

# 基于类平衡损失的咽喉反流语义分割与诊断方法

郑宝志<sup>1,2</sup>, 戴厚德<sup>2</sup>, 刘鹏华<sup>2</sup>, 姚瀚晨<sup>2</sup>, 王增伟<sup>2\*</sup>

<sup>1</sup>福州大学电气工程与自动化学院, 福建 福州 350108;

<sup>2</sup>中国科学院泉州装备制造研究中心, 福建 泉州 362216

**摘要** 当前咽喉反流疾病的筛查主要依靠电子喉镜图像通过反流体征评分(RFS)量表进行评分, 尽管这种量化评估方式增强了筛查诊断的客观性, 但误诊率、筛查效率仍有待进一步改进。通过深度学习算法实现基于 RFS 的咽喉反流量化辅助评估。首先, 提出一种基于类平衡损失的咽喉反流语义分割与诊断(CBD-FCN)算法, 通过 RFS 量表先验知识对电子喉镜图像进行喉部多区域语义分割, 该算法有效解决了数据集样本类别不平衡和小目标检测的问题, 平均交并比(IoU)提高 6.38 个百分点, 声带沟、肉芽肿和黏液等小目标检出率分别提升 4 个百分点、18 个百分点和 75 个百分点。其次, 针对 RFS 量表中难量化评估的主观项, 通过 SE-ResNet 和目标区域分割特征进行量化并实现评分。上述辅助评分结果可以有效快速地实现咽喉反流的筛查诊断, 实验结果表明, 所提方法的诊断正确率达到 94.40%。该研究不仅提供了一种创新的计算机辅助咽喉反流量化评估方法, 同时也为基于 RFS 量表的咽喉反流评估提供了诊断参考, 有助于咽喉反流相关疾病的研究。

**关键词** 图像处理; 咽喉反流; 语义分割; 类别不平衡; 深度学习; 图像处理

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP221902

## Semantic Segmentation and Diagnosis of Laryngopharyngeal Reflux Based on Class-Balanced Loss

Zheng Baozhi<sup>1,2</sup>, Dai Houde<sup>2</sup>, Liu Penghua<sup>2</sup>, Yao Hanchen<sup>2</sup>, Wang Zengwei<sup>2\*</sup>

<sup>1</sup>College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, Fujian, China;

<sup>2</sup>Quanzhou Institute of Equipment Manufacturing, Chinese Academy of Sciences,  
Quanzhou 362216, Fujian, China

**Abstract** Presently, an electronic laryngoscope image is used to assess the severity of laryngopharyngeal reflux disease based on the reflux finding score (RFS) scale. This quantitative evaluation method increases the screening diagnosis objectivity. However, its misdiagnosis rate is high, and screening efficiency is moderate. An anti-flow-aided evaluation of the throat region based on RFS can be implemented using a deep learning algorithm. We propose a semantic segmentation algorithm for diagnosing laryngopharyngeal reflux disease based on existing knowledge of the RFS scale to segment the throat multi-region semantics in an electronic laryngoscope image. This algorithm resolves the problems of unbalanced sample categories and small target detection in the dataset used for this study. The intersection over union ratio for the dataset increased by 6.38 percentage points. Moreover, detection rates for small targets, such as voice-band groove, granuloma, and mucus, increased by 4 percentage points, 18 percentage points, and 75 percentage points, respectively. Furthermore, SE-ResNet and target area segmentation are used to quantify and evaluate the subjective items in the RFS scale. Thus, the auxiliary evaluation results aid in rapid and effective diagnosis of laryngopharyngeal reflux. The diagnostic accuracy of the proposed method is 94.40%. This study provides an innovative computer-aided assessment method for throat regurgitation that can be used for diagnostic reference based on the RFS scale. Hence, this study lays foundation for further research into throat regurgitation-related diseases.

**Key words** image processing; laryngopharyngeal reflux; semantic segmentation; category imbalance; deep learning

收稿日期: 2022-06-10; 修回日期: 2022-06-24; 录用日期: 2022-09-26; 网络首发日期: 2022-10-06

基金项目: 福建省科技计划项目(2021Y0048)

通信作者: \*willzwang@163.com

## 1 引言

咽喉反流疾病(LPRD)是指咽喉反流(LPR)时胃内容物(包括固体、液体、气体及其混合物)倒流至食管上括约肌以上部位对咽喉部黏膜造成损害,从而引起的一系列咽喉部的炎症体征,甚至恶性病变<sup>[1-2]</sup>。由于现代社会人们的饮食生活不规律、抽烟酗酒缺乏节制,咽喉反流疾病发病率不断升高,病患可占到耳鼻喉科门诊全部就诊患者中的10%、声嘶患者的50%<sup>[3]</sup>。但门诊往往将其当作普通咽喉炎治疗,患者在各家医院间辗转求诊而不愈,浪费社会医疗资源,同时延误了最佳就诊时间,给患者造成了巨大的身心伤害<sup>[4]</sup>。此外,目前已有研究表明,咽喉反流疾病与多种喉部疾病,尤其是喉癌、喉前病变、下咽癌和哮喘等疾病的发生有重要关系<sup>[5-6]</sup>。因此,近几年来咽喉反流疾病成为咽喉界研究热点。

目前临床上将反流体征评分(RFS)量表作为权威的咽喉反流评估手段,RFS量表可以量化返流关联喉部体征,包括8项常见体征:假声带沟、喉室消失、红斑和(或)充血、声带水肿、弥漫性喉水肿、后联合增生、肉芽肿和喉内黏液附着。Belafsky等<sup>[7]</sup>发现量表总评分大于7分时具有较高的评估诊断效能,并且RFS在LPR评估诊断上取得了较好的临床效用,提升了评估效率。目前实现RFS量表咽喉反流评估诊断主要依赖喉部内窥镜,由医生对喉镜影像进行分析,并根据RFS量表进行评估。虽然RFS总分对于准确筛查LPR是较为可靠的,但是部分量表内容仍然存在内部一致性较差等问题<sup>[8]</sup>。造成这一缺陷的原因是部分项目仍然存在量化评估主观性较强的问题。评估准确性与评估者的临床经验、个人因素相关。快速可靠的LPR评估有助于提高门诊效率,降低患者就诊成本。因此,实现客观可靠的RFS返流评估和诊断具有重要意义。

目前严重缺乏对喉部图像的返流关联喉部体征分

割任务的研究,对喉部图像的分割任务大多停留在声带和声门区域<sup>[9]</sup>以完成对特定喉部疾病的分类,无法对LPR这种复杂疾病提供客观的病情评估,但对喉部图像的研究证明了深度学习在内窥镜图像分割和评估方面的有效性。Witt等<sup>[10]</sup>利用神经网络对喉部图像的颜色、纹理特征进行LPR评估分类,但由于存在主观判断,这种方法耗时且不准确。24 h双探针pH检测可区分LPR<sup>[11-12]</sup>,但耗费时间过长。

依据RFS量表的任務信息,本文旨在通过深度学习的喉镜图像进行完整的区域分割。针对电子喉镜中声带沟、肉芽肿、黏液目标小及样本少的问题,为了提高小样本和小目标的分割精度,提出一种基于类平衡损失的咽喉反流语义分割与诊断(CBD-FCN)算法。通过对RFS量表中3个主观性较强的病症进行评分,验证了所提算法辅助医生进行LPR评估的可行性。三折验证下的咽喉反流评估结果表明,所提基于类平衡损失的咽喉反流语义分割与诊断算法可以提高评估速度和降低误诊率。

## 2 语义分割算法与量化诊断策略

首先,对电子喉镜图像按照RFS量表的相关区域进行语义分割;然后,针对3个主观性较强的病症进行总评分量化,辅助医生进行LPR的评估;最后,针对医学数据集具有类别不平衡的特点,添加一种新的类平衡损失函数——CB Dice损失,提高模型分割精度。

所提基于类平衡损失的咽喉反流语义分割算法整体流程如图1所示。首先将喉镜图像输入全卷积网络(FCN)进行语义分割训练,使用所提CB Dice损失作为分割训练的损失函数构造CBD-FCN算法,输出分割结果和客观病症分数。结合病理分析,对3项较难评估的病症根据病理将其对应的分割掩码区域或全图输入SE-ResNet18进行回归预测,然后将SE-ResNet18输出的预测分数输入线性回归模块拟合,实现总分量化。

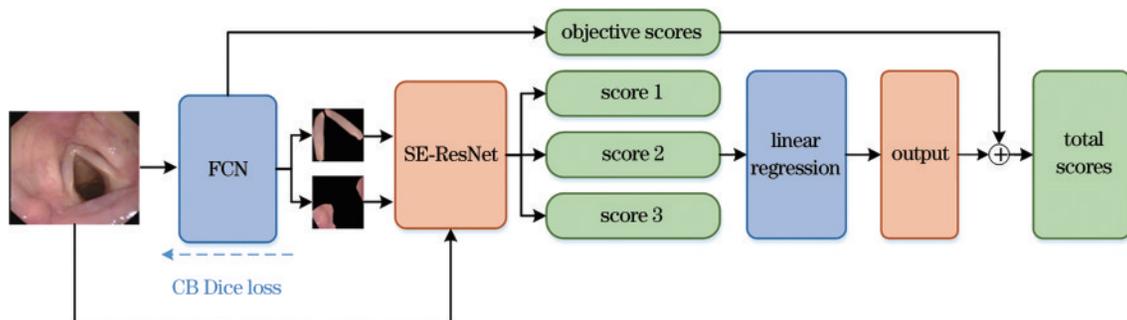


图1 整体流程图

Fig. 1 Overall flow chart

### 2.1 分割算法

近年来,深度学习在各个领域取得不错的效果,在医学影像分析领域也取得显著进步。医学影像中的内

窥镜图像分割是一个热门的研究领域,由于分割任务的多样性,不存在“黄金标准”方法。FCN<sup>[13]</sup>是一种常见的分割模型,对图像进行像素级别的分类,可解决语

义分割级别的图像分割问题。FCN 风格的卷积神经网络(CNN)模型已被用于息肉检测、肝脏分割和手术器械跟踪等。FCN 经过前级的卷积下采样后,采用反卷积层对卷积得到的最后一个特征图进行上采样,使它恢复到输入图像的尺寸,从而可以对每个像素都产生一个预测,同时又保留原始输入图像中的空间信息。为了实现更好的分割性能,选取 FCN-ResNet101 预训练模型进行语义分割任务的训练,通过迁移学习的方法实现对模型的鲁棒训练。将 FCN-ResNet101 作为基准网络,以所提 CB Dice 损失作为损失函数构造 CBD-FCN 算法。

## 2.2 类平衡骰子损失函数

RFS 量表可以客观表征患者是否患有 LPR,但 RFS 量表所涉及的区域较多,无法保证所有的数据类别分布均匀,存在数据不平衡的问题。而交叉熵(CE)损失常被用于像素级别的分割任务,但 CE 损失在处理不平衡类别的任务上表现较差,所以引入类平衡(CB)损失<sup>[14]</sup>。假设对于某个样本数据集  $S$ ,样本数量为  $N$ ,随机从  $S$  中抽取数据  $a$  放到集合  $A$  中,直至  $A$  的数据完全覆盖  $S$  的所有样本。当  $A = \Phi$  时,取  $a$  放入  $A$  中, $A$  的样本数为 1。当  $A$  中已有样本时,在不考虑部分重叠的情况下,新的样本与  $A$  中的样本存在两种可能:完全在之前的采样数据中的概率为  $p$ ,或完全在原来的数据集之外的概率为  $1-p$ 。设  $E_n$  为第  $n$  次采样的期望值,则有  $E_n = (1 - \beta^n)/(1 - \beta)$ ,  $\beta = (N - 1)/N$ 。假设之前已经采样了  $n - 1$  个样本,即将采样第  $n$  个样本,那么先前采样数据的预期量为  $E_{n-1}$ ,新采样的数据点与先前样本重叠的概率  $p = E_{n-1}/N$ ,则有

$$E_n = pE_{n-1} + (1 - p)(E_{n-1} + 1) = 1 + \frac{N - 1}{N} E_{n-1}, \quad (1)$$

此时  $E_{n-1} = (1 - \beta^{n-1})/(1 - \beta)$ , 则

$$E_n = 1 + \beta \frac{1 - \beta^{n-1}}{1 - \beta} = \frac{1 - \beta + \beta - \beta^n}{1 - \beta} = \frac{1 - \beta^n}{1 - \beta}. \quad (2)$$

即有效样本数量是  $n$  的指数函数,超参数  $\beta \in [0, 1)$ ,  $E_n$  与  $n$  成正比。类平衡损失旨在通过引入与有效样本数成反比的加权因子来解决不平衡数据中的训练问题,类平衡损失项可以应用于广泛的深度网络和损失函数。假设模型的所有类别预测输出  $z = [z_1, z_2, \dots, z_c]z_j$ , 其中,  $c$  为类别总数。采用 Softmax 函数计算所有类别的概率分布:

$$p_i = \exp(z_i) / \sum_{j=1}^c \exp(z_j), i \in \{1, 2, \dots, c\}. \quad (3)$$

给定一个类别为  $y$  的样本,则该样本的 Softmax cross-entropy 损失为

$$L_{\text{Softmax CE}}(z, y) = -\log \frac{\exp(z_y)}{\sum_{j=1}^c \exp(z_j)}, \quad (4)$$

假设类别  $y$  的样本个数为  $n_y$ , 那么类平衡 Softmax cross-entropy 损失为

$$L_{\text{Softmax CB}}(z, y) = -\frac{1 - \beta}{1 - \beta^{n_y}} \log \frac{\exp(z_y)}{\sum_{j=1}^c \exp(z_j)}. \quad (5)$$

CB Dice 损失由 CB Softmax 损失和 Dice 损失的加权和组成。Dice 损失是一种区域相关的损失,当前像素的损失不仅和当前像素的预测值有关,还与其他点的值有关。二者结合使用,既达到了平衡样本损失的效果,还保证了分割精度。Dice 损失和 CB Dice 损失的损失函数分别为

$$L_{\text{Dice}} = 1 - \frac{1}{c} \sum_i \sum_j \frac{2p_{ij}y_{ij} + \gamma}{p_{ij}^2 + y_{ij}^2 + \gamma}, \quad (6)$$

$$L_{\text{segm}} = \alpha L_{\text{CB}} + (1 - \alpha) L_{\text{Dice}}. \quad (7)$$

式中:  $\alpha$  为权重,设置为 0.8;  $N$  为分割像素点总数;  $p_{ij}$  表示第  $i$  个通道第  $j$  个元素预测为第  $i$  类的概率;  $y_{ij}$  表示第  $i$  个通道第  $j$  个元素所属的真实类别;  $\gamma$  设置为 1, 以便达到平滑的目的。

## 2.3 线性回归

通过 SE-ResNet18<sup>[15]</sup> 输出的 3 个病症分数可以通过线性回归的方式进行总分量化。线性回归是指将一个或者多个自变量和因变量之间的关系进行建模的一种分析方式,可以建立特征值与目标值之间的关系。

$$f(x) = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n, \quad (8)$$

式中:要求的参数  $W = [w_0, w_1, \dots, w_n]$ ; 输入的特征值  $X = [x_1, x_2, \dots, x_n]$ 。将 3 个病症预测分数作为自变量,总分作为因变量建立模型进行训练可以达到预测总分的效果。

## 3 实验与结果分析

本实验采用三折交叉验证的方式,确保每一折的测试集数据均未参与训练,保证模型的泛化能力。

### 3.1 数据集

目前对于咽喉部分的分割任务数据集较少,主要难点在于:咽喉反流病症数据需要专业的医生采集和标注,采集过程费时费力。所有实验数据来自福建省立医院,在患者签署《医学调查知情书》后分配给 3 位高级医师采集并标注,经过多个医生反复讨论,去除标注质量差和画质模糊的图像,最终确定并形成数据集。数据集共包含 1661 张图像,输入模型时统一将图像调整为  $224 \times 224$  的固定大小。

### 3.2 分割结果

为了展示 CBD-FCN 在数据不平衡情况下的分割效果,选取语义分割中常用的 CE 损失和针对不平衡数据集的 Focal 损失以及 weighted cross entropy (WCE) 损失共同进行实验。图 2 展示了不同损失函数下分割模型输出的分割效果图,所有分割结果中:红色代表后联合;绿色代表喉室;黄色代表声带;蓝色代表声带沟;紫色代表杓区;青色代表肉芽肿;灰色代表

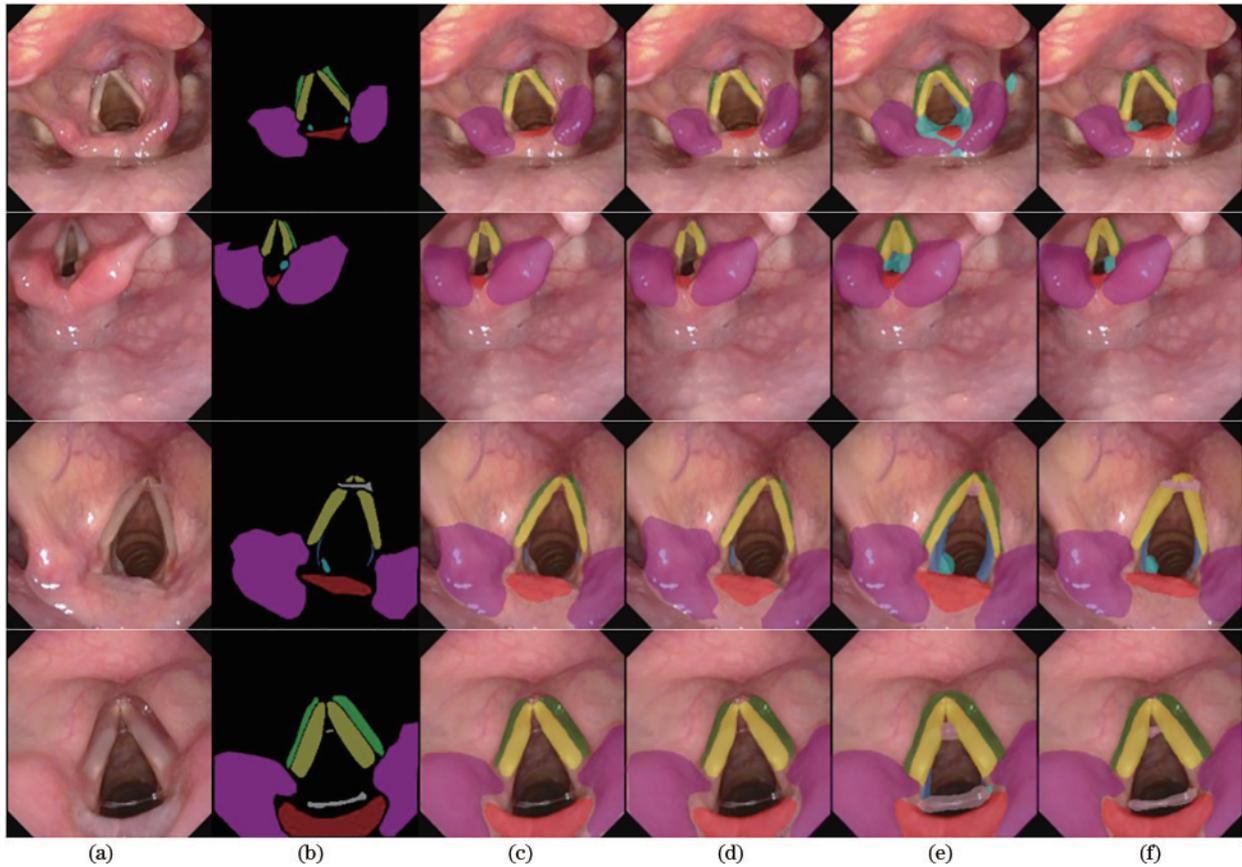


图2 不同损失函数下模型预测对比。(a)原图;(b)真值标签图;(c) CE-FCN分割结果;(d) Focal-FCN分割结果;(e) WCE-FCN分割结果;(f) CBD-FCN分割结果

Fig. 2 Comparison of model predictions under different loss functions. (a) Original images; (b) ground truth; (c) CE-FCN segmentation results; (d) Focal-FCN results; (e) WCE-FCN results; (f) CBD-FCN results

黏液。为了展示分割模型的效果,对多张测试图像的分割结果进行可视化,包括不同的旋转角度图片以及垂直距离各不相同的图片。

表1给出了不同损失函数下模型分割的交并比(IoU),其中,PC、LV、VF、SG、ARY、GRA、MCU分别是后联合、喉室、声带、声带沟、杓区、肉芽肿、黏液的缩写。由于CE损失无法分割黏液,因此无法用于辅助评估系统,不参与对比。与WCE进行对比,所提损失函数在声带沟、肉芽肿以及黏液这种小目标区域的

IoU均有提高,平均IoU提高了6.38个百分点。声带沟、肉芽肿和黏液区域在RFS中为二分类,医学诊断二分类常以F1和特异性作为评价指标,F1越高代表模型预测阳性的能力越好,特异性越高代表模型预测阴性的能力越好。表2给出了不同损失函数在3个区域检出率的评价指标。可以看出:所提损失函数在F1上均优于其他损失函数;在特异性上,Focal损失由于阳性检出率过低导致声带沟和黏液的特异性为1;所提函数的指标均优于WCE。

表1 不同损失函数下的IoU

Table 1 IoU under different loss functions unit: %

Function	PC	LV	VF	SG	ARY	GRA	MUC	Mean
CE	76.23	67.67	81.89	38.54	87.44	43.64		56.49
WCE	58.58	47.13	72.14	16.09	81.86	30.25	7.49	44.79
Focal	68.15	50.62	73.55	14.61	80.51	43.76	0.58	47.40
Proposed function	67.20	55.96	77.83	25.16	85.99	50.25	14.08	53.78

### 3.3 消融实验

为验证所采用的损失函数对提高小目标及小样本区域的有效性,采用Deeplab V3进行消融研究。比较不同的损失函数在数据集上的IoU,结果如表3所示。

由表3可知:所提CB Dice损失在Deeplab V3上

仍然适用,平均IoU提高了2.04个百分点。

### 3.4 回归结果

相关研究表明<sup>[16-18]</sup>,咽喉反流的RFS得分以7分为界限:小于7分表示患者未患有咽喉反流;大于等于7分表示患者存在咽喉反流现象,需要进行后续的诊

表 2 不同损失函数检测小目标区域的评价指标

Table 2 Indexes of evaluation for recognizing small target areas with various loss functions

Function	SG		GRA		MUC	
	F1	Specificity	F1	Specificity	F1	Specificity
CE	0.86	0.92	0.65	0.99	0	1.00
WCE	0.80	0.23	0.76	0.95	0.53	0.73
Focal	0.02	1.00	0.78	0.99	0.22	1.00
Proposed function	0.90	0.75	0.87	0.99	0.75	0.90

表 3 消融实验结果

Table 3 Results of ablation experiments

unit: %

Function	PC	LV	VF	SG	ARY	GRA	MUC	Mean
CE	77.45	68.38	82.41	45.80	87.38	48.53	0	58.56
WCE	64.31	51.66	74.24	21.13	83.53	41.64	11.91	49.77
Focal	71.20	52.19	75.44	14.34	83.20	50.49	0.82	49.67
Proposed function	67.98	52.16	76.60	24.33	85.74	42.63	13.22	51.81

断治疗。Vance 等<sup>[8]</sup>测试了不同评估者针对 RFS 评分的各个症状的一致性,其中,声带水肿、红斑/出血和弥漫性喉水肿评估内信度最低,分别为 68.32%、69.62% 和 66.86%,于是对这 3 类主观性较强的病症分别进行回归训练,输出各子模型的预测分数,最后对 3 类模型的预测分数进行线性回归处理。

对于线性回归,同样需要划分训练集和验证集。由于原始分数是离散和非连续的,于是向训练集中添加白噪声使其连续。图 3 为添加噪声以及拟合 3 项

评分的流程图。根据 3 个模型各类输出结果,可以得到每个类别回归预测分数的均值和方差,计算出三折平均的均值和方差,将通过高斯函数随机生成噪声添加进训练集中对应的类别分值,再进行线性回归的训练和预测。图 4 为三折的预测总分与真值之间的误差分布,平均 94.22% 的样本误差在 1 分以内,对预测分数和客观病症分数求和并按照 7 分的界限进行是否患病的评估,最终的平均评估正确率为 94.40%,如表 4 所示。

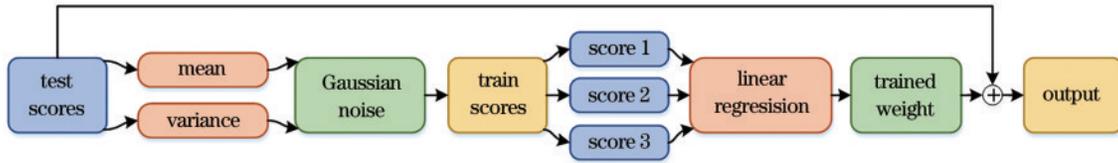


图 3 噪声添加和线性回归模型

Fig. 3 Noise addition and linear regression models

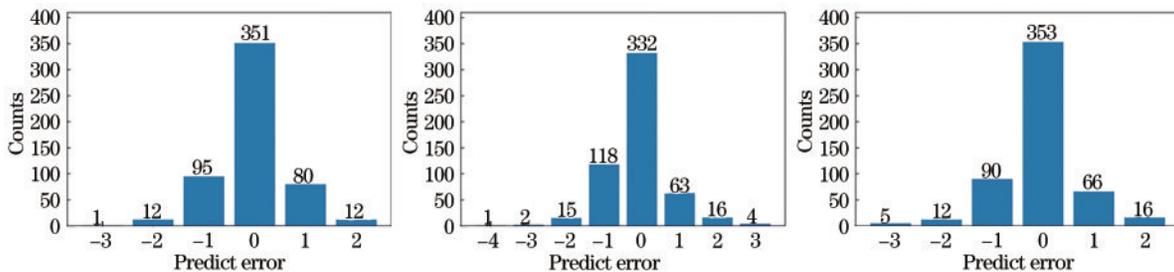


图 4 三折交叉验证下线性回归输出总分与真实总分的偏差

Fig. 4 Under threefold cross-validation, the difference between the output total score and the real total score of linear regression

表 4 三折交叉验证下咽喉反流评估正确率

Table 4 Three-fold cross validation of the accuracy of LPRD reflux assessment

Folds	1	2	3	Average
Accuracy / %	94.73	94.19	94.28	94.40

## 4 结 论

提出一种咽喉反流疾病的语义分割与诊断方法,通过深度学习实现对RFS中3个主观性较强的病症量化评分和辅助诊断。针对医学数据集类别不平衡的特点,所提CBD-FCN算法对于类别不平衡的语义分割任务的分割精度显著提高。在真实的患者数据集上的实验结果表明,所提算法的平均IoU上升8.99个百分点,小目标区域的F1和specificity也高于其他损失函数。同时也完成了客观量化咽喉反流病症3个主观性较强的总分评估,结合医生给出的剩余病症分数,咽喉反流的评估诊断准确率达到94.40%。

对RFS中的3项主观病症进行拟合的结果表明,利用深度学习算法评估咽喉反流是可行的,这有助于咽喉反流的临床辅助诊断和评估。在将来的工作中将提高分割效率以及所有评分的准确性,实现一种实时的全自动咽喉反流辅助评估系统。

### 参 考 文 献

- [1] Lechien J R, Akst L M, Hamdan A L, et al. Evaluation and management of laryngopharyngeal reflux disease: state of the art review[J]. *Otolaryngology-Head and Neck Surgery*, 2019, 160(5): 762-782.
- [2] Kaufman J A, Aviv J E, Casiano R R, et al. Laryngopharyngeal reflux: position statement of the committee on speech, voice, and swallowing disorders of the American Academy of Otolaryngology-Head and Neck Surgery[J]. *Otolaryngology-Head and Neck Surgery*, 2002, 127(1): 32-35.
- [3] Kaufman J A, Amin M R, Panetti M. Prevalence of reflux in 113 consecutive patients with laryngeal and voice disorders[J]. *Otolaryngology-Head and Neck Surgery*, 2000, 123(4): 385-388.
- [4] Massawe W A, Nkya A, Abraham Z S, et al. Laryngopharyngeal reflux disease, prevalence and clinical characteristics in ENT department of a tertiary hospital Tanzania[J]. *World Journal of Otorhinolaryngology-Head and Neck Surgery*, 2020, 7(1): 28-33.
- [5] McCormick C A, Samuels T L, Battle M A, et al. H<sup>+</sup>/K<sup>+</sup>-ATPase expression in the larynx of laryngopharyngeal reflux and laryngeal cancer patients[J]. *The Laryngoscope*, 2021, 131(1): 130-135.
- [6] Copper M P, Smit C F, Stanojic L D, et al. High incidence of laryngopharyngeal reflux in patients with head and neck cancer[J]. *The Laryngoscope*, 2000, 110(6): 1007-1011.
- [7] Belafsky P C, Postma G N, Koufman J A. The validity and reliability of the reflux finding score (RFS)[J]. *The Laryngoscope*, 2001, 111(8): 1313-1317.
- [8] Vance D, Alnouri G, Shah P, et al. The validity and reliability of the reflux finding score[J/OL]. *Journal of Voice*: 1-5[2022-08-09]. <https://www.sciencedirect.com/science/article/pii/S0892199720304215?via%3Dihub>.
- [9] Fehling M K, Grosch F, Schuster M E, et al. Fully automatic segmentation of glottis and vocal folds in endoscopic laryngeal high-speed videos using a deep Convolutional LSTM Network[J]. *PLoS One*, 2020, 15(2): 0227791.
- [10] Witt D R, Chen H J, Mielens J D, et al. Detection of chronic laryngitis due to laryngopharyngeal reflux using color and texture analysis of laryngoscopic images[J]. *Journal of Voice*, 2014, 28(1): 98-105.
- [11] Muderris T, Gokcan M K, Yorulmaz I. The clinical value of pharyngeal pH monitoring using a double-probe, triple-sensor catheter in patients with laryngopharyngeal reflux[J]. *Archives of Otolaryngology-Head & Neck Surgery*, 2009, 135(2): 163-167.
- [12] Dobhan R, Castell D O. Normal, and abnormal proximal esophageal acid exposure: results of ambulatory dual-probe pH monitoring[J]. *The American Journal of Gastroenterology*, 1993, 88(1): 25-29.
- [13] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//*IEEE Transactions on Pattern Analysis and Machine Intelligence*, June 7-12, 2015, New York: IEEE Press, 2015: 640-651.
- [14] Cui Y, Jia M L, Lin T Y, et al. Class-balanced loss based on an effective number of samples[C]//*2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 9260-9269.
- [15] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//*2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [16] Chang B A, MacNeil S D, Morrison M D, et al. The reliability of the reflux finding score among general otolaryngologists[J]. *Journal of Voice*, 2015, 29(5): 572-577.
- [17] 中华耳鼻咽喉头颈外科杂志编辑委员会咽喉组, 中华医学会耳鼻咽喉头颈外科学分会咽喉学组. 咽喉反流性疾病诊断与治疗专家共识(2015年)[J]. *中华耳鼻咽喉头颈外科杂志*, 2016, 51(5): 324-326. Chinese Journal of Otorhinolaryngology-Head and Neck Surgery Editorial Committee, grouppharyngology, otorhinolaryngology head and neck surgery branch, Chinese Medical Association. Experts' consensus on diagnosis and treatment of laryngopharyngeal reflux disease (2015)[J]. *Chinese Journal of Otorhinolaryngology-Head and Neck Surgery*, 2016, 51(5): 324-326.
- [18] 李进让, 肖水芳, 李湘平, 等. 咽喉反流性疾病诊断与治疗专家共识(2015年)解读[J]. *中华耳鼻咽喉头颈外科杂志*, 2016(5): 327-332. Li J R, Xiao S F, Li X P, et al. Explanation of the expert's consensus on diagnosis and treatment of laryngopharyngeal reflux disease (2015) [J]. *Chinese Journal of Otorhinolaryngology-Head and Neck Surgery*, 2016(5): 327-332.