

中图法分类号: 文献标识码: 文章编号: 1006-8961(XXXX)XX-0001-14

论文引用格式: Wu Zhen, Chen Sheng, Cheng Ye. Dental instance segmentation using multi-dimensional hybrid framework[J/OL]. Journal of Image and Graphics, XXXX: 1-14. DOI: 10.11834/jig.260131. (吴镇, 陈胜, 程晔. 多维度混合框架的牙颌实例分割[J/OL]. 中国图象图形学报, XXXX: 1-14. DOI: 10.11834/jig.260131.) [DOI: 10.11834/jig.260131]

多维度混合框架的牙颌实例分割

吴镇, 陈胜*, 程晔

上海理工大学光电信息与计算机工程学院, 上海市 200093

摘要: 目的 精准分割牙齿与牙龈对于牙齿正畸及隐形矫治器的设计至关重要, 同时可视化的模拟也能显著提升诊断效率, 加强医患沟通。然而, 现有研究对缺牙和重叠情况下的分割问题关注较少。为此, 本文提出一种名为HaTransTooth的混合深度学习框架。方法 总体采用“由粗到细”的策略: 首先, 通过平行投影将三维扫描模型转换为二维深度图像, 并利用改进的YOLOv8(you only look once version 8)检测算法实现牙齿的快速检测和编号, 有效解决了三维空间中牙齿实例分离的难题, 提升了牙位识别的准确率和效率; 随后, 通过建立的映射关系, 将二维检测区反向投影至三维空间, 提取出包含单个牙齿及其周边牙龈的三维感兴趣区域(3D regions of interest, 3D ROI); 最后, 针对每个3D ROI, 引入了分层自适应注意力机制的点云转换网络(point cloud transformer, PCT)进行精细分割, 同时使用了Focal Loss和Dice Loss的组合损失函数和梯度累积训练策略。结果 实验在自行采集的真实病例数据上与经典的7种方法进行了比较, 仅是平均准确率(mean accuracy, mACC)位列第二, 达到了96.74%, 与第一几乎持平, 而平均交并比(mean intersection over union, mIoU)和Dice相似系数(the dice similarity coefficient, DSC)分别比第二名高出4.86%和2.41%。此外还验证了平均表面距离(average symmetric surface distance, ASSD)、召回率(recall, R值)和F1分数(F1 score), 均达到了较高水平, 具有较高的临床价值。在公开数据集Teeth3DS(teeth 3D scan dataset)上的交叉验证进一步证明了模型的泛化能力。结论 本文提出的框架显著提升了对牙齿-牙龈模糊边界的分割精度, 并能准确分割具有缺牙和牙齿重叠情况的牙颌, 通过实验表明, 此框架在多项指标上优于现有主流方法。

关键词: 口腔点云; 实例分割; 缺牙情况; 维度转换; 目标检测; 分层自适应注意力机制

Dental instance segmentation using multi-dimensional hybrid framework

Wu Zhen, Chen Sheng*, Cheng Ye

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

Abstract: Objective Accurate segmentation of individual teeth and adjacent gingiva is a prerequisite for reliable digital orthodontic diagnosis, virtual treatment planning, clear aligner fabrication, prosthodontic design, and implant-related assessment. In daily clinical practice, a visually interpretable segmentation result can also shorten the communication loop between dentists and patients by converting complex intraoral geometry into intuitive tooth-level models. Nevertheless, dental scans collected from patients who require orthodontic intervention or implant restoration frequently contain missing teeth, severe crowding, overlapped crowns, extraction gaps, irregular gingival margins, orthodontic attachments, and partially visible tooth surfaces. These factors make instance separation substantially more difficult than ordinary semantic segmentation. Existing geometric approaches are usually sensitive to curvature thresholds, manually selected seed points, and

收稿日期: 2026-03-11; 修回日期: 2026-08-16

* 通信作者: 陈胜 chnshn@163.com

基金项目: 国家自然科学基金项目(编号: 81101116)

Supported by: National Natural Science Foundation of China(81101116)

© 中国图象图形学报版权所有

boundary line assumptions, while many deep learning approaches either lose three-dimensional spatial cues during 2D projection or suffer from instance confusion and high computational cost when the whole jaw point cloud is processed directly. Therefore, this study aims to develop a robust, clinically oriented segmentation framework that can maintain the efficiency of 2D detection while preserving the geometric accuracy of 3D point cloud learning, with particular attention to missing-tooth and overlapping-tooth conditions. **Method** To address the above challenges, this paper proposes HaTransTooth, a multi-dimensional hybrid deep learning framework based on a coarse-to-fine workflow. First, the original 3D intraoral scan is transformed into a 1024×1024 depth image through parallel projection along the estimated normal direction of the dental arch occlusal plane. During this projection process, the camera pose, coordinate correspondence, and depth information are retained so that each detected 2D region can be accurately mapped back to the original 3D space. An improved YOLOv8 detector is then retrained for dental depth images to perform rapid tooth localization and preliminary numbering. Considering the dense, sparse, and partially missing distribution patterns of teeth, the anchor settings and training samples are adjusted, and data augmentation strategies such as random rotation and Mosaic augmentation are adopted to enhance robustness in complex oral scenes. Second, the predicted 2D bounding boxes are expanded by a small spatial margin and back-projected to generate 3D regions of interest (3D ROI). Each 3D ROI contains one target tooth, a limited amount of surrounding gingiva, and small parts of adjacent teeth, which reduces the ambiguity caused by full-jaw instance separation while still preserving boundary context. Before fine segmentation, point cloud sampling, centroid normalization, unit-sphere scaling, and statistical outlier removal are applied to standardize the input distribution and suppress scanning noise. Third, each ROI is segmented by an improved Point Cloud Transformer network (PCT). A hierarchical adaptive attention mechanism is introduced into the PCT backbone to combine local geometric details with global semantic dependencies. Local attention focuses on neighboring points near the tooth-gingiva junction, whereas global attention captures the overall shape pattern of the tooth instance; a learnable gate dynamically balances the two feature streams. To further handle class imbalance between tooth and gingival points and to improve the learning of hard boundary samples, the model is optimized with a combined Focal Loss and Dice Loss, together with a gradient accumulation strategy under limited GPU memory. The framework is trained and evaluated on 2,000 real clinical cases collected by intraoral scanners, each containing both upper and lower jaws. The dataset includes approximately normal dentitions, pre-orthodontic crowding and overlap, post-extraction and missing-tooth cases, aligned cases with spaces, orthodontic attachments, implants, wisdom teeth, and mixed dentition. All tooth and gingiva labels are manually annotated with CloudCompare and verified by professional dentists. The data are divided into 1,400 training cases, 300 validation cases, and 300 testing cases, and the experiments are conducted on a single NVIDIA GeForce RTX 3090 GPU. **Result** Experiments on the self-collected clinical dataset demonstrate that HaTransTooth achieves competitive and stable performance when compared with seven representative segmentation methods. Although its mean accuracy (mACC) reaches 96.74%, ranking a close second to TSegNet, the proposed method shows a clearer advantage in metrics that better reflect region overlap and boundary consistency. Specifically, it achieves a mean Intersection over Union (mIoU) of 95.26% and a Dice Similarity Coefficient (DSC) of 97.50%, exceeding the second-best method by 4.86% and 2.41%, respectively. Additional evaluation also confirms the clinical usefulness of the framework, with an Average Symmetric Surface Distance (ASSD) of 0.0074, a recall of 98.10%, and an F1 score of 97.41%. On the difficult missing-tooth subset, the method obtains 97.19% mAcc, 95.41% mIoU, and 97.49% DSC; on the crowded and overlapping-tooth subset, it still reaches 96.51% mAcc, 94.39% mIoU, and 97.18% DSC. These results indicate that the method can maintain high segmentation quality in cases where adjacent crowns are in close contact, tooth numbers are incomplete, or gingival boundaries are unclear. Cross-validation on the public Teeth3DS dataset further verifies its generalization ability. Without retraining on Teeth3DS, the proposed framework achieves 97.21% mAcc, 96.13% mIoU, and 97.91% DSC, outperforming the compared approaches in the main segmentation metrics. Ablation experiments show that the 2D projection detection and 3D ROI extraction module provides the largest performance gain by reducing instance confusion, while the hierarchical adaptive attention module and the combined loss with gradient accumulation further improve boundary discrimination and training stability. Visual comparisons also reveal that HaTransTooth produces more complete tooth surfaces, fewer gingival misclassifications, and clearer inter-tooth boundaries than conventional full-jaw point cloud segmentation methods. **Conclusion** The proposed HaTransTooth framework provides an effective

solution for automatic dental instance segmentation under complex intraoral conditions. By transforming the initial instance separation problem into efficient 2D detection and then performing attention-enhanced 3D fine segmentation within localized ROIs, the framework integrates the strengths of image-based detection and point-cloud-based geometric modeling. It improves segmentation accuracy at ambiguous tooth-gingiva boundaries and remains robust in missing-tooth, crowded, overlapping, and attachment-bearing cases. The results on both a large real clinical dataset and a public benchmark suggest that the framework has strong potential for supporting digital orthodontic diagnosis, aligner design, prosthodontic planning, and other computer-aided dental applications.

Key words: oral point cloud; segmentation of instances; missing teeth; dimension transformation; object detection; hierarchical adaptive attention mechanism

0 引言

随着数字化技术在口腔医学领域的应用日益广泛,基于三维牙颌模型的计算机辅助诊断(computer aided diagnosis, CAD)与治疗规划已成为现代牙科,特别是正畸、修复及种植的常规手段(赵一姣等, 2024)。锥形束计算机断层扫描(cone beam computed tomography, CBCT)和口腔内扫描仪(intraoral scanner, IOS)能够获取高精度的牙颌三维数据,为制定治疗方案提供详细的口内信息。在临床工作中,准确识别并分割每颗牙齿,是诊断牙齿问题以及设计个性化治疗方案(如间隙保持器、早期矫治等)的关键前提。但由于患者牙齿生长状况各异,比如牙齿排列不齐、缺损或儿童换牙期乳恒牙混合等情况,实现精准的自动分割仍然比较困难。以往依靠医生手动标注的方式,不仅效率低、工作量大,还容易受到主观经验的影响,难以保证结果的客观一致。因此,开发一种能智能、精准分割复杂牙颌模型的自动化算法,具有重要的临床意义和实际价值。

目前已有的牙齿自动分割方法大致可分为传统几何算法和基于深度学习的方法两大类:

1)传统几何方法:如区域生长算法、基于边界线搜寻的方法(刘志华等, 2024)等,在一定程度上能够处理规则牙列。但是此类方法通常过度依赖人工设置的阈值或种子点,对于牙齿拥挤、边界模糊以及儿童牙颌的复杂形态适应性较差,容易出现欠分割或过分割现象,泛化能力较弱。

2)深度学习方法:近年来已成为研究主流。这些方法又可根据数据处理方式分为:(1)基于2D投影的方法:将3D点云投影为多个2D视图(如深度图),再利用成熟的2D卷积神经网络(convolutional

neural networks, CNN)进行处理。例如,有研究采用多视角投影结合Transformer架构进行牙齿分类(刘沐然等, 2025)。这类方法虽然利用了2D CNN的优势,但在投影过程中不可避免地会损失部分三维空间几何信息,进而导致分割缺失和不全。(2)直接处理3D点云的方法:如PointNet++(Qi等, 2017b)、Point Cloud Transformer(Guo等, 2021)、3D Tooth Mesh Seg(Jana等, 2023)等网络,能够直接从点云中学习特征,更好地保留空间结构,Hao等人(2025)提出的双重注意力方法,将增强后的语义特征与实例特征有效融合也进一步提升了过往点云模型的分割精度。然而,它们在处理全颌点云时,难以有效区分紧密排列的牙齿实例,且计算开销较大。

近期,有研究尝试结合2D检测与3D分割的思路,例如Wu等人(2022)提出的TS-MDL(two-stage mesh deep learning)框架,先用iMeshSegNet方法进行标记,再用轻量级PointNet(Qi等, 2017a)进行分割;Cui等人(2021)提出的TSegNet单牙齿精确分割网络,通过牙齿质心预测和点云数据上的预测实现单个牙齿分割。以上多个模型都展现了混合范式的潜力。此外,适配分割一切模型(如Tooth-ASAM)也在多模态牙齿图像分割中展现出优异性能(Wang等, 2025),Jiang等人(2025)提出的IOPS(intra-oral scan pose sandardization)方法,通过分解-合并策略,将多个低分辨率数据的牙齿分割结果合并为一个高分辨率数据,为高分辨率分割提供了一种新思路。针对最棘手的牙冠-牙龈边界模糊问题,最新的方法如CrossTooth引入了跨模态边界增强策略。通过对三维网格在牙-龈交界处进行选择性地下采样以保留更多几何细节,同时从多视角渲染的二维图像中提取判别性边界特征,融合后显著提升了边界分割的精度(Xi等, 2025)。

而针对上述研究空白与临床需求,本文提出了一种专为有缺牙和牙齿拥挤重叠情况的牙颌设计的混合2D-3D深度学习框架——HaTransTooth。主要贡献体现在以下几个方面:

1)创新的混合范式:本文设计了一个高效的三阶段流程。第一阶段,利用沿法向量的平行投影将三维口扫数据投影为二维深度图,保存相机位姿数据,接着利用YOLOv8(Ultralytics, 2023)在2D投影图上快速、准确地实现牙齿实例检测和初步编号,巧妙地将复杂的3D实例分离问题转化为更易解决的2D目标检测问题。第二阶段,通过保存的相机位姿数据和目标预测标签,精准地将2D Bbox反投影为3D ROI,获取每个牙齿的局部三维点云块,为第三阶段精细分割奠定基础。

2)针对性的3D精细分割网络:在第三阶段,本文改进了PCT网络(Guo等, 2021),引入了分层自适应注意力机制(Huang等, 2021),使其能同时捕捉局部细节和全局上下文信息,有效处理牙齿与牙龈的模糊边界。同时采用了Focal Loss和Dice Loss的组

合损失函数,并引入梯度累积训练策略,重点提升模型对类别不平衡(牙齿和牙肉的占有比例不同)和遮挡目标(如牙齿前后层叠)的分割性能。

3)构建了高质量临床数据集:使用口内扫描仪采集数据进行标注并构建数据集,数据来自上海市多家医院和牙科诊所的真实患者病历,包含2000个病例,超50000颗牙齿样本。数据集严格遵循临床样本采集标准,涵盖了正畸前(拥挤/重叠)、正畸中(拔牙后缺陷)和正畸后(排齐但缺牙)等多种状态,并包含大量正畸附件。针对性的数据集保证了研究成果具有较高的实际应用价值。

1 精确分割框架

本文提出的混合2D-3D框架——HaTransTooth,旨在解决牙颌实例中存在缺牙和重叠情况的精准与鲁棒分割问题,收集到的多种口腔牙齿问题如图1所示。



图1 口内牙齿情况

Fig. 1 Tooth condition in the mouth

1.1 网络结构

本框架核心创新在于采用了一种“由粗到细”的协同策略,巧妙地将二维图像检测的高效性与三维点云分割的精细性相结合,整体流程结构如图2所示,流程主要包括三个核心阶段:1)基于2D投影的牙齿实例检测;2)从2D到3D的关键区域(ROI)提取与点云预处理;3)基于分层自适应注意力机制的PCT模型的精细分割和可视化。

1.1.1 2D投影与实例检测

为将三维空间信息转化为更适合高效检测的二维形式,本研究采用了正交投影技术,沿牙弓咬合面法向量将三维模型投影至二维平面,生成深度图像。在此过程中同步创建并保存一个相机位姿参数表,为后续至关重要的反向映射过程奠定了坚实基础。

本研究定义了投影平面,设 $\mathbf{n}$ 为沿牙弓咬合面法向量的单位向量,如图3展示了完整的投影流程,该法向量可通过主成分分析或基于牙弓形状的估计方法得到。投影过程为将三维点 p_i'' 垂直投影至与 $\mathbf{n}$ 垂直的平面上。投影后的二维像素坐标 (u_i, v_i) 通过下式计算:

$$\begin{bmatrix} u_i \\ v_i \end{bmatrix} = [\text{Res} \cdot \mathbf{M} \cdot p_i''] \quad (1)$$

式中,Res为期望的图像分辨率(本实验为1024×1024), $\mathbf{M} \in \mathbf{R}^{2 \times 3}$ 为一个旋转矩阵,用于将三维坐标对齐到二维投影平面。

在获得的二维深度图像上,本实验部署了轻量化的YOLOv8(Ultralytics, 2023)目标检测模型,以实现每个牙齿实例的快速初步定位。针对数据特点



图2 整体框架结构

Fig. 2 Overall frame structure


牙齿排列密集稀疏差异大、缺损的情况,我们对模型的锚框尺寸进行了针对性调整,并采用了包括随机旋转和 Mosaic 增强(陈翠琴等,2022)在内的数据增强策略,提升了模型在口内复杂环境下的泛化能力。YOLOv8(Ultralytics,2023)模型输出的二维边界框,高效地解决了在复杂三维点云中直接进行实例分离的初始难题,网络结构如图4所示。

1.1.2 2D Bbox 到 3D ROI 反向映射及点云预处理

本步骤是连接 2D 与 3D 处理的关键桥梁。其核心在于利用通过 YOLOv8(Ultralytics,2023)模型预

测出的二维深度图中每个牙齿的标签数据,来初步分割出每颗牙齿。为了避免将牙齿少切或过度切割,实际切割线都比每一侧实际最外围像素点外扩了 2mm,且单牙颌每一个牙齿的切割都是在完整牙颌的基础上进行切割。切割后再利用投影时保存的相机位姿数据将 2D 数据反投影回 3D 空间。其中,每个 ROI 包含了目标牙齿的主体以及周围少量的牙龈组织和相邻牙齿的小部分。

在输入给点云模型之前,首先对粗分割后的三维模型进行点云采样和预处理。给定一个原始点



(a)三维点云及其法向量计算 (b)投影平面的定义及投影过程 (c)生成的二维深度图像

((a) 3D point cloud and its normal vector calculation; (b) Definition of projection plane and projection process; (c) Generated 2D depth image)

图3 二维投影流程图

Fig. 3 2D projection flowchart




图4 YOLOv8模型结构图

Fig. 4 Structure diagram of the YOLOv8 model

云 $\mathcal{P} = p_i \in \mathbf{R}^{3N}_{(i=1)}$, 其中 $p_i = (x_i, y_i, z_i)$ 表示一个三维点坐标, N 为点云总数。首先, 通过平移归一化将点云中心平移至坐标原点, 其公式为:

$$\mu = \frac{1}{N} \sum_{i=1}^N p_i, p'_i = p_i - \mu \quad (2)$$

式中, μ 为点云的质心。通过缩放归一化, 将点云缩放至单位球空间内, 其公式为:

$$d_{\max} = \max_i \|p'_i\|, p''_i = \frac{p'_i}{d_{\max}} \quad (3)$$

经过此步骤, 所有的 $\|p''_i\| \leq 1$ 。

随后, 本研究采用统计离群值去除算法来滤除噪声点。对于每个点 p''_i , 计算其到 k 个最近邻点的平均距离 d_i 。假设这些距离服从高斯分布, 那么若所有与分布均值 μ_d 和标准差 σ_d 满足以下关系的点将被视为离群点被移除:

$$d_i > \mu_d + \alpha \cdot \sigma_d \quad (4)$$

式中, α 为标准差倍数阈值, 本研究根据实验经验设

置为1.0。

1.1.3 基于改进PCT网络的精细分割

对于每个提取出的3D ROI,本研究采用改进的Point Cloud Transformer网络进行逐点分类。改进后的模型专注于二元输出(牙龈/背景为0,牙齿为1),同时保留了骨干网络的核心Transformer机制(Guo等,2021),因其能通过自注意力机制有效捕捉点云中的长程依赖关系,核心的自注意力机制可表达为:

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}} + P\right)V \quad (5)$$

式中, $Q, K, V \in \mathbb{R}^{N \times d}$ 分别表示查询、键和值矩阵, $P \in \mathbb{R}^{N \times N}$ 为位置编码, d_k 为键的维度。

为解决牙齿-牙龈边界模糊的问题,本研究引入了分层自适应注意力机制,其结构如图4所示。这一改进旨在增强模型的多尺度特征捕捉能力,通过堆叠多个注意力层来实现更深层的语义表示,同时统一特征维度以减少参数冗余并改善梯度流动。原模型依赖单层Transformer块进行局部注意力计算,而改进后模型采用多层堆叠结构(默认num_layers=2),允许逐层精炼特征表示,在网络的不同层级应用不同感受野的注意力,局部注意力在点 p_i 的 k -近邻 $\mathcal{N}(p_i)$ 内计算:

$$y_i^{\text{local}} = \sum_{p_j \in \mathcal{N}(p_i)} \text{Softmax}\left(\frac{q_i k_j^T}{\sqrt{d_k}} + \Delta p_{ij} \cdot W_p\right) v_j \quad (6)$$

式中, $\Delta p_{ij} = p_i - p_j$, W_p 为可学习的位置编码权重。全局注意力在整个点云子集上计算,捕捉长程依赖:

$$y_i^{\text{global}} = \sum_{j=1}^N \text{Softmax}\left(\frac{q_i k_j^T}{\sqrt{d_k}}\right) v_j \quad (7)$$

两种注意力输出的融合通过门控机制实现,由可学习的自适应权重动态调节局部几何特征与全局语义特征的融合比例。该机制基于输入特征自动生成门控信号,实现特征级别的精细调制,确保在不同牙齿区域采用最优的特征组合策略,门控机制表达为:

$$y_i = \sigma\left(W_g[y_i^{\text{local}} \parallel y_i^{\text{global}}]\right) \odot y_i^{\text{local}} + \left(1 - \sigma\left(W_g[y_i^{\text{local}} \parallel y_i^{\text{global}}]\right)\right) \odot y_i^{\text{global}} \quad (8)$$

式中, σ 为 sigmoid 函数, $\parallel$ 表示拼接操作, W_g 为可学习参数。

因此能更好地处理牙齿点云的复杂几何结构和

标签不均衡问题。实验结果显示,该机制显著提高了分割精度,尤其在牙龈-牙齿边界区域的识别准确率。

1.2 损失函数

本实验摒弃了传统的交叉熵损失,采用了由Focal Loss和Dice Loss构成的组合损失函数(Yeung等,2022)。Focal Loss解决类别不平衡问题,关注难分样本,其公式为:

$$L_{\text{focal}} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C (1 - p_{i,c})^\gamma y_{i,c} \log(p_{i,c}) \quad (9)$$

式中, $p_{i,c}$ 是点 i 属于类别 c 的预测概率, $y_{i,c}$ 是真实标签, γ 是聚焦参数(实验中设为2)。

Dice Loss直接优化分割性能指标,其公式为:

$$L_{\text{dice}} = 1 - \frac{2 \sum_{i=1}^N \sum_{c=1}^C p_{i,c} y_{i,c} + \epsilon}{\sum_{i=1}^N \sum_{c=1}^C (p_{i,c}^2 + y_{i,c}^2) + \epsilon} \quad (10)$$

式中, ϵ 是平滑项防止除零。

总损失函数为两者的加权和:

$$L_{\text{total}} = \alpha L_{\text{focal}} + \beta L_{\text{dice}} \quad (11)$$

式中, α 和 β 为平衡超参数,通过网格搜索确定最优值。

1.3 梯度累积策略

为在有限计算资源下稳定训练,本实验引入了梯度累积策略。设目标批大小为 B ,实际可用批大小为 b ($b < B$),则累积步数 $k = B/b$ 。参数更新规则为:

$$\theta_{i+1} = \theta_i - \eta \cdot \frac{1}{k} \sum_{i=1}^k \nabla_{\theta} L(\theta_i; B_i) \quad (12)$$

式中, η 为学习率, B_i 为第 i 个小批量。

2 实验与结果分析

本节中,在从医院和诊所收集的给真实患者扫描的数据集上进行训练和评估算法性能。牙齿识别和标记基于牙齿标记系统(ISO3950)(Grace等,2000),全牙颌可视化结果基于图6示例进行设置。

2.1 数据集和实验设置

本研究构建的数据集共包含2000个真实患者的牙颌扫描病例,每个病例均包含上颌和下颌数据。所有数据均使用口内扫描仪采集,并严格遵循临床样本采集标准。数据使用CloudCompare软件进行




图5 分层注意力机制结构

Fig. 5 Hierarchical attention mechanism architecture




图6 ISO标准牙号系统和颜色编码

Fig. 6 ISO standard tooth number system and color coding

逐颗牙齿和牙龈的精细标注并由专业牙科医生审核。数据集的具体构成如下:

- 1) 基本正常的口内情况 (约 700 例): 上下颌牙齿基本整齐, 并未见明显的缺损或其他问题。
- 2) 正畸前的病例 (约 700 例): 包含牙齿拥挤、错位、重叠等情况。
- 3) 正畸过程中的病例 (约 500 例): 包含排齐但

存在缺牙、牙缝较大的情况以及拔牙后牙齿移动中的各种状态, 部分病例伴有正畸附件。

4) 其他情况病例 (约 100 例): 包含有种植牙、智齿萌生、乳恒牙并存等情况。

5) 困难子集: 从上述数据中特别筛选出 100 例缺牙病例和 100 例存在牙齿重叠拥挤病例, 用于专项评估。

实验训练准备时将数据随机分为三个子集, 其中 1400 个案例用于训练, 300 个用于验证, 300 个用于测试, 确保各子集中均包含不同难度和类型的病例。

本实验训练与测试过程在配备单张 NVIDIA 3090 (24GB) GPU 及 AMD Ryzen9 5900X CPU (12 核心) 的电脑上完成, 实验环境基于 PyTorch2. 1. 1 和 Python3. 8。各阶段的具体实验配置如下: 1) 2D 牙齿目标检测阶段: 使用 YOLOv8x 的预训练权重 (Ultralytics, 2023), 初始学习率设置为 0. 001, batch_size 为 16, 总共训练 150 轮。2) 3D 牙齿点云分割阶段: 使用改进的 PCT 网络, 初始学习率为 0. 001, batch_size 为 8, 总共训练 200 轮。

为避免数据分布差异对结果造成干扰,本文中的主实验、对比实验与消融实验均基于相同的数据集上进行,并保持优化器、学习率和训练轮数等核心设置一致,仅针对待分析模块进行控制变量调整。但为了说明模型框架的泛化能力,还在公开数据集 Teeth3DS (Ben-Hamadou 等, 2023) 上进行了测试对比。

2.2 评价指标

2D 牙齿检测模型参考 YOLOv8 的指标 (Ultralytics, 2023), 包括召回率 (recall, R 值)、精确率 (precision, P 值)、平均精度 (mean average precision (mAP50 和 mAP50-95))。

3D 分割中使用了点云分割中最常用的三大指标: 平均准确率 (mean Accuracy, mAcc)、平均交并比 (mean intersection over union, mIoU)、相似系数 (the dice similarity coefficient, DSC)。本研究中对牙齿点云分割, DSC 更为重要:

$$DSC_i = \frac{2 \times |X \cap Y|}{|X| + |Y|} \quad (13)$$

式中, X 是预测集合, Y 是真实集合。

此外, 为衡量牙齿分割方法的优越性, 还增加了预测分割结果与真实分割结果之间的表面距离 ASSD (Average Symmetric Surface Distance) (Sundar 等, 2022)、召回率 Recall 和 F1 分数 (召回率和准确率的调和平均数)。其中 ASSD 是一个基于边界 (表面) 的距离度量指标, 它比基于区域的指标 (如 IoU) 更能敏感地反映分割边界的精确度。分别提取预测结果 S 和真实标签 G 的表面顶点, 记为 S_{surf} 和 G_{surf} 。

(1) 计算预测表面到真实表面的平均距离:

$$d(S_{surf} \rightarrow G_{surf}) = \frac{1}{|S_{surf}|} \sum_{s \in S_{surf}} \min_{g \in G_{surf}} \|s - g\| \quad (14)$$

(2) 计算真实表面到预测表面的平均距离:

$$d(G_{surf} \rightarrow S_{surf}) = \frac{1}{|G_{surf}|} \sum_{g \in G_{surf}} \min_{s \in S_{surf}} \|g - s\| \quad (15)$$

(3) ASSD 是上述两个方向距离的平均值:

$$ASSD = \frac{d(S_{surf} \rightarrow G_{surf}) + d(G_{surf} \rightarrow S_{surf})}{2} \quad (16)$$

ASSD 值越小, 说明两个表面越接近, 分割边界越准确。

2.3 实验结果

第一阶段的目标检测关系到牙齿识别和牙号编排的准确率, 也是后期精分割的基础, 本研究选择目

前最高效的目标检测模型 YOLO 实现, 在 YOLOv8x 预训练模型 (Ultralytics, 2023) 的基础上进行针对性训练, 同时也对比了多个版本的模型, 综合考量选择了 YOLOv8x 模型 (Ultralytics, 2023), 对比结果如表 1 所示。YOLOv8x 模型 (Ultralytics, 2023) 除了精确率上略低于 YOLOv12x (Tian 等, 2025), 其余的指标均明显高于其他三个模型, 并且本实验类别并不平衡, 需要高精度识别, 因此 mAP50-95 指标更为重要, YOLOv8x (Ultralytics, 2023) 在这一指标上的表现较为优越。

不同模型在最终参数指标上的对比如表 2 所示, 平均准确率上 TSegNet (Cui 等, 2021) 最高, 达到 97.12%, 略高于本文方法的 96.74%。而在 mIoU 和 DSC 指标上, 本方法的优势则体现得更加明显, 在实验使用的数据集表现分别比其他方法高出至少 4.86% 和 2.41%。

为验证模型的泛化性, 在公开数据集 Teeth3DS (来自 MICCAI 2022 的 3DTeethSeg 挑战赛) (Ben-Hamadou 等, 2023) 上进行了交叉验证。在未使用 Teeth3DS 数据进行训练的情况下, 直接使用在自建数据集上训练好的模型进行测试。结果如表 3 所示, 在 Teeth3DS 数据集上, 本方法取得了 96.13% 的 mIoU 和 97.91% 的 DSC, 优于其他模型, 证明了本方法在理想数据下的高精度和稳定性。

除了常规指标, 本实验还增加了 ASSD、召回率 R 值和 F1 分数, 具体在 3.2 节中已说明, 极低的表面距离进一步说明了本方法在分割中边缘处理的极高精度, 具体结果如表 4 所示。

为了进一步说明研究的临床可行性及对复杂情况的处理能力, 本研究在困难子集 (缺牙、拥挤重叠病例) 上进行了专项评估, 依然保持了 DSC 均大于 97% 的高性能, 具体测试结果如表 5 所示, 证明了其在处理缺牙和牙齿拥挤重叠问题上的鲁棒性。

为了更好地展示本实验的效果, 本文选择了一个典型病例, 此患者处于上下颌各拔去了一颗第一前磨牙的缺牙状态且存在牙齿前后错位有遮挡重叠情况, 图 7 为该病例的在本文方法下的可视化结果。无论是牙号识别还是重叠牙的分割和边缘细节处理都达到了较好的效果。

全牙颌的可视化对比如图 8 所示, 选择了三个典型牙颌的不同视角来做对比, 包括了不缺牙但牙齿空隙较大的情况、上颌有缺牙但已经过正畸调整

表1 不同YOLO模型在二维牙齿检测中的结果
Table 1 Results of different YOLO models in 2D tooth detection

	R 值 (%)	mAcc (%)	mAP50 (%)	mAP50- 95 (%)
YOLOv5x(Jocher, 2021)	93.31	95.7	94.42	91.11
YOLOv8x(Ultralytics, 2023)	95.3	97.32	96.85	96.23
YOLOv10x(Wang等, 2024)	90.16	94.47	96.23	93.54
YOLOv12x(Tian等, 2025)	94.18	97.61	96.3	94.52

注:加粗字体为每项的最优值。

表2 不同模型在本研究数据集上的分割性能对比
Table 2 Comparison of segmentation performance of different models on the dataset of this study

	mAcc (%)	mIoU (%)	DSC(%)
PointNet(Qi等, 2017a)	90.13	60.14	66.89
PointNet++(Qi等, 2017b)	91.24	67.25	78.26
DBGANet(Lin等, 2024)	92.74	87.08	93.14
TSGCN(Zhao等, 2022)	93.97	86.32	92.44
DADSN(Jiang等, 2025)	96.61	82.65	91.77
TSegNet(Cui等, 2021)	97.12	90.4	95.09
PCT(Guo等, 2021)	93.86	82.04	89.11
Ours	96.74	95.26	97.5

注:加粗字体为每项的最优值。

表3 不同模型在Teeth3DS数据集上的分割性能对比
Table 3 Comparison of segmentation performance of different models on the dataset of Teeth3DS

	mAcc (%)	mIoU (%)	DSC(%)
PointNet(Qi等, 2017a)	91.7	80.66	85.62
PointNet++(Qi等, 2017b)	91.24	88.1	89.14
DBGANet(Lin等, 2024)	93.52	87.91	93.44
TSGCN(Zhao等, 2022)	93.87	88.3	92.59
DADSN(Jiang等, 2025)	96.08	88.85	95.81
TSegNet(Cui等, 2021)	97.19	93.11	96.17
PCT(Guo等, 2021)	93.86	84.5	91.6
Ours	97.21	96.13	97.91

注:加粗字体为每项的最优值。

之后的情况、下颌有缺牙还未进行正畸工作并且存在牙齿参差重叠的情况,此外牙齿表面还有用于隐

表4 本实验的其他参数指标
Table 4 Other parameter indexes of this experiment

	ASSD(mm)	R 值(%)	F1 分数(%)
Ours	0.0074	98.1	97.41

表5 本方法在困难子集上的测试结果
Table 5 Test results of the proposed method on difficult subsets

	mAcc(%)	mIoU(%)	DSC(%)
缺牙子集	97.19	95.41	97.49
拥挤重叠子集	96.51	94.39	97.18

形正畸的附着件,进一步增加了分割的难度。从分割结果来看,PointNet(Qi等, 2017a)和PointNet++(Qi等, 2017b)用于牙齿分割中整体效果较差,牙齿误判和边界残缺较多。而TSGCN(two-stream graph convolutional network)(Zhao等, 2022)和DADSN(dispersion-adaptive dilated segmentation network)(Jiang等, 2025)两种分割方案在牙齿排列较好的时候有着不错的效果,但对于有缺牙、牙齿错位和带有附着件的情况下存在边界的过分割或欠分割,并且TSGCN(Zhao等, 2022)存在相邻牙齿边沿模糊错判的现象。DBGANet(dual-branch geometric attention network)(Lin等, 2024)对于牙齿上附着件的处理较好,但也存在牙齿与牙龈交界处有牙龈被标记成牙齿的现象。而本文的方法对于以上的问题都有着良好的表现,表现出较强的鲁棒性。

2.4 消融实验

为了验证所提出混合框架中各组成模块的有效性,本研究采用逐步叠加的方式开展消融实验,结果如表5所示。所有实验均使用相同的数据划分、训练轮数、学习率与优化器设置,仅改变待验证模块。PCT(Guo等, 2021)表示直接对全牙颌点云进行分割的基线模型;S1表示在PCT(Guo等, 2021)前加入“2D投影检测-3D ROI反投影”维度转换粗分割流程;S2表示在PCT(Guo等, 2021)点云模型中引入分层自适应注意力机制;S3表示将原始点云模型中的损失函数修改为Focal Loss与Dice Loss的组合损失,并配合梯度累积策略。此外,还补充了S2、S3在PCT(Guo等, 2021)基础模型上的效果,以表明其独立有效性。

由表6可见,S1带来的提升最为显著,说明通过
© 中国图象图形学报版权所有




图7 基于本文方法的单牙可视化结果
Fig. 7 The visualization results of single teeth based on the method proposed in this paper




图8 全牙颌可视化结果对比
Fig. 8 Comparison of the visual results of the whole tooth and jaw

2D检测粗分割之后的3D点云分割有效降低了全牙颌直接分割的混淆错判;S2、S3对于点云模型的针对性修改也同样有效,S2进一步提升了mIoU和DSC,表明分层自适应注意力机制能够改善牙齿-牙龈边界及相邻牙齿接触区域的判别能力;S3在整体指标上的增益相对较小,但其作用主要体现在训练稳定性与困难样本的边界细化上。

2.5 实验结果分析与未来展望

尽管本文方法在整体指标上取得了较好结果,但从测试集指标和可视化结果上看,仍存在少量分割失败或结果不理想的情形,主要可归纳为以下三点:

1)平均准确率(mAcc)上TSegNet(Cui等,2021)最高,达到97.12%,略高于本文方法的96.74%。分


表6 消融实验结果						
Table 6 Results of ablation experiments						
	PCT	PCT+S2	PCT+S3	S1	S1+S2	S1+S2+S3
mAcc(%)	93.86	95.21	94.68	96.7	96.71	96.74
mIoU(%)	82.04	84.15	84.09	93.12	94.33	95.26
DSC(%)	89.11	92.3	90.97	96.55	97.1	97.5

注:S1:使用维度转换的混合框架;S2:在点云模型中增加分层自适应注意力机制;S3:使用组合损失和梯度累积策略。

析其原因,TSegNet专注于质心预测和单体素分割,在单个牙齿的识别准确率上有优势。然而,在衡量整体分割区域重叠度的mIoU和DSC指标上,本方法的优势则体现得更加明显,分别比其他方法高出至

少4.86%和2.41%。这表明本方法虽然在整体准确率上略有不及,但其分割出的牙齿区域与真实标签的吻合度更高,尤其是在牙齿-牙龈边界处。mAcc对大面积易分类内部点更敏感,而本文的优化重点更多放在复杂边界和困难病例的整体重叠一致性,但这恰恰凸显了 mIoU 和 DSC 作为核心分割指标的重要性。但在单独测试的困难子集——缺牙病例中,本文方法的测试结果已超过 TSegNet 的准确率,因此也说明了本方法在针对性数据上的卓越效果,同时因为数据集存在一定不平衡性也同样导致了总体准确率的略微不足。

2)数据集的针对性,同样也表明样本不够全面,导致对于极少数有刚刚萌出的牙齿或是换牙期儿童有乳恒牙并存等情况下会出现识别不准确进而导致最后的分割效果欠佳的情况,如图9所示,(a)中橙色虚线框是未完全萌出的智齿未被识别到;(b)为儿童牙颌,橙色虚线框为未完全萌出的恒牙同样未被分割出来,其次紫色虚线框中的灰色牙齿因为根据模型的形态学检测,这些牙齿的置信度过低导致未被分配到相应牙号。这些属于数据集中的极少数情况,而本研究暂未给儿童牙齿进行分类编号和针对性训练,这也是未来需要进一步补充的。



(a)存在未完全萌生的智齿 (b)存在儿童恒牙萌出、乳恒牙并存

((a) Incomplete wisdom teeth are present; (b) The eruption of children's permanent teeth and the coexistence of deciduous and permanent teeth were observed)

图9 失败案例

Fig. 9 Failure cases

3)总体测试集上的召回率(R值)高达98.1%,对应的精确率(P值)经计算为96.8%,F1分数为97.4%。极高的召回率表明模型对牙齿区域(包括困难边界)的捕捉能力很强,而精确率略低于召回率,提示存在轻微的过分割风险(即将少量牙龈组织误判为牙齿),这也是未来需要优化的方向。

因此后续研究将从以下四个方面进一步改进:一是通过更全面的数据,提升学习框架的泛化能力和全面性以适配更多的病例情况;二是引入多视角或可学习投影策略,减轻单视角投影可能带来的遮挡误差,进一步提升分割效果;三是在公开数据集及多中心临床数据上开展外部验证,并补充病例级推理时间统计,以进一步评估临床部署潜力;四是进一步优化模型参数、改进训练,防止过分割的风险。

3 结论

本研究提出并验证了一种名为 HaTransTooth 的新型混合深度学习框架,该框架能够有效应对因缺牙、牙齿重叠或牙缝较大等情况导致的牙齿分割不准的问题。方法上,采用了“由粗到细”的协同思路:首先借助改进的 YOLOv8 模型在二维投影图上快速定位并识别每颗牙齿,再通过从二维到三维的反向投影提取关键区域,从而将复杂的实例分离问题简化。在分割阶段,设计了专门用于牙齿点云的分割网络,其中引入分层自适应注意力机制,能同时捕捉局部细节与整体语义信息,显著改善了牙齿与牙龈交界模糊处的分割效果;此外,通过结合 Focal loss 与 Dice loss 的组合损失函数,并采用梯度累积策略,缓解了类别不均衡问题,加强了对难分样本的学习能力。基于上海多家医院和诊所提供的真实口腔扫描数据开展实验,并且在 Teeth3DS 数据集上进行了测试评估,结果显示,该方法在多项评价指标上均优于现有主流方法,尤其在缺牙、牙齿重叠等复杂案例中表现稳定,为口腔数字化诊断与正畸规划提供了可靠工具。

参考文献(References)

- Ben-Hamadou A, Smaoui O, Rekik A, Pujades S, Boyer E, Lim H Ket al. 2023. 3DTeethSeg'22: 3D Teeth Scan Segmentation and LabelingChallenge[EB/OL].[2026-4-19].
<https://doi.org/10.48550/arXiv.2305.18277>
- Chen C Q, Fan Y C and Wang L. 2022. Logo detection based on improved Mosaic data enhancement and feature fusion. Computer Measurement and Control, 30(10): 188-194 (陈翠琴,范亚臣,王林. 2022. 基于改进 Mosaic 数据增强和特征融合的 Logo 检测. 计算机测量与控制, 30(10): 188-194) [DOI: 10.16526/j.cnki.11-4762/tp.2022.10.029]

- Cui Z M, Li C J, Chen N L, Wei G D, Chen R N, Zhou Y Fet al. 2021. TSegNet: An efficient and accurate tooth segmentation network on 3D dental model. *Medical Image Analysis*, 69: 101949 [DOI: 10.1016/j.media.2020.101949]
- Grace and Mike. 2000. Dental notation. *British Dental Journal*, 488(5): 229 [DOI: 10.1038/sj.bdj.4800438]
- Guo M H, Cai J X, Liu Z N, Mu T J, Martin R R and Hu S M. 2021. PCT: Point cloud transformer. *Computational Visual Media*, 7(2): 187 - 199 [DOI: 10.1007/s41095-021-0229-5]
- Hao W, Zuo Z B, Lu H S, Liang W, Jin H Y, Shi Z H. 2025. Enhanced attention-based joint semantic instance segmentation network for point clouds. 30(12): 3914-3926 (郝雯, 左占彬, 卢翰森, 梁玮, 金海燕, 石争浩. 2025. 基于增强注意力的点云语义实例联合分割. *中国图象图形学报*, 30(12): 3914-3926) [DOI: 10.11834/jig.240445]
- Huang Y R, Chen J J, Zheng S M, Xue Y and Hu X H. 2021. Hierarchical multi-attention networks for document classification. *International Journal of Machine Learning and Cybernetics*, 12(6): 1639 - 1647 [DOI: 10.1007/s13042-020-01260-x]
- Jana A, Subhash H M and Metaxas D. 2023. 3D Tooth mesh segmentation with simplified mesh cell representation// *Proceedings of 2023 IEEE 20th International Symposium on Biomedical Imaging (ISBI)*. Cartagena, Colombia: IEEE: 1-5. [DOI: 10.1109/ISBI53787.2023.10230650]
- Jiang Y X, Wang X Y, Yang T, Ji C K, He L S, Liu Y Set al. 2025. Morphology prior enhanced teeth segm entation for high-resolution oral scans. *IEEE Journal of Biomedical and Health Informatics*, Advance online publication [DOI: 10.1109/JBHI.2025.3616205]
- Jocher G, Stoken A, Chaurasia A, Borovec J, Code N, Xie Tet al. 2021. Ultralytics/yolov5: v6.0 - YOLOv5n 'Nano' models, Robo-flow integration, TensorFlow export, OpenCV DNN support [EB/OL]. [2025-12-9]. [https:// doi.org/10.5281/zenodo.5563715](https://doi.org/10.5281/zenodo.5563715)
- Ultralytics. 2023. Ultralytics YOLOv8 [EB/OL]. [2026-12-11]. <https://github.com/ultralytics/ultralytics>.
- Lin Z J, He Z S, Wang X, Zhang B, Liu C, Su W Qet al. 2024. DBGANet: Dual-branch geometric attention network for accurate 3D tooth segmentation. *IEEE Transactions on Circuits and Systems for Video Technology*, 34(6): 4285-4298 [DOI: 10.1109/TCSVT.2023.3331589]
- Liu M R, Tan M H and Zhang Y. 2025. Classification of teeth in CBCT images using deep learning with multi-view projection. *Chinese Journal of Medical Physics*. *Chinese Journal of Medical Physics*, 42(3): 313-319 (刘沐然, 谭敏慧, 张煜. 2025. 基于深度学习对 CBCT 图像采用多视角投影的牙齿分类. *中国医学物理学杂志*, 42(3): 313-319) [DOI: 10.3969/j.issn.1005-202X.2025.03.005]
- Liu Z H, Xue J T, Tang H and Liao Y H. 2024. Research on intelligent tooth segmentation method combining multiple seed region growth and boundary extension. 41(3): 520-526 (刘志华, 薛久涛, 唐浩, 廖与禾. 2024. 结合多种子区域生长和边界延伸的智能牙齿分割方法研究. *生物医学工程学杂志*, 41(3): 520-526) [DOI: 10.7507/1001-5515.202309030]
- Qi C R, Su H, Mo K and Guibas L J. 2017a. PointNet: deep learning on point sets for 3D classification and segmentation//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA: IEEE: 77-85 [DOI: 10.1109/CVPR.2017.16]
- Qi C R, Yi L, Su H and Guibas L J. 2017b. PointNet++: deep hierarchical feature learning on point sets in a metric space//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach, USA: Curran Associates Inc.: 5105-5114 [DOI: 10.48550/arXiv.1706.02413]
- Sundar L K S, Yu J, Muzik O, C. Kulterer O, Fueger B, Kifjak D, Nakuz Tet al. 2022. Fully automated, semantic segmentation of whole-body 18F-FDG PET/CT images based on data-centric artificial intelligence. *Journal of Nuclear Medicine*, 63 (12) : 1941-1948 [DOI: 10.2967/jnumed.122.264063]
- Tian Y J, Ye Q X and Doermann D. 2025. YOLOv12: Attention-Centric Real-Time Object Detectors [EB/OL]. [2025-12-16]. <https://doi.org/10.48550/arXiv.2502.12524>
- Wang A, Chen H, Liu L H, Chen K, Lin Z J, Han J Get al. 2024. YOLOv10: real-time end-to-end object detection [EB/OL]. [2025-12-14]. <https://doi.org/10.48550/arXiv.2405.14458>
- Wang P J, Gu H J and Sun Y L. 2025. Tooth segmentation on multi-modal images using adapted segment anything model. *Scientific Reports*, 15: 13874 [DOI: 10.1038/s41598-025-96301-2]
- Wu T H, Lian C F, Lee S, Pastewait M, Piers C, Liu Jet al. 2022. Two-stage mesh deep learning for automated tooth segmentation and landmark localization on 3D intraoral scans. *IEEE Transactions on Medical Imaging*, 41(11): 3158-3166 [DOI: 10.1109/TMI.2022.3180343]
- Xi S F, Liu Z X, Chang J L, Wu H Y, Wang X G and Hao A M. 2025. 3D dental model segmentation with geometrical boundary preserving//*Proceedings of 2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, TN, USA: IEEE: 10476-10485 [DOI: 10.1109/CVPR52734.2025.00980]
- Yeung M, Sala E, Schönlieb C B and Rundo L. 2022. Unified focal loss: Generalising dice and cross entropy-based losses to handle class imbalanced medical image segmentation. *Computerized Medical Imaging and Graphics*, 95: 102026 [DOI: 10.1016/j.compmedimag.2021.102026]
- Zhao Y, Zhang L M, Liu Y, Meng D Y, Cui Z M, Gao C Qet al. 2022. Two-stream graph convolutional network for intra-oral scanner image segmentation. *IEEE Transactions on Medical Imaging*, 41 (4): 826-835 [DOI: 10.1109/TMI.2021.3124217]
- Zhao Y J and Wang Y. 2024. Current status and analysis of the clinical application of digital technology in oral medicine. *Journal of Sich-*

uan University(Medical Sciences), 55(1): 101-110 (赵一姣,王
勇. 数字化技术在口腔医学的临床应用现状与分析. 四川大学
学报(医学版),55(1):101-110) [DOI: 10.12182/20240160301]

作者简介

吴镇,男,硕士研究生,主要研究方向为点云分割。E-mail:

243370849@st.usst.edu.cn

陈胜,男,副教授,主要研究方向为计算机辅助诊断、模式识别与智能系统、医学图像处理与分析。E-mail: chnshn@163.com

程晔,男,硕士研究生,主要研究方向为点云处理与分割。E-mail: chengye102102102@outlook.com