杜世龙, 韩院彬, 张嘉欣, 等. 基于特征融合的 CHN 骨龄评估级联模型[J]. 智能计算机与应用,2026,16(1):59-65. DOI: 10.20169/j.issn.2095-2163.24031901

基于特征融合的 CHN 骨龄评估级联模型

杜世龙[1], 韩院彬[1], 张嘉欣[2], 高瑞贞[2]
(1 河北工程大学 信息与电气工程学院, 河北 邯郸 056038; 2 河北工程大学 机械与装备工程学院, 河北 邯郸 056038)

摘 要: 现有的骨龄评估(BAA)方法多数是基于西方 GP 和 TW 方法的改进,并不符合中国青少年的发育曲线。本文针对骨龄评估呈现出的民族化、地区化和时代化的趋势,采用一种基于中国人手腕骨发育标准 05-CHN 法并联合先验知识,融合多区域特征的级联模型,以实现更准确的骨龄预测。先使用 YOLOv8 算法将 CHN 法对特征骨的权重分配作为先验知识应用于评估模型中;再使用特征融合网络 HiFuse,结合 Transformer 的优势,引入卷积注意力机制,改进特征提取器,以提高评估的准确性。在自制的 05-CHN 数据集上获得的平均绝对误差(MAE)为 5.83 个月,在公共数据集 RNSA 上获得的 MAE 为 6.24 个月,相较于原算法检测速度提高了 33.8%,MAE 明显降低,进一步提升了两阶段评估方法的性能。

关键词: 骨龄评估; 医学图像处理; 05-CHN 法; 特征融合; 级联模型
中图分类号: TP391.41 **文献标志码**: A **文章编号**: 2095-2163(2026)01-0059-07

A cascade model for CHN Bone Age Assessment based on feature fusion

DU Shilong[1], HAN Yuanbin[1], ZHANG Jiaxin[2], GAO Ruizhen[2]
(1 School of Information and Electrical Engineering, Hebei University of Engineering, Handan 056038, Hebei, China; 2 School of Mechanical and Equipment Engineering, Hebei University of Engineering, Handan 056038, Hebei, China)

Abstract: Most of the existing Bone Age Assessment (BAA) methods are based on the improvement of Western GP and TW methods, which are not consistent with the development curve of Chinese adolescents. In view of the trend of nationalization, regionalization and modernization of bone age assessment, this paper adopts a cascade model based on the Chinese wrist bone development standard 05-CHN method and combined with prior knowledge, which integrates multi-regional features to achieve more accurate bone age prediction. Firstly, the YOLOv8 algorithm is used to apply the weight distribution of the CHN method to the feature bone as a priori knowledge to the evaluation model. Then, using the feature fusion network HiFuse, combined with the advantages of Transformer, the convolutional attention mechanism is introduced to improve the feature extractor to improve the accuracy of the evaluation. Experiments on the self-made 05-CHN dataset show that the Mean Absolute Error (MAE) obtained is 5.83 months, and the MAE obtained on the public dataset RNSA is 6.24 months. Compared with the original algorithm, the detection speed is increased by 33.8 %, and the MAE is significantly reduced, which further improves the performance of the two-stage evaluation method.

Key words: Bone Age Assessment; medical image processing; 05-CHN; feature fusion; cascade modeling

0 引 言

骨龄评估是一种典型的生物学年龄鉴定方法,在青少年保健、运动员选材等方面具有广泛应用。通过对特征骨块的发育特征进行识别,如骨骼的形状和位置、骨骺的大小等特征,从而对骨骼发育程度进行等级判定。在临床实践中,手腕骨 X 线片获取简便,该部位集中了多个特征骨,具备如大小、形态、结构以及骨骼间的相互关系等诸多骨骼发育变化特征,可以呈现不同阶段的变化规律,是评价骨骼发育成熟程度的理想部位。国际上常用的骨龄评估方法是 GP 和 TW 方法,但两者成型较早,统计方法落后,以及在东西方种族、时代背景等方面存在差异,因此国内张绍岩等学者[1]根据结合国内儿童发育特征,制定了技术更为先进、评测更简单高效的基于差方分析自动赋权的成熟度几何平均法《中国人手腕骨发育标准 CHN 法》。随着中国儿童出现的快速发育趋势,2005 年修订版《中国人手腕骨发育标

作者简介: 杜世龙(1999—),男,硕士研究生,主要研究方向:图像识别,医学图像处理。Email:du13561532851@163.com; 韩院彬(1983—),男,博士,副教授,主要研究方向:服务计算,物联网技术; 高瑞贞(1979—),男,博士,教授,主要研究方向:机器人系统,计算机视觉。

收稿日期: 2024-03-19

准-中华 05》[2] 以中国儿童样本为基础并融合了 TW3 和 RUS-CHN 方法,建立了更详细的评价规则,已成为评价中国儿童骨龄的新标准。

在人工智能发展之前,临床主要采用机器学习方法进行骨龄评估,对 X 线片进行图像处理,提取骨骼发育特征,利用机器学习浅层算法预测骨龄,但这种方法仍要依赖人工设计骨骼的独特特征来用于后续的评估任务,极大地限制了骨龄评估的自动化程度。并且人工设计直接影响评估方法的性能,同时机器学习方法只能提取和学习数据的浅层特征,准确率有待提高。随着深度学习的进一步发展,利用卷积神经网络、Transformer 等算法能够自动提取深层特征,既提高了预测准确率,又极大地解放人力[3]。

基于深度学习方法的骨龄评估通过对图像进行处理,设置边界框、分割图像、标注骨部关键点、设置关键区域以获取信息,再通过 VGGNet、R-CNN 等卷积神经网络估计骨龄,但并未充分利用特征。为了准确分析手部骨骼的各种特征以提高准确率,在评估之前首先提取骨骼的感兴趣区域(ROI),并提出两阶段评估方法:

(1)Tang 等学者[4] 提出一种迁移学习方法,从 X 射线图像中提取并融合 SIFT 和 HOG 特征,将其输入到网络中进行评估,但该方法没有充分利用关键骨区域丰富的信息。

(2)Iglovikov 等学者[5] 提出 U-Net 和 VGGNet 的组合,其中 U-Net 用于分割关键骨区域,VGGNet 进行特征提取和分类,综合运用了回归和分类模型,并考虑了不同骨面积对评估结果的影响,取得了 6.1 个月的 MAE。

(3)Ren 等学者[6] 设计了一种用于自动 BAA 的回归卷积神经网络,利用速度更快的 R-CNN 来检测骨骼区域,将注意力图输入回归网络以获得骨龄,取得了 5.2 个月的 MAE。

(4)Li 等学者[7] 首先运用了无监督方法对整个手部进行最大区域分割,接着使用 MobileNetv3 进行特征提取,最后通过多层感知器进行骨龄估计,其 MAE 为 6.2 个月。

(5)Wu 等学者[8] 采用 Mask R-CNN 来分割手部骨骼区域,然后使用残差注意力网络估计骨龄,MAE 为 7.38 个月。

(6)Son 等学者[9] 基于 TW3 方法,使用了 Faster R-CNN 从图像中提取出 13 个 ROI 来训练 VGG 网络,获得了 5.52 个月的 MAE,但需要进行大量且繁琐的图像处理工作。

两阶段方法对特征进行了标注更准确标注,提高了评估的准确率。本文基于 05-CHN 腕骨特征的多 ROI 等级判定方法进行两阶段评估骨龄,通过使用多个 ROI 提取更丰富的手腕骨特征,提高了骨龄预测的准确率;该方法将网络注意力集中在手腕骨结构上,降低对指骨等次要特征的重视程度,简化了特征提取的过程;采用多 ROI 等级判定方法使得分类模型各个类别相互独立,分类器设计更加简单,无需关注分类器之间的组合问题,减少了分类模型的计算量和复杂性,进而降低了两阶段方法的复杂性。

1 基于 05-CHN 标准的两阶段骨龄评估算法

利用 05-CHN 标准和卷积神经网络对骨骼成熟度进行检测和评分。工作流程如图 1 所示,分为 2 个阶段。第 1 阶段利用训练好的 YOLOv8 模型对图像中的腕骨、掌骨等 14 个 ROI 区域进行定位和裁剪,缩小了关键骨区域的范围,使得后续评估模型的计算资源集中在关键骨上,从而提高准确性;第 2 阶段将第 1 阶段得到的全部 ROI 聚合并用于改进的卷积神经网络,无需对输入的图像进行调整和优化,节省时间和成本,训练好的模型将预测特征骨的发育分期等级并计算 14 块特征骨得分总和,对照骨龄查分表得到骨龄。两阶段的骨龄评估方法具有较强的灵活性,可以根据不同的评估对象和场景进行调整和优化,评估过程可随时中断,便于定位评估过程中出现的问题。两阶段方法结合了目标检测和分类网络的优势,既能够在较短时间内进行初步判断,又能够在需要时进行更细致的评估,提高评估结果可靠性和灵活性。

1.1 数据集

使用由石家庄展望未来科技有限公司提供的 05-CHN 数据集(图像由 CHN 骨龄标准的主要完成人绍伟东研究员亲自标定发育分期),包含了 807 例 1~18 岁的原始左手 X 射线图像,数据集中在 5~13 岁的青少年,经过数据增强后每个年龄段按照 8∶2 的比例随机分为训练集和测试集,由于评估模型是在某个年龄段内单独训练,因此数据分布不影响模型训练结果。数据集中各年龄段的数据分布如图 2 所示。目标检测需要大量数据进行训练,为避免训练重复数据导致过拟合,因此 ROI 提取阶段(第 1 阶段)使用 RSNA 学会提供的无注释数据集。该数据集提供了 12 611 张训练图像、1 425 张验证图像和 200 张测试图像。ROI 提取阶段主要学习骨骼的形状、大小、致密性等特征,只需对特征骨进行识别即可,因此不必区分种族人群,不影响评估阶段的准确性。

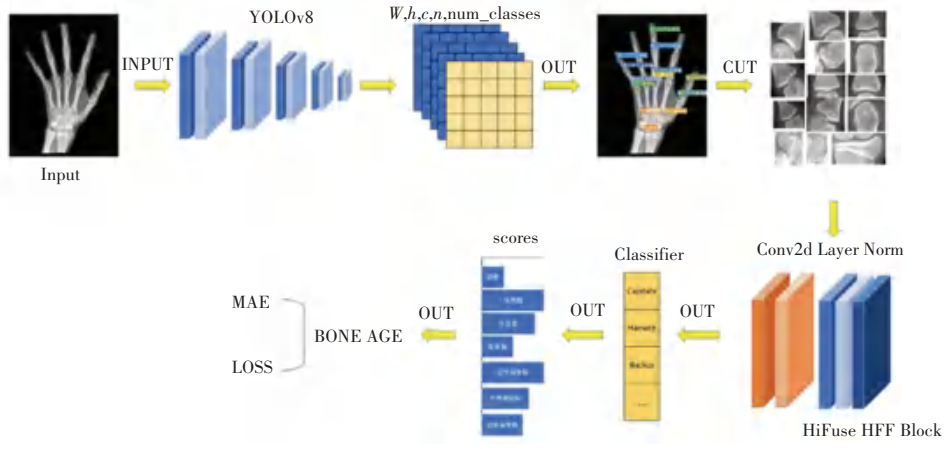

图 1　两阶段骨龄评估模型

Fig. 1　Two-stage bone age assessment model

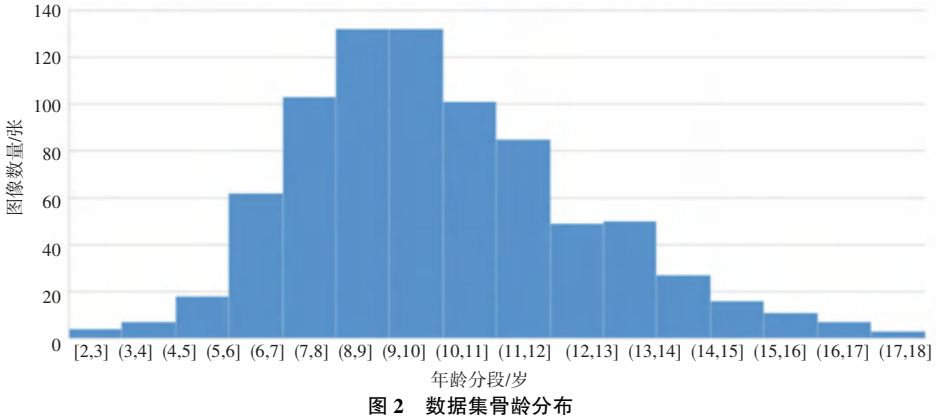

图 2　数据集骨龄分布

Fig. 2　Distribution of bone age in the dataset

1.2　感兴趣区域提取

为了使模型专注于 05-CHN 法评估所需的感兴趣区域，最大化利用关键骨区域的丰富信息，将 05-CHN 法的 14 个 ROIs 作为先验知识输入到评估模型中。为去除背景噪声对图像识别的不利影响，在标注前对图像进行预处理，去除隐私信息和无关信息，减少噪声干扰。待提取的 ROI 如图 3 所示。

1—钩骨；2—头状骨；3—桡骨；4—第一掌骨骺；5—第三掌骨骺；6—第五掌骨骺；7—第一远节指骨骺；8—第一近节指骨骺；9—第三远节指骨骺；10—第三中节指骨骺；11—第三近节指骨骺；12—第五远节指骨骺；13—第五中节指骨骺；14—第五近节指骨骺

图 3　待提取 ROIs

Fig. 3　ROIs to be extracted

本文使用 YOLOv8 算法来提取 ROIs。YOLOv8 算法包含特征提取、特征融合、和预测三个流程，通过使用不同大小的卷积核来捕捉不同尺度的特征，并将其融合对目标进行预测。算法网络会将图像划分成网格，每个网格负责检测其中心落在该网格内的对象，随后输出对象框的坐标以及对象框中对象的预测类别。概率公式如下：

$$P_r(\text{class}_n \mid \text{object}) \times P_r(\text{object}) \times \text{IoU}_{\text{pre}}^{\text{true}} = P_r(\text{class}_n) \times \text{IoU}_{\text{pre}}^{\text{true}} \tag{1}$$

其中，object 表示检测对象，也就是待提取的 ROI；class 表示 ROI 的类别；$P_r(\text{object})$ 表示边界框包含对象的概率；$\text{IoU}_{\text{pre}}^{\text{true}}$ 表示预测框与实际值的交集比；$P_r(\text{class}_n \mid \text{object})$ 表示每个边界框的置信度；$P_r(\text{class}_n)$ 表示目标框所属类别的概率。

1.3　骨龄评估

评估阶段可以看作是按特征骨发育分期等级分类的，ROIs 图像作为输入、特征骨发育等级作为输出的多分类任务。由于 05-CHN 标准分别独立制定了男女发育分期等级的划分，因此评估中不必区分性别，输出等级结果后对照骨龄查分表即可获得不

同性别的骨龄预测值。使用 HiFuse[10] 作为基线模型并针对手骨图像进行改进,为提高模型评估效率,将 YOLOv8 和 HiFuse 进行组合级联[11],将检测阶段所提取到的 ROIs 分类聚合并输入到改进的 HiFuse 模型中。利用模型中的分支并行结构分别提取各个 ROI 的特征,在特征层面将不同数据进行融合,对数据做出预测,然后对其进行合并和加权平均,输出目标特征骨的发育等级,最后对照 05-CHN 骨龄查分表获得骨龄预测值。

1.4 改进特征提取器结构

主要使用 HiFuse 的分支并行结构,针对分类任务,去除其全局特征提取分支。为了最大化提取手骨特征的能力,优化了 HiFuse 中的特征提取器,首先将局部分支中的卷积核从 3×3 扩大到 5×5,扩大了特征提取器的感受野(RF)。卷积核的大小与 RF 的关系公式如下:

$$RF_K = RF_{K-1} + (f_k - 1) \times \prod_{i=0}^{k-1} s_i, k \geqslant 2 \quad (2)$$

其中,k 表示卷积网络的层数;RF_{K-1} 表示第 k 层对应的感受野的大小;f_K 表示第 k 层卷积核的大小;s_i 表示卷积操作的步长。

其次,为了进一步提升网络的图像识别能力,在模型中的卷积层后加入归一化层(BN),使得数据更容易落入激活函数的敏感区域,加快网络收敛。为提高识别速率,将较为复杂的 GeLU 激活函数改为 ReLU 函数;在全连接层之间采用 Dropout 技术,提高模型泛化能力,避免过拟合。

1.5 卷积注意力模块

HiFuse 对医学图像具有很强的泛化能力,但在骨骼这种类间差异小、类内差异大的分类任务中表现出的性能略有欠缺,因此,本文在局部特征提取分支引入了卷积注意力模块(CBAM)[12],增大网络对特征提取模块的资源分配。CBAM 由通道注意模块(CAM)和空间注意模块(SAM)组成,2 个模块串行生成注意力,并对其改进以调整网络的空间和通道权重,提升模型的性能。计算方法公式如下:

$$M_c(F) = \sigma(\mathrm{MLP}(\mathrm{AvgPool}(F)) + \mathrm{MLP}(\mathrm{MaxPool}(F))) \quad (3)$$

$$M_s(F) = \sigma(f^{5\times5}[\mathrm{AvgPool}(F); \mathrm{MLP}(\mathrm{MaxPool}(F))]) \quad (4)$$

其中,F 表示输入特征图;$M_c(F)$ 表示 CAM 特征;$M_s(F)$ 表示 SAM 特征;σ 表示 Sigmoid 激活函数;AvgPool 和 MaxPool 表示平均池化和最大池化;MLP 表示多层感知器结构;MLP(MaxPool(F)) 表示强调函数 f 的参数。

2 实验结果与分析

2.1 实验环境与训练参数

本文使用的深度学习框架是 PyTorch,硬件配置包括 Intel(R) Core(TM) i7-10700K CPU 和 NVIDIA GeForce RTX 3080 GPU。在 ROI 提取阶段,使用 SGD 作为优化器,初始学习率为 0.01,训练周期为 200;骨龄评估阶段使用 AdamW 作为优化器,初始学习率为 0.001,训练周期为 300,激活函数为 ReLU。

2.2 ROI 提取结果

YOLOv8 定位感兴趣区域的物体框坐标,从原始图像中分割出 ROIs 图像,提取手骨 ROIs 的过程如图 4 所示。

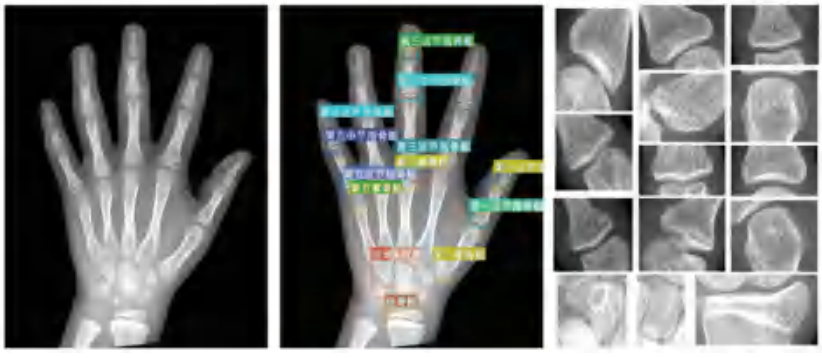

(a) 原始图像 (b) YOLOv8 检测定位的 ROIs 图片 (c) YOLOv8 分割输出的 14 个 ROIs

图 4 YOLOv8 提取 ROIs

Fig. 4 YOLOv8 extracting ROIs

为了验证 ROIs 提取模型的定位性能,随机选择 200 张图像来做测试。表 1 显示了不同 ROI 的平均精度(mAP)。mAP 的定义公式如下:

$$\mathrm{mAP} = \frac{\sum_{i=1}^{k} \mathrm{AP}_i}{k} \tag{5}$$

其中，mAP 表示所有类别 AP 的平均值，k 表示测试集中包含的不同类别的数量。在表 1 中，mAP@0.5 表示 IoU>0.5 的平均精度，mAP@0.50∶0.95 表示 IoU 阈值从 0.50 增加到 0.95（以 0.05 为步长）的平均精度。

表 1　不同 ROI 定位的 mAP

Table 1　mAP for different ROI positioning

ROIs	数据集	mAP@0.5	mAP@0.50∶0.95
钩骨	RSNA	0.99	0.86
头状骨	RSNA	0.98	0.86
桡骨	RSNA	0.99	0.91
掌骨骺	RSNA	0.96	0.79
指骨骺	RSNA	0.98	0.85

2.3　评估结果分析

将模型对骨龄的预测值与专家评估所得的实际值的平均绝对误差（MAE）作为本文的评价指标。具体计算公式如下：

$$\mathrm{MAE} = \frac{1}{n}\sum_{i=1}^{n} \left| (y_i - \hat{y}_i) \right| \tag{6}$$

其中，y_i 表示实际骨龄值；$\hat{y}_i$ 表示预测骨龄值；n 表示数据总量。

为了选择最适合骨骼发育分期等级分类的卷积网络，将几种常用的卷积神经网络和未改进的 HiFuse 模型进行对比实验，不经过 ROI 提取，直接将原始图像输入到网络中，所得结果见表 2。

表 2　基线模型骨龄评估结果对比

Table 2　Comparison of bone age assessment results from baseline models

基线模型	参数量/百万	范围/岁	MAE/月
GoogleNet[13]	5.00	1~18	12.41
AlexNet[13]	61.00	1~18	10.23
VGGNet19[14]	143.68	1~18	9.77
ResNet50[14]	25.00	1~18	9.49
MobileNetv2[15]	3.40	1~18	8.71
EfficientNetv2[16]	24.00	1~18	8.95
HiFuse	127.80	1~18	8.42

GoogleNet 和 AlexNet 是早期的网络模型，需要与其他网络配合使用，单独实验相比于其他网络识别效果和性能较差；VGGNet19 通过重复使用简单的 3×3 卷积核深化了网络结构，但由于卷积核较小，不能充分利用骨骼图像的特征信息，且模型参数非常庞大，导致需要较大的存储空间和计算机资源，计算成本高；RestNet50 通过引入残差学习使得网络可以通过增加层数来提高准确率，但需要大量数据来支撑其进行抽象特征的学习，不适用于医疗数据等小型数据集；MobileNetv2 和 EfficientNetv2 是轻量级网络，更适合在移动设备等资源受限的环境中运行，在骨龄图像分类这种需要深层次特征提取的复杂任务上，性能略差；HiFuse 专为医学图像分类任务设计，其特有的特征融合模块能够有效减少骨龄图像的噪声干扰，且较大的卷积核更容易捕获图像的全局和局部特征，提高分类精度，同时分支并行结构加快了识别速度。从表 2 可以看出，HiFuse 模型更适合进行特征骨发育分期的分类任务。

2.4　BAA 模型消融实验。

为了评估改进的特征提取器和 ROIs 标签的有效性，通过增减改进的模块在 RSNA 数据集上进行了消融实验（实验结果见表 3）。表 3 中，K：5×5 表示更换大小为 5×5 的卷积核，CBAM 表示引入 CBAM 注意力机制，ROIs 表示使用提取后的 14 个 ROIs 进行训练。

表 3　消融实验结果

Table 3　Results of ablation experiments

改进的特征提取器		ROIs	MAE/月
K：5×5	CBAM		
√	×	×	8.46
√	×	√	8.02
×	√	×	7.95
×	√	√	7.39
√	√	×	7.47
√	√	√	6.24

从消融结果看出，相较于 HiFuse 原算法，使用改进的特征提取器并结合提取的 ROIs 后，MAE 得到显著降低，表明改进方法性能得到了较好提升。

2.5　与其他方法的对比

为了验证模型的性能，分别在 RNSA 公共数据集和 05-CHN 自制数据集上进行验证。对比实验结果见表 4、表 5。Zulkifley 等学者[17]提出的注意力接受网络（AXNet）从背景中提取手部区域，根据 4 个关键点旋转图像，结合多层空间注意机制判断骨龄，取得了 7.70 个月的 MAE，但该方法仅提取了整手区域，对特征骨区域不够重视。Wibisono 等学者[3]

实现了一个基于 X 线片的决策支持系统,基于手部分割区域提出了特征连接层(RB-FCL),取得的最佳误差结果为 6.97 个月,表明利用关键骨区域的方法优于标准深度学习的测试结果。Zhao 等学者[18]利用深度主动学习方法从原始图像中分割特定的 ROIs 并增强图像质量,微调网络后取得了 7.66 的 MAE。Wu 等学者[8]模仿临床工作流程,首先使用 MaskR-CNN 网络分割手部骨骼,然后使用残留注意力网络预测骨龄,取得了 7.38 个月的 MAE,优于当时其他方法,但分割区域仍显粗糙,未能充分利用各个特征骨区域。Hao 等学者[19]提出一种多模态数据融合网络,利用文本和图像进行骨龄评估,实验取得了最好为 6.29 的 MAE,但其文本注释带来了巨大的工作量。

表 4 不同方法在 RSNA 数据集上对比

Table 4 Comparison of different methods on RNSA dataset

方法	数据集	ROIs	MAE/月
Zulkifley, et al.[17]	RSNA	√	7.70
Wibisono, et al.[3]	RSNA	√	6.97
Zhao, et al.[18]	RSNA	√	7.66
Wu, et al.[8]	RSNA	√	7.38
Hao, et al.[19]	RSNA	√	6.29
本文	RSNA	√	6.24

表 5 不同方法在 05-CHN 数据集上对比

Table 5 Comparison of different methods on 05-CHN dataset

方法	数据集	ROIs	MAE/月
Zulkifley, et al[17]	05-CHN	√	7.94
Wibisono, et al.[3]	05-CHN	√	7.06
Zhao, et al.[18]	05-CHN	√	7.36
Wu, et al.[8]	05-CHN	√	7.44
Hao, et al.[19]	05-CHN	√	6.14
本文	05-CHN	√	5.83

由表 4、表 5 可知,在公共数据集和私人数据集上都使用提取后的 ROIs 作为先验知识输入到网络中时,改进的 HiFuse 模型具有较低的 MAE,表明准确率相比其他方法有所提高。分析认为,这是由于本文提出的两阶段级联模型更符合骨龄评估的工作流程和特点,充分利用关键骨区域的丰富信息,从而提高了 BAA 模型的性能。

2.6 模型在不同年龄段的性能表现

为了检验模型在各个年龄段上的性能,将 1~18 岁分为 16 个年龄段进行测试。受数据量影响,为避免训练数据与验证数据混用,将 1~3 岁作为一个年龄段进行测试。不同年龄段的评估结果见表 6。

表 6 不同年龄段的评估结果

Table 6 Assessment results for different age groups

年龄段	数据集	MAE/月
(1,3]	05-CHN	5.45
(3,4]	05-CHN	7.02
(4,5]	05-CHN	6.33
(5,6]	05-CHN	5.10
(6,7]	05-CHN	4.24
(7,8]	05-CHN	3.16
(8,9]	05-CHN	3.51
(9,10]	05-CHN	3.92
(10,11]	05-CHN	4.09
(11,12]	05-CHN	5.47
(12,13]	05-CHN	5.85
(13,14]	05-CHN	5.91
(14,15]	05-CHN	6.60
(15,16]	05-CHN	6.92
(16,17]	05-CHN	7.37
(17,18]	05-CHN	9.04

从表 6 中可以看出,模型在 6~14 岁之间表现较好;受数据量过小影响,即使经过数据增强仍不足以全面学习特征信息,因此在 1~5 岁之间 MAE 误差较大;从 14~18 岁,青少年的手腕骨发育逐渐成熟,腕骨、掌骨等体现发育特征的关键骨形态不再具有明显的变化,这使得模型难以准确评估该年龄段的骨龄。

3 结束语

本文为骨龄自动化评估研究提出了 YOLOv8 和 Hifuse 顺序级联的两阶段 CHN 法智能骨龄评估,先根据 05-CHN 法有效提取腕骨特征,再细粒度地对图像的 ROIs 区域进行自动化提取,两者结合提高了医生读片的效率和一致性。训练结果表明,相比现有的其他方法,本文提出的级联模型表现出了较好的性能,取得了更好的结果,如特征骨区域的提取准确率和骨龄评估的平均绝对误差,可以作为骨龄评估的辅助工具来进一步展开研究。

参考文献

[1] 张绍岩, 杨士增, 邵伟东, 等. 中国人手腕骨发育标准:CHN 法[J]. 体育科学, 1993, 13(6): 33-39.

[2] 张绍岩,刘丽娟,吴真列,等. 中国人手腕骨发育标准-中华 05 I. TW_3-CRUS、TW_3-C 腕骨和 RUS-CHN 方法[J]. 中国运动

医学杂志. 2006,25(5):509-516.
[3] WIBISONO A, MURSANTO P. Multi region-based feature connected layer (RB-FCL) of deep learning models for bone age assessment[J]. Journal of Big Data, 2020, 7(1): 67.
[4] TANG Wei, WU Gang, SHEN Gang. Improved automatic radiographic bone age prediction with deep transfer learning[C]// International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI). Piscataway,NJ: IEEE, 2019: 1-6.
[5] IGLOVIKOV V, RAKHLIN A, KALININ A A, et al. Pediatric bone age assessment using deep convolutional neural networks[J]. arXiv preprint arXiv,1712.05053, 2017.
[6] REN Xuhua, LI Tingting, YANG Xiujun, et al. Regression convolutional neural network for automated pediatric bone age assessment from hand radiograph[J]. IEEE Journal of Biomedical and Health Informatics, 2018, 23(5): 2030-2038.
[7] LI Shaowei, LIU Bowen, LI Shulian, et al. A deep learning-based computer-aided diagnosis method of X-ray images for bone age assessment[J]. Complex & Intelligent Systems, 2022, 8(3): 1929-1939.
[8] WU E, KONG Bin, WANG Xin, et al. Residual attention based network for hand bone age assessment[C]//Proceedings of the International Symposium on Biomedical Imaging (ISBI 2019). Piscataway,NJ:IEEE, 2019: 1158-1161.
[9] SON S J, SONG Y, KIM N, et al. TW3-based fully automated bone age assessment system using deep neural networks[J]. IEEE Access, 2019, 7: 33346-33358.
[10] HUO Xiangzuo, SUN Gang, TIAN Shengwei, et al. HiFuse: Hierarchical multi-scale feature fusion network for medical image classification[J]. Biomedical Signal Processing and Control, 2024, 87: 105534.
[11] LI Nanxin, CHENG Bochao, ZHANG Junran. A cascade model with prior knowledge for bone age assessment[J]. Applied Sciences, 2022, 12(15): 7371.
[12] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV). Cham:Springer,2018: 3-19.
[13] ALMAS B, SATHESH K, RAJASEKARAN S. A deep analysis of GoogleNet and AlexNet for lung cancer detection[J]. International Journal of Engineering and Advanced Technology, 2019, 9(2): 395-399.
[14] IKECHUKWU A V, MURALI S, DEEPU R, et al. ResNet-50 vs VGG-19 vs training from scratch: A comparative analysis of the segmentation and classification of Pneumonia from chest X-ray images[J]. Global Transitions Proceedings, 2021, 2(2): 375-381.
[15] SANDLER M, HOWARD A, ZHU Menglong, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway,NJ:IEEE, 2018: 4510-4520.
[16] TAN Mingxing, LE Q. EfficientNet: Rethinking model scaling for convolutional neural networks[C]//Proceedings of International Conference on Machine Learning. Long Beach,USA: IMLS, 2019: 6105-6114.
[17] ZULKIFLEY M A, MOHAMED N A, ABDANI S R, et al. Intelligent bone age assessment: An automated system to detect a bone growth problem using convolutional neural networks with attention mechanism[J]. Diagnostics, 2021, 11(5): 765.
[18] ZHAO Chen, HAN Jungang, JIA Yang, et al. Versatile framework for medical image processing and analysis with application to automatic bone age assessment[J]. Journal of Electrical and Computer Engineering, 2018, 2018: 2187247.
[19] HAO Pengyi, YE Taotao, XIE Xuhang, et al. Radiographs and texts fusion learning based deep networks for skeletal bone age assessment[J]. Multimedia Tools and Applications, 2021, 80: 16347-16366.