DOI:10.16016/j.2097-0927.202311033

创伤性脑出血体积定量的深度学习方法研究

陈地友[1,2*],时心怡[3*],吴鹏飞[2],詹 力[1],赵文兵[2],谢静茹[2],张 良[2],赵 辉[2] 400042 重庆,陆军特色医学中心:放射科[1],军事交通伤防治研究室[2];401135 重庆,重庆理工大学两江人工智能学院[3]

[摘要] **目的** 基于 Trans-UNet 模型构建创伤性脑出血(traumatic intracerebral hemorrhage, TICH)体积定量的深度学习方法,并与公式法进行比较。**方法** 收集我院放射科于 2018 年 5 月至 2023 年 5 月收治的 141 例创伤性脑出血患者的 CT 资料,建立基于 Trans-UNet 模型的深度学习方法,以影像归档与通讯系统(picture archiving and communication system, PACS)人工勾画为金标准,对比其与公式法(共 10 种)在创伤性脑出血体积定量的准确性、一致性和测量耗时差异。**结果** PACS 人工勾画的创伤性脑出血中位体积为 1.167 mL,单个患者的测量中位时间为 135 s。深度学习方法与 PACS 人工勾画的体积百分误差中位数为 3.59%,Spearman 相关系数为 0.999(P<0.001),单个患者测量的中位时间仅为 4.38 s;而公式法中,最低体积百分误差中位数为 16.451%,最高 Spearman 相关系数为 0.986(P<0.001),单个患者测量的最低中位时间为 20 s。两类方法在体积百分误差和测量时间上的差异均具有统计学意义(P 均<0.001)。**结论** 本研究所构建的深度学习方法相较于公式法,在测量准确性和时效上均表现更优。

[关键词] 创伤性脑出血;计算机体层摄影;深度学习;体积定量;创伤性脑损伤
[中图法分类号] R319; R445.2; R743.34 [文献标志码] A

Deep learning for volumetric assessment of traumatic cerebral hematoma

CHEN Diyou[1,2], SHI Xinyi[3], WU Pengfei[2], ZHAN Li[1], ZHAO Wenbing[2], XIE Jingru[2], ZHANG Liang[2], ZHAO Hui[2]
[1]Department of Radiology, [2]Department of Military Traffic Injury Prevention, Army Medical Center of PLA, Chongqing, 400042; [3]Liangjiang Institute of Artificial Intelligence, Chongqing University of Technology, Chongqing, 401135, China

[**Abstract**] **Objective** To develop a deep learning method for volumetric assessment of traumatic intracerebral hemorrhage (TICH) using the Trans-UNet model and to compare its performance with traditional formula-based methods. **Methods** CT data from 141 TICH patients admitted to Army Medical Center of PLA between May 2018 and May 2023 were collected. A deep learning method based on the Trans-UNet model was established. Manual delineation *via* picture archiving and communication system (PACS) was served as the gold standard for comparing the accuracy, consistency, and time efficiency of our method against 10 different formula-based methods for measuring the amount of TICH. **Results** The median volume of TICH, as manual delineation *via* PACS, was 1.167 mL, with a median measurement time of 135 s per patient. The median percentage error in volume between the deep learning method and manual delineation *via* PACS was 3.59%. Spearman correlation coefficient was 0.999 (P<0.001), and a median measurement time was only 4.38 s per patient. In contrast, in the formula-based methods, the lowest median percentage error in volume

* 同等贡献

[基金项目] 重庆市自然科学基金创新发展联合基金(CSTB2023NSCQ-LZX0155)

[通信作者] 赵 辉,E-mail:box.zhaohui@163.com

2097-0927/Copyright © 2024, 陆军军医大学(第三军医大学)。这篇开放获取文章遵循 CC BY 许可协议(https://creativecommons.org/licenses/by/4.0/)

was 16.451%, the highest Spearman correlation coefficient was 0.986 ($P<0.001$), and the lowest median measurement time was 20 s for a single patient. The statistical differences were observed in percentage error in volume and measurement time between the 2 types of methods (all $P<0.001$). **Conclusion** Our developed deep learning method for volumetric assessment of TICH is superior to the formula-based methods in terms of measurement accuracy and time efficiency.

[**Key words**] traumatic intracerebral hemorrhage; computed tomography; deep learning; volumetric quantification; traumatic brain injury

CHEN Diyou and SHI Xinyi contributed equally to the article. Supported by the Innovation and Development Joint Fund of Natural Science Foundation of Chongqing (CSTB2023NSCQ-LZX0155). Corresponding author: ZHAO Hui, E-mail: box.zhaohui@163.com

创伤性脑出血(traumatic intracerebral hemorrhage, TICH)是指头部受到外力引起的脑出血,占创伤性脑继发性损伤的1/3~1/2[1]。TICH可导致40%~50%的创伤人群死亡,也是创伤后致残重要因素[2-3]。TICH的治疗方式主要包括凝血治疗、脑室-腹膜分流术和开颅手术等[4]。基于TICH体积的评分是临床常用的分级系统[5],也是判断是否需要手术治疗和确定手术方式的关键指征。准确定量TICH体积,并制定合理治疗措施,对于改善患者预后具有重要的临床意义[6-9]。

目前,基于计算机断层扫描(computed tomography, CT)切片在影像归档与通讯系统(picture archiving and communication system, PACS)上人工勾画完成的测量是TICH体积定量的金标准。然而,该方法过程费时,诊断效率低。此外,基于TICH病灶最大切片几何参数的公式法(如多田公式)是临床最常用的定量方法,虽然可行性高,但准确性不足(特别是对于不规则形状的病灶)[10-11]。鉴于TICH病情凶险,病灶形态多变且分布较广,异质性高,临床亟待优化TICH的体积定量方法。人工智能(artificial intelligence, AI)算法的发展和应用,为TICH的快速精确定量提供了可能。既往研究报道了一些具有良好性能的AI模型,但主要集中在自发性脑出血领域[12-13]。由于缺乏高质量标签和相邻切片信息,国内外目前对基于二维CT的TICH体积定量AI的研究报道较少。因此,本研究构建基于Trans-UNet模型的深度学习方法,以PACS人工勾画作为金标准,对比多田公式等10种公式法,并探讨该深度学习方法在TICH体积定量的可行性和准确性,以期为TICH的临床治疗方式选择提供参考。

1 材料与方法

1.1 一般资料

本研究纳入2018年5月至2023年5月期间在陆军特色医学中心放射科接受颅脑CT检查的141例TICH患者,以脑挫伤型TICH为主,包含极少量的硬膜下和硬膜外血肿。纳入标准:①病历描述中包含明确外伤史,且经头颅CT确诊为TICH;②无外院治疗史;③年龄≥18岁。排除标准:①首次CT扫描距离受伤超过24 h;②首次CT扫描前已完成头颅手术;③严重CT伪影;④单纯外伤性蛛网膜下腔出血(体积较小,不规则,不易勾画);⑤幕下病灶。该研究已获得陆军特色医学中心伦理委员会的批准(2023-194号)。

1.2 影像设备及扫描参数

头颅轴位CT检查采用美国通用医疗64排vCT或荷兰飞利浦128排iCT。扫描基线为听眶线,扫描范围包含整个头部。具体参数:①64排vCT:层厚5 mm,层间距5 mm,管电压120 kV,管电流350 mA;②128排iCT:层厚5 mm,层间距5 mm,管电压120 kV,管电流200 mA。

1.3 TICH体积定量方法

1.3.1 PACS人工勾画 以PACS人工勾画作为TICH体积定量的金标准并由2名工作经验超过8年的CT影像技师独立完成。首先将原始CT图像导入PACS,接着动态调整窗宽、窗位,手动勾画TICH病灶边缘,获得体积(2次勾画取平均值)。

1.3.2 公式法 包括既往报道的以下2类(共10种)公式法[10-11, 14-15]。一类是基于TICH病灶最大切面的最长径的公式:ABC/2、ABC/3、2.5ABC/6、2ABC/3、π/6ABC;另一类是基于TICH病灶最大切面的面积的公式:SH/2、SH/3、2.5SH/6、2SH/3和π/6SH。其中,A表示TICH病灶最大切面的最长径;B表示TICH病灶最大切面上与A垂直的最长径;S表示TICH病灶最大切面的面积;C表示存在TICH病灶的CT切片数;H表示TICH病灶高度(切片数×切片厚度)。存在多个病灶时,分别计算后累加。

1.3.3 深度学习方法

1.3.3.1 图像预处理 一共包含141例患者,由2位工作经验5年以上的放射诊断医师采用开源软件Insight Toolkit SNAP(ITK-SNAP, https://itk.org/)[16]

进行筛选和勾画,经过一系列数据预处理得到 910 张存在 TICH 阳性病灶的 CT 切片。数据预处理过程如下:首先将 DICOM 格式影像转换为 NIFTI 格式数据,设置恰当的窗宽、窗位后,将 NIFTI 格式数据逐层转换为 PNG 图片(分辨率为 256×256)。随机将病灶切片按照 8∶1∶1的比例划分为训练集、验证集和测试集,且每个集合中均不存在数据交叉。最终,训练集、验证集和测试集的切片数分别为 732 张、90 张和 88 张。

1.3.3.2 图像分割 采用 Trans-UNet[17] 进行图像分割(图 1),同时与 UNet[18]、Attention-UNet[19]、UNet++[20]、SA-UNet++[21]、UNet3+[22]、Deeplabv3_resnet50[23] 和 HR-Net[24] 分割模型进行比较。为减少训练波动,本研究计算 soft Dice 系数(即在常规 Dice 系数计算公式的分子和分母各加上约 10^{-5} 大小的偏置项 ε)。使用 5 折交叉验证法减少模型的过拟合,各分割模型在测试集上的评价指标以 $\bar{x}\pm s$ 表示。

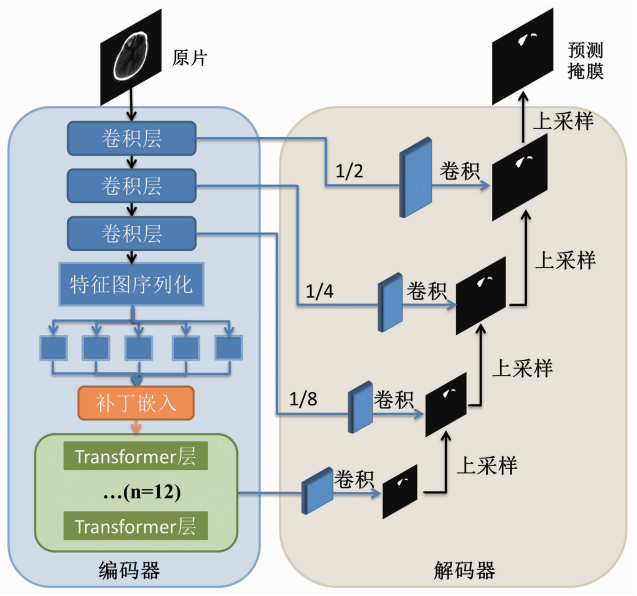


图 1 Trans-UNet 模型框架图

1.3.3.3 体积计算 借助逐像素点图像处理完成 TICH 体积计算(公式 1)。首先,计算某张切片上 TICH 病灶的像素点和,并将该像素点和与像素间距相乘;接着,逐层累加该乘积(由于存在某个切片上的 TICH 病灶小于层厚的情况,所以乘上系数 1/2);最后,将上一步骤的求和结果乘上层厚即得到病灶的整体体积(图 2)。公式如下。式中,V 表示体积,N 表示 TICH 病灶切片层数,T 表示像素间距与层厚的乘积(常数项),A_i 表示第 i 层切片的病灶的像素点和。

$$V=\frac{T}{1\ 000}\sum_{i=0}^{N-1}\frac{A_1+A_{i+1}}{2}(i=0,1,\cdots N) \qquad (1)$$

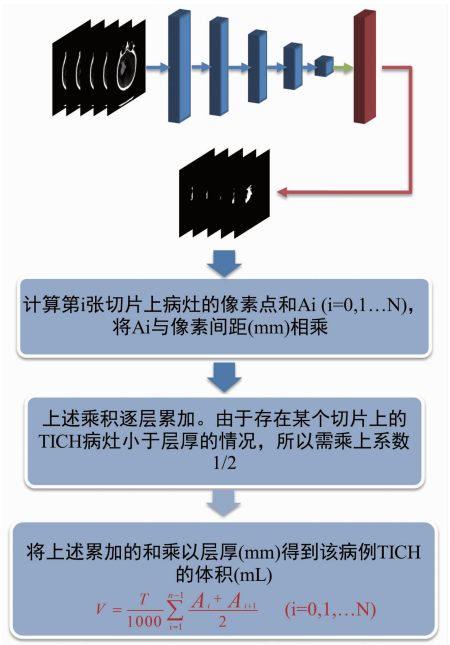


图 2 基于逐像素点图像处理的 TICH 体积计算流程图

1.4 评价指标

主要比较不同定量方法的准确性、一致性和测量耗时。我们使用百分误差(公式 2)评估不同方法较 PACS 人工勾画的准确性。公式如下。V 表示体积。

$$\text{百分误差}=(V_{\text{其他方法}}-V_{\text{人工勾画}})/V_{\text{人工勾画}}\times 100\% \qquad (2)$$

1.5 统计学分析

采用 SPSS 23.0 软件进行统计学分析,$P\leqslant 0.05$ 被认为差异具有统计学意义。使用 Kolmogorov-Smirnov 检验对计量数据进行正态性检验,服从正态分布的资料用 $\bar{x}\pm s$ 表示;不服从正态分布的资料以 $M(P_{25}, P_{75})$ 表示。接下来,采用 Friedman M 检验来比较不同体积定量方法之间的差异。在进行两两比较时,使用 Bonferroni 校正来控制误差。为了检验一致性,采用 Bland-Altman 分析(均数-差值)和 Spearman 相关分析。在绘制 Bland-Altman 分析图时,结合了 Python 中 spicy 库的自定义分析方法。使用 Origin 软件作部分统计图。

2 结果

2.1 分割模型的效能评估

本研究采用 Trans-UNet 模型进行图像分割。与 UNet、Attention-UNet、UNet++、SA-UNet++、UNet3+、Deeplabv3_resnet50 和 HR-Net 在测试集上的分割效果相比,本研究的模型在平均 Dice 系数、平均精确率和平均 HD 距离方面表现最优,分别为 0.821、0.877 和 36.8 mm。平均召回率为 0.782,略低于 SA-UNet++ 和 UNet,其余指标均处于较优水平(表 1)。为直观比

较 Trans-UNet 模型与其他模型的分割效果,在测试集上对靠近颅骨的 TICH 病灶的分割进行了对比展示(图 3),发现 Trans-UNet 模型能够更精准地捕获接近颅骨内板区域的信息,与原片图像具有更好的一致性。

2.2 不同定量方法的 TICH 体积及稳定性比较

本研究中计算得到的 TICH 体积及百分误差不服从正态分布($P<0.05$)。表 2 列出了不同方法获得的 TICH 体积、与 PACS 人工勾画的百分误差。Trans-UNet 模型预测得到的体积与 PACS 人工勾画最接近($P>0.05$,图 4),百分误差中位数为 3.590%。在余下方法中,π/6SH 百分误差最低,为 16.451%,而最常用的多田公式(ABC/2)的百分误差高达 40.436%。

表 1 不同模型的分割效果($\bar{x}\pm s$)

模型名称	平均 Dice 系数	平均 HD 距离/mm	平均 Jaccard 系数	平均精确率	平均召回率
UNet	0.752±0.150	75.654±39.841	0.623±0.171	0.759±0.202	0.789±0.118
Attention-UNet	0.788±0.136	60.870±40.569	0.667±0.163	0.854±0.136	0.756±0.156
UNet++	0.783±0.133	58.313±38.224	0.660±0.160	0.842±0.148	0.758±0.150
SA-UNet++	0.799±0.126	50.708±38.648	0.682±0.158	0.835±0.160	0.796±0.136
UNet3+	0.678±0.178	79.064±34.753	0.537±0.191	0.660±0.227	0.763±0.142
Deeplabv3_resnet50	0.775±0.152	44.983±39.194	0.658±0.186	0.864±0.144	0.734±0.181
HR-Net	0.803±0.124	38.287±36.909	0.688±0.161	0.870±0.151	0.767±0.137
Trans-UNet	0.821±0.142	36.800±40.040	0.700±0.167	0.877±0.124	0.782±0.162

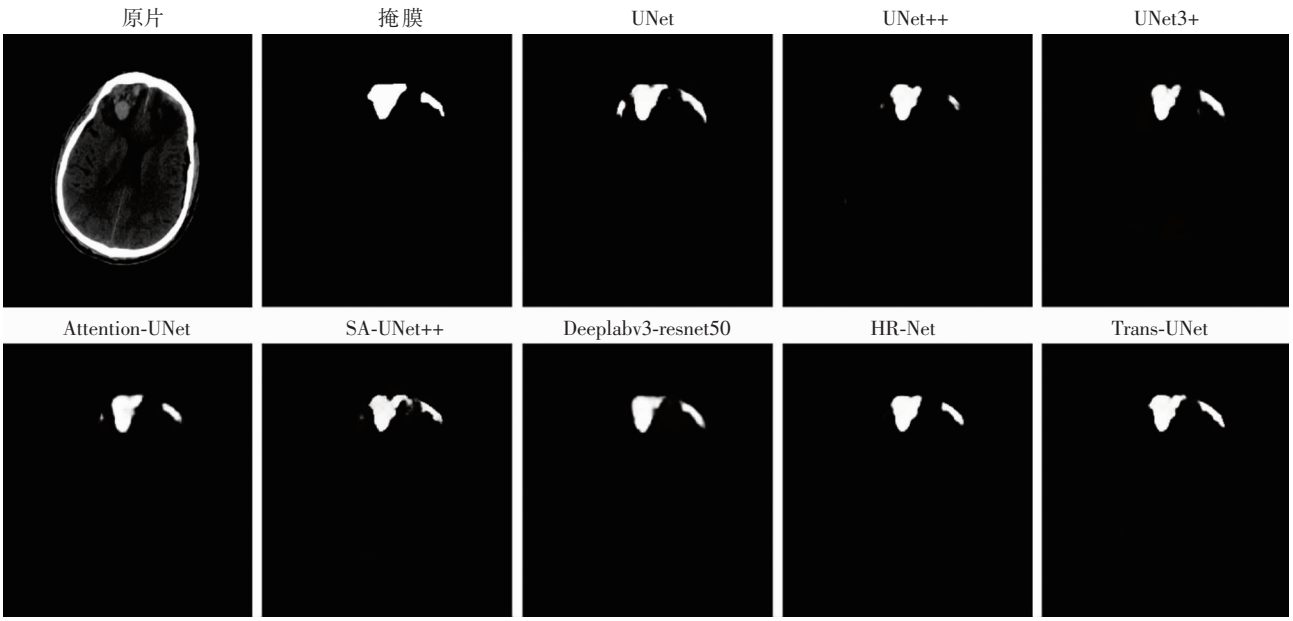
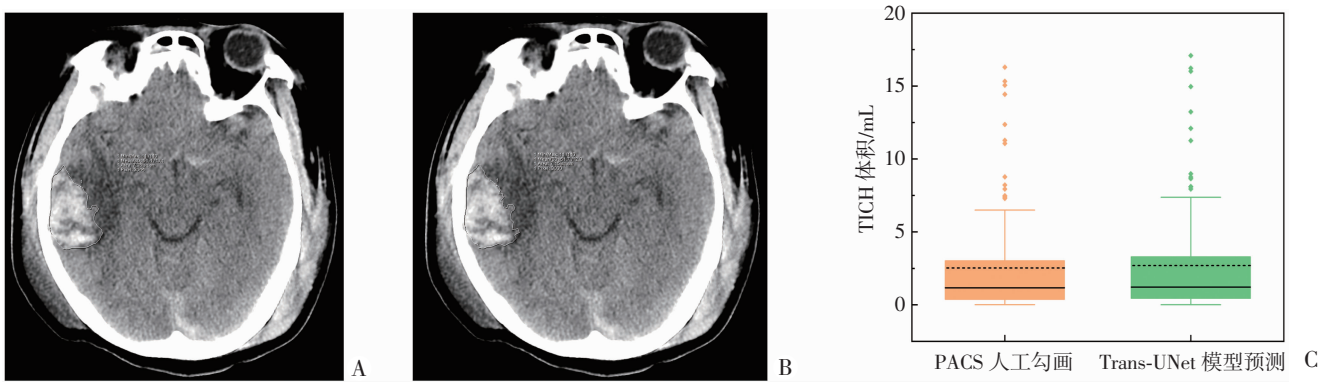


图 3 相同切片上不同模型对近颅骨 TICH 的分割可视化结果对比

表 2 不同定量方法的 TICH 体积及百分误差[$n=141$, M (P_{25}, P_{75})]

定量方法	血肿体积/mL	百分误差(%)
PACS 人工勾画	1.167(0.374, 3.179)	-
ABC/2	1.417(0.389, 4.022)	40.436(18.534,76.951)
2.5ABC/6	1.181(0.324, 3.351)	32.862(15.002, 60.138)
π/6ABC	1.484(0.408, 4.211)	43.474(20.242, 85.303)
ABC/3	0.945(0.260, 2.681)	32.586(17.363, 56.281)
2ABC/3	1.889(0.519, 5.362)	66.308(32.686, 135.935)
SH/2	1.075(0.343, 2.692)	19.408(8.739, 26.600)
π/6SH	1.126(0.360, 2.819)	16.451(6.683, 25.349)
2SH/3	1.434(0.458, 3.589)	18.911(6.917, 35.633)
SH/3	0.717(0.229, 1.795)	40.791(32.183, 48.968)
2.5SH/6	0.896(0.286, 2.243)	26.964(16.864, 36.724)
Trans-UNet 模型预测	1.200(0.358, 3.292)	3.590(1.090, 10.190)



A:Trans-UNet 模型预测的单层 TICH 面积;B:PACS 人工勾画的单层 TICH 面积;C:PACS 人工勾画与 Trans-UNet 模型预测的 TICH 体积箱线图

图 4 Trans-UNet 模型预测与 PACS 人工勾画的 TICH 体积比较

采用 Friedman M 检验进一步探究不同方法量化的体积差异,发现差异有统计学意义($\chi^2=875.183$,$P<0.001$)。经过 Bonferroni 校正后,两两比较,除表 3 列出的组合外,其余组间均存在显著性差异(调整后 P 均<0.05)。不同定量方法的体积百分误差差异具有统计学意义($\chi^2=563.028$,$P<0.001$),其中 2ABC/3 的误差最大(66.31%)。经过 Bonferroni 校正后的两两比较发现,Trans-UNet 模型预测组均明显低于其他组(调整后 P 均<0.001)。

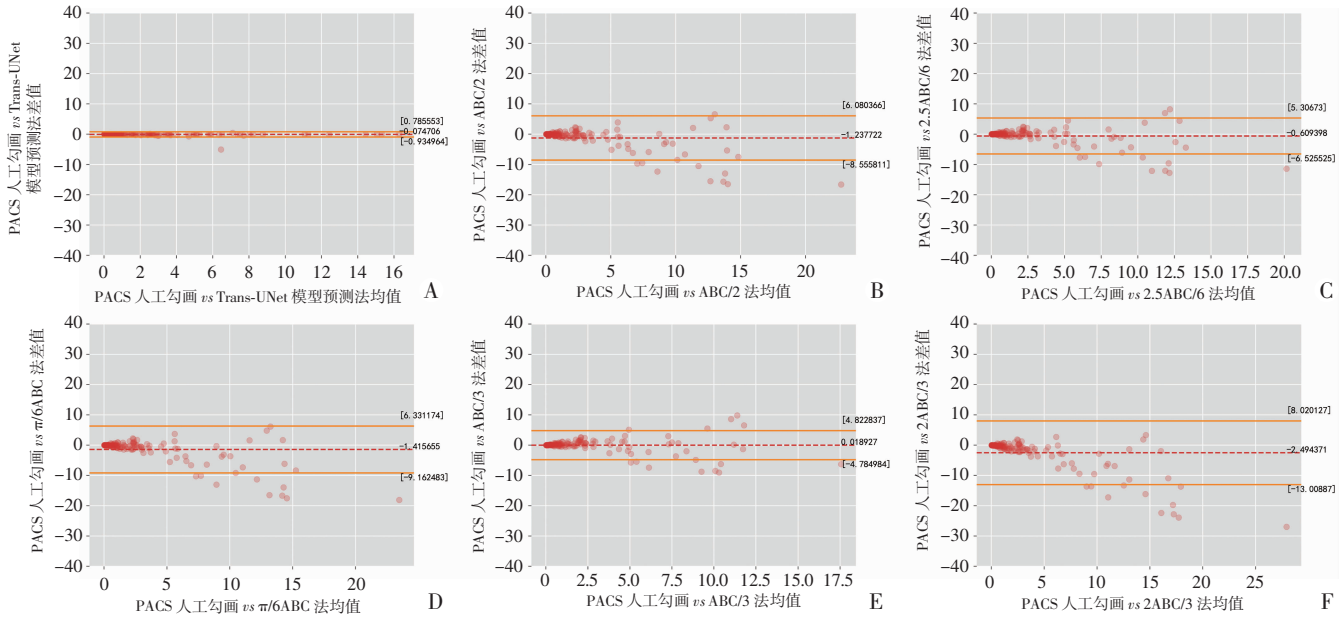
2.3 不同定量方法与 PACS 人工勾画的一致性和相关性

在各种方法和 PACS 人工勾画 TICH 体积之间的差异方面,Trans-UNet 模型预测的波动最小,其 95% 的计算限制范围(limits of agreement,LOA)为-0.935 至 0.786 mL,只有 0.70%(1/141)的数据点超出了 95%的 LOA 范围。而 π/6SH、2SH/3、SH/2、2.5SH/6、SH/3、ABC/3、2.5ABC/6、ABC/2、π/6ABC、2ABC/3 的波动逐渐增加。这些方法在 95%的 LOA 范围之外的数据点的比例分别为 4.97%、4.26%、5.67%、4.97%、4.97%、9.22%、7.80%、7.80%、7.10%和 7.10%(图 5、6)。

各方法与 PACS 人工勾画之间的 Spearman 相关性分析结果均显示出了较强正相关性(图 7、8)。Trans-UNet 模型预测与 PACS 人工勾画的 Spearman 相关系数(rs)为 0.999;而 ABC/2、2.5ABC/6、π/6ABC、ABC/3、2ABC/3 的 rs 为 0.928(P 均<0.001);SH/2、π/6SH、2SH/3、SH/3、2.5SH/6 的 rs 为 0.986(P 均<0.001)。

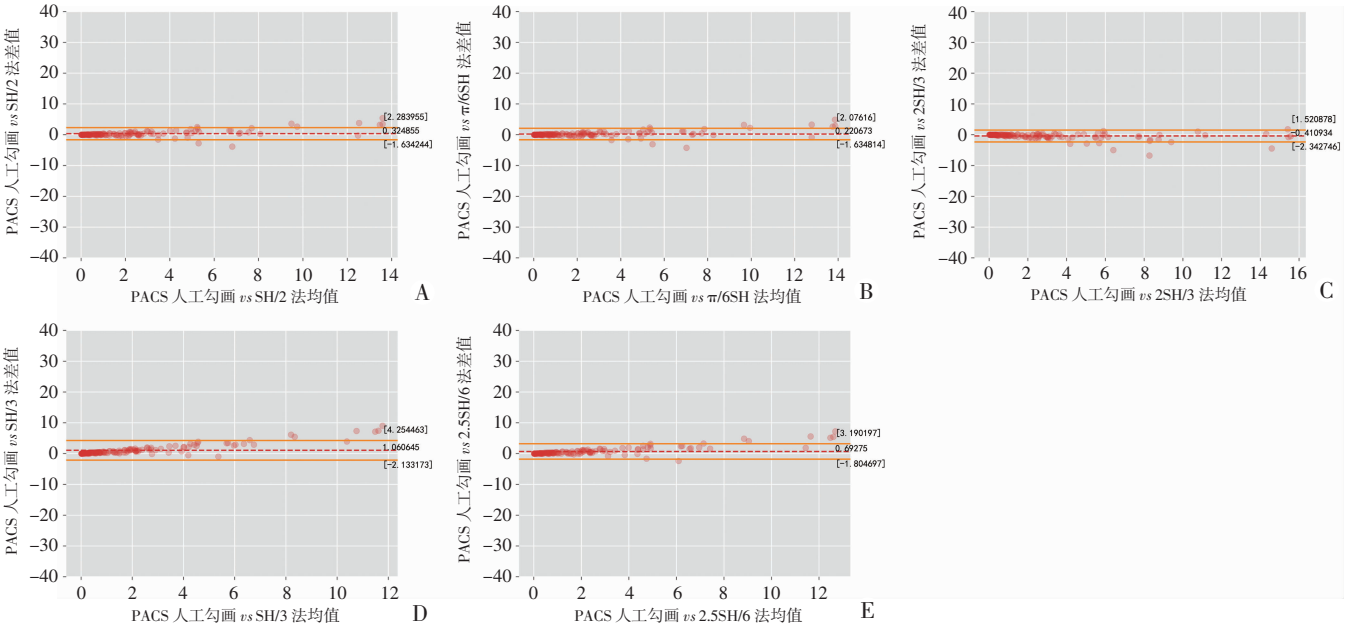
表 3 TICH 体积定量方法的部分两两比较

对比项目	标准检验统计量	调整后 P 值
ABC/3 *vs* 2SH/3	1.932	1.000
ABC/3 *vs* SH/2	-2.411	1.000
SH/2 *vs* 2.5SH/6	-2.940	0.217
SH/2 *vs* 2.5ABC/6	3.072	0.140
2.5SH/6 *vs* 2.5ABC/6	0.132	1.000
2.5SH/6 *vs* PACS 人工勾画	0.991	1.000
2.5SH/6 *vs* Trans-UNet 模型预测	2.081	1.000
2.5ABC/6 *vs* PACS 人工勾画	0.859	1.000
2.5ABC/6 *vs* Trans-UNet 模型预测	1.949	1.000
PACS 人工勾画 *vs* Trans-UNet 模型预测	1.090	1.000
ABC/2 *vs* PACS 人工勾画	-3.353	0.053
ABC/2 *vs* Trans-UNet 模型预测	-2.263	1.000
ABC/2 *vs* 2SH/3	-2.031	1.000
ABC/2 *vs* π/6ABC	-2.643	0.543
2SH/3 *vs* π/6ABC	0.611	1.000



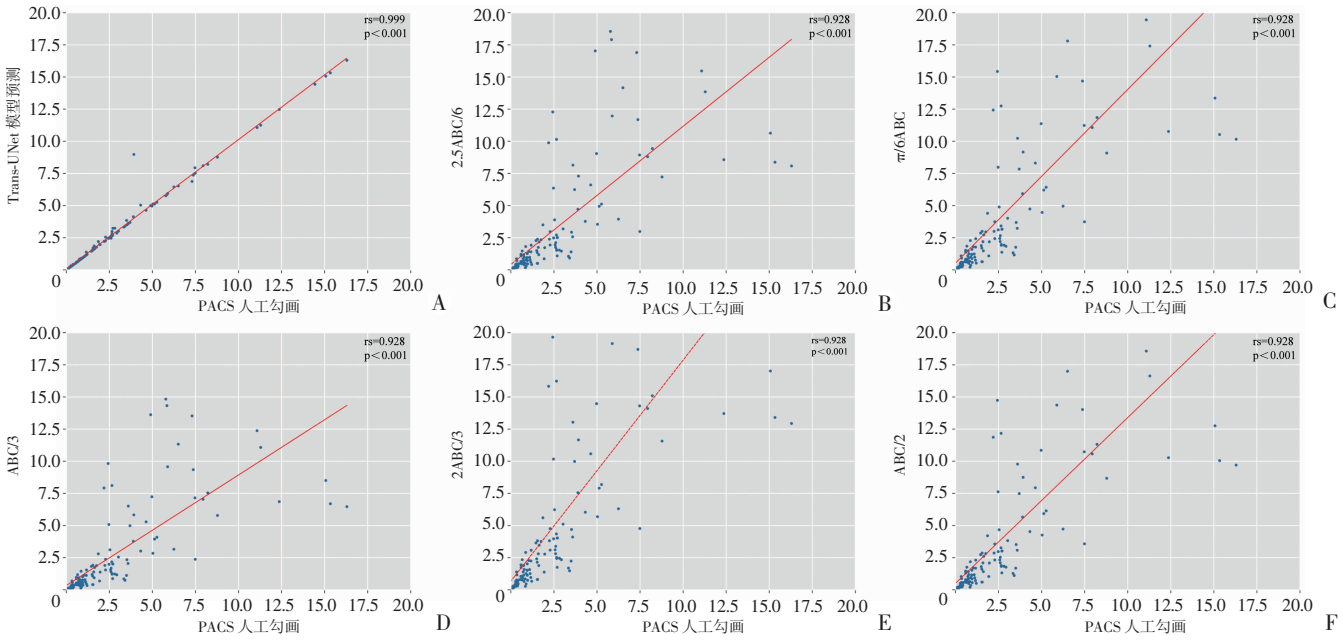
A:Trans-UNet 模型预测与 PACS 人工勾画体积均值差值;B:ABC/2 与 PACS 人工勾画体积均值差值;C:2.5ABC/6 与 PACS 人工勾画体积均值差值;D:π/6ABC 与 PACS 人工勾画体积均值差值;E:ABC/3 与 PACS 人工勾画体积均值差值;F:2ABC/3 与 PACS 人工勾画体积均值差值

图 5 Trans-UNet 模型预测、基于 TICH 病灶最大切面长轴 A 的公式法与 PACS 人工勾画的 TICH 体积差值比较



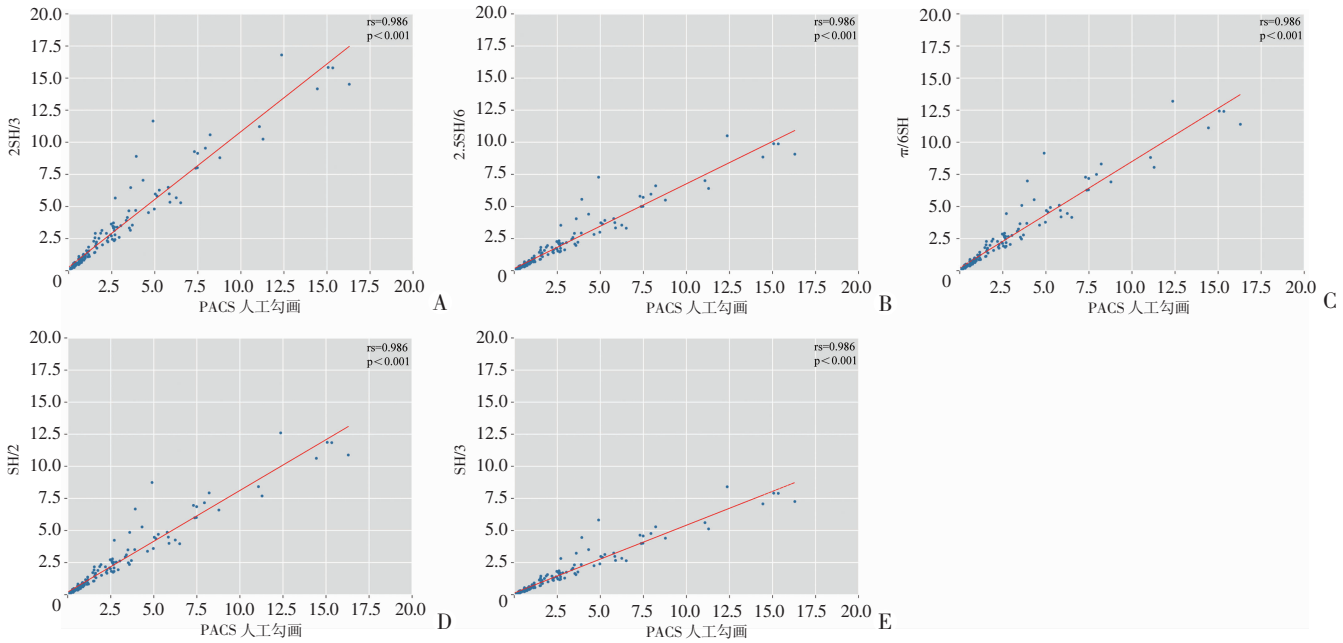
A:SH/2 与 PACS 人工勾画体积均值差值;B:π/6SH 与 PACS 人工勾画体积均值差值;C:2SH/3 与 PACS 人工勾画体积均值差值;D:SH/3 与 PACS 人工勾画体积均值差值;E:2.5SH/6 与 PACS 人工勾画体积均值差值

图 6 基于 TICH 病灶最大切面面积 S 的公式法与 PACS 人工勾画的 TICH 体积差值比较



A:Trans-UNet 模型预测与 PACS 人工勾画的体积相关性;B:2.5ABC/6 与 PACS 人工勾画的体积相关性;C:π/6ABC 与 PACS 人工勾画的体积相关性;D:ABC/3 与 PACS 人工勾画的体积相关性;E:2ABC/3 与 PACS 人工勾画的体积相关性;F:ABC/2 与 PACS 人工勾画的体积相关性

图 7 Trans-UNet 模型预测、基于病灶最大切面长轴 A 的公式法与 PACS 人工勾画的 TICH 体积相关性分析



A:2SH/3 与 PACS 人工勾画的体积相关性;B:2.5SH/6 与 PACS 人工勾画的体积相关性;C:π/6SH 与 PACS 人工勾画的体积相关性;D:SH/2 与 PACS 人工勾画的体积相关性;E:SH/3 与 PACS 人工勾画的体积相关性

图 8 基于病灶最大切面面积 S 的公式法与 PACS 人工勾画的 TICH 体积相关性分析

2.4 不同定量方法的测量时间比较

表4列出了不同定量方法的单个患者平均耗时,差异有统计学意义($P<0.001$)。Trans-UNet模型预测单个患者测量中位时间仅4.38 s,远短于PACS人工勾画的135 s。基于最大切面长轴A的公式(ABC/2、2.5ABC/6、π/6ABC、ABC/3、2ABC/3)的中位时间为21 s,而使用基于最大切面面积S的公式(SH/2、π/6SH、2SH/3、SH/3、2.5SH/6)的中位时间为20 s。两两比较发现,基于最大切面长轴A的公式与基于最大切面面积S的公式之间没有显著性差异($P>0.05$),而其余比较均具有统计学意义($P<0.001$)。

表4 不同定量方法的单个患者体积测量的中位时间

[$n=141$, M (P_{25}, P_{75})]

定量方法	时间/s
PACS人工勾画	135.00(81.00, 216.00)
基于TICH病灶最大切面长轴A的公式	21.00(17.00, 24.00)
基于TICH病灶最大切面面积S的公式	20.00(16.00, 22.00)
Trans-UNet模型预测	4.38(4.03, 4.91)

3 讨论

外伤性脑损伤后脑出血对患者临床转归不利,给公共卫生带来严重负担[3, 25]。血肿体积常作为判断是否需要手术治疗的指征之一[6],与患者预后密切相关[7-8]。本研究采用Trans-UNet模型进行图像分割,并利用逐像素点图像处理计算TICH体积,是AI在影像数据分析中的新应用,并取得较好效果。

本研究采用Trans-UNet模型分割TICH,效果优于UNet等分割模型。TICH区别于自发性脑出血,具有离散性分布特点,识别较困难。前期,本课题组在自发性脑出血的数据集上成功建立了效果良好的分割算法[26],并初步应用于TICH中,取得一定效果[27]。在此基础上,本研究尝试构建基于二维CT影像的TICH的AI定量方法。为减少训练波动,对Dice系数计算时,分别在分子和分母加上了一个偏置项(约10^{-5})。本分割模型的平均Dice系数达到0.821,与MACINTOSH等[28]的VIOLA-AI模型接近(0.82)。INKEAW等[29]采用三维卷积神经网络模型对不同TICH亚型进行分割,各亚型的Dice系数中位数均超过0.37,低于本研究构建的模型。目前,已有一些改进的U-Net模型开始应用于TICH的分割,而这些模型更注重体素方向上的病灶分割[30-31]。

本研究建立的TICH体积定量深度学习方法,准确性优于传统公式法,在不规则出血体积计算上优势更明显。临床工作中,主要采用基于椭球模型几何原理的公式法计算血肿体积。ABC/2是最常用的公式,尽管操作便捷,但对分叶状和硬膜下血肿的计算误差大[32],较实际体积偏大[10],高估率为8.53%~29.30%[15, 33]。此外,ABC/3常低估血肿体积[15],2SH/3对不规则血肿计算更准确[11]。ZHAO等[14]比较了π/6ABC、ABC/2、ABC/3、2SH/3、SH/2、π/6SH和2.5ABC/6的准确性,认为SH/2和π/6SH是计算血肿体积的最优公式。与上述既往研究一致,本研究中,ABC/2的百分误差达到40.436%,仅低于2ABC/3(66.308%);2SH/3的百分误差低至18.911%,ABC/3低估了0.22 mL;同时,SH/2和π/6SH较金标准也显示出良好的准确性,相关系数达到0.986。与公式法相比,深度学习方法的体积百分误差仅为3.590%,比公式法中最优的π/6SH低12.860%,与PACS人工勾画的相关性较高(rs=0.999),优于公式法中最大的SH/2和π/6SH(0.986),仅有0.7%的数据超出95%一致性界限。除准确性和一致性差异明显外,单个患者测量耗时较基于TICH病灶最大切面面积和长轴的公式法分别节约15.62 s和16.62 s。

本研究建立的TICH体积定量深度学习方法的效率显著高于既往国内外脑出血AI定量方法。贾永军等[34]的研究中,基于深度学习的计算机辅助诊断的平均误差为6.05%。田风选等[35]采用卷积神经网络分割硬膜下和硬膜外血肿,百分误差为23.62%,94.89%的测值在95%一致性界限内。李涛等[36]基于改进U-Net(MSHA-UNet)测量血肿体积,其百分误差为8.20%,与人工勾画的组内相关系数为0.987,96%的数据在95%一致性界限内。窦末未等[37]采用辅助分诊软件(uAI-HematomaCare)自动计算TICH体积,与手工勾画相比,TICH的体积相关性为0.949,勾画时间为48 s。姜雪等[38]采用AI软件测量的脑出血体积中位数较人工勾画低2.53 mL,人工测量费时(112.38±113.00) s,AI测量仅(5.27±0.71) s,与本研究的结果最接近。白珊韦等[39]探讨双源CT虚拟平扫联合AI在急性颅内出血的应用价值,与专家测量的组内相关系数为0.959,测量中位时间节约62.4 s。MACINTOSH等[28]使用沿注意力正交水平相交的体素AI(VIOLA-AI)对TICH进行量化,与手工勾画相比,体积中位数略高估0.47 mL。JAIN等[31]开发的基于U-Net的卷积神经网络模型与专家勾画相比,TICH体积中位数差

为0.07 mL,相关系数为0.94,并完成了多中心数据集验证。

本研究是AI领域前沿技术在TICH诊断中的新应用,建立的深度学习方法所取得的效果优于既往报道。其主要原因可能为:①本研究采用Trans-UNet模型,该模型同时结合了Transformer和卷积神经网络的优点,将来自卷积神经网络特征图的图像块编码为包含上下文信息的序列[40]。在考虑全局信息的同时,又充分利用局部信息,达到了较为理想的TICH病灶区域定位与边缘分割效果[17]。而U-Net、UNet++等模型均仅基于卷积神经网络而设计,卷积运算发生在局部,导致获取的信息局限,未能较好地建立信息的远程依赖关系[18, 20]。②本研究采用逐像素点图像处理保证数据的完整性,而传统AI借助积分求面积,因连通域由边界像素点的中心点构成常导致边界像素点丢失,从而计算值偏小,导致TICH体积定量不准。

本研究存在以下不足:①样本量小且为单中心,可能存在选择偏倚;②采用2D深度学习分割模型,虽然进行了系数修正,但相邻层间的空间关系并不明确,对于较小病灶的识别能力有待优化;③重点对脑挫伤型TICH进行分割,仅包含了极少的硬膜外和硬膜下血肿,缺乏不同亚型的分割效果对比。

综上所述,本研究结合逐像素点图像处理,成功构建了基于Trans-UNet模型的TICH体积定量深度学习方法。与传统公式法相比,本方法准确性更高,判读速度更快,能够及时对TICH患者进行分级,有助于临床医师合理选择治疗方式。同时,为后续TICH的AI定量研究、预后研究奠定理论基础。

参考文献:

[1] PEREL P, ROBERTS I, BOUAMRA O, *et al*. Intracranial bleeding in patients with traumatic brain injury: a prognostic study[J]. BMC Emerg Med, 2009, 9: 15. DOI: 10.1186/1471-227X-9-15.

[2] KAUVAR D S, WADE C E. The epidemiology and modern management of traumatic hemorrhage: US and international perspectives[J]. Crit Care, 2005, 9(Suppl 5): S1-S9. DOI: 10.1186/cc3779.

[3] SUBAIYA S, ROBERTS I, KOMOLAFE E, *et al*. Predicting intracranial hemorrhage after traumatic brain injury in low and middle-income countries: a prognostic model based on a large, multi-center, international cohort[J]. BMC Emerg Med, 2012, 12: 17. DOI: 10.1186/1471-227X-12-17.

[4] HEMPHILL J C 3rd, GREENBERG S M, ANDERSON C S, *et al*. Guidelines for the management of spontaneous intracerebral hemorrhage: a guideline for healthcare professionals from the American Heart Association/American Stroke Association[J]. Stroke, 2015, 46(7): 2032-2060. DOI: 10.1161/STR.0000000000000069.

[5] HEMPHILL J C, BONOVICH D C, BESMERTIS L, *et al*. The ICH score: a simple, reliable grading scale for intracerebral hemorrhage[J]. Stroke, 2001, 32(4): 891-897. DOI: 10.1161/01.str.32.4.891.

[6] LOPRESTI M A, BRUCE S S, CAMACHO E, *et al*. Hematoma volume as the major determinant of outcomes after intracerebral hemorrhage[J]. J Neurol Sci, 2014, 345(1/2): 3-7. DOI: 10.1016/j.jns.2014.06.057.

[7] SHAHANGIAN B, POURGHASSEM H. Automatic brain hemorrhage segmentation and classification algorithm based on weighted grayscale histogram feature in a hierarchical classification structure[J]. Biocybern Biomed Eng, 2016, 36(1): 217-232. DOI: 10.1016/j.bbe.2015.12.001.

[8] CHEN D, BIAN L, HE H Y, *et al*. Evaluation of traumatic subdural hematoma volume by using image segmentation assessment based on deep learning[J]. Comput Math Methods Med, 2022, 2022: 3830245. DOI: 10.1155/2022/3830245.

[9] JACOBS B, BEEMS T, VAN DER VLIET T M, *et al*. Computed tomography and outcome in moderate and severe traumatic brain injury: hematoma volume and midline shift revisited[J]. J Neurotrauma, 2011, 28(2): 203-215. DOI: 10.1089/neu.2010.1558.

[10] ZHU Y, QI S H, WU H M, *et al*. New measuring method for the volume of intracerebral hematoma[J]. Neurosurg Q, 2015, 25(2): 183-188. DOI: 10.1097/wnq.0000000000000021.

[11] YANG W L, FENG Y L, ZHANG Y Y, *et al*. Volume quantification of acute infratentorial hemorrhage with computed tomography: validation of the formula 1/2ABC and 2/3SH[J]. PLoS One, 2013, 8(4): e62286. DOI: 10.1371/journal.pone.0062286.

[12] MUSCHELLI J, SWEENEY E M, ULLMAN N L, *et al*. PItcHPERFeCT: primary intracranial hemorrhage probability estimation using random forests on CT[J]. Neuroimage Clin, 2017, 14: 379-390. DOI: 10.1016/j.nicl.2017.02.007.

[13] GREWAL M, WIERSMA J, WESTERVELD H, *et al*. Automatic landmark correspondence detection in medical images with an application to deformable image registration

[J]. J Med Imaging, 2023, 10(1): 014007. DOI: 10.1117/1.JMI.10.1.014007.

[14] ZHAO B, JIA W B, ZHANG L Y, *et al*. 1/2SH: a simple, accurate, and reliable method of calculating the hematoma volume of spontaneous intracerebral hemorrhage[J]. Stroke, 2020, 51(1): 193-201. DOI: 10.1161/STROKEAHA.119.026951.

[15] WANG C W, JUAN C J, LIU Y J, *et al*. Volume-dependent overestimation of spontaneous intracerebral hematoma volume by the ABC/2 formula[J]. Acta Radiol, 2009, 50(3): 306-311. DOI: 10.1080/02841850802647039.

[16] YUSHKEVICH P A, PIVEN J, HAZLETT H C, *et al*. User-guided 3D active contour segmentation of anatomical structures: significantly improved efficiency and reliability[J]. Neuroimage, 2006, 31(3): 1116-1128. DOI: 10.1016/j.neuroimage.2006.01.015.

[17] CHEN J N, LU Y Y, YU Q H, *et al*. TransUNet: transformers make strong encoders for medical image segmentation[EB/OL]. 2021: 2102.04306. http://arxiv.org/abs/2102.04306v1

[18] BOUSABARAH K, RUGE M, BRAND J S, *et al*. Deep convolutional neural networks for automated segmentation of brain metastases trained on clinical data[J]. Radiat Oncol, 2020, 15(1): 87. DOI: 10.1186/s13014-020-01514-6.

[19] OKTAY O, SCHLEMPER J, LE FOLGOC L, *et al*. Attention U-net: learning where to look for the pancreas[EB/OL]. 2018: 1804.03999. https://arxiv.org/abs/1804.03999v3.

[20] ZHOU Z W, SIDDIQUEE M M R, TAJBAKHSH N, *et al*. UNet: redesigning skip connections to exploit multiscale features in image segmentation[J]. IEEE Trans Med Imag, 2020, 39(6): 1856-1867. DOI: 10.1109/TMI.2019.2959609.

[21] XIAO H G, RAN Z Q, MABU S, *et al*. SAUNet++: an automatic segmentation model of COVID-19 lesion from CT slices[J]. Vis Comput, 2023, 39(6): 2291-2304. DOI: 10.1007/s00371-022-02414-4.

[22] HUANG H M, LIN L F, TONG R F, *et al*. UNet 3: a full-scale connected UNet for medical image segmentation[C]//ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Barcelona, Spain. IEEE, 2020: 1055-1059. DOI: 10.1109/ICASSP40776.2020.9053405.

[23] HE K M, ZHANG X Y, REN S Q, *et al*. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA. IEEE, 2016: 770-778. DOI: 10.1109/CVPR.2016.90.

[24] SUN K, XIAO B, LIU D, *et al*. Deep high-resolution representation learning for human pose estimation[EB/OL]. 2019: 1902.09212. http://arxiv.org/abs/1902.09212v1

[25] POWERS A Y, PINTO M B, TANG O Y, *et al*. Predicting mortality in traumatic intracranial hemorrhage[J]. J Neurosurg, 2019, 132(2): 552-559. DOI: 10.3171/2018.11.JNS182199.

[26] XIAO H G, SHI X Y, XIA Q L, *et al*. DFMA-ICH: a deformable mixed-attention model for intracranial hemorrhage lesion segmentation based on deep supervision[J]. Neural Comput Appl, 2024, 36(15): 8657-8679. DOI: 10.1007/s00521-024-09545-w.

[27] PENG K, LI Y L, XIA Q L, *et al*. MSMCNet: Differential context drives accurate localization and edge smoothing of lesions for medical image segmentation[J]. Comput Biol Med, 2023, 167: 107624. DOI: 10.1016/j.compbiomed.2023.107624.

[28] MACINTOSH B J, LIU Q H, SCHELLHORN T, *et al*. Radiological features of brain hemorrhage through automated segmentation from computed tomography in stroke and traumatic brain injury[J]. Front Neurol, 2023, 14: 1244672. DOI: 10.3389/fneur.2023.1244672.

[29] INKEAW P, ANGKURAWARANON S, KHUMRIN P, *et al*. Automatic hemorrhage segmentation on head CT scan for traumatic brain injury using 3D deep learning model[J]. Comput Biol Med, 2022, 146: 105530. DOI: 10.1016/j.compbiomed.2022.105530.

[30] KELLOGG R T, VARGAS J, BARROS G, *et al*. Segmentation of chronic subdural hematomas using 3D convolutional neural networks[J]. World Neurosurg, 2021, 148: e58-e65. DOI: 10.1016/j.wneu.2020.12.014.

[31] JAIN S, VYVERE T V, TERZOPOULOS V, *et al*. Automatic quantification of computed tomography features in acute traumatic brain injury[J]. J Neurotrauma, 2019, 36(11): 1794-1803. DOI: 10.1089/neu.2018.6183.

[32] WEBB A J, ULLMAN N L, MORGAN T C, *et al*. Accuracy of the ABC/2 score for intracerebral hemorrhage: systematic review and analysis of MISTIE, CLEAR-IVH, and CLEAR III[J]. Stroke, 2015, 46(9): 2470-2476. DOI: 10.1161/STROKEAHA.114.007343.

[33] XU X H, CHEN X L, ZHANG J, *et al*. Comparison of the Tada formula with software slicer: precise and low-cost method for volume assessment of intracerebral hematoma

[J]. Stroke, 2014, 45(11): 3433-3435. DOI: 10.1161/STROKEAHA.114.007095.

[34] 贾永军, 于楠, 于勇, 等. 基于深度学习的计算机辅助诊断系统对脑出血血肿体积的测量研究[J]. 中国中西医结合影像学杂志, 2021, 19(2): 180-183. DOI: 10.3969/j.issn.1672-0512.2021.02.022.
JIA Y J, YU N, YU Y, *et al*. Accuracy of deep learning-based computer aided diagnosis system for measuring the intracranial hematoma volume[J]. Chin Imag J Integr Tradit West Med, 2021, 19(2): 180-183. DOI: 10.3969/j.issn.1672-0512.2021.02.022.

[35] 田风选, 常健博, 陈亦豪, 等. 基于卷积神经网络的硬膜下和硬膜外血肿分割方法的一致性评价[J]. 中国现代神经疾病杂志, 2021, 21(3): 192-196. DOI: 10.3969/j.issn.1672-6731.2021.03.011.
TIAN F X, CHANG J B, CHEN Y H, *et al*. Agreement evaluation of an automatic segmentation algorithm for quantifying subdural/epidural hemorrhage volume using convolution neural network[J]. Chin J Contemp Neurol Neurosurg, 2021, 21(3): 192-196. DOI: 10.3969/j.issn.1672-6731.2021.03.011.

[36] 李涛, 陈凯, 刘耀辉, 等. 基于改进U-net网络的脑血肿CT图像分割与体积测量研究[J]. 湘南学院学报(医学版), 2022, 24(2): 1-6. DOI: 10.16500/j.cnki.1673-498x.2022.02.001.
LI T, CHEN K, LIU Y H, *et al*. Segmentation and volume measurement of intracerebral hemorrhage in CT images based on improved U-NET network[J]. J Xiangnan Univ Med Sci, 2022, 24(2): 1-6. DOI: 10.16500/j.cnki.1673-498x.2022.02.001.

[37] 窦末未, 刘远健, 陈凯, 等. 人工智能对外伤性脑出血的诊断及定量临床应用研究[J]. 医学信息, 2023, 36(15): 57-63. DOI: 10.3969/j.issn.1006-1959.2023.15.010.
DOU M W, LIU Y J, CHEN K, *et al*. Study on diagnosis and quantitative clinical application of artificial intelligence in traumatic intracerebral hemorrhage[J]. J Med Inf, 2023, 36(15): 57-63. DOI: 10.3969/j.issn.1006-1959.2023.15.010.

[38] 姜雪, 吕发金, 李昱仑, 等. 医学影像人工智能技术评价脑出血准确性研究[J]. 中国医学计算机成像杂志, 2021, 27(1): 1-5. DOI: 10.19627/j.cnki.cn31-1700/th.2021.01.001.
JIANG X, LV F J, LI Y L, *et al*. The accuracy of medical imaging artificial intelligence technology in evaluation of cerebral hemorrhage[J]. Chin Comput Med Imag, 2021, 27(1): 1-5. DOI: 10.19627/j.cnki.cn31-1700/th.2021.01.001.

[39] 白珊玮, 韦鑫, 周治明, 等. 双源CT虚拟平扫技术联合人工智能在急性颅内出血诊断中的应用价值[J]. 陆军军医大学学报, 2023, 45(12): 1320-1327. DOI: 10.16016/j.2097-0927.202210168.
BAI S W, WEI X, ZHOU Z M, *et al*. Application value of dual-source virtual non-contrast CT combined with AI in diagnosis of acute intracranial hemorrhage[J]. J Army Med Univ, 2023, 45(12): 1320-1327. DOI: 10.16016/j.2097-0927.202210168.

[40] FONSECA J, LIU X Y, OLIVEIRA H P, *et al*. Mortality prediction using medical time series on TBI patients[J]. Comput Methods Programs Biomed, 2023, 242: 107806. DOI: 10.1016/j.cmpb.2023.107806.

(**收稿**:2023-11-07;**修回**:2024-05-10)

(编辑 邓强庭)