

DOI:10.13364/j.issn.1672-6510.20240136

网络首发日期: 2025-01-21; 网络首发地址: <http://link.cnki.net/urlid/12.1355.N.20250120.1739.001>

## 医学图像检测和分割模型在肋骨骨折诊断中的应用进展

赵婷婷<sup>1</sup>, 郭宇<sup>1</sup>, 才佳<sup>1</sup>, 罗嗣频<sup>2</sup>, 孙志伟<sup>1</sup>, 畅卫功<sup>1</sup>

(1. 天津科技大学人工智能学院, 天津 300457; 2. 天津医院放射科, 天津 300211)

**摘要:** 肋骨骨折是一种高发疾病, 具有较高的误诊率, 对于医学图像处理技术的诊断速度和准确率要求较高, 而图像检测与分割是实现肋骨骨折诊断的关键技术。本文综述了当前医学图像检测和分割模型在肋骨骨折诊断中的研究进展。首先对当前主流的图像检测和分割模型进行了系统介绍, 然后对现有模型进行归纳和总结, 分析了基于深度模型骨折诊断的各种算法, 最后利用 RibFrac 挑战赛的公共数据库对模型进行对比分析。研究表明, 基于图像检测和分割的肋骨骨折诊断方法在临床上已经有了长足的发展。然而, 模型训练过程中容易受到样本数据的干扰, 三维数据需要耗费大量的时间和资源, 并且新模型和新技术难以实现。因此, 在肋骨骨折诊断方面, 图像检测和分割模型仍面临着许多挑战, 有较大的发展空间。

**关键词:** 图像检测模型; 图像分割模型; 肋骨骨折; RibFrac; U-Net

中图分类号: TP391

文献标志码: A

文章编号: 1672-6510(2025)01-0001-12

## A Review of Advances in Medical Image Detection and Segmentation Models for Rib Fracture Diagnosis

ZHAO Tingting<sup>1</sup>, GUO Yu<sup>1</sup>, CAI Jia<sup>1</sup>, LUO Sipin<sup>2</sup>, SUN Zhiwei<sup>1</sup>, CHANG Weigong<sup>1</sup>

(1. College of Artificial Intelligence, Tianjin University of Science and Technology, Tianjin 300457, China;

2. Department of Radiology, Tianjin Hospital, Tianjin 300211, China)

**Abstract:** Rib fracture is a high incidence disease with high misdiagnosis rate, so the diagnostic speed and accuracy requirements for medical image processing technology are high, and image detection and segmentation is the key technology to achieve rib fracture diagnosis. Therefore, the current research progress in the application of medical image detection and segmentation models in rib fracture diagnosis is reviewed in this article. Specifically, the current mainstream image detection and segmentation models are firstly introduced systematically, then the present models are summarized and concluded, and various fracture diagnosis algorithms based on depth models are analysed, and finally, a comparative analysis of the models is conducted using the RibFrac Challenge public database. The study shows that rib fracture diagnosis methods based on image detection and segmentation have made great strides in clinical practice. However, the model training process is susceptible to interference from sample data, 3D data is time-consuming and resource-intensive, and it is difficult to implement new models and technologies. Therefore, there are a lot of challenges and opportunities to develop in the diagnosis of rib fracture.

**Key words:** image detection model; image segmentation model; rib fracture; RibFrac; U-Net

**引文格式:**

赵婷婷, 郭宇, 才佳, 等. 医学图像检测和分割模型在肋骨骨折诊断中的应用进展[J]. 天津科技大学学报, 2025, 40(1): 1-12.

ZHAO T T, GUO Y, CAI J, et al. A review of advances in medical image detection and segmentation models for rib fracture diagnosis[J]. Journal of Tianjin university of science and technology, 2025, 40(1): 1-12.

收稿日期: 2024-07-03; 修回日期: 2024-10-23

基金项目: 国家自然科学基金项目(61976156)

作者简介: 赵婷婷(1986—), 女, 内蒙古赤峰人, 教授, [tingting@tust.edu.cn](mailto:tingting@tust.edu.cn)

肋骨骨折是临床中最常见的胸部外伤,即整个或局部的肋骨结构的连续断裂<sup>[1]</sup>,具有较高的发病率、死亡率和误诊率。随着人们生活方式的转变以及人口老龄化问题的加重,肋骨骨折的发生率呈上升趋势。该病多见于儿童及老年人,其产生的原因有多种,如交通事故、高空跌落、打架斗殴等<sup>[2]</sup>。约 12% 的肋骨骨折患者会发生死亡,中青年人肋骨骨折的死亡率约为 10%,老年人则跃升至 22%,患者的死亡率与肋骨骨折的数量成正比<sup>[3]</sup>。确定诊断肋骨骨折的数目有助于临床医生对患者创伤程度的诊断<sup>[4]</sup>。由于骨折发病突然,因此对诊断的速度和准确率提出了更高的要求。如果不能及时、准确地做出正确的诊断,就会导致患者的预后不佳。因此,对肋骨骨折病灶区域快速、精准定位对于后续的治疗至关重要。

近几十年来,以 X 射线(X-ray)<sup>[5]</sup>、计算机断层扫描(computed tomography, CT)<sup>[6-7]</sup>、磁共振成像(nuclear magnetic resonance imaging, MRI)<sup>[8]</sup>、超声为代表的医学成像技术得到了飞速发展,使放射科医师和普通内科医师能够快速、准确地做出判断。虽然这些方法可以大大改善普通诊断的准确率,但是这对医师的能力要求很高。与此同时,医疗影像数据的日益庞大,给医师带来了巨大的负荷,因此亟需一种能够帮助医师快速诊断的图像检测和分割算法,从而提升医师的工作效率,减少医师的工作量。当前医疗相关的辅助诊断及应用研究逐渐成为计算机视觉领域的热点,建立“智慧化”的诊疗系统已成为我国健康产业未来发展的重要方向之一。

早期计算机辅助诊断技术主要是从影像学的视角辅助影像医师作出更加精确的诊断<sup>[3]</sup>,其特点在于通过三维重构或曲面重构,可以让医师从不同的视角更加清晰地看到肋骨骨折,从而减少误诊。目前,医学图像辅助诊断系统主要利用计算机和图像处理技术,协助医师诊断和评估患者的病情。基于图像处理、机器学习和深度学习等技术,依据问题的复杂性和样本量,选择合适的机器学习模型,从而提高临床诊断的准确率和图像判读的速度。

深度学习是由多层非线性变换构成的分层学习算法,其实质是将底层特征进行融合,得到最优特征<sup>[9]</sup>。与传统方法相比,深度学习可以从数据中自动抽取高层抽象特征,其在医学图像的分类<sup>[10-12]</sup>、分割<sup>[13-15]</sup>和检测<sup>[16]</sup>等方面表现出独特的优越性。基于图像分割的方法对肋骨骨折的诊断和预后评价具有重要意义,已成为计算机视觉研究的一个方向。经过

几十年的发展,已经有许多方法被提出并广泛应用<sup>[17]</sup>。医学影像分割方法就是为了满足医疗诊断与临床治疗的需要,将影像中病灶区域准确分割出来的一项重要技术,也是影像质量分析的前提。因此,精确、高效的医学影像分割可以为医生提供极大帮助,对疾病的诊断和后期评估具有重要作用<sup>[18]</sup>。

鉴于此,本文以现有的肋骨骨折图像分割模型为起点,综述了当前主流的图像分割方法。同时,本文从结构和非结构两个方面对各模型结构的改进进行了归纳分析,并对相关措施进行了总结。此外,本文还探讨了基础的分割模型及其改进模型在肋骨骨折图像分割处理领域的应用效果,并进行了统计分析和论述。最后,本文总结了改进网络模型在肋骨骨折图像处理中的应用,综述了当前的重点和难点,并对未来相关工作的开展提出了建议,旨在为后续的网络改善提供相应的参考。

## 1 图像分割模型

医学图像分割技术能够将图像划分成多个独立的、具有特征的区域,在定量分析、临床诊断和医疗干预等方面有着广泛的应用前景。医学影像分割具有多模态、多尺度、有效性等特征。

医学图像通常是多模态的,通过多种成像技术,如 X-ray<sup>[5]</sup>、CT 图像<sup>[6-7]</sup>、磁共振成像<sup>[8]</sup>等,获取更全面的信息以支持分割。由于不同影像学方法提供不同的观察角度和组织特征,将多模态图像有机融合在一起,可以有效提高图像分割的精度和可信度。不同医学图像具有不同的模态和分辨率,因此在医学图像分割中需要考虑多模态数据融合的特点。通过多模态分割,能够突破单一模式的局限,实现对肿瘤、器官、组织等目标区域的有效识别,从而更准确地区分不同组织或病灶区域,提升对肿瘤、器官和组织的识别能力<sup>[19]</sup>。

多尺度处理是指采用多尺度的图像分割方法,克服不同尺度下的数据缺失和模糊问题。医疗影像中的组织和病灶在尺寸和形态上差异显著,为更好地描述这些特征,需要对不同尺度的图像进行分割。传统的基于像素点的分割算法难以满足多尺度的需求,而多尺度分割方法能够有效解决单个尺度上的不足,同时兼顾多个层次的数据结构<sup>[20-22]</sup>。

有效性是指在给定的时间段内,对图像进行准确分割。如何保证图像的有效分割是医学图像处理中

的一个关键问题,这涉及利用较少的标签数据迅速适应新数据的问题。医学图像的分割结果对后续图像处理质量有很大的影响,因而对图像分割的效率和准确度要求很高。通过有效的分割算法,可以精确定位和描述感兴趣的区域,为临床医生提供新的诊疗思路和方法,提高工作效率,减轻工作负担,并有助于提高医学诊断的准确率。

传统的语义分割方法有基于阈值<sup>[23]</sup>、基于聚类<sup>[20]</sup>、基于边缘<sup>[21]</sup>和基于区域<sup>[22]</sup>等分割方法。然而,这些方法的计算复杂度高、耗时长,且难以有效处理大规模图像和背景复杂、具有噪声等的图像,因此分割结果准确率较低,适用范围受限。随着深度神经网络的出现,图像分割技术采用图像检测和分割模型作为基本框架,例如全卷积神经网络、U-Net 模型、FracNet 模型、Faster RCNN (region with CNN feature, RCNN) 模型等,并在其基础上进行改进,以获得更高准确率和分割精度的模型。

### 1.1 全卷积神经网络

全卷积神经网络 (fully convolutional networks, FCN) 是 Long 等<sup>[24]</sup>提出的一种端到端的图像语义分割框架(图 1<sup>[24]</sup>),是深度学习用于语义分割领域的先驱之作。相比经典的深度模型 AlexNet<sup>[25]</sup>、VGGNet<sup>[26]</sup>、GoogleNet<sup>[27]</sup>等,FCN 在训练过程中学习卷积核的参数,并针对图像尺寸进行设定,其使用全卷积化处理逐个像素的预测问题,因此能够接受任何尺寸的图像作为输入。




图 1 全卷积神经网络结构

Fig. 1 Structure of fully convolutional networks

整个卷积网络由完全卷积神经网络和反卷积两个部分组成,利用经典的卷积网络,如 VGG、ResNet<sup>[28]</sup>等,进行特征提取。在反卷积运算中,对已有语义分割的图像进行上采样,获得原始意义上的分割结果。全卷积神经网络以任意大小的图像作为输入,输出的图像与输入维数保持一致,信道数目为  $n+1$ ,其中  $n$  表示对象类数目,1 表示背景个数。

在特征提取过程中,由于卷积运算、池化运算等操作,特征图的尺寸会逐渐减小,因此密集的像素预测需要经过上采样才能实现。双线性插值 (bilinear) 可以实现上采样,通常由固定的卷积核通过转置卷积 (transposed convolution) 实现。当仅通过上采样获得原始图像尺寸时,其分割结果通常不够理想。由于最后一层的特征图细小,会造成细节缺失。为此,采用跳跃连接把带有全局信息的预测和局部信息的浅层预测结合起来,从而实现局部与整体的有效结合。

FCN 的优点是具有多层特征学习,它能够从多个层面上对特征进行学习。浅层卷积更接近输入图像,可以捕获更局部、更具体的特征;深层卷积可以获得更广的感知范围,从而可以学习到更为抽象的特性。

由于全卷积化会导致信息丢失,因此 FCN 无法捕获高分辨率的特征信息。FCN 针对图像边界区域不敏感,导致模型在分割边界处出现毛刺或断裂的问题。同时,由于全卷积神经网络对标记数据的要求较高,运算量也较大,因此它的适用范围受到了很大的限制。

### 1.2 U-Net

U-Net 是 2015 年由 Ronneberger 等<sup>[29]</sup>在全卷积神经网络基础上提出的一种适用于医学图像分割的端到端深度神经网络模型,目前广泛应用于图像分割处理,其网络结构如图 2<sup>[29]</sup>所示。U-Net 是典型的编码器-解码器网络结构,为对称结构,由编码器(左侧)、解码器(右侧)和跳跃连接 3 部分组成。

在编码过程中,利用传统的卷积神经网络进行特征提取。在此过程中,通过对图像进行下采样提取特征,并将其分解为多个层次的语义信息。每一步由 2 个  $3 \times 3$  的非填充卷积和 ReLU 激活函数构成。另外,特征图采用  $2 \times 2$  最大池化层进行下采样,卷积层数增加使通道数增加。通过连续的  $3 \times 3$  卷积运算,在保持原始分割精度的同时,减少了网络的计算复杂性。最大池化层的持续缩减,本质上是用更少的编码表达原始信息,有助于提取图像中的重要特征。经过多次最大池化后,该模型能够从显著特征中提取更显著的特征。

解码部分可以看作是一种特征融合网络,路径包括 2 个连续的  $3 \times 3$  卷积、ReLU 激活函数以及上采样操作。对特征图进行上采样恢复分辨率,将特征图的通道数目减少一半。相较于传统的反卷积上采样方法,解码器采用跳跃连接,对左侧传入的特征图进

行裁剪,使二者维度相同,再进行拼接和卷积运算,提取图像的特征,实现低层位置和深度语义信息的

融合。




图 2 U-Net 结构

Fig. 2 Structure of U-Net

U-Net 的良好性能与其自身网络结构以及医疗影像的特性紧密相关。首先,医学影像的结构相对于自然影像来说是固定的,语义也较为单一,所以高层与底层特征可以互补。底层特征可以作为精确的分割基础,而高层的特征可以作为目标的识别基础。其次,医疗图像具有复杂的边界和梯度,这就要求有充分的高分辨信息对分割的轮廓进行细化。同时,U-Net 结构的对称性、反卷积和跳跃连接,将多个尺度的特征进行有效融合,赋予高层高分辨信息,提升分割精度。这些特性使其在医学影像分割等方面有很好的应用前景。

U-Net 与 FCN 网络一样,都是通过编码和解码的方式实现对图像的分割。不过,与 FCN 相比,U-Net 的结构特点是完全对称。在跳跃连接节点中,U-Net 采用拼接方法实现特征融合。由于 U-Net 的算法灵活、简单,在小样本条件下也能得到很好的分割结果,因此它是目前医学影像分割的主流算法。但是,现有 U-Net 的算法都是基于二维卷积实现,因此该算法在学习过程中没有得到很好的利用。针对以上问题,研究人员提出了一系列 U-Net 的改进模型,如 3D U-Net、NNU-Net 等,以满足实际应用需求。

### 1.3 FracNet

U-Net 最初是以二维影像为主,而目前常用的核磁共振、计算机断层扫描、三维超声成像等医学成像

技术的成像结果均为三维影像,这对影像处理提出了更高要求。Çiçek 等<sup>[30]</sup>改进了 U-Net,提出了 3D U-Net,并将其用于三维图像处理。与传统的 U-Net 相比,两者在结构上是相同的,其最大的不同之处在于模型训练数据的维度不同,并将卷积、池化等运算用三维的卷积层和池化代替,具体结构如图 3<sup>[30]</sup>所示。因此,3D U-Net 能够更好地保持三维数据的空间信息,捕捉三维结构的上下文信息,在处理体数据时具有更大的优势。




图 3 3D U-Net 结构

Fig. 3 Structure of 3D U-Net

由于 3D U-Net 能够同时考虑 3 个维度上的信息,在分割任务中通常能够得到更准确的结果,特别是在对肿瘤、肋骨骨折等需要精确分割的情况下,表现更为突出。在基于图像分割方法的研究中,Jin 等<sup>[31]</sup>建立了 3D U-Net 深度网络模型 FracNet,通过



RibFrac 数据库对该模型进行训练, 从而实现肋骨骨折的检测和分割。在改进的模型检测下, 医生的诊断效率得到提高, 时间减少了 86%。

但是, 在三维卷积中, 存在着数据量与参数之间的匹配问题, 所需参数较多, 且存在过拟合等问题。同时, 3D U-Net 占用大量的内存资源, 在一定程度上消耗了大量的时间, 不利于快速分割骨折区域。

#### 1.4 Faster RCNN

RCNN(region with CNN feature)<sup>[32]</sup>是基于深度学习进行检测的先驱之作, 其核心思想是利用选择性搜索(selective search, 简称 SS 算法)产生候选框, 在此基础上, 采用深度神经网络提取各候选区域的特征, 将这些特征输入各个类别的支持向量机(SVM)分类器中, 获得候选区域的位置。由于 RCNN 存在训练速度慢、所需空间大等缺点, 因此 Girshick<sup>[33]</sup>提出了 Fast RCNN。该方法是将 SS 算法生成的候选区域映射到特征图上, 再根据所关注的区域点对特征图进行缩放, 达到对图像进行预测的目的。尽管 Fast RCNN 速度有所提升, 但是速度瓶颈仍然存在。因此, 在 RCNN<sup>[32]</sup>和 Fast RCNN<sup>[33]</sup>的基础上, Ren 等<sup>[34]</sup>提出了 Faster RCNN(如图 4<sup>[34]</sup>所示)。




图 4 Faster RCNN 网络结构

Fig. 4 Structure of Faster RCNN

当前在计算机视觉领域, YOLO(you only look once)是一系列具有开创性的目标检测模型, 每个版本都对目标检测领域有巨大贡献。YOLOv1 到 YOLOv10 的发展展示了模型架构、训练方法和性能优化等方面的显著变化, 是当前研究的热点模型。但是, 在骨折诊断领域, CT 图像中骨折区域相对较小, 相比于 YOLO 模型, Faster RCNN 在小目标检测和复杂场景中的表现更突出。

在结构上, Faster RCNN 融合了特征提取(feature extraction)、方案提取(proposal extraction)、边界框回归(bounding box regression)、分类(classification), 显著提升了系统的综合性能, 特别是在检测速度上。

Faster RCNN 主要分为卷积层(convolution layers)、区域提取网络(region proposal networks, RPN)、感兴趣区域池化(ROI pooling)和分类(classification)4 个模块。卷积网络由一系列的卷积、激活函数和池化层组成, 对图像进行特征映射。在 RPN 和完全连通层中, 将这些特性图采用 RPN 神经网络生成区域提取算法。区域提取根据 Softmax 判定是阳性还是阴性, 然后利用边界框回归方法进行修正, 得到精确的结果。ROI pooling 层采集输入的特征图和候选区域(proposals), 并对其进行汇总, 然后抽取区域特征图, 将其送到下一个全连接层进行分类判断。分类层使用区域特征图计算候选区域的分类, 然后通过边界框回归得到最后的检测框的准确位置。

Zhang 等<sup>[35]</sup>提出一种由 Foveal 网络<sup>[36]</sup>和 Faster RCNN 网络组成的肋骨骨折检测模型, 用于辅助放射科医师提高肋骨骨折 CT 检测的准确率和读取效率。通过 Foveal 网络获取肋骨的分割掩码, 将该掩码输入 Faster RCNN 网络中, 并提出肋骨骨折候选点, 其在骨折诊断中的性能<sup>[37]</sup>比 YOLOv3<sup>[38]</sup>的效果好, 因此选择 Faster RCNN 作为辅助医生诊断的模型。这使医生诊断的准确率提高了 10.8%。

## 2 图像分割模型在肋骨骨折诊断中的改进方法

随着人工智能技术在医疗领域的蓬勃发展, 利用深度学习方法不断改进医学诊断是科研工作者的追求目标。传统的分割网络在医学图像分割领域已经显示出一定的效果, 但在实际医学应用中, 尤其是在肋骨骨折诊断方面, 情况更为复杂。结合实际问题对模型进行优化, 也是当前骨折诊断技术中的一项迫切需求。针对在当前临床中存在的肋骨骨折诊断问题, 根据分割目的的不同, 从结构和非结构两个方面对图像分割模型进行改进。

### 2.1 非结构性改进

非结构性改进是指通过非模型结构角度的改进, 包括数据预处理、激活函数及后期处理等。模型的预处理、训练等各个环节之间并非独立存在, 其对模型的整体性能会有很大影响。Isensee 等<sup>[39]</sup>从预处理、训练和后期处理 3 个方面对 U-Net 模型进行改进, 提出了 NNU-Net, 这一改进在提升模型性能方面起到了重要作用。

#### 2.1.1 数据增强

数据增强是在通过对已有数据进行一系列的转

换或修正,产生新的数据,从而提高训练数据的规模与多样性,扩大数据集。数据增强算法通常依赖于特定的任务、数据集的特点和对模型的要求。对于肋骨骨折 CT 图像的数据增强,常见的方法包括随机旋转或翻转图像、添加高斯噪声、随机剪裁、弹性变形等。在医学图像分割问题中,存在难以获取海量标注数据的问题<sup>[30]</sup>,而在基于小样本的深度学习模型训练中,容易出现过拟合的情况<sup>[29]</sup>。数据增强技术通过在样本中加入一定的随机性和多样性,提高模型对样本的自适应性,从而降低对训练样本的过拟合程度,使模型能够更适应不同的输入数据。

FracNet<sup>[31]</sup>不仅采用了旋转、缩放、灰度值增强等方法,而且在数据和真实标签(ground truth)上都使用了平滑的密集变形区域。V-Net<sup>[40]</sup>采用随机非线性变换进行训练,并将转换后的图像输入密集变形场中。NNU-Net<sup>[39]</sup>利用旋转、缩放和弹性变换等方法随机对图像进行数据增强,以避免过拟合。通过数据增强,有效地解决了数据不足的问题,生成了更多的数据样本,增加了训练数据量和样本多样性。

### 2.1.2 激活函数

激活函数是深度神经网络模型改进的关键,它能在输入与输出之间建立一种非线性映射关系,使网络可以学习更复杂的信息<sup>[41]</sup>。

李智唯<sup>[42]</sup>对经典的图像分割模型 3D U-Net 进行优化,采用 LeakyReLU<sup>[43]</sup>代替原有的激活函数,解决了 ReLU 激活函数在负值区域为 0 的问题,其公式如式(1)所示,构建了 LUNet 网络(图 5<sup>[42]</sup>),从而更好地实现对肋骨骨折区域的分割,提高分割的精度和准确率。

$$f(x) = \begin{cases} a \times x & x < 0 \\ x & x \geq 0 \end{cases} \quad (1)$$




图5 LUNet网络结构  
Fig. 5 Structure of LUNet

## 2.2 结构性改进

结构性改进是指对模型网络结构的改进,通过修改网络结构提高模型的检测和分割精度,本节将针对下采样特征映射信息少等问题改进的网络结构进行归纳和总结。

### 2.2.1 NOL-LUNet

针对下采样特征映射信息较少的问题,李智唯<sup>[42]</sup>提出了一种基于轻量化非局部模块的改进 3D U-Net 网络(NOL-LUNet)。结构化改进方法分为两个部分。首先,对 LUNet 模型的非局部模块进行三维层面的改进,在 LUNet 网络的两个特定下采样层中加入 2 个三维非局部模块(3D non-local block<sup>[44]</sup>),从而增大模型的感受野,获得更多的全局信息。对于改进的 3D non-local 模块,实际上是将 non-local 模块中所有的二维卷积操作以及相应的参数计算转化为三维卷积操作和三维参数运算,具体过程如图 6<sup>[42]</sup>所示。其次,在上述改进的基础上,为了减少内存占用和计算量,对网络中指定位置采用分组卷积方法进行轻量级处理,从而降低训练过程中的计算量和参数量。

改进后的 NOL-LUNet 网络进一步提高了肋骨骨折病灶识别的准确率,对于缓解医院对 CT 图像质量和医师经验在肋骨骨折诊断和治疗上的过度依赖具有重要的学术和临床意义。

### 2.2.2 Rib-Net

针对检测精度低、漏诊率高等问题,何学才等<sup>[45]</sup>提出了 Rib-Net 网络结构,由目标检测集成网络 ED-Net、完全候选框融合算法(cross bilateral filter, CBF)<sup>[46]</sup>与分割模型 3D U-Net<sup>[30]</sup>构成,网络结构如图 7<sup>[45]</sup>所示。针对此网络的结构化改进主要分为两部分,分别是基于目标检测集成网络 ED-Net 和候选框融合算法。

目标检测集成网络 ED-Net,由 Retina U-Net<sup>[47]</sup>、UFRCNN+、Mask RCNN<sup>[48]</sup>组成,结构示意图如图 8<sup>[45]</sup>所示。

Retina U-Net 以 Retina Net<sup>[49]</sup>为主要架构,将语义损失计算引入网络的特征金字塔(feature pyramid networks, FPN)<sup>[50]</sup>  $P_0$  层中,利用反向传播将丢失的信息传递至各层级,从而实现对整个网络的语义监督。UFRCNN+ 以 Faster RCNN 为主要架构,FPN 进行特征提取,在  $P_0$  层进行全局语义损失计算,最后通过反向传播对第 2 层到第 5 层实现网络语义监督,以提高检测的准确率。 $P_0$  层的损失函数为

$$L = L_{CE} + L_{Dice} \quad (2)$$

Mask RCNN 通过利用候选框中的语义信息计算

划分损失, 并对子网络进行局部监督, 以提高检测准确率。

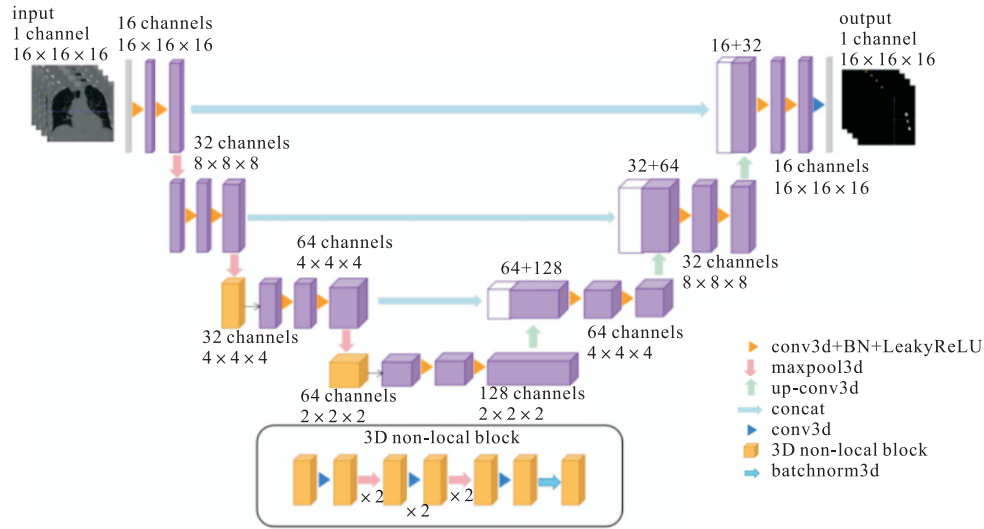


图 6 NOL-LUNet 网络结构  
Fig. 6 Structure of NOL-LUNet




图 7 Rib-Net 网络结构  
Fig. 7 Structure of Rib-Net

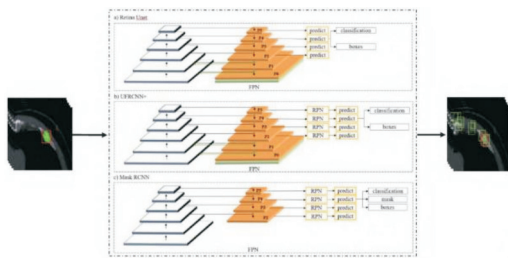


图 8 ED-Net 网络结构示意图  
Fig. 8 Structure diagram of ED-Net

基于 Rib-Net 的完全候选框融合算法可以对有重叠的区域进行融合, 从而得到定位准确、可信度高的候选框。基于加权盒融合 (weighted box fusion, WBF)<sup>[51]</sup>算法, 完全候选框融合算法通过对候选框的分类可信度进行加权融合, 得到一个新的候选框。但是, 分类子网与回归子网的优化目标不同, 分类信度并没有完全反映候选框的位置权值, 因而有一些不足。为此, 研究人员提出了 3 种新的度量方法: 交并比 (intersection over union, IoU<sup>[52]</sup>)、中心点距离  $d$  以及候选框的重叠框数量  $r$ , 以达到更好的预测结果。

最后, 将 U-Net 应用于肋骨骨折图像的分割中, 能够更准确地诊断肋骨骨折位置。

Rib-Net 网络中的 Retina U-Net 模块利用骨折语义监督信息使 FROC (free response ROC) 提升了 7%, CBF 模块的召回率提升了 0.02, 降低了高置信度假阳性候选框的置信度, Dice 系数提升了 0.03, 提高了候选框的定位精度, 使整个模型的检测效果达到最优, 可以有效协助医生进行骨折诊断。

### 2.2.3 DCNN

针对骨折识别与定位不准等问题, Lin 等<sup>[53]</sup>提出基于 DCNN 模型<sup>[25-26, 54-55]</sup>的肋骨骨折定位和诊断方法。将预处理后的数据经过 HourglassNet<sup>[56]</sup>的初级特征提取 (如图 9<sup>[56]</sup>所示) 和 Inception<sup>[27]</sup>的多尺度特征提取, 然后输入 DCNN 模型中。在 DCNN 模型的结构化改进中, 针对 V-Net 网络<sup>[57]</sup>性能差、计算量大等问题, 采用残差模块<sup>[28]</sup>和 Bottleneck 残差模块<sup>[58]</sup>对 V-Net 网络模型进行修正。整个流程先采用改进的 V-Net 网络<sup>[57]</sup>分割经过预处理数据的肋骨骨折区域, 再利用 VRN-Net<sup>[59]</sup>对关键点提取, 将其与关键点结合,



实现肋骨骨折裂缝区域的准确识别,并将其应用到临床诊断中。该模型能够实现对骨折点的自动识别,从而减少了医师人工定位的工作量,如图10<sup>[54]</sup>所示。

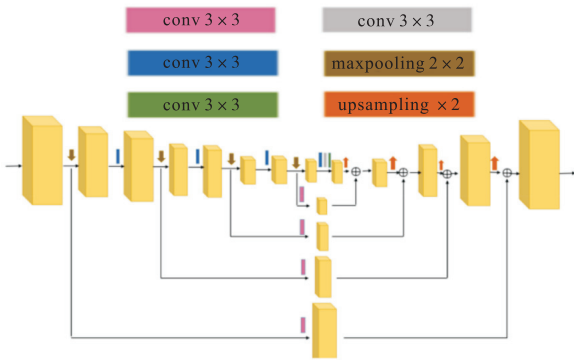


图9 HourglassNet网络结构  
Fig. 9 Structure of HourglassNet

在DCNN模型的辅助下,准确率提高了7.3%,召回率提高了10%,大大缩短了诊断时间,降低了漏检率和误检率,为提高胸部CT图像中肋骨骨折裂缝的诊断效率提供了可行性。

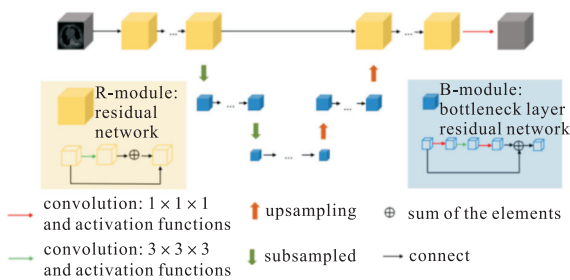


图10 DCNN网络结构  
Fig. 10 Structure of DCNN

### 3 数据集

在肋骨骨折诊断领域,通常采用“MICCAI 2020 RibFrac Challenge: Rib Fracture Detection and Classification”挑战赛提供的数据训练模型<sup>[31]</sup>,该挑战赛以复旦大学附属华东医院的660例胸部肋骨骨折患者的CT图像作为研究对象,并随机划分了3组数据集,针对数据集的具体划分见表1。

对于数据集中患者的胸腹CT图像,采用3D Slicer查看三维数据,以3个轴坐标方向进行展示,如图11所示。

语义分割常用的评价指标有FROC(free-response ROC)、召回率(recall)、交并比(intersection

over union, IoU)等,各研究方法在RibFrac数据集的表现结果见表2。

表1 RibFrac数据集划分

Tab. 1 Division of the RibFrac dataset

类别	训练集	验证集	测试集
胸腹CT图(images)	420	80	160
掩码图(masks)	420	80	无
骨折数量(处)	3 987	435	882
格式	NII	NII	NII




图11 RibFrac图像

Fig. 11 Images of RibFrac

表2 各研究方法在RibFrac的表现

Tab. 2 Performance of each research method in RibFrac

模型	FROC	召回率	Dice系数	IoU
NOL-LUNet	—	—	0.658	0.490
Retina Net+U-Net	0.723	0.878	0.530	—
Retina U-Net+U-Net	0.773	0.887	0.530	—
Retina U-Net+CBF+U-Net	0.785	0.882	0.560	—
Rib-Net	0.859	0.923	0.610	—
FracNet	—	—	0.715	0.556
3D FCN <sup>[24]</sup>	—	—	0.662	0.491
3D DeepLab <sup>[25]</sup>	—	—	0.687	0.503

FROC指标代表假阳性率-真阳性率曲线,是一种常用的医学影像诊断性能评估指标。FROC值通常针对每个阈值对应的假阳性的个数(FPs)和召回率(recall),计算每个点之间连线下的曲线面积。召回率是一种分类结果完整性的度量,反映了样本中的正例是否被正确预测,即在全部真实的阳性样本中,准确预测阳性样本的比例。IoU表示真实框和预测框的重合程度,在图像分割中是量化对象检测和分割中预测区域和真实区域之间重叠的基本指标。通过调整IoU值可以影响模型的精确率和召回率等指标,从而优化模型的性能。



## 4 肋骨骨折诊断应用

计算机辅助诊断系统是一种利用计算机技术辅助医生进行疾病诊断和治疗方案选择的系统。肋骨骨折辅助诊断系统是一种特定领域的计算机辅助诊断系统,旨在帮助医生更快速、更准确地诊断肋骨骨折,其结合了医学影像分析技术和机器学习算法,能够处理 X 射线、CT 扫描或 MRI 等医学影像数据。李秀涛<sup>[60]</sup>对人工智能(Artificial Intelligence, AI)辅助诊断技术在肋骨骨折早期 CT 诊断中的应用进行探索,如图 12 所示。Zhou 等<sup>[37]</sup>采用卷积神经网络作为辅助诊断系统,提高了诊断效率。Arpitha 等<sup>[61]</sup>提出建立基于 CT 图像的脊柱压缩性骨折诊断系统,用于检测、标记、分割腰椎区域,进而判定患者是否存在恶性压缩骨折等疾病。朱雅茹等<sup>[62]</sup>通过辅助诊断系统实现了对肋骨骨折病灶的分割,以此辅助医师进行正确诊断,如图 13 所示。





图 12 AI 诊断陈旧性骨折  
Fig. 12 AI diagnosis of old fractures




(a) 初诊 (b) 复查

图 13 右侧第 6 后肋无错位骨折及 1 个月后复查 CT 图像  
Fig. 13 CT images of undisplaced fracture of the right 6th posterior rib and reexamination after one month

白洁等<sup>[63]</sup>设计人工智能辅助肋骨骨折诊断系统,在胸部外伤致肋骨骨折患者的 CT 影像中诊断骨折区域,如图 14 所示。张斌等<sup>[64]</sup>设计基于深度学习的计算机辅助诊断系统,对首都医科大学大兴教学医院急性胸部外伤胸部 CT 检查的患者进行骨折诊断。熊山等<sup>[65]</sup>通过计算机辅助诊断系统与医师对 CT 图

像阅片进行比较,表明利用深度学习辅助医生阅片,可以增加诊断敏感性,在提高诊断效率的同时不增加假阳性率。张倩等<sup>[66]</sup>在推想科技提供的计算机辅助诊断系统中进行阅片,提高了模型在骨折诊断的数字 X 射线影像的灵敏度,降低了假阳性率。



(a) 受伤当日 (b) 伤后 3 个月

图 14 实际肋骨骨折案例的模型识别结果

Fig. 14 Model identification results for actual rib fracture cases

骨折辅助诊断系统能够自动识别医学影像中的肋骨,并检测可能存在的骨折。此外,系统能够根据机器学习算法学习肋骨骨折的特征和模式,从而在新的影像数据中自动识别和定位骨折区域。最后根据影像分析结果和患者的临床信息提供诊断建议,帮助医生作出准确的诊断和治疗方案选择。这样不仅可以快速处理大量的影像数据,有效缩短诊断时间,提高诊断准确率,而且减轻了医生的工作负担,对于急诊科、放射科等医疗部门具有重要意义。

## 5 展望

基于分割网络的改进在肋骨骨折诊断上已取得初步成果,具有广阔的应用前景。从评价指标来看,该方法优于传统方法,这表明基于深度神经网络的检测和分割模型在医学图像领域的应用具有重要意义。然而,在实际应用中仍然存在以下问题及挑战。

(1) 医学图像数据,尤其是高质量的肋骨 CT 图像,获取难度较大。同时,数据集单一,缺乏多样性,容易导致模型出现过拟合,数据的标注工作也极具挑战性,需要具有专业医学知识的研究人员进行精确标注。

(2) 在医学领域,CT 数据是三维的,但导入模型后需要大量的计算资源支持训练和推理,消耗时间长,这在实际应用中可能会受到限制。

(3) 肋骨骨折的类型多样,包括线性骨折、粉碎性骨折等,而且骨折部位可能伴随周围组织的水肿、出血等变化,增加了分割的难度。

因此,相关工作还有待完善和改进。基于上述问题,未来基于分割网络的改进和相关应用应集中在以下几个方面。

(1) 利用旋转、缩放、平移等数据增强方法对样本进行扩展,提升其推广能力。同时,通过对已有样本进行预训练得到的模型进行迁移,从而提高模型的训练速度。

(2) 尝试将三维数据与二维数据进行组合优化,弥补二维数据空间信息不足的缺点,减少三维数据带来的资源占用问题。

(3) 针对肋骨骨折的特点,可以设计更加精细的分割网络结构,如细粒度图像检测和分割方法,以提高准确率。

(4) 除了图像信息外,还可以结合患者的年龄、性别、病史等临床信息,为模型提供更加丰富的上下文信息,提高诊断的准确率。

## 6 结 语

本文介绍了图像检测与分割模型的结构和基本原理,并且从非结构性优化和结构性优化两个角度对模型的相关改进和应用进行了探讨和归纳。根据分析可知,当前关于肋骨骨折诊断的图像检测和分割模型主要是通过激活函数、损失函数、卷积层、FPN、残差模块等方式进行改进。在非结构性优化方面,当前更加重视对数据的预处理,通过改变激活函数,增强了模型的特征表示能力,提高了模型的稳定性和泛化能力。在结构性优化方面,改进方法使模型的维度和信息不丢失,通过调整感受野的大小进行有效的特征提取,最大程度保证图像的空间信息,提高模型运行的效率。

本文基于肋骨骨折领域的公开数据集 RibFrac,通过相关的评价指标,如 Dice 系数、IoU 值、召回率等,对模型的性能进行比较和总结,以期为临床医师进行肋骨骨折的诊治提供参考和帮助。同时,对网络结构的优化和性能的提高提出了改进建议。

随着深度学习的发展,深度网络模型及其优化在肋骨骨折诊断领域将会得到更加广泛的应用,有望推动肋骨骨折诊断领域的不断突破和创新。

### 参考文献:

- [1] SIRMALI M, TÜRÜT H, TOPÇU S, et al. A comprehensive analysis of traumatic rib fractures: morbidity, mortality and management[J]. *European journal of cardio-thoracic surgery*, 2003, 24(1): 133-138.
- [2] 杨金良, 黄刚. 肋骨骨折治疗策略、操作技术以及未来方向[J]. *创伤外科杂志*, 2016, 18(1): 1-5.
- [3] KHUNG S, MASSET P, DUHAMEL A, et al. Automated 3D rendering of ribs in 110 polytrauma patients: strengths and limitations[J]. *Academic radiology*, 2017, 24(2): 146-152.
- [4] JIN L, GE X, LU F, et al. Low-dose CT examination for rib fracture evaluation: a pilot study[J]. *Medicine*, 2018, 97(30): e11624.
- [5] MARY P R, JADOON M, DUFFY J. Nontraumatic rupture of the costal margin: a single-center experience[J]. *Asian cardiovascular and thoracic annals*, 2019, 27(2): 105-109.
- [6] MARINI C P, PETRONE P, SOTO-SÁNCHEZ A, et al. Predictors of mortality in patients with rib fractures[J]. *European journal of trauma and emergency surgery*, 2021, 47: 1527-1534.
- [7] BASS G A, DUFFY C C, KAPLAN L J, et al. The revised cardiac risk index is associated with morbidity and mortality independent of injury severity in elderly patients with rib fractures[J]. *Injury*, 2023, 54(1): 56-62.
- [8] GOU J, JIANG Z, WANG P, et al. Diagnostic value of multi-slice spiral CT scan in lung compression ratio of patients with pulmonary contusion complicated by pneumothorax or hydropneumothorax[J]. *American journal of translational research*, 2021, 13(4): 3004.
- [9] SONG L I, GEOFFREY K F, KAIJIAN H E. Bottleneck feature supervised U-Net for pixel-wise liver and tumor segmentation[J]. *Expert systems with applications*, 2020, 145: 113131.
- [10] TAGHANAKI S A, ABHISHEK K, COHEN J P, et al. Deep semantic segmentation of natural and medical images: a review[J]. *Artificial intelligence review*, 2021, 54: 137-178.
- [11] QURESHI I, YAN J, ABBAS Q, et al. Medical image segmentation using deep semantic-based methods: a review of techniques, applications and emerging trends[J]. *Information fusion*, 2023, 90: 316-352.
- [12] BINDHU V. Biomedical image analysis using semantic segmentation[J]. *Journal of innovative image processing*, 2019, 1(2): 91-101.
- [13] ROTH H R, SHEN C, ODA H, et al. Deep learning and its application to medical image segmentation[J]. *Med-*

- ical imaging technology, 2018, 36(2): 63–71.
- [14] 周涛,侯森宝,陆惠玲,等. 探析 U-Net 的改进机制及其在医学图像分割的应用[J]. 生物医学工程学杂志, 2022, 39(4): 806–825.
- [15] 周涛,董雅丽,霍兵强,等. U-Net 网络医学图像分割应用综述[J]. 中国图象图形学报, 2021, 26(9): 2058–2077.
- [16] HUANG B, TIAN J, ZHANG H, et al. Deep semantic segmentation feature-based radiomics for the classification tasks in medical image analysis[J]. IEEE Journal of biomedical and health informatics, 2020, 25(7): 2655–2664.
- [17] SEZGIN M, SANKUR B. Survey over image thresholding techniques and quantitative performance evaluation[J]. Journal of electronic imaging, 2004, 13(1): 146–168.
- [18] 黄晓鸣,何富运,唐晓虎,等. U-Net 及其变体在医学图像分割中的应用研究综述[J]. 中国生物医学工程学报, 2022, 41(5): 567–576.
- [19] 窦猛,陈哲彬,王辛,等. 基于深度学习的多模态医学图像分割综述[J]. 计算机应用, 2023, 43(11): 3385–3395.
- [20] HARTIGAN J A, WONG M A. Algorithm AS 136: a k-means clustering algorithm[J]. Journal of the royal statistical society: series C, 1979, 28(1): 100–108.
- [21] KIRILLOV A, WU Y, HE K, et al. PointRend: image segmentation as rendering[C]//IEEE. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2020: 9799–9808.
- [22] SIRMACEK B, UNSALAN C. A probabilistic framework to detect buildings in aerial and satellite images[J]. IEEE Transactions on geoscience and remote sensing, 2010, 49(1): 211–221.
- [23] OTSU N. A threshold selection method from gray-level histogram[J]. IEEE Transactions on system, man, and cybernetics, 1979, 9(1): 62–66.
- [24] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//IEEE. Proceedings of the IEEE conference on computer vision and pattern recognition. New York: IEEE, 2015: 3431–3440.
- [25] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Advances in neural information processing systems, 2012, 25: 3065386.
- [26] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. [2024-03-01]. <https://arxiv.org/pdf/1409.1556>.
- [27] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//IEEE. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2015: 1–9.
- [28] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//IEEE. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2016: 770–778.
- [29] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//Springer Cham. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Berlin: Springer, 2015: 234–241.
- [30] ÇIÇEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation[C]//MICCAI. Medical Image Computing and Computer-Assisted Intervention 2016: 19th International Conference. Berlin: Springer International Publishing, 2016: 424–432.
- [31] JIN L, YANG J, KUANG K, et al. Deep-learning-assisted detection and segmentation of rib fractures from CT scans: development and validation of FracNet[J]. eBioMedicine, 2020, 62: 103106.
- [32] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//IEEE. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2014: 580–587.
- [33] GIRSHICK R. Fast R-CNN[C]//IEEE. Proceedings of the IEEE International Conference on Computer Vision. New York: IEEE, 2015: 1440–1448.
- [34] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. Advances in neural information processing systems, 2017, 30(6): 1137–1149.
- [35] ZHANG B, JIA C, WU R, et al. Improving rib fracture detection accuracy and reading efficiency with deep learning-based detection software: a clinical evaluation[J]. The British journal of radiology, 2021, 94(1118): 20200870.
- [36] KONG T, SUN F, LIU H, et al. FoveaBox: beyond anchor-based object detection[J]. IEEE Transactions on

- image processing, 2020, 29: 7389–7398.
- [37] ZHOU Q Q, WANG J, TANG W, et al. Automatic detection and classification of rib fractures on thoracic CT using convolutional neural network: accuracy and feasibility[J]. Korean journal of radiology, 2020, 21 (7) : 869.
- [38] FARHADI A, REDMON J. YOLOv3: an incremental improvement[C]//Computer Vision and Pattern Recognition. Berlin: Springer, 2018, 1804: 1–6.
- [39] ISENSEE F, PETERSEN J, KLEIN A, et al. NNU-Net: self-adapting framework for U-Net-based medical image segmentation[EB/OL]. [2024-03-01]. <https://doi.org/10.48550/arXiv.1809.10486>.
- [40] MILLETARI F, NAVAB N, AHMADI S A. V-Net: fully convolutional neural networks for volumetric medical image segmentation[C]//IEEE. 2016 Fourth International Conference on 3D Vision(3DV). New York: IEEE, 2016: 565–571.
- [41] 张欢, 仇大伟, 冯毅博, 等. U-Net 模型改进及其在医学图像分割上的研究综述[J]. 激光与光电子学进展, 2022, 59(2) : 1–17.
- [42] 李智唯. 基于胸部 CT 图像的肋骨骨折病灶识别研究[D]. 济南: 山东中医药大学, 2023.
- [43] MAAS A L, HANNUN A Y, NG A Y. Rectifier nonlinearities improve neural network acoustic models [EB/OL]. [2024-03-01]. [http://robotics.stanford.edu/~amaas/papers/relu\\_hybrid\\_icml2013\\_final.pdf](http://robotics.stanford.edu/~amaas/papers/relu_hybrid_icml2013_final.pdf).
- [44] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C]//IEEE. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2018: 7794–7803.
- [45] 何学才, 金惊, 李铭, 等. 基于完全融合集成网络候选框的肋骨骨折检测方法[J]. 解剖学报, 2022, 53(3) : 396–401.
- [46] SHREYAMSHA-KUMAR B K. Image fusion based on pixel significance using cross bilateral filter[J]. Signal, image and video processing, 2015, 9: 1193–1204.
- [47] JAEGER P F, KOHL S A A, BICKELHAUPT S, et al. Retina U-Net: embarrassingly simple exploitation of segmentation supervision for medical object detection[C]//PMLR. Machine Learning for Health Workshop. New York: PMLR, 2020: 171–183.
- [48] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C]//IEEE. Proceedings of the IEEE International Conference on Computer Vision. New York: IEEE, 2017: 2961–2969.
- [49] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//IEEE. Proceedings of the IEEE International Conference on Computer Vision. New York: IEEE, 2017: 2980–2988.
- [50] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//IEEE. Proceedings of the IEEE International Conference on Computer Vision. New York: IEEE, 2017: 2117–2125.
- [51] SOLOVYEV R, WANG W, GABRUSEVA T. Weighted boxes fusion: ensembling boxes from different object detection models[J]. Image and vision computing, 2021, 107: 104117.
- [52] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//IEEE. Proceedings of the IEEE International Conference on Computer Vision. New York: IEEE, 2017: 7263–7271.
- [53] LIN Z, DAI W, LAI Q Q, et al. Deep learning-based computed tomography applied to the diagnosis of rib fractures[J]. Journal of radiation research and applied sciences, 2023, 16(2) : 100558.
- [54] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11) : 2278–2324.
- [55] ROLET P, SEBAG M, TEYTAUD O. Integrated recognition, localization and detection using convolutional networks[C]//ECML. Proceedings of the ECML Conference. Berlin: ECML, 2012: 1255–1263.
- [56] NEWELL A, YANG K, DENG J. Stacked hourglass networks for human pose estimation[C]//ECCV. Computer Vision-ECCV 2016: 14th European Conference. Berlin: Springer International Publishing, 2016: 483–499.
- [57] AKTOLUN C. Artificial intelligence and radiomics in nuclear medicine: potentials and challenges[J]. European journal of nuclear medicine and molecular imaging, 2019, 46: 2731–2736.
- [58] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks[C]//ECCV. Computer Vision-ECCV 2016: 14th European Conference. Berlin: Springer International Publishing, 2016: 630–645.
- [59] ATHER S, KADIR T, GLEESON F. Artificial intelligence and radiomics in pulmonary nodule management: current status and future applications[J]. Clinical radiology, 2020, 75(1) : 13–19.



- 334(6052):72-75.
- [22] WEI Y, PARMENTIER T E, DE JONG K P, et al. Tailoring and visualizing the pore architecture of hierarchical zeolites[J]. Chemical society reviews, 2015, 44(20):7234-7261.
- [23] PŘECH J, PIZARRO P, SERRANO D P, et al. From 3D to 2D zeolite catalytic materials[J]. Chemical society reviews, 2018, 47(22):8263-8306.
- [24] CHOI M, NA K, KIM J, et al. Stable single-unit-cell nanosheets of zeolite MFI as active and long-lived catalysts[J]. Nature, 2009, 461(7261):246-249.
- [25] BLEKEN B T L, WRAGG D S, ARSTAD B, et al. Unit cell thick nanosheets of zeolite H-ZSM-5: structure and activity[J]. Topics in catalysis, 2013, 56:558-566.
- [26] YANG J H, GONG K, MIAO D Y, et al. Enhanced aromatic selectivity by the sheet-like ZSM-5 in syngas conversion[J]. Journal of energy chemistry, 2019, 35:44-48.
- [27] ZHANG J X, REN L M, ZHOU A J, et al. Tailored synthesis of ZSM-5 nanosheets with controllable *b*-axis thickness and aspect ratio: strategy and growth mechanism[J]. Chemistry of materials, 2022, 34(7):3217-3226.
- [28] QIAO Z Y, ZHANG J, ZHOU C, et al. Enhanced lactide yield in catalytic conversion of *L*-lactic acid from passivation of external acidic sites on aluminosilicate Beta zeolites by coating siliceous beta zeolite[J]. Chemical engineering journal, 2024, 479:147803.

责任编辑:周建军

---

(上接第12页)

- [60] 李秀涛. 基于人工智能检测技术在早期 CT 诊断肋骨骨折中的临床应用研究[D]. 广州:广州医科大学, 2023.
- [61] ARPITHA A, RANGARAJAN L. Computational techniques to segment and classify lumbar compression fractures[J]. La radiologia medica, 2020, 125(6):551-560.
- [62] 朱雅茹, 祁良, 徐磊, 等. 人工智能软件辅助诊断新鲜肋骨骨折的效能评估[J]. 南京医科大学学报(自然科学版), 2022, 42(2):227-232.
- [63] 白洁, 孙晶, 程晓光, 等. 基于 YOLOv3 算法的肋骨骨折诊断模型的构建及应用[J]. 法医学杂志, 2023, 39(4):343-349.
- [64] 张斌, 成跃, 杜静波, 等. 基于深度学习的计算机辅助诊断系统在诊断肋骨骨折方面的应用价值[J]. 武警医学, 2023, 34(8):656-659.
- [65] 熊山, 陈博, 毛杰, 等. 基于深度学习的计算机辅助诊断系统在肋骨骨折诊断中的应用[J]. CT 理论与应用研究, 2022, 31(5):617-622.
- [66] 张倩. 深度学习计算机辅助诊断系统在检测胸部 DR 肋骨骨折中的应用价值研究[D]. 沈阳:中国医科大学, 2023.

责任编辑:郎婧