·临床研究·

基于双层探测器CT引导标注的3D nnU-Net模型在非增强CT食管分割中的应用：与Total Segmentator模型的对比研究

万云天[1]，陈志林[2]，崔筱洁[1]，白卓杰[1]，王　友[1]，王　皓[1*]

[1]南京医科大学第四附属医院放射科，江苏　南京　210031；[2]东南大学附属中大医院放射科，江苏　南京　210009

［摘　要］ **目的：**针对非增强CT（non-contrast computed tomography，NCCT）食管组织对比度低、分割难度大、通用分割模型性能受限的临床难点，探索基于双层探测器CT（dual-layer computed tomography，DLCT）引导标注的3D无新U-Net（no new U-Net，nnU-Net）模型，提升NCCT食管分割的精度与泛化能力，并与Total Segmentator通用模型进行性能对比。**方法：**回顾性纳入南京医科大学第四附属医院300例胸部DLCT检查患者，融合虚拟平扫（virtual non-contrast，VNC）与增强图像完成食管人工分割金标准，并用VNC训练3D nnU-Net模型，以真实平扫（true non-contrast，TNC）作为内部验证集；另纳入东南大学附属中大医院100例NCCT、国家生物信息中心48例NCCT作为2个外部测试集。采用Dice相似系数（Dice similarity coefficient，DSC）、95%豪斯多夫距离（95% Hausdorff distance，HD95）、组内相关系数（Intraclass correlation coefficient，ICC）及Likert 5分法主观评分，对比两模型的分割性能。**结果：**在内部验证集及2个独立外部测试集中，3D nnU-Net模型的核心分割性能（DSC：0.756~0.798，HD95：4.00~4.10 mm）均显著优于Total Segmentator模型（DSC：0.687~0.697，HD95：5.00~5.00 mm；Z=3.875~13.045，P < 0.001）。该模型与人工勾画金标准的一致性更佳（Spearman r_s=0.821~0.887，ICC=0.84~0.91），显著高于对照模型（Spearman r_s=0.626~0.716，ICC=0.64~0.70）；Bland-Altman分析显示其95%一致性界限更窄、测量偏移更小，体积偏差处于临床可接受范围。同时，3D nnU-Net模型的主观分割质量评分稳定为5.00分，显著高于对照模型（P < 0.001）。**结论：**基于DLCT引导标注的3D nnU-Net模型在食管分割中具有更优的分割性能与泛化能力，为NCCT自动化分割提供了新的技术策略。

［关键词］ 双层探测器CT；虚拟平扫；非增强CT；食管；图像分割

［中图分类号］ R814.42　　［文献标志码］ A　　［文章编号］ 1007-4368（2026）11-1682-09

doi：10.7655/NYDXBNSN260446

Application of 3D nnU - Net model guided by dual - layer detector CT annotation in esophagus segmentation on non - contrast CT：a comparative study with the total segmentator model

Wan Yuntian[1]，Chen Zhilin[2]，Cui Xiaojie[1]，Bai Zhuojie[1]，Wang You[1]，Wang Hao[1*]

[1]Department of Radiology，the Fourth Affiliated Hospital of Nanjing Medical University，Nanjing 210031；[2]Department of Radiology，Zhongda Hospital，Southeast University，Nanjing 210009，China

［**Abstract**］ **Objective：** To address the clinical challenges of poor esophageal tissue contrast，inherent segmentation difficulty，and suboptimal performance of generic segmentation models on non-contrast computed tomography（NCCT），this study developed a dual-layer computed tomography（DLCT）annotation - guided 3D no new U - Net（3D nnU - Net）model to improve the accuracy and generalizability of NCCT-based esophageal segmentation，and compared its performance with the widely used generic model Total Segmentator. **Methods：** A total of 300 patients who underwent chest DLCT examination at the Fourth Affiliated Hospital of Nanjing Medical University were retrospectively enrolled. The manual esophageal segmentation gold standard was established by fusing virtual non-contrast（VNC）and contrast-enhanced CT images. The 3D nnU-Net model was trained on VNC images，with true non-contrast（TNC）images serving as the internal validation set. Two independent external test sets were included：100 NCCT cases from Zhongda Hospital Affiliated to Southeast University，and 48 NCCT cases from the National Center for Bioinformation. Segmentation performance

［基金项目］ 南京江北新区重点研发项目计划（ZDYF202520）；南京医科大学科技发展基金一般项目（NMUB20250298）

*通信作者（Corresponding author），E-mail：blasthao@hotmail.com（OCRID：0000-0003-2659-7231）

of the two models was compared via quantitative metrics（Dice similarity coefficient，DSC；95% Hausdorff distance，HD95；intraclass correlation coefficient，ICC）and qualitative 5-point Likert subjective scoring. **Results**：Across the internal validation set and two external test sets，the proposed 3D nnU-Net model achieved excellent core segmentation performance（DSC：0.756-0.798，HD95：4.00-4.10 mm），and significantly outperformed the Total Segmentator model（DSC：0.687-0.697，HD95：5.00~5.00 mm；Z=3.875-13.045，all P < 0.001）. The proposed model exhibited stronger agreement with the manual gold standard（Spearman r_s=0.821-0.887，ICC=0.84-0.91），markedly higher than the control model（Spearman r_s=0.626-0.716，ICC=0.64-0.70）. Bland-Altman analysis confirmed the 3D nnU-Net model had narrower 95% limits of agreement and smaller measurement bias，with volumetric deviation within the clinically acceptable range. Meanwhile，the proposed model yielded a stable median subjective segmentation quality score of 5.00，significantly higher than that of the control model（P < 0.001）. **Conclusion**：The DLCT annotation-guided 3D nnU-Net model achieves superior esophageal segmentation performance and generalization capability，providing a novel technical strategy for automated NCCT-based esophageal segmentation.

［**Key words**］ spectral CT；virtual non-contrast；non-contrast computed tomography；esophagus；image segmentation

［J Nanjing Med Univ，2026，46（11）：1682-1690］

食管作为胸腹部重要的管状肌性器官，因其走行迂曲、管壁菲薄，且易受纵隔内心脏、大血管等邻近组织压迫而形态多变，是医学影像分割领域的难点[1]。CT影像下的食管精准分割，是食管癌放疗靶区自动勾画、食管良恶性病变早筛与胸腹部相关疾病诊疗的核心环节，对临床规范化诊疗具有重要的支撑价值[2-4]。非增强CT（non-contrast computed tomography，NCCT）因无造影剂相关风险、检查成本低、成像速度快、临床可及性高等优势，具备突出的临床适用性与规模化推广潜力[5-6]。然而，受食管自身复杂解剖特性与NCCT软组织低对比度的双重限制，食管与周围组织边界模糊，不仅人工分割难度大、耗时长，且存在显著的观察者间差异[7-9]。增强CT（contrast-enhanced computed tomography，CECT）虽可通过提升组织对比度清晰显示食管边界，联合多模态配准也可进一步提升分割精度，但不仅会带来造影剂过敏、肾损伤等不良反应风险，还易受呼吸、心跳生理运动及扫描时相差异影响产生配准偏差[10-11]。目前临床广泛应用的Total Segmentator通用分割模型，虽可实现高效自动化分割，但其模型架构未针对食管的特殊解剖特征与NCCT低对比度的成像特点做专项优化，存在精度不足、泛化性能受限的核心问题，无法满足前述临床需求对分割性能的要求[12]。

无新U-Net（no new U-net，nnU-Net）凭借自适应网络架构与高效的特征提取能力，无需额外自定义参数即可通过标准化流程优化医学图像分割效率与精度，在多器官分割任务中展现出优异性能[13]；但作为监督学习模型，其分割效果高度依赖训练数据的标注精准度，而NCCT图像中食管标注难度大、准确性低，直接制约了模型分割性能[14]。双层探测器CT（dual-layer detector computed tomography，DLCT）可通过单次增强扫描，重建出空间解剖信息完全匹配的虚拟平扫（virtual non-contrast，VNC）图像，现有研究已证实VNC可替代真实平扫（true non-contrast，TNC）用于胸腹部脏器病变的定量分析[15-17]。尽管DLCT在消化道影像学评估中应用广泛，但VNC能否稳定替代TNC用于食管分割深度学习模型的训练，尚无充分研究验证。

综上所述，本研究采用DLCT引导标注策略，以VNC图像训练nnU-Net食管分割模型，在TNC图像完成内部验证，并通过多中心NCCT数据开展外部测试，同时与Total Segmentator通用模型进行头对头对比，旨在构建高精度、强泛化性的NCCT食管自动分割模型，为临床食管自动化精准分割提供新的技术方案。

1　对象和方法

1.1　对象

本研究共纳入来自3个中心的对象，分组如下：①训练集：选取2022年9月—2025年11月于南京医科大学第四附属医院接受Philips IQon Spectral CT（光谱CT）胸腹部平扫+增强扫描的患者300例，其中男201例、女99例，年龄（60.54±15.19）岁。②验证集：采用与训练集相同患者的TNC图像数据。③外部测试集1：选取于东南大学附属中大医院接受联影CT胸部平扫的患者100例，其中男73例、女27例，年龄（65.23±14.19）岁；④外部测试集2：选取国家生

物信息中心（https://ngdc.cncb.ac.cn/obia/home）中符合本研究纳入排除标准的48例样本，其中男41例、女7例，年龄（61.48±7.45）岁[18]。本研究统一排除标准为：①图像存在严重伪影，无法清晰识别解剖结构；②食管存在器质性病变并已造成形态改变；③有食管插管操作史或食管相关手术史。本研究为回顾性研究，研究方案经南京医科大学第四附属医院伦理审查委员会批准（审批编号：SFY20250210-K206），并获准豁免患者知情同意。

1.2　方法

1.2.1　图像获得

训练集与验证集所有患者的CT图像均使用Philips IQon Spectral CT（飞利浦医疗，荷兰）完成了胸部CT或胸腹部CT平扫+增强扫描。检查中患者仰卧位扫描，足先进，双臂抬高置于头顶上方，在深吸气屏气状态下采集图像，胸部扫描范围胸廓入口（肺尖上方1~2 mm）至膈肌下2~3 mm；胸腹部扫描范围为胸廓入口至耻骨联合。扫描参数如下：管电压120 kVp，管电流采用自动管电流调制技术，螺距1.258，球管转速0.5 s/r，准直器宽度64.000×0.625 mm，视野FOV350 mm，层厚与层间距均为5 mm，矩阵512×512，采用迭代重建（iDose^4）与Standard卷积核，窗宽350 HU、窗位60 HU。

采用高压注射器经肘正中静脉注射碘海醇（350 mgI/mL，江苏恒瑞医药），药量为250~300 mgI/kg，注射流率2.5~3 mL/s，后续以相同流率注射20~30 mL生理盐水，以胸降主动脉中心为感兴趣区域（region of interest，ROI），当ROI内CT值达到120 HU时，采用“团注追踪（bolus tracking）”自动追踪触发动脉期扫描。分别于造影剂注射后60~70 s、120 s采集静脉期、延迟期（胸腹部）图像，所有增强序列均开启光谱基图像（spectral base image，SBI）。通过飞利浦星云工作站，进入能谱分析模式，重建出VNC 2种图像，所有图像以DICOM格式存入PACS系统。

外部测试集1：100例患者的胸部平扫图像，采用uCT960（上海联影医疗）进行扫描，检查时患者仰卧位扫描，头先进，双臂抬高置于头顶上方，在深吸气结束时屏气状态下采集图像，胸部扫描范围胸廓入口（肺尖上方1~2 mm）至膈肌下2~3 mm；参数为：管电压120 kVp，管电流自动调节（平均70 mAs），准直宽度80.0×0.5 mm，视野FOV 350 mm，螺距1.987 5，图像矩阵512×512，采用KDL3D Level 5迭代重建算法，卷积核为B_soft_B，层厚、层间距均为0.625 mm，窗宽250 HU、窗位50 HU，重建为层厚5 mm纵隔窗；外部测试集2：为国家生物信息中心的胸腹部平扫纵隔窗图像，层厚均为5 mm纵隔窗。

1.2.2　图像预处理

所有中心图像均以DICOM格式保存并导入3D Slicer软件（https://www.slicer.org），统一转换为NIfTI格式，同时采用resample模块将图像重采样成1×1×5 mm。对所有图像进行去标识化处理，隐匿患者个人信息及诊断相关信息，为每位患者分配唯一识别ID，保证数据隐私性。

1.2.3　食管组织分割标注

邀请1名具有10年影像学诊断经验的主治医师完成食管手动勾画标注。针对训练集，将VNC、CECT图像同时载入，调整CECT融合权重至食管边界清晰后，从甲状软骨至胃食管结合部层面逐层勾画食管；验证集与两个测试集则直接在TNC序列上完成勾画。所有标注结果由1名20年影像学诊断经验的主任医师审核，存在分歧时，双方通过共同阅片、充分商议，最终达成一致意见，以共识结果作为最终标注标准。

1.2.4　模型训练与推理

模型采用nnU-Net框架的3D全分辨率（full resolution，fullres），基于在300例CECT辅助勾画的VNC图像进行训练。训练环境为搭载RTX 3080Ti 12G显卡的工作站，初始学习率为0.01，batch size为2，轮次为1 000轮，每轮55 s。模型训练好后，将3D full-resolution模型对内部验证集及两个外部测试集进行推理，同时采用公开模型Total Segmentator（https://github.com/wasserth/TotalSegmentator，版本：2.12.0，high resolution模式）对相同数据集进行推理。推理采用训练模型时在同样的工作站进行，分别保存分割mask。

1.2.5　客观评价

采用Dice相似系数（Dice Similarity Coefficient，DSC）和95%豪斯多夫距离（95% Hausdorff Distance，HD95）作为食管分割模型的性能客观评价指标。DSC用于量化预测区域与金标准的体积重叠度，取值0~1，数值越高，重叠度与分割精度越高；HD95用于量化模型预测分割边界与金标准真实边界的吻合精度，定义为预测边界点集与真实边界点集之间距离的95%分位数。HD95数值越低，边界吻合度与分割效果越优。根据两个模型分割结果与人工分割结果，分别计算DSC与HD95值。

1.2.6　主观评价

邀请2名副高级胸部影像诊断医师，在双盲条件下对3个数据集的3D nnU-Net、Total Segmentator模

型分割结果与人工分割图像进行对照评阅，采用Likert 5分法对模型分割效果进行独立评分，评分标准严格围绕食管分割的解剖特点制定，具体如下。1分：分割结果与人工分割严重不符，存在大面积过或欠分割；2分：分割结果存在明显误差，边界严重模糊，与周围组织混淆；3分：分割结果存在轻微误差，小范围过或欠分割；4分：分割结果与人工分割高度匹配，边界基本清晰，无明显过或欠分割；5分：分割结果与人工分割几乎完全一致，边界清晰、走行连续，与邻近组织区分度极佳。

1.3　统计学方法

正态性检验：采用Shapiro-Wilk检验验证各中心数据分布，正态分布数据采用配对样本t检验，非正态分布数据采用Wilcoxon符号秩检验。一致性分析：自动分割与人工分割体积行Bland-Altman分析、Spearman秩相关分析，r_s≥0.85为一致性极好，0.70~0.85为良好，<0.70为较差。两模型与人工金标准及医师主观评价一致性：组内相关系数（intra-class correlation coefficient，ICC）检验评价者之间及模型于人工分割的一致性，ICC≥0.8为一致性极好，0.7~0.8为一致性良好。P < 0.05为差异有统计学意义。

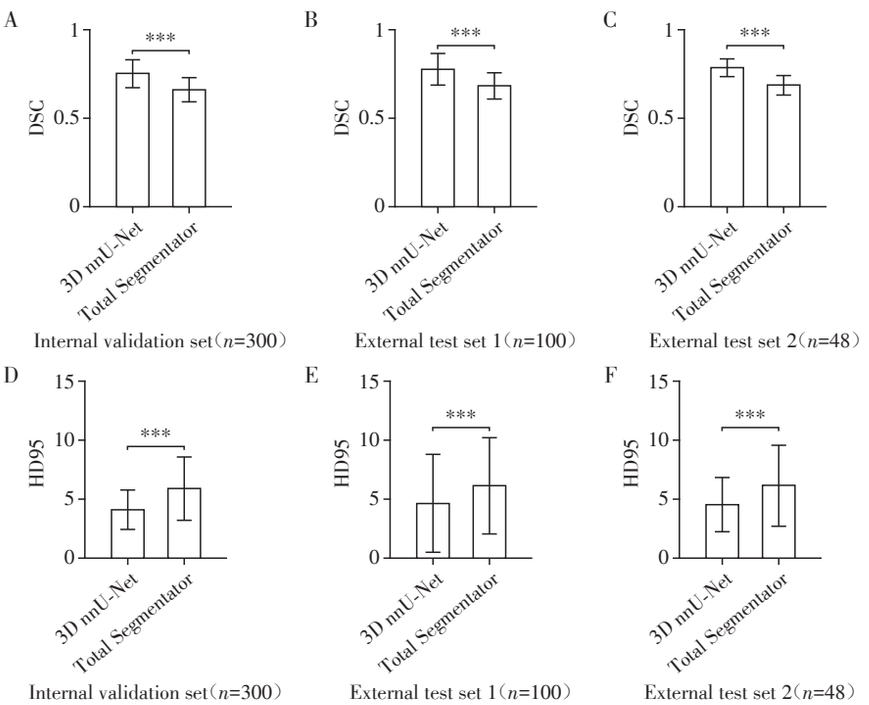
2　结　果

2.1　自动分割模型性能评价

内部验证集与两组外部测试集中，3D nnU-Net模型分割性能均优于Total Segmentator模型。3D nnU-Net模型DSC为0.756（0.696，0.818）、0.787（0.768，0.809）、0.798（0.769，0.816），HD95为4.10（2.61，5.00）、4.00（2.82，5.00）、4.07（3.00，5.00），显著优于Total Segmentator模型：DSC为0.663（0.618，0.715）、0.687（0.662，0.719）、0.697（0.663，0.727），HD95为5.00（4.79，5.75）、5.00（5.00，5.52）、5.00（5.00，5.89）。所有组间P均<0.001，差异有统计学意义。3D nnU-Net模型分割结果比Total Segmentator更加稳定优异（图1、表1）。

2.2　自动分割体积与人工金标准体积一致性分析

内部验证集与两组外部测试集中，Spearman秩相关分析显示，3D nnU-Net模型食管自动分割体积与人工分割体积的Spearman r_s分别为0.821、0.822、0.887，ICC值为：0.84、0.84、0.91；Total Segmentator的Spearman r_s分别为0.715、0.626、0.716，ICC值为：



A：Comparison of DSC between 3D nnU-Net and Total Segmentator in the internal validation set. B：DSC comparison of the two models in external validation set 1. C：DSC comparison of the two models in external validation set 2. D：Comparison of HD95 between 3D nnU-Net and Total Segmentator in the internal validation set. E：HD95 comparison of the two models in external validation set 1. F：HD95 comparison of the two models in external validation set.

图1　分割效果差异对比图

Figure 1　Display of segmentation performance differences

表1　3D nnU-Net与Total Segmentator分割性能对比

Table 1　Comparison of segmentation performance between 3D nnU-Net and Total Segmentator

Dataset	Metrics	3D nnU-Net	Total Segmentator	*Z*	*P*
Internal validation set	DSC	0.756(0.696,0.818)	0.663(0.618,0.715)	13.045	<0.001
	HD95(mm)	4.10(2.61,5.00)	5.00(4.79,5.75)	10.498	<0.001
External test set 1	DSC	0.787(0.768,0.809)	0.687(0.662,0.719)	11.186	<0.001
	HD95(mm)	4.00(2.82,5.00)	5.00(5.00,5.52)	6.199	<0.001
External test set 2	DSC	0.798(0.769,0.816)	0.697(0.663,0.727)	7.071	<0.001
	HD95(mm)	4.07(3.00,5.00)	5.00(5.00,5.89)	3.875	<0.001

0.73、0.64、0.70。各数据集检验*P*值均<0.001，差异有统计学意义。Bland-Altman分析结果显示：3D nnU-Net模型分割结果95%一致性界限分别为：−10 436.183~5 162.883、−12 830.236~1 852.136、−9 837.682~4 623.099，整体偏移数量少，体积测量偏差处于可接受范围。Total Segmentator模型95%一致性界限明显增宽，分别为：−12 273.482~8 118.064、−17 285.176~4 928.976、−13 266.584~10 612.417，体积差值离散度更大，存在多处极端测量偏差（表2、图2）。上述结果证实，3D nnU-Net模型分割的食管体积与人工金标准契合度更高，体积一致性比对照模型更稳定。

2.3　主观评价

两位医师对3D nnU-Net模型的评分为5.00(4.25,5.00)、5.00(5.00,5.00)，显著高于Total Segmentator模型的1.00(1.00,2.00)、2.00(2.00,2.00)。并且两位医师之间也展现出了较强的一致性，ICC为0.794~0.976，*P*<0.001。两模型评分组间对比，*Z*值分别为23.270~23.308、12.787~12.819、8.948~8.985。两名医师的主观判定结果一致性良好，内部验证集与两组外部测试集ICC区间为0.786~0.976，整体一致性优异。所有组间差异有统计学意义（*P*均<0.001，图3、表3）。

3　讨　论

本研究采用DLCT的VNC与CECT融合策略，结合3D nnU-Net模型开展食管组织自动分割模型训练，并在NCCT图像上完成模型验证。结果显示，所构建的3D模型在NCCT食管分割任务中的分割精度、边界吻合度及泛化性能均比Total segmentator表现更优。

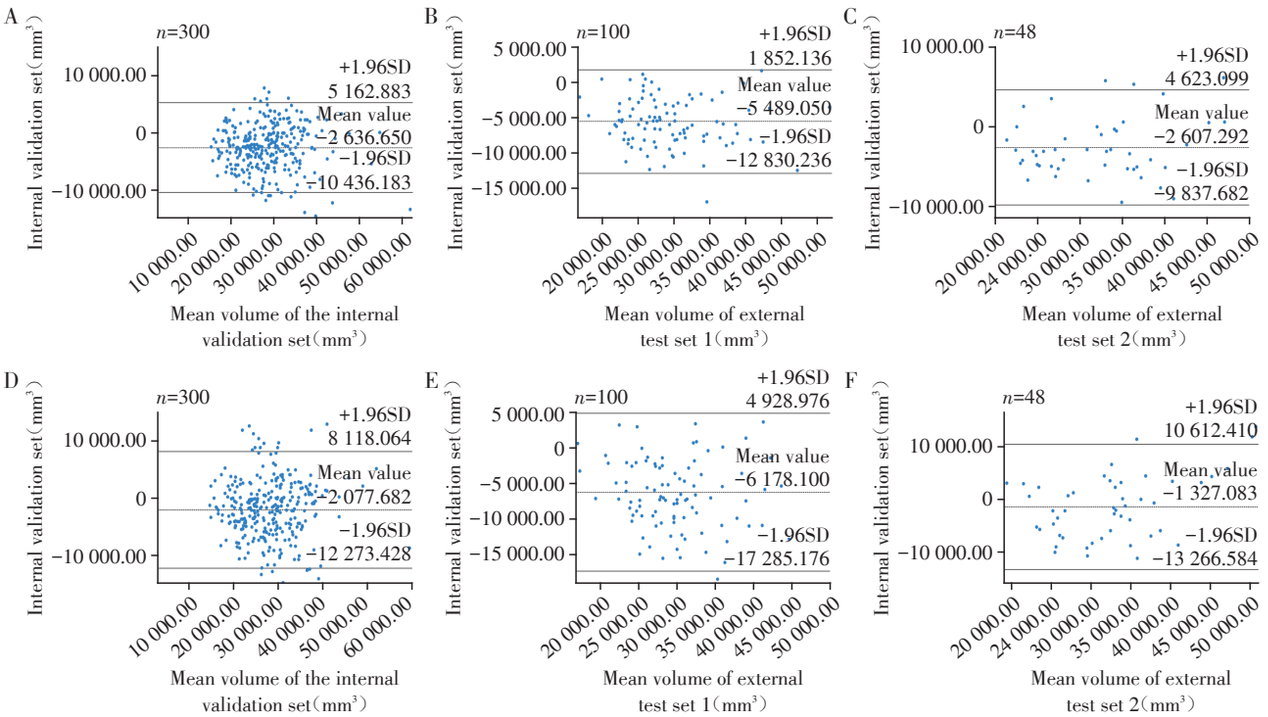
先前研究中，Li等[19]基于NCCT构建nnU-Net食管分割模型，其DSC达0.771，HD95为6.55 mm；Park等[20]采用3D nnUNet构建了两步式胃肠道自动分割模型，先完成全胃肠道整体分割，再分割食管等解剖结构，食管组织DSC在内外测试集中为0.821、0.807，HD95结果未显示。尽管现有研究模型分割性能良好，但存在样本量较少且泛化性缺少验证等问题。本研究纳入了448例患者进行训练和验证分割该模型，DSC为0.756~0.798，HD95稳定在4.00~4.10 mm。尽管DSC较前者略低，但得益于分割图像与训练图像的精准匹配，HD95显著优于前者。与此同时，本研究纳入了一个外部测试集和一个公开数据测试集，均获得了较高的分割性能，并明显优于通用的Total Segmentator模型，证明本研究的模型具有更好的泛化性能。

表2　两种分割模型容积测量结果与人工分割的一致性分析

Table 2　Consistency analysis of volumetric measurements from two segmentation models and manual Segmentation

Dataset	Model	Sample size(*n*)	r_s	ICC	*P*
Internal validation set	3D nnU-Net	300	0.821	0.843	<0.001
	Total Segmentator		0.715	0.735	<0.001
External test set 1	3D nnU-Net	100	0.822	0.842	<0.001
	Total Segmentator		0.626	0.641	<0.001
External test set 2	3D nnU-Net	48	0.887	0.912	<0.001
	Total Segmentator		0.716	0.707	<0.001

r_s refers to the Spearman rank correlation test. A value > 0.85 indicates strong correlation, and 0.70−0.85 indicates moderately strong correlation; ICC is the intraclass correlation coefficient. A value ≥ 0.8 indicates excellent consistency, and 0.7−0.8 indicates good consistency.



A：Limits of agreement between volumetric measurements from the 3D nnU-Net and manual delineations in the internal validation cohort. B：Limits of agreement between volumetric measurements from the 3D nnU-Net and manual delineations in external validation cohort 1. C：Limits of agreement between volumetric measurements from the 3D nnU-Net and manual delineations in external validation cohort 2. D：Limits of agreement between volumetric measurements from Total Segmentator and manual delineations in the internal validation cohort. E：Limits of agreement between volumetric measurements from Total Segmentator and manual delineations in external validation cohort 1. F：Limits of agreement between volumetric measurements from Total Segmentator and manual delineations in external validation cohort 2.

图2　模型分割体积与人工分割的Bland-Altman一致性分析

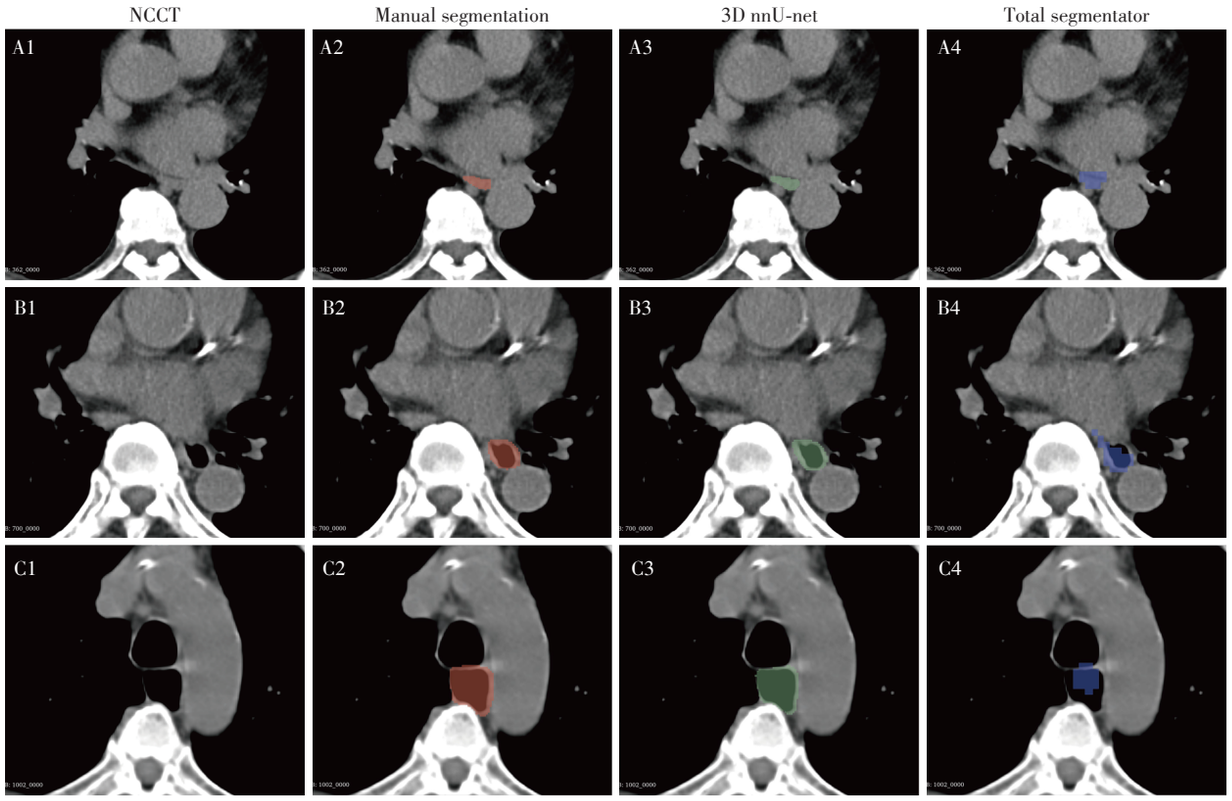
Figure 2　Bland-Altman analysis of volumetric segmentation between model and manual segmentation

表3　两名放射科医师对3D nnU-Net与Total Segmentator的主观评估结果

Table 3　Subjective evaluation of 3D nnU-Net and Total Segmentator by two radiologists

Radiologist	Dataset	3D nnU-Net	Total Segmentator	*Z*	*P*
Radiologist A	Internal validation set	5.00（5.00，5.00）	2.00（2.00，2.00）	23.308	<0.001
	External test set 1	5.00（4.00，5.00）	2.00（1.00，2.00）	12.787	<0.001
	External test set 2	5.00（5.00，5.00）	1.00（1.00，2.00）	8.985	<0.001
Radiologist B	Internal validation set	5.00（5.00，5.00）	2.00（2.00，2.00）	23.270	<0.001
	External test set 1	5.00（4.25，5.00）	2.00（1.00，2.00）	12.819	<0.001
	External test set 2	5.00（5.00，5.00）	1.00（1.00，2.00）	8.948	<0.001
ICC	Internal validation set	0.794	0.976	–	–
	External test set 1	0.946	0.976	–	–
	External test set 2	0.960	0.786	–	–

在训练阶段，创新性引入DLCT融合引导标注策略。该策略通过单次CECT扫描同步生成VNC图像，二者融合后可借助CECT清晰区分食管与毗邻结构，有效缓解NCCT图像中食管因自身形态特点导致的人工金标准难度大的问题；同时，二者源自同一扫描时相及呼吸状态，可实现空间解剖信息完全一致，且通过VNC替代TNC图像进行模型训练，从根本上避免了分次扫描导致的人工金标准与训练图像配准偏差，降低了系统性误差。结合3D fullres对食管管腔形态特征捕捉，该策略同时减少了nnU-Net监督学习中因训练数据不准确导致的模型性能下降，最终在1 000轮次的训练中，收敛优异（图4）。该策略证实，DLCT-VNC图像训练的食管分割模型，可在NCCT图像中实现稳定、高精度的分割，为



A1, B1, C1: Original Non-Contrast CT images. A2, B2, C2: manual segmentation results (red). A3, B3, C3: segmentation results of the 3D nnU-Net model (green). A4, B4, C4: segmentation results of the Total Segmentator model (blue). The results demonstrate that the segmentation contours of the 3D nnU-Net model are highly consistent with manual segmentation, whereas the Total Segmentator model exhibits over-segmentation or under-segmentation in some cases.

图3　模型分割效果图

Figure 3　Model segmentation display diagram

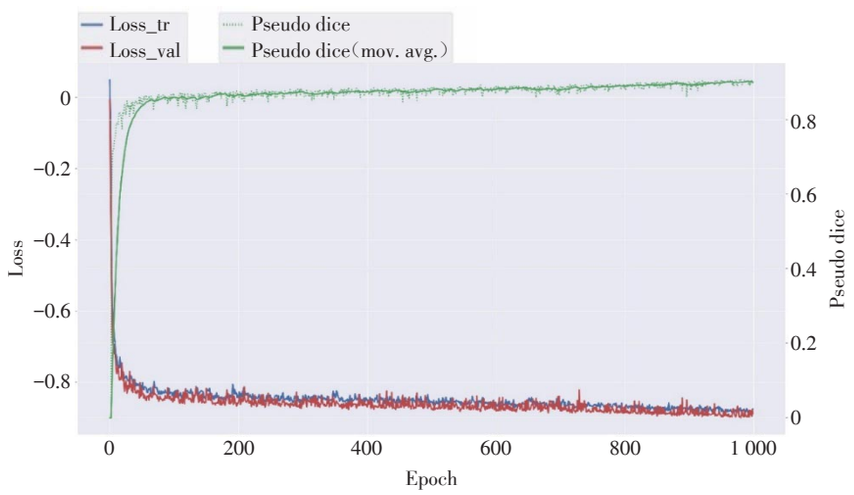


图4　3D nnU-Net模型训练曲线

Figure 4　Training curve of the 3D nnU-Net model

NCCT食管分割模型的训练提供了新的技术路径。

目前NCCT食管精准分割研究多服务于早期食管癌筛查及肿瘤治疗，针对急诊场景的应用相对有限。食管急症的CT评估，必须以正常食管解剖轮廓为基准，而NCCT无对比剂风险、检查快速，是急诊首选影像手段[21-22]。本研究针对正常食管构建的自动化分割模型，可在NCCT上快速、稳定地勾勒食管解剖边界，为识别管壁缺损、异物占位等急症影像

征象提供标准化解剖参照，为临床快速诊断和治疗决策提供量化依据。

本研究仍存在若干局限性：纳入设备来源单一，模型跨设备泛化能力缺乏充分验证；研究仅聚焦正常食管组织，未纳入病变样本，难以评估模型对异常食管结构的分割效能，临床应用场景受限；本研究采用5 mm层厚纵隔重建图像，层厚较大，易降低食管细微结构的分割精度；训练集与内部验证集来源于同一患者人群，仅影像序列不同，存在潜在数据泄露问题；同时所有人工标注并未进行多名医师一致性验证，存在一定的主观判读偏倚。未来研究将进一步扩充样本量，纳入多中心、多设备数据，并增加食管病变样本；引入薄层CT图像，优化模型层间特征融合能力，提升食管细微边界的分割精度；同时优化数据集划分方案，严格规避同一患者多序列数据混杂划分，从源头减少数据泄露与偏倚；此外采用双医师独立标注模式，结合量化指标一致性，进一步提升数据集质量与模型的临床实用价值。

综上所述，本研究采用VNC与CECT融合引导标注策略，构建了自动分割食管的nnU-Net模型，在分割精度、边界吻合度及多中心泛化性能上，均显著优于Total Segmentator通用模型。本研究创新性地将双层探测器CT与深度学习结合，为医学影像技术与人工智能算法的融合发展提供新的思路与参考。

利益冲突声明：

所有作者声明无利益冲突。

Conflict of Interests:

All authors declare no conflict of interests.

作者贡献声明：

万云天负责数据收集、模型构建、论文撰写与修改；陈志林和崔筱洁负责数据收集、图像评估；白卓杰负责论文指导、论文修订；王友和王皓负责提供项目基金支持和论文指导、负责研究方案、技术支持。

Author's Contributions:

Wan Yuntian performed data collection, model construction, manuscript drafting and revision. Chen Zhilin and Cui Xiaojie completed data collection and image evaluation. BAI Zhuojie carried out manuscript revision. Wang You and Wang Hao were responsible for fund acquisition, study supervision, research protocol design and technical support.

数据可用性声明：

本研究中的模型权重、训练代码均已在中国数据银行开源并提供下载（https://doi.org/10.577 60/sciencedb.35531）。出于隐私保护及机构政策要求，患者数据集采用受控访问模式，研究者在获得伦理审查委员会的正式审批并签署数据使用协议后，可向通讯作者提出合理申请获取数据。

Data availability statement:

The model weights and training code in this study have been open-sourced and available for download in the Science Data Bank（https://doi.org/10.57760/sciencedb.35531）. For privacy protection and institutional policy requirements, the patient dataset adopts a controlled access mode. Researchers may submit a reasonable application to the corresponding author to obtain the data after obtaining formal approval from the ethics review committee and signing a data usage agreement.

［参考文献］

［1］ Lou X, Zhu J, Yang J, et al. Enhanced cross-stage-attention U-Net for esophageal target volume segmentation [J]. BMC Med Imaging, 2024, 24(1): 339

［2］ Tian F R, Tian Z Q, Chen Z, et al. Surface-GCN: learning interaction experience for organ segmentation in 3D medical images[J]. Med Phys, 2023, 50(8): 5030-5044

［3］ Jian M W, Tao C, Wu R H, et al. HRU-Net: a high-resolution convolutional neural network for esophageal cancer radiotherapy target segmentation [J]. Comput Meth Programs Biomed, 2024, 250: 108177

［4］ Pang Y, Li Y H, Liang J M, et al. SegTom: a 3D volumetric medical image segmentation framework for thoracoabdominal multi-organ anatomical structures [J]. IEEE J Biomed Heal Inform, 2026, 30(1): 551-563

［5］ Lin C, Guo Y, Huang X, et al. Esophageal cancer detection *via* non-contrast CT and deep learning [J]. Front Med, 2024, 11: 1356752

［6］ 阙煜轩，周晓颖. 人工智能在消化道早癌诊疗中的应用进展[J]. 南京医科大学学报（自然科学版），2025，45（10）：1521-1527，1536
Que Y X, Zhou X Y. Application progress of artificial intelligence in the diagnosis and treatment of early gastrointestinal cancers[J]. Journal of Nanjing Medical University (Natural Sciences), 2025, 45(10): 1521-1527, 1536

［7］ Yan Y J, Kehayias C, He J, et al. Edge roughness quantifies impact of physician variation on training and performance of deep learning auto-segmentation models for the esophagus[J]. Sci Rep, 2024, 14(1): 2536

［8］ Zhong L M, Xiao R L, Shu H, et al. NCCT-to-CECT synthesis with contrast-enhanced knowledge and anatomical perception for multi-organ segmentation in non-contrast CT images[J]. Med Image Anal, 2025, 100: 103397

［9］ Qi F, Ye Q, Xu C, et al. MDPNet: a multi-scale difference perception network for esophageal cancer segmentation in CT images[J]. BMC Medical Imaging, 2026, 26(1): 150

［10］ Liu J Y, Tian Y L, Duzgol C, et al. Virtual contrast enhancement for CT scans of abdomen and pelvis[J]. Comput Med Imaging Graph, 2022, 100: 102094

[11] Hu Y F, Zhang Y, Tang Z Y, et al. Comparative analysis of U-Mamba and no new U-Net for the detection and segmentation of esophageal cancer in contrast-enhanced computed tomography images[J]. Quant Imaging Med Surg, 2025, 15(3): 2119-2131

[12] Wasserthal J, Breit H C, Meyer M T, et al. TotalSegmentator: robust segmentation of 104 anatomic structures in CT images[J]. Radiol Artif Intell, 2023, 5(5): e230024

[13] Isensee F, Jaeger P F, Kohl S A A, et al. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation[J]. Nat Meth, 2021, 18(2): 203-211

[14] Bernhardt M, Castro D C, Tanno R, et al. Active label cleaning for improved dataset quality under resource constraints[J]. Nat Commun, 2022, 13(1): 1161

[15] Soltani M B, Bouchard H. Spectral virtual non-contrast imaging assisted by artificial intelligence segmentation[J]. Med Phys, 2025, 52(11): e70095

[16] Guo Y B, Fan Q J, Ren Z L, et al. Feasibility of replacing true non-contrast images with virtual non-contrast images in quantitative analysis of emphysema[J]. Radiologie (Heidelb), 2025, 65(Suppl 1): 44-51

[17] Mingkwansook V, Puwametwongsa K, Wat-charakorn A, et al. Comparative study of true and virtual non-contrast imaging generated from dual-layer spectral CT in patients with upper aerodigestive tract cancer[J]. Pol J Radiol, 2022, 87: e678-e687

[18] Jin E H, Zhao D L, Wu G G, et al. OBIA: an open biomedical imaging archive[J]. Genom Proteom Bioinform, 2023, 21(5): 1059-1065

[19] Li Z B, Gan G H, Guo J, et al. Accurate object localization facilitates automatic esophagus segmentation in deep learning[J]. Radiat Oncol, 2024, 19(1): 55

[20] Park J, Park S, Chung H J, et al. Deep learning for automatic volumetric bowel segmentation on body CT images[J]. Eur Radiol, 2025, 35(11): 7307-7319

[21] Salehpoor A, Thompson W. Imaging of esophageal perforation including in the postoperative patient: a contemporary review[J]. Abdom Radiol, 2026, 51(2): 650-659

[22] Yasrab M, Crawford C K, Chu L C, et al. CT of the esophagus in the ER: what you need to know and what you need to remember[J]. Emerg Radiol, 2025, 32(3): 447-455

（收稿：2026-04-09；修回：2026-06-30；录用：2026-07-02）
（本文编辑：戴王娟）

（上接第1672页）

flammation, how influenza promotes lung damage[J]. J Leukoc Biol, 2021, 110(1): 115-122

[16] 黄静雯，马心怡，范博雅，等. Toll样受体4在甲型流感病毒诱导小鼠肺部炎症中的作用机制[J]. 中国病理生理杂志，2023，39(8)：1357-1365
Huang J W, Ma X Y, Fan B Y, et al. Mechanism of Toll-like receptor 4 in lung inflammation induced by influenza A virus in mice[J]. Chinese Journal of Pathophysiology, 2023, 39(8): 1357-1365

[17] Zhang W W, Li X Y, Liu Q, et al. High-accuracy lung sound classification for healthy versus unhealthy diagnosis using artificial neural network[J]. Front Bioeng Biotechnol, 2025, 13: 1583416

[18] Lee J K H, Lam G K L, Shin T, et al. Efficacy and effectiveness of high-dose influenza vaccine in older adults by circulating strain and antigenic match: an updated systematic review and meta-analysis[J]. Vaccine, 2021, 39: A24-A35

[19] Shetty S A, Van Beek J, Bijvank E, et al. Associations and recovery dynamics of the nasopharyngeal microbiota during influenza-like illness in the aging population[J]. Sci Rep, 2022, 12(1): 1915

[20] Kniss K, Sumner K M, Tastad K J, et al. Risk for infection in humans after exposure to birds infected with highly pathogenic avian influenza A(H5N1)virus, United States, 2022[J]. Emerg Infect Dis, 2023, 29(6): 1215-1219

[21] He Y Y, Guo Z J, Subiaur S, et al. Antibody inhibition of influenza A virus assembly and release[J]. J Virol, 2024, 98(2): e01398-23

[22] Xiao C, Cheng S, Li R, et al. Isoforskolin alleviates AECOPD by improving pulmonary function and attenuating inflammation which involves downregulation of Th17/IL-17A and NF-κB/NLRP3[J]. Front Pharmacol, 2021, 12: 721273

（收稿：2025-12-08；修回：2026-07-01；录用：2026-07-06）
（本文编辑：戴王娟）