度异质，既可表现为边界不清的微小斑片影，亦可呈大片实变；二是病灶一背景对比度弱，纹理特征与正常肺纹理、血管影近似，易致误判。然而标准的 ResNet 网络在设计上存在以下潜在局限性：一是局部细节信息丢失，网络通过连续的下采样操作（步长为 2 的卷积或池化）来逐层扩大感受野，但这会降低特征图的空间分辨率，削弱了对早期、微小病灶等关键局部细节的捕捉能力。二是全局上下文建模不足，标准的卷积操作本质上是在局部邻域内进行，虽然通过堆叠可以扩大感受野，但在高效捕捉远距离像素间依赖关系、构建跨区域的上下文关联以及理解病灶在整个肺野中的空间位置与分布等方面，其能力依然有限。

为解决上述问题，本研究设计并提出了一种混合全局-局部特征增强模块（HGFE）。该模块的核心设计思想在于，通过一个并行的双分支结构，对来自主干网络的特征进行处理，以实现协同提取并增强全局与局部这两类对肺炎诊断至关重要且相互补充的特征信息。HGFE 模块的详细结构如图 2 所示。具体而言，HGFE 模块以 ResNet34 主干网络每个阶段输出的中间特征图 C_i 作为输入，经两个并行分支分别对全局特征与局部特征进行增强和融合，得到最终输出特征图 C'_i 。




图 2 HGFE 模块

局部细节特征分支的目标是捕获病灶区域的局部细节信息。为此，本研究引入空洞卷积（Dilated Convolution）^[20]，与标准卷积不同，局部分支采用空洞卷积，在不增参、不降采样的前提下扩大感受野，精准捕获 X 线影像中肺炎病灶边缘纹理及其与周边正常结构的细微差异，强化局部判别力。

全局特征提取分支旨在高效地捕获具有位置敏感性的全局上下文信息，以增强模型对病灶整体空间分布的理解能力。本研究使用了坐标注意力（Coordinate Attention, CA）机制^[21]，以克服传统通道注意力方法^[22-24]在空间位置信息保留方面的不足。坐标注意力机制主要包含两个步骤：一是坐标信息嵌入:为了避免二维全局池化导致的空间信息完全丢失，分别沿着水平和垂直方向对输入特征图进行一维的平均池化，从而将空间信息聚合成两个方向感知的特征图。二是坐标注意力生成:将上述两个方向的特征图进行拼接，然后通过共享的 1x1 卷积、归一化和非线性激活函数进行变换，最后再分离成两个独立的张量，并分别通过 Sigmoid 函数生成沿水平和垂直方向的注意力权重。通过这种方式，坐标注意力机制能够捕获长距离的空间依赖关系，并生成一个同时包含方向和位置信息的注意力图。

局部细节特征分支和全局特征提取分支分别生成了特征图 C_i^L 和 C_i^G 。这两个特征图在相同的空间分辨率上进行逐元素相加，实现初步的特征融合。为了进一步优化特征的通道权重，混合全局-局部特征增强模块引入了通道注意力机制 SE 模块。SE 模块通过全局平均池化压缩特征图的通道信息，然后通过两个全连接层（FC）学习每个通道的重要性权重，并将其应用于原始特征图 C_i^L 和 C_i^G ，以强化各自的特征。最后将 C_i^L 和 C_i^G 逐元素相加，生成更强的特征表示 C_i' 。

3.1.3 整体网络结构

为了充分发挥 HGFE 模块在增强特征表达能力上的优势，本研究将 HGFE 模块插入在 ResNet34 每一个残差阶段堆叠的残差块之后，如图 3 所示。将 HGFE 模块逐层级嵌入 ResNet34 每一残差阶段后，以渐进方式在各尺度同步增强局部细节与全局上下文，实现从低阶到高阶特征的连续优化，显著提升肺炎病灶的多尺度感知与判别性能。




图 3 整体网络结构图

3.2 实验设计

3.2.1 实验环境

本研究使用 PyTorch 深度学习框架，并在搭载 NVIDIA GeForce RTX 3090 的计算平台上进行训练和测试。模型训练的批量大小为 16，并采用 SGD 优化器，其中动量设定为 0.937，权重衰减为 0.0005。初始学习率设定为 0.01，总的训练周期为 200，图片大小统一缩放到 224×224。此外，模型训练采用交叉熵损失函数（Cross-Entropy Loss）进行误差反向传播。各项实验参数与实验环境设置如表1 所示。

表 1 训练参数与实验环境设置

实验环境	配置
优化器	SGD
初始学习率	0.01
学习率衰减方式	余弦退火衰减策略
批量大小	16
训练周期	200
图片大小	224×224
操作系统	Ubuntu20.04.5
深度学习框架	Pytorch1.13

3.2.2 数据集

本研究采用公开的 Chest X-Ray 2017 数据集开展实验^[25]。由广州市妇女儿童医疗中心的儿科患者的胸部 X 光片回顾性队列整理而来，是肺炎检测领域广泛使用的基准数据集之一。该数据集包含了两个类别的图像：肺炎（Pneumonia）和正常（Normal）。其中，肺炎类别又可细分为细菌性肺炎和病毒性肺炎，但在本研究的二分类任务中，本研究将它们统一视为肺炎类别。为确保实验结果具备严谨的可比性，本研究严格沿用该数据集官方的标准划分策略：训练集包含 5216 张图像（正常 1341 张，肺炎 3875 张），用于模型训练；验证集包含 16 张图像（正常 8 张，肺炎 8 张），用于微调；测试集包含 624 张图像（正常 234 张，肺炎 390 张），仅用于最终独立评估模型性能。此外，为了验证模型的泛化能力和克服单一数据集可能带来的过拟合问题，本研究额外引入了 COVID-19 Radiography 数据集^[26]进行外部验证实验。该数据集共包含 21,165 张胸部 X 光图像，其中正常（Normal）类别图像 10,192 张，肺炎类别图像（包含 COVID-19、普通病毒性肺炎及肺部阴影等）共计 10,973 张。在本验证实验的二分类任务中，实验中按照 8:1:1 的比例将该数据集随机划分为训练集（约 16,931 张）、验证集（约 2,117

10.12201/bmr.202608.00019V1

张)和测试集(约 2,117 张)。X 射线图像受拍摄设备和参数影响,存在尺寸不一、对比度差异等问题,为了适配 ResNet34 网络的输入要求,将所有图像的尺寸统一缩放(Resize)至 224×224 像素。为缓解模型过拟合现象并增强其泛化能力,本实验引入了在线数据增强策略,包括随机水平翻转和随机旋转。

3.2.3 评价指标

本研究采用经典分类评价指标对该模型进行评价,包括准确率(accuracy)、精确率(precision)、召回率(recall)、F1 分数(F1-score),计算方式如下。其中真阳性(True Positive, TP)指的是实际为阳性的样本被模型正确识别为阳性的数量;真阴性(True Negative, TN)则表示实际为阴性的样本被模型正确识别为阴性的数量。假阳性(False Positive, FP)表示实际为阴性但被模型错误分类为阳性的样本数;假阴性(False Negative, FN)则指实际为阳性的样本被模型错误分类为阴性的数量。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (5)$$

此外,为了更好地契合医学影像分类的临床评价需求,本研究引入了敏感度(Sensitivity)和特异度(Specificity)两个核心临床评价指标。敏感度等同于召回率,反映了模型对真正肺炎患者的检出能力;特异度则反映了模型对正常健康人群的排除能力,其计算公式如下:

$$Sensitivity = \frac{TP}{TP + FN} \quad (6)$$

$$Specificity = \frac{TN}{TN + FP} \quad (7)$$

4 实验结果分析

4.1 对比实验

为验证本研究提出的 ResNet-HGFE 模型的有效性，本研究选取了多个经典的卷积神经网络模型进行对比，包括 VGG16^[27]

1、ResNet34^[19]、ResNet50^[19]、MobileNetv3^[28]、ConvNeXtv2^[29]、RepViT^[30]等模型，并使用 ResNet34 作为基线模型。所有模型均在相同的实验环境下进行训练和测试，各模型在 ChestX-ray2017 数据集上的性能表现如下表 2 所示。

表 2 ChestX-ray2017 数据集上的结果比较

模型	精确率	敏感度(召回率)	准确率	F1 分数	特异度	参数量(M)
VGG16	0.9115	0.8402	0.8782	0.8598	0.6880	138.36
MobileNetv3	0.9208	0.8889	0.9103	0.9009	0.8889	5.48
3						
ResNet34	0.9685	0.9504	0.9615	0.9582	0.9504	21.80
ResNet50	0.9650	0.9440	0.9567	0.9529	0.9440	25.56
ConvNeXtv	0.9438	0.9295	0.9407	0.9358	0.9295	28.58
2						
RepViT	0.9709	0.9577	0.9623	0.9636	0.9577	14.52
Ours	0.9816	0.9709	0.9776	0.9758	0.9719	43.32

从表 2 可以看出，本文提出的 ResNet34-HGFE 模型在 ChestX-ray2017 数据集上整体表现优于各对比模型。与基线 ResNet34 相比，ResNet34-HGFE 在精确率、敏感度、准确率、F1 分数和特异度等指标上均有所提升，说明 HGFE 模块能够增强模型对肺炎病灶关键特征的提取能力。与 VGG16、MobileNetv3、ResNet50、ConvNeXtv2 和 RepViT 等模型相比，本文模型在综合分类性能方面具有一定优势，尤其在敏感度和特异度上表现较为稳定，表明其在降低漏诊和误诊风险方面具有较好的应用潜力。需要指出的是，由于 HGFE 模块引入了空洞卷积、坐标注意力和 SE 特征重标定结构，模型参数量较原始 ResNet34 有所增加，因此本文模型的优势主要体现在分类性能和特征表征能力方面，而非模型轻量化方面。

为了进一步验证模型在不同数据分布下的鲁棒性和泛化能力，避免在单一数据集上产生过拟合，本研究在 COVID-19 Radiography 数据集上进行了外部验证。各模型在该数据集上的性能表现如表 3 所示。结果表明，本文提出的 ResNet34-HGFE 模型在该数据集上同样取得了最优表现，其准确率达到 96.94%，验证了本方法在多数数据集场景下的稳定性和普适性。

表 3 COVID-19 Radiography 数据集上的结果比较

模型	精确率	敏感度(召回率)	准确率	F1 分数	特异度	参数量(M)
VGG16	0.9502	0.9394	0.9399	0.9445	0.9761	138.36
MobileNetv	0.9228	0.9281	0.9188	0.9253	0.9688	5.48
3						
ResNet34	0.9539	0.9596	0.9546	0.9566	0.9825	21.80

ResNet50	0.9565	0.9616	0.9569	0.9590	0.9835	25.56
ConvNeXtv	0.9396	0.9315	0.9334	0.9354	0.9740	28.58
2						
RepViT	0.9551	0.9649	0.9559	0.9598	0.9831	14.52
Ours	0.9752	0.9697	0.9694	0.9724	0.9878	43.32

4.2 消融实验

为了进一步探究 HGFE 模块内部各组件的具体贡献，本研究设计了一系列消融实验。实验以 ResNet34 为基线，逐步添加 HGFE 模块的不同部分，并在测试集上评估其性能。结果如下：

表 4 HGFE 模块消融实验

模型	精确率	敏感度(召回率)	准确率	F1 分数	特异度
ResNet34	0.9685	0.9504	0.9615	0.9582	0.9504
ResNet34+Dilate					
d Convolution	0.9713	0.9537	0.9674	0.9573	0.9587
ResNet34+CA	0.9768	0.9594	0.9696	0.9670	0.9616
Ours	0.9816	0.9709	0.9776	0.9758	0.9719

表 4 展示了 HGFE 模块中不同组成部分的消融实验结果。与基线 ResNet34 相比，单独引入空洞卷积或坐标注意力机制后，模型整体性能均有所改善，说明局部细节增强和全局上下文建模均有助于肺炎影像分类。其中，坐标注意力机制对模型性能提升更为明显，表明空间位置信息和长程依赖关系对于肺炎病灶识别具有重要作用。完整的 ResNet34-HGFE 模型取得最佳综合表现，说明局部特征、全局上下文和通道重标定之间具有互补作用，能够进一步增强模型的判别能力。

4.3 ROC 曲线分析

为了更直观地理解模型的行为和性能，本研究比较了各模型的 ROC 曲线。如图 4 所示，所有模型的 ROC 曲线都位于左上角，表明它们都具有较好的分类性能。ROC 曲线下方的面积（Area Under the Curve, AUC）是一个关键的量化指标，其值越接近 1.0，代表模型的综合分类性能越优越。本研究提出的 ResNet34-HGFE 模型取得了 **0.9896** 的最高 AUC 值。其 ROC 曲线在所有模型中最贴近左上角顶点，这意味着在任意假正率（False Positive Rate）阈值下，本研究模型几乎都能达到最高的真正率（True Positive Rate）。这进一步证明了本研究模型拥有最强的区分正负样本的能力，综合性能最优。




图 4 ROC 曲线图

4.4 热力图分析

为了进一步验证模型在肺炎诊断中的可解释性，本研究采用类激活映射（Class Activation Mapping,CAM）技术生成了特征热力图。如图 5 所示，本文展示了原图以及 ResNet34、ResNet50 和本文提出的 ResNet34-HGFE 模型对同一典型肺炎 X 光片进行分类时的注意力热力图对比。在热力图中，颜色越偏向暖色调（红色/黄色）代表模型对该区域的关注度越高。从图 5 的可视化结果可以直观地观察到，基线模型 ResNet34 和 ResNet50 的注意力区域相对发散，不仅未能精准覆盖完整的渗出区域，甚至部分高亮区域偏离了肺野，受到了周边组织或背景噪声的干扰。相比之下，本文提出的 ResNet34-HGFE 模型的高响应区域（红色中心）精准且集中地定位在真实的肺部炎性渗出病灶上，没有出现向图像边缘发散的现象。这充分证明了 HGFE 模块通过引入空洞卷积和坐标注意力机制，不仅扩大了感受野，还有效抑制了无关背景噪声的干扰，确保了模型是真正基于肺炎病理特征进行诊断分类的，大幅提升了该自动诊断系统的临床可靠性与实际应用价值。




图 5 热力图比较

5 讨论

本研究为了解决胸部 X 光肺炎影像诊断中面临的诊断效率低、主观性强及微小病灶易漏诊等问题，提出了一种基于 ResNet34 和混合全局-局部特征增强模块（HGFE）的分类方法。实验结果表明，该方法在多个关键评估指标上均表现出色。

肺炎病灶在 X 射线影像中往往呈现出形态多变、边缘模糊且与周边组织对比度弱的特点。本研究设计的双分支 HGFE 模块有效改善了传统卷积神经网络在特征提取上的局限性：其局部分支利用空洞卷积扩大了感受野，精准捕捉了微小病灶的边缘纹理；全局分支引入坐标注意力机制（CA），有效建立了跨区域的长程上下文依赖。这种全局与局部特征的有机融合，使得模型精确率达到 98.16%，准确率达到 97.76%。

在真实的临床场景中，极高的敏感度意味着极低的肺炎漏诊率，这对于疾病的早期干预至关重要。此外，在医疗资源分布不均的现状下，该计算机辅助诊断（CAD）系统能够为基层放射科医师提供客观可靠的“第二意见”。它不仅能实现大批量 X 光片的自动化快速初筛，有效缓解影像科医生的工作负荷，还能显著降低因疲劳或经验不足导致的误判风险。

尽管本模型在 ChestX-ray2017 和外部 COVID-19 Radiography 多个数据集中均表现优异，但仍存在一定的局限性。首先，本研究当前主要聚焦于“肺炎”与“正常”的二分类任务，尚未对肺炎的具体致病亚型（如细菌性肺炎与病毒性肺炎）进行更细粒度的鉴别。其次，当前诊断仅依赖于单一的图像模态。未来的研究将致力于优化模型以实现肺炎的多分类细粒度诊断，并尝试引入患者的临床电子病历文本数据，探索多模态融合技术，以进一步提升诊断的综合精度。同时，在真实临床环境下的多中心前瞻性队列验证也将是本研究走向实际应用的下一步重点。

此外，本文模型仍存在模型复杂度较高的问题。与原始 ResNet34 和

10.12201/bmr.202608.00019V1

ResNet50 相比，ResNet34-HGFE 由于引入混合全局-局部特征增强模块，参数量和计算量均有所增加。这意味着该模型更适用于对诊断准确性要求较高、具备一定计算资源支持的辅助诊断场景。对于基层医疗机构或边缘设备等资源受限场景，后续仍需进一步开展模型压缩、知识蒸馏、剪枝和轻量化模块替换等研究，以降低模型部署成本。

6 总结

本研究提出了一种基于 ResNet34-HGFE 的改进型深度学习分类方法，通过引入混合全局-局部特征增强模块（HGFE），显著提升了肺炎识别的准确率。实验结果表明，相较于其他自动分类方法，其精确率和准确率更高。随着医学影像数据的快速增长，该研究为肺炎的自动化高精度诊断提供了有效解决方案，具有重要的临床实用价值。基于 ResNet 的自动分类方法将展现出更大的应用潜力。未来研究将进一步优化模型，提升分类速度和准确率，以增强该方法在医学图像分析中的实用价值。

参考文献

- [1] Ruuskanen O, Lahti E, Jennings L C, et al. Viral pneumonia [J]. The Lancet, 2011, 377(9773): 1264-1275.
- [2] Yeasmin M N, Al Amin M, Joti T J, et al. Advances of AI in image-based computer-aided diagnosis: A review [J]. Array, 2024, 23: 100357.
- [3] Bhandarkar A, Naik P, Vakkund K, et al. Deep learning based computer aided diagnosis of Alzheimer's disease: a snapshot of last 5 years, gaps, and future directions [J]. Artificial Intelligence Review, 2024, 57(2): 30.
- [4] Chen C-C, DaPonte J S, Fox M D. Fractal feature analysis and classification in medical imaging [J]. IEEE transactions on medical imaging, 1989, 8(2): 133-142.
- [5] Kumar R, Kumbharkar P, Vanam S, et al. Medical images classification using deep learning: a survey [J]. Multimedia Tools and Applications, 2024, 83(7): 19683-19728.
- [6] Obuchowicz R, Strzelecki M, Piórkowski A. Clinical applications of artificial intelligence in medical imaging and image processing—A review [Z]. MDPI. 2024: 1870
- [7] Sharma P, Nayak D R, Balabantaray B K, et al. A survey on cancer detection via convolutional neural networks: Current challenges and future directions [J]. Neural Networks, 2024, 169: 637-659.
- [8] 常川. 基于 ResNet 深度网络的人类蛋白质图谱图像分类方法研究 [J]. 医学信息学杂志, 2019, 40(7): 45-49.
- [9] 王杰, 王至诚, 娄帅, et al. 基于深度学习算法 Mask R-CNN 的甲状腺结节检测模型研究 [J]. 医学信息学杂志, 2025, 46(3): 84-89.
- [10] 赵姗姗, 史浩霖, 王颖帅, et al. 一种基于改进 Swin Transformer 模型的阿尔茨海默病 MRI 图像分类方法研究 [J]. 医学信息学杂志, 2025, 46(5): 79-85, 97.
- [11] Wang Z, Wu Z, Agarwal D, et al. Medclip: Contrastive learning from unpaired medical images and text [C]. Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing, 2022: 3876-3887.
- [12] Moor M, Banerjee O, Abad Z S H, et al. Foundation models for generalist medical artificial intelligence [J]. nature, 2023, 616(7956): 259-265.
- [13] Zhuang Q, Gan S, Zhang L. Human-computer interaction based health diagnostics using ResNet34 for tongue image classification [J]. Computer Methods and Programs in Biomedicine, 2022, 226: 107096.
- [14] Subaar C, Addai F T, Addison E C K, et al. Investigating the detection of

- breast cancer with deep transfer learning using ResNet18 and ResNet34 [J]. Biomedical Physics & Engineering Express, 2024, 10(3): 035029.
- [15] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions [C]. Proceedings of the IEEE conference on computer vision and pattern recognition, 2015: 1-9.
- [16] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors [J]. nature, 1986, 323(6088): 533-536.
- [17] LeCun Y, Boser B, Denker J, et al. Handwritten digit recognition with a back-propagation network [J]. Advances in neural information processing systems, 1989, 2.
- [18] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks [J]. Advances in neural information processing systems, 2012, 25.
- [19] 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, 2016: 770-778.
- [20] Yu F, Koltun V, Funkhouser T. Dilated residual networks [C]. Proceedings of the IEEE conference on computer vision and pattern recognition, 2017: 472-480.
- [21] Hou Q, Zhou D, Feng J. Coordinate attention for efficient mobile network design [C]. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2021: 13713-13722.
- [22] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]. Proceedings of the IEEE conference on computer vision and pattern recognition, 2018: 7132-7141.
- [23] Wang Q, Wu B, Zhu P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2020: 11534-11542.
- [24] Woo S, Park J, Lee J-Y, et al. Cbam: Convolutional block attention module [C]. Proceedings of the European conference on computer vision (ECCV), 2018: 3-19.
- [25] Kermany D S, Goldbaum M, Cai W, et al. Identifying medical diagnoses and treatable diseases by image-based deep learning [J]. cell, 2018, 172(5): 1122-1131. e1129.
- [26] Rahman T, Khandakar A, Qiblawey Y, et al. Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images [J]. Computers in biology and medicine, 2021, 132: 104319.
- [27] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J]. arXiv preprint arXiv:14091556, 2014.
- [28] Howard A, Sandler M, Chu G, et al. Searching for mobilenetv3 [C]. Proceedings of the IEEE/CVF international conference on computer vision, 2019: 1314-1324.
- [29] Woo S, Debnath S, Hu R, et al. Convnext v2: Co-designing and scaling convnets with masked autoencoders [C]. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2023: 16133-16142.
- [30] Wang A, Chen H, Lin Z, et al. Repvit: Revisiting mobile cnn from vit perspective [C]. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2024: 15909-15920.

作者简介:

孙贵苗, 女, 研究生在读, 2002 年 5 月, 社会医学与卫生事业管理, 郑州大学公共卫生学院, 郑州, 450001_15660826030@163.com

作者贡献声明和利益冲突声明:

作者贡献：孙贵苗负责数据分析与论文撰写；刘新奎负责论文的整篇指导；刘腾岳负责数据分析，高梦雪负责论文部分撰写与参考文献整理，许梦珂与赵艳婷负责论文的修改。

利益声明：所有作者均声明不存在利益冲突。