

基于迁移学习和深度卷积神经网络的胸腰椎骨折AI分类研究

郝引¹, 陈馨¹, 莫云海², 吴禄源³, 仝敬博³

(1. 四川省中西医结合医院放射科, 四川 成都 610041;

2. 成都市第七人民医院放射科, 四川 成都 610044;

3. 河南大学河南省人工智能理论及算法工程研究中心, 河南 开封 450001)

摘要: 传统的胸腰椎骨折影像辅助分类方法准确率低、泛化能力差, 为此提出一种基于深度卷积神经网络方法辅助诊断的胸腰椎骨折AI分类方法。收集四川省中西医结合医院胸腰椎骨折患者CT影像图片共698张, 建立数据集, 其中单纯压缩性骨折(A类)279张, 爆裂性骨折(B类)295张, 正常(C类)124张。对传统卷积神经网络模型ResNet-50进行改进并融入迁移学习, 对数据集进行训练, 获得胸腰椎骨折AI分类模型。采用混淆矩阵评估预测模型分类性能, 模型的训练集和验证集准确率分别为95.75%和96.36%, 表明训练得到的智能分类模型具有较好的准确率和泛化能力。本文提出胸腰椎骨折影像辅助分类方法, 可以提高人工诊断的效率和准确率。

关键词: 胸腰椎骨折; 深度卷积神经网络; AI分类方法; 泛化能力

中图分类号: R687.3

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202426

Research on AI classification of thoracolumbar fractures based on deep convolutional neural network and transfer learning

HAO Yin¹, CHEN Xin¹, MO Yunhai², WU Luyuan³, TONG Jingbo³

1. Radiology Department, Sichuan Integrative Medicine Hospital, Chengdu 610041, China

2. Radiology Department, Chengdu Seventh People's Hospital, Chengdu 610044, China

3. Henan Artificial Intelligence Algorithm Center, Henan University, Kaifeng 450001, China

Abstract: The traditional thoracolumbar fracture image-assisted classification method has low accuracy and poor generalization ability. Therefore, based on deep convolutional neural network, this paper proposes an AI classification method for thoracolumbar fracture for auxiliary diagnosis. Firstly, a total of 698 CT images of patients with lumbar spine fractures were collected from Sichuan Integrative Medicine Hospital, and a data set was established, including 279 compression fractures (category A), 295 burst fractures (category B), and 124 normal (category C). Secondly, the convolutional neural network model ResNet-50 was modified and combined with transfer learning to train, verify and test the data set to obtain the AI classification model of thoracolumbar fracture. Then, the Confusion Matrix is used to evaluate the prediction model. The accuracy of the training set and the validation set of the model is 95.75% and 96.36%, respectively, indicating that the model obtained by training has good accuracy and generalization ability. This paper proposes an image-assisted classification method for thoracolumbar fracture, which can improve the efficiency and accuracy of manual diagnosis.

Key words: thoracolumbar fracture, deep convolutional neural network, AI classification method, generalization ability

0 引言

胸腰椎骨折是一种常见的脊椎骨折类型,通常由外力作用或骨密度降低引起,损伤的机理复杂,表现形式多样。CT是一种有效的成像方式,能可视化椎体的状态,并帮助作出必要的诊断。但不同临床医师的经验和技能参差不齐,对同一病患的影像诊断分型具有较大的差异性,因此及时准确地诊断和分类腰椎骨折对于临床治疗和患者康复至关重要。然而,传统的胸腰椎骨折影像辅助分类方法存在准确率低和泛化能力差的问题,这限制了其在临床实践中的应用。随着深度学习和计算机视觉领域的快速发展,深度卷积神经网络(convolutional neural network, CNN)已经在大脑^[1-3]、内脏^[4-5]、多器官^[6-8]医学影像处理中取得了显著的成就。CNN能够从图像中学习特征并自动进行分类^[9-11],相对于人和传统的方法,可以对影像中的异常区域快速识别,因此在腰椎骨折的诊断和分类方面具有巨大的潜力。

近年来,计算机辅助成像分析和诊断技术已在临床实践中得到广泛应用,其中包括放射组学(radiomics, Rad)和深度学习方法,以协助医疗决策^[12]。这些技术相比于人类,能够更客观、定量和稳定地评估各种疾病。Rad技术将临床上的视觉评估转变为机器通过提取和分析医学图像中的定量高通量特征来进行评估。深度学习则利用深度卷积神经网络的卷积层堆叠,从图像数据中提取高维特征^[13-25]。Chen等^[16]使用CNN对X射线图像进行椎体骨折识别,报告的准确率约为73.59%。Murata等^[17]基于CNN识别胸腰椎骨折,获得的准确率、灵敏度和特异性分别为86.0%、84.7%和87.3%。Li等^[18]通过深度学习集成方法对941张脊柱侧位X光片进行骨质疏松性腰椎骨折检测,取得了93%的准确率、91%的灵敏度和93%的特异性。Chou等^[19]使用集成模型对1305张胸腰椎X光片进行椎体骨折识别,达到了93.36%的准确率、88.97%的灵敏度和94.26%的特异性。Shen等^[20]开发并验证了基于深度学习的系统(AI_OVF_SH),用于使用普通X光片对骨质疏松性椎体骨折进行诊断和分级。Naguib等^[21]开发了一种基于深度学习模型(如AlexNet和GoogLeNet)的计算机辅助诊断系统,使用X射线图像将颈椎损伤分类为骨折或脱位。Zhang等^[22]采用U-net和U-Graph卷积网络进行胸腰椎定位和分类,通过多分支输出网络实现

AO分类,系统对骨折检测的准确率为97.93%,对AO分类评估的准确率为79.56%,表明其能够根据AO分类准确评估OVF。Zhang等^[23]基于ResNet-50架构模型实现了深度迁移学习,基于RadImageNet数据集的DLR模型在预测OVF分类方面优于ImageNet模型,AUC和准确率分别为0.809和0.692。尽管上述学者验证了CNN对胸腰椎骨折分类的有效性,但这些研究主要基于大模型实现,较少关注轻量化模型^[24-25]。

本文将深度卷积神经网络和迁移学习结合,提出一种有效的胸腰椎骨折AI分类方法。该方法可以显著提高胸腰椎骨折的诊断效率和准确性,可为医学影像领域的自动化分类提供一种有前景的解决方案,从而为临床医生提供更好的辅助诊断工具,帮助患者更早地接受治疗,提高治疗成功率。

1 数据集的构建

深度学习模型的成功通常依赖于大规模且高质量的数据集。对于胸腰椎骨折的研究,构建一个包括各种类型和严重程度的标记数据的数据集至关重要。

1.1 数据收集

数据收集是数据集构建的第一步。本文中患者CT影像图片均来自四川省中西医结合医院,一共收集698张胸腰椎骨折患者CT影像图片,其中压缩性骨折患者279个,爆裂性骨折患者295个,正常患者124个,每个样本由3张图像组成,如图1所示。




图1 各类样本图像

1.2 数据标记

对于监督学习任务,数据需要进行标记,即为每个图像分配正确的标签,指明是否存在胸腰

椎骨折以及骨折的类型，标记数据由专业医生进行。

1.3 数据预处理

CT影像图片数据通常需要进行预处理，如消除噪声、调整图像大小和对比度等，以确保模型的稳定性和性能，同时使用数据增强方法增加数据集的多样性，使网络更具有泛化性。常用的数据增强方法有旋转、镜像、对比度调整、亮度调整和高斯噪声等^[26]。数据增强技术不仅在训练阶段增加了数据的多样性，还通过增加训练样本的变化，提升了模型在实际应用中的泛化能力，确保了胸腰椎骨折智能分类模型在处理不同病患数据时的稳定性和准确性。训练集、验证集和测试集比例为8:1:1，在划分出测试集后对训练集使用数据增强后的数据集如表1所示，基于CNN的腰椎骨折智能分类方法模型整体流程如图2所示。

表1 数据集增强前后对比

病害类型	增强前数量/张	增强后数量/张
压缩性骨折	253	759
爆裂性骨折	257	771
正常	109	763

1.4 评价指标

通过4个指标判定胸腰椎骨折智能分类模型的性能，包括准确率、精确率、召回率以及损失，4个评价指标的计算式如下。通常来说，准确率越高，胸腰椎骨折智能分类模型的性能就越好。

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

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

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

$$\text{Loss} = - \sum_{i=1}^n y_i \lg(p_i) \quad (4)$$




图2 胸腰椎骨折智能分类模型整体流程

其中, TP 为模型预测为正类的正样本数; TN 为模型预测为负类的负样本数; FP 为模型预测为正类的负样本数; FN 为模型预测为负类的正样本数; n 为分类类别个数; y_i 为标签, 预测正确时, $y_i=1$, 否则, $y_i=0$ 。

2 基于CNN的腰椎骨折智能分类方法

深度卷积神经网络 (CNN) 是机器学习领域备受关注的方法之一, 它在图像分类、物体检测和图像识别等领域得到了广泛应用。通常情况下, 深度 CNN 由一个或多个卷积层、激活层、池化层和全连接层组成^[27]。卷积层的主要作用是从胸腰椎骨折的 CT 图像中提取关键特征, 激活层通过添加非线性变换来丰富卷积输出的特征表达, 常用的激活函数是 ReLU。激活层之后是池化层, 其主要目的在于减少特征图的尺寸和模型的参数数量, 从而降低模型复杂性, 避免过拟合问题。池化层通常采用两种主要策略: 平均池化和最大池化。平均池化通过对每个池化窗口的元素进行平均, 减小特征图的尺寸; 而最大池化则选择窗口内的最大值, 以保留最显著的特征。架构的最后一部分是全连接层, 或称输出层, 通常用于将网络的输出转换为更高层次的特征表示。在多分类任务中, Softmax 是常用的激活函数, 因为它可以将输出值转换为概率分布。Softmax 激活函数通过指数运算将每个类的输出转化为一个介于 0 和 1 之间的值, 并确保所有输出的总和等于 1。Softmax 激活函数为:

$$f(X_i) = \frac{e^{X_i}}{\sum_{i=1}^C e^{X_i}} \quad (5)$$

其中, X_i 为第 i 个节点的输出值, C 为分类类别个数, $f(X_i)$ 为类别为 i 时的概率。

目前, 许多 CNN 架构 (如 AlexNet^[28]、VGG-Net^[29]、GoogLeNet^[30] 和 ResNet^[31]) 已经在医学领域的图像识别分类和目标检测中取得了较好的准确率和鲁棒性。本文对 ResNet-50 全连接层进行调整, 通过迁移学习训练出胸腰椎骨折 CT 图像分类模型。

2.1 ResNet 网络结构

ResNet 即深度残差网络, 是深度学习的图像分类中经典模型之一, 由微软实验室提出^[31], 以网络中的不同层数命名, ResNet-50 是其中的一个例子。这个网络架构包含一个步长为 2 的 64 个 7×7

卷积核, 以及一个步长为 2 的 3×3 最大池化层。它还包括 16 个残差结构模块、一个平均池化层和一个全连接层, 最终连接到 Softmax 输出层。在深度神经网络中, 随着层数的增加, 梯度在反向传播过程中可能面临两个主要问题: 梯度消失和梯度爆炸。梯度消失是指在网络反向传播中, 反复乘以小于 1 的系数, 导致梯度逐渐接近零, 这会使深度网络难以训练。相反, 梯度爆炸则是由于反复乘以大于 1 的系数, 导致梯度快速增长, 可能引起训练的不稳定。而 ResNet 通过引入残差连接来缓解这两个问题。残差结构模块的核心是残差连接, 这种连接与标准卷积层平行, 其作用是在经过几个权重层后, 将输入直接添加到输出, 从而形成“跳跃连接”。如图 3 所示, 这种方式可以让模型在训练时跳过一层或多层, 避免不必要的计算, 从而维持更好的训练效率和稳定性。也正是因为这种设计, ResNet 系列的网络在深度增加的同时, 仍能保持较佳的训练性能。通常, 残差连接输出 $H(x)$ 可以定义为:

$$H(x) = F(x) + x \quad (6)$$

其中, $F(x)$ 代表一层或者多层的非线性权重层, x 代表残差模块上一层输入的特征权重, $H(x)$ 代表输出结果。




图3 单个残差模块

2.2 改进 ResNet-50 网络结构

传统的 ResNet-50 网络在其 Softmax 层中通常用于处理 1 000 个分类类别。这意味着网络的最后阶段由两个全连接层组成, 结构为 $[4\ 096, 1\ 000]$ 。其中, 第一个全连接层接收来自前一层池化层的输出, 包含 4 096 个神经元, 并产生 $2\ 048 \times 4\ 096 + 4\ 096 = 8\ 392\ 704$ 个参数。而第二个全连接层用于输出分类结果, 共有 $4\ 096 \times 1\ 000 + 1\ 000 = 4\ 097\ 000$ 个参数。本文的研究对象是针对骨骼骨折 CT 图像的 3 种分类任务。在这种情况下, 原版 ResNet-50 网络的

全连接层参数过于繁多，不但没有显著提升模型的准确性，反而可能增加过拟合的风险。因此，本文对 ResNet-50 网络的全连接层结构进行了改进。改进后的结构如图 4 所示，将原来的[4 096, 1 000]架构重新设计为[1 024, 256, 3]，形成三层全连接结构。新的全连接层参数分别为：2 098 176、262 400 和 771。总的全连接层参数数量因此降至 2 098 176+262 400+771=2 361 347，相比原始 ResNet-50 网络的全连接层参数总数 8 802 404，减少了约 73%。这一改进有效降低了模型的复杂性，减少了过拟合的风险，同时使模型在三分类任务中保持了良好的性能。

2.3 迁移学习

由于本文胸腰椎骨折 CT 影像分类数据集规模较小，网络提取各类特征的能力有限，因此引入迁移学习方法^[32]，训练得到适合于本文胸腰椎骨折 CT 影像分类数据集的分类模型。

迁移学习是一种利用已有知识解决相关领域中不同问题的机器学习方法^[33]。通过迁移学习，预训练的网络模型可以作为新模型的参数初始化，这种初始化方式将预先学习的知识迁移到新的网络中，从而使新网络具备快速学习的能力。这不仅可以缓解训练数据集不足导致的网络过拟合问题，还能增强识别模型在复杂自然环境下对胸腰椎骨折图像的泛化能力。

迁移学习主要有两种策略：特征提取和参数微调。特征提取是指保留预训练模型的部分网络参数，并将其用于新的案例中。这种策略利用了预训练模型在基础特征提取方面的优势，例如颜色、轮廓、纹理等低级特征^[34]。这些基础特征在不同的

任务中通常是通用的，因此通过特征提取可以在新任务上快速建立有效的模型。参数微调则与特征提取不同，其用目标数据集继续对预训练模型的部分或全部参数进行训练，调整网络所有层或部分层的参数以适应新的识别任务^[35]。因此，当自己建立的数据集规模较小时，可以使用预训练模型的初始权重在浅层网络提取一些通用的特征（边缘特征），从而使网络训练更加高效。

本文模型的训练采用了以下方法：首先，冻结预训练卷积层中的权重来训练模型，这样模型能够使预先训练的特征适应新数据；第二步涉及解冻卷积层中的权重，并以一个的较小学习率重新训练整个模型，这一过程称为微调，通过小步调整预训练权重，使模型能够更好地适应特定任务的数据特性，从而提高模型的整体性能。

3 结果

3.1 迁移学习的有效性

通过加入迁移学习使胸腰椎智能识别模型加速收敛，同时增加模型的准确率。有无迁移学习训练损失值和准确率对比如图 5 所示，可以看出，加入迁移学习方法后，准确率曲线收敛速度明显比没有迁移学习时更快，同时准确率也比没有迁移学习时的高。因此胸腰椎智能识别模型加入迁移学习方法不仅加速模型的收敛速度，同时还提高了网络的鲁棒性。

3.2 超参数优化

超参数优化在深度学习模型中起着关键作用，不同的超参数组合可能导致模型的准确性有显著差异。因此，优化超参数对于胸腰椎智能识别模型的




图4 ResNet-50 网络架构改进前后




图5 有无迁移学习训练损失值、准确率对比

性能非常重要。本文的研究重点是分析批次大小 (batch size)、学习率 (learning rate) 和训练次数 (epochs) 这3个超参数对模型效果的影响, 并寻找最优组合。图6给出了不同批次大小和学习率的准确率, 从图中可以看出批次大小为8和学习率为0.0005时, 模型的整体准确率最好。

以改进后的 ResNet-50 模型为基础网络模型, 在训练集和验证集上的准确率和损失值如图7所示, 由图7可知模型在训练次数为60后整体趋于稳定, 模型达到最优。而验证集上下波动较大, 这是由于验证集数量样本较少, 每个样本的预测结果对整体准确率的影响较大, 导致验证集在训练过程中无法趋于稳定。在训练次数为60~100, 验证集的平均准确率也达到92.03%, 此时模型性能达到最优。因此, 模型的超参数设置组合在批次大小为8, 学习率为0.0005和迭代次数为100时效果最好。

3.3 ResNet-50 模型改进试验结果

本文聚焦于改进 ResNet-50 模型的全连接层, 将原始参数较大的两层全连接层替换为参数量更少的三层全连接层, 实现了参数量减少73%的优化。此改进不仅在保证模型准确率的前提下显著加速了训练过程, 还减小了模型的整体规模。图8为 ResNet-50 模型改进前后训练集准确率曲线, 从图8可以看出改进后的模型在训练过程中准确率显著提高, 表明模型的优化策略有效提升了性能。表2对比了几种经典网络模型的实验结果, 进一步验证了改进后 ResNet-50*模型的优势, 改进后的 ResNet-50*模型相较于原始的 ResNet-50 模型, 整体模型所占空间减少了30.7 MB, 从而降低了存储和传输的需求, 同时平均每张图像测试时间减少了0.73 s, 有效降低了推理过程中的计算资源消耗和时间成本。

基于 CNN 算法, 结合迁移学习, 获得胸腰椎




图6 不同批次大小和学习率情况下的准确率




图7 训练集和验证集的准确率、损失值




图8 ResNet-50改进前后训练集准确率对比

表2 不同模型试验结果对比

模型	训练集准确率	验证集准确率	模型大小/MB	单张测试时长/s
ResNet-50*	0.957 4	0.963 6	97.90	1.130
ResNet-50	0.933 1	0.927 2	128.60	1.860
ResNet-101	0.873 0	0.818 0	172.00	1.528
EfficientNet	0.832 6	0.836 3	208.00	1.990
MobileNet	0.861 9	0.854 5	18.66	0.820
GoogLeNet	0.925 0	0.884 0	39.30	0.413
VGGNet	0.854 1	0.838 7	268.00	2.272
AlexNet	0.910 8	0.895 8	55.60	0.612

骨折智能分类模型，调用模型对测试集CT图像分类。压缩性骨折（A类）、爆裂性骨折（B类）和正常（C类）智能分类结果实例如图9所示，每张图片的横坐标表示图片的尺寸，分类模型给出每一张CT图属于A类、B类和C类的概率，展示在图片下面，概率最大的就属于此分类。图9（a）医

生诊断为压缩性骨折，分类模型诊断为A类的概率是97.76%；（b）医生诊断为爆裂性骨折，分类模型诊断为B类的概率是99.99%；（c）医生诊断为正常无骨折，分类模型诊断为C类的概率是100%，即通过提出的分类模型可以很好地辅助医生进行诊断。

测试集包含26张A类图片、38张B类及15张C类，测试的结果采用混淆矩阵（confusion matrix, CM）表示，CM是评估分类模型优劣的重要指标，其包含的基础指标主要有准确率、精准率和召回率。准确率是衡量分类模型性能的常用指标，定义为正确分类的样本数量与总样本数量的比值。这一指标给出了模型整体分类的准确性，但在处理类别不平衡的数据集时，准确率可能并不适合用作唯一的性能评估指标。精确率是指模型正确预测为正类别的样本数量占所有预测为正类别的样本数量的比例，衡量了模型在所有正类别预测中的准确性，适用于关注减少误报的情况。召回率是指模型正确预测为正类别的样本数量占所有实际正类别的样本数量的比例，用于衡量模型在所有实际正类别样本中的覆盖程度，适用于关注减少漏报的情况。

混淆矩阵预测结果如图10所示，B类压缩性骨折38个病例，其中，31个分类正确，1个预测为C类，6个预测为A类。15个C类正常的病例有2例预测为B类。但A类单纯性压缩性骨折26个病例，其中，10个分类正确，6个错误分类为B类，其原因是这6个病例是比较稳定的爆裂性骨折，骨折线虽累及椎体后缘，但没有明显分离错位，压迫脊髓，椎管也没有确切狭窄；或者骨折线未见明显累




图9 测试集三种类型智能分类示例




图10 测试集预测混淆矩阵

及椎体后缘，但骨折块略突入椎管，椎管狭窄不明显，也容易诊断为压缩性骨折。但表3中3个指标值可验证模型分类性能整体上表现良好。

3.4 可视化分析

为验证本文提出的改进模型对胸腰椎骨折CT图像分类的特征学习能力，随机挑选了6张不同骨折类型以及正常的CT图像，利用梯度加权分类激活映射（gradient-weighted class activation mapping, Grad-CAM）方法^[36]生成网络模型的可视化热力图，如图11所示。

Grad-CAM方法生成的可视化热力图能够清晰地展示神经网络模型关注的区域。从图11可以看




图11 Grad-CAM可视化结果

出，对于压缩性和爆裂性骨折，热力图中的高亮区域精准定位于骨折部位。这表明模型在识别这些骨折类型时，能够聚焦于受损区域，从而利用相关特征进行正确分类。对于正常的骨骼CT图像，热力图的高亮区域则较为均匀地分布在骨骼结构上。这种分布特征表明，模型在判断骨骼正常时，综合评估了整个骨骼的结构完整性和均匀性。

对于压缩性骨折，热力图在压缩性骨折的CT影像上高亮区域集中在椎体的压缩变形部位，反映了模型对椎体高度丧失和变形的关注。热力图在爆裂性骨折的CT影像上的高亮区域覆盖了椎体碎片

表3 ResNet模型的准确率、精确率和召回率

数据集	类型	图像数量	TP	TN	FP	FN	准确率	精确率	召回率
测试集	A	26	20	73	6	6	88.57%	76.9%	76.9%
	B	38	31	71	8	7	87.18%	79.5%	81.6%
	C	15	13	78	1	2	96.81%	92.9%	86.7%

的分布区域,尤其是在椎体前缘和中央区,这反映了模型对骨折碎片分布和脊髓压迫风险的关注。在正常的骨骼CT图像上,热力图的高亮区域均匀分布于骨骼各个部分,这说明模型在评估正常骨骼时,没有集中于某一特定区域,而是全面分析了骨骼的结构均匀性和完整性。综上,本文改进的CNN模型可以准确注意到骨折CT图像中受损的区域并给出正确分类。

4 结束语

本文基于四川省中西医结合医院的胸腰椎骨折CT图像数据,针对ResNet-50模型的全连接层进行了创新性改进。通过将原始的两层全连接层替换为三层更为细致的全连接层,参数量减少了73%。同时采用冻结卷积层权重初始训练和微调卷积层权重的渐进式训练策略,确保模型充分利用预训练特征,同时通过微调进一步优化模型,适应新数据特性。这种两阶段训练方法在保证模型稳定性的同时,显著提升了模型的泛化能力和性能。这一改进在保证模型高准确率的同时,显著加速了训练过程并减小了模型整体规模。采用改进后的ResNet-50*模型在多个性能指标上表现优异,在训练、验证和测试集上的准确率、模型大小以及训练时间都优于其他主流网络模型。混淆矩阵反映出对于分类错误的A类和B类,分类模型将1个B类判断为C类,将6个B类判断为A类,判断错误的原因可以归纳为两个方面。一方面是数据集数量不够多,骨折的特征较多,计算机视觉算法识别的特征不够多;另一方面临床中有一些比较稳定的爆裂性骨折,骨折线虽累及椎体后缘,但没有明显分离错位,压迫脊髓,椎管也没有确切狭窄,或者骨折线未见明显累及椎体后缘,但骨折块略突入椎管,椎管狭窄不明显,也容易诊断为压缩性骨折。AI识别时择取的横断位、矢状位断面也重要,单看一个断面也容易识别错误。未来工作应致力于扩大数据集规模,包含更多类型和复杂程度的骨折样本。这将有助于提高模型在不同临床情境下的适应性和鲁棒性。同时应结合患者的临床信息,如年龄、性别、病史等,构建更为全面的预测模型,从而提高诊断的精准度。

参考文献:

- [1] HAVAEI M, DAVY A, WARDE-FARLEY D, et al. Brain tumor segmentation with deep neural networks[J]. Medical Image Analysis, 2017, 35: 18-31.
- [2] PEREIRA S, PINTO A, ALVES V, et al. Brain tumor segmentation using convolutional neural networks in MRI images[J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1240-1251.
- [3] MENZE B H, JAKAB A, BAUER S, et al. The multimodal brain tumor image segmentation benchmark (BRATS) [J]. IEEE Transactions on Medical Imaging, 2015, 34(10): 1993-2024.
- [4] CHRIST P F, ELSHAER M E A, ETTLINGER F, et al. Automatic liver and lesion segmentation in CT using cascaded fully convolutional neural networks and 3D conditional random fields[M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2016: 415-423.
- [5] ROTH H R, LU L, FARAG A, et al. DeepOrgan: multi-level deep convolutional networks for automated pancreas segmentation[M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2015: 556-564.
- [6] ZHOU X R, TAKAYAMA R, WANG S, et al. Deep learning of the sectional appearances of 3D CT images for anatomical structure segmentation based on an FCN voting method[J]. Medical Physics, 2017, 44(10): 5221-5233.
- [7] 邵虹, 张鸣坤, 崔文成. 基于分层卷积神经网络的皮肤镜图像分类方法[J]. 智能科学与技术学报, 2021, 3(4): 474-481.
SHAO H, ZHANG M K, CUI W C. Classification method of dermoscopic image based on hierarchical convolution neural network[J]. Chinese Journal of Intelligent Science and Technology, 2021, 3(4): 474-481.
- [8] 王禾扬, 杨启鸣, 朱旗. 基于深度卷积集成网络的视网膜多种疾病筛查和识别方法[J]. 智能科学与技术学报, 2021, 3(3): 256-267.
WANG H Y, YANG Q M, ZHU Q. Retinal multi-disease screening and recognition method based on deep convolution ensemble network[J]. Chinese Journal of Intelligent Science and Technology, 2021, 3(3): 256-267.
- [9] OLCZAK J, FAHLBERG N, MAKI A, et al. Artificial intelligence for analyzing orthopedic trauma radiographs[J]. Acta Orthop, 2017, 88(4): 581-586.
- [10] 余锦娟, 林勇. 基于机器学习的骨质疏松性骨折预测研究[J]. 中国医学物理学杂志, 2018, 35(11): 1329-1333.
YU J J, LIN Y. Prediction of osteoporotic fractures based on machine learning[J]. Chinese Journal of Medical Physics, 2018, 35(11): 1329-1333.
- [11] BURNS J E, YAO J H, SUMMERS R M. Vertebral body compression fractures and bone density: automated detection and classification on CT images[J]. Radiology, 2017, 284(3): 788-797.
- [12] ZHANG X P, ZHANG Y C, ZHANG G J, et al. Deep learning with radiomics for disease diagnosis and treatment: challenges and potential[J]. Frontiers in Oncology, 2022, 12: 773840.
- [13] BIAMONTE E, LEVI R, CARRONE F, et al. Artificial intelligence-based radiomics on computed tomography of lumbar spine in subjects with fragility vertebral fractures[J]. Journal of Endocrinological Investigation, 2022, 45(10): 2007-2017.
- [14] LIU H, JIAO M L, YUAN Y, et al. Benign and malignant diagnosis of spinal tumors based on deep learning and weighted fusion framework on MRI[J]. Insights into Imaging, 2022, 13(1): 87.
- [15] YODA T, MAKI S, FURUYA T, et al. Automated differentiation between osteoporotic vertebral fracture and malignant vertebral fracture on MRI using a deep convolutional neural network[J]. Spine, 2022, 47(8): 347-352.
- [16] CHEN H Y, HSU B W Y, YIN Y K, et al. Application of deep learning algorithm to detect and visualize vertebral fractures on plain frontal radiographs[J]. PLoS One, 2021, 16(1): e0245992.
- [1] HAVAEI M, DAVY A, WARDE-FARLEY D, et al. Brain tumor segmentation with deep neural networks[J]. Medical Image Analysis,

- [17] MURATA K, ENDO K, AIHARA T, et al. Artificial intelligence for the detection of vertebral fractures on plain spinal radiography[J]. Scientific Reports, 2020, 10(1): 20031.
- [18] LI Y C, CHEN H H, LU H H S, et al. Can a deep-learning model for the automated detection of vertebral fractures approach the performance level of human subspecialists? [J]. Clinical Orthopaedics and Related Research, 2021, 479(7): 1598-1612.
- [19] CHOU P H, JOU T H T, WU H T H, et al. Ground truth generalizability affects performance of the artificial intelligence model in automated vertebral fracture detection on plain lateral radiographs of the spine[J]. The Spine Journal: Official Journal of the North American Spine Society, 2022, 22(4): 511-523.
- [20] SHEN L, GAO C, HU S D, et al. Using artificial intelligence to diagnose osteoporotic vertebral fractures on plain radiographs[J]. Journal of Bone and Mineral Research, 2023, 38(9): 1278-1287.
- [21] NAGUIB S M, HAMZA H M, HOSNY K M, et al. Classification of cervical spine fracture and dislocation using refined pre-trained deep model and saliency map[J]. Diagnostics, 2023, 13(7): 1273.
- [22] ZHANG J L, LIU F, XU J X, et al. Automated detection and classification of acute vertebral body fractures using a convolutional neural network on computed tomography[J]. Frontiers in Endocrinology, 2023, 14: 1132725.
- [23] ZHANG J, XIA L, LIU J Y, et al. Exploring deep learning radiomics for classifying osteoporotic vertebral fractures in X-ray images[J]. Front Endocrinol, 2024(15): 1370838.
- [24] CHEE C G, YOON M A, KIM K W, et al. Combined radiomics-clinical model to predict malignancy of vertebral compression fractures on CT[J]. European Radiology, 2021, 31(9): 6825-6834.
- [25] 邵虹, 左常升, 张萍. 结合 Attention U-Net 与瓶颈检测的肺部细胞图像分割方法[J]. 智能科学与技术学报, 2022(4): 610-616.
- SHAO H, ZUO C S, ZHANG P. Lung cell image segmentation method combining Attention U-Net and bottleneck detection[J]. Chinese Journal of Intelligent Science and Technology, 2022(4): 610-616.
- [26] SHORTEN C, KHOSHGOFTAAAR T M. A survey on image data augmentation for deep learning[J]. Journal of Big Data, 2019, 6(1): 60.
- [27] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2014: 818-833.
- [28] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [29] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB]. arXiv preprint, 2014, arXiv: 1409.1556.
- [30] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2015: 1-9.
- [31] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2016: 770-778.
- [32] ZHUANG F Z, QI Z Y, DUAN K Y, et al. A comprehensive survey on transfer learning[J]. Proceedings of the IEEE, 2021, 109(1): 43-76.
- [33] 庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1): 26-39.
- ZHUANG F Z, LUO P, HE Q, et al. Survey on transfer learning research[J]. Journal of Software, 2015, 26(1): 26-39.
- [34] YOSINSKI J, CLUNE J, BENGIO Y, et al. How transferable are fea-

tures in deep neural networks?[J]. Advances in Neural Information Processing Systems, 2014, 4(1): 3320-3328.

- [35] RAZAVIAN A S, AZIZPOUR H, SULLIVAN J, et al. CNN features off-the-shelf: an astounding baseline for recognition[C]//Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE Press, 2014: 512-519.
- [36] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848.

[作者简介]



郝引 (1986-), 女, 成都医学院医学影像学学士, 主治医师, 主要研究方向为神经系统及肌骨系统疾病的影像学诊断。



陈馨 (1982-), 女, 川北医学院医学影像学学士, 副主任医师, 主要研究方向为生殖系统及肌骨系统疾病的影像学诊断。



莫云海 (1981-), 男, 川北医学院医学影像学学士, 主任医师, 主要研究方向为消化系统及血管影像学诊断。



吴禄源 (1990-), 男, 河南省人工智能算法中心副教授, 主要研究方向为人工智能与岩石力学、城市内涝灾害智能视觉识别。



仝敬博 (1998-), 男, 河南省人工智能算法中心硕士生, 主要研究方向为城市内涝灾害智能视觉识别。