

基于深度学习的多模态气管插管智能目标检测

徐天意¹, 夏明¹, 李峰², 常敏², 姜虹¹

(1. 上海交通大学医学院附属第九人民医院 麻醉科, 上海 200011;
2. 上海理工大学 医用光学技术与仪器教育部重点实验室, 上海 200093)

摘要: 针对困难气道气管插管过程中内窥镜图像视角较小、目标尺度变化大、相互遮挡等问题, 融合内窥镜图像和 CO₂ 浓度信息, 提出基于深度学习的多模态气管插管智能目标检测算法。首先, 对传统的 YOLOv3 网络进行改进, 利用不同扩张率的空洞卷积构建并行多分支空洞卷积模块, 并对输出特征进行上采样和张量拼接; 其次, 根据多路 CO₂ 浓度差异, 利用矢量化定位算法定位目标中心位置, 校正 YOLOv3 得到的边界框的中心坐标, 提升小目标检测的精度, 辅助气道位置的定位; 最后, 基于该算法, 研发了新型多模态气管插管辅助装置初代样机, 并在模拟气道中进行实验, 验证其可行性。在模拟气道中, 该新型辅助装置的操作时间中位数为 15.5 s, 操作成功率可达 97.3%。研究表明, 基于深度学习的多模态气管插管智能目标检测算法能够有效地辅助气管插管操作。

关键词: 深度学习; 多模态; 卷积神经网络; 目标检测

中图分类号: TP 391 **文献标志码:** A

Multimodal intelligent target detection for endotracheal intubation based on deep learning

XU Tianyi¹, XIA Ming¹, LI Feng², CHANG Min², JIANG Hong¹

(1. Department of Anesthesia, Shanghai Ninth People's Hospital, School of Medicine, Shanghai Jiaotong University, Shanghai 200011, China; 2. Key Laboratory of the Ministry of Education on Optical Technology and Instrument for Medicine, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: In order to solve the small angle of the endoscopic view, large changes of target scale and mutual occlusion during endotracheal intubation in difficult airways, a multi-modal intelligent target detection algorithm for endotracheal intubation based on deep learning was proposed with a combination of endoscopic images and carbon dioxide concentration information. First, the traditional YOLOv3 network was improved. It adopted parallel multi-branch dilated convolution block with different dilated rates to extract more information, and up-sampled the output features and concatenated these tensors. Second, the vector localization algorithm was applied to locate the center of the target

收稿日期: 2021-02-12

基金项目: 上海市科委生药支撑项目 (18441904600); 上海申康中心临床技能与临床创新三年行动计划 (SHDC2020 CR3043B)

第一作者: 徐天意 (1995-), 女, 硕士研究生。研究方向: 困难气道。E-mail: luvnty@163.com

通信作者: 姜虹 (1967-), 女, 教授。研究方向: 困难气道管理、麻醉相关新型化合物和材料、麻醉药物与认知功能障碍。E-mail: jianghongjiuyuan@163.com

according to the difference of multi-channel carbon dioxide concentration, so as to further correct the center position of the boundary box predicted by YOLOv3 network. It helped improve the accuracy of small target detection and assisted to locate airway. Finally, a prototype of the new multimodal endotracheal intubation assistant device was developed based on the proposed algorithm, and tested in a simulated airway to verify its feasibility. The effect of the prototype was satisfactory with a median operation time of 15.5 s and a success rate of 97.3%. The study shows that the multi-modal intelligent target detection algorithm for endotracheal intubation based on deep learning has good operation results and can effectively assist endotracheal intubation.

Keywords: *deep learning; multimodal; convolutional neural network; target detection*

气管内插管是麻醉医生对全麻状态下患者进行气道管理的重要手段，其在保持气道通畅、通气供氧、呼吸支持、维持氧合等方面起到了重要作用，而困难气道则是麻醉医生在气道管理时遇到的极具挑战性的一种临床情况。困难气道指接受常规训练的麻醉医师在面罩通气或气管插管时遇到困难的状况，常见原因如颅颌面畸形、外伤、瘢痕粘连等。在接受全身麻醉的患者中，困难气道的发生率约为 0.5%~10%^[1-2]。困难或者失败的气管插管会导致永久性脑损伤甚至死亡等不良结局^[3-4]。为此，临床上常采用纤支镜引导的清醒气管插管方式来最大程度地保障患者安全^[5]。

近年来，随着人工智能和深度学习的兴起和发展，许多研究人员将人工智能技术应用到医学图像检测领域，取得了显著成果。在气管插管装置方面，插管辅助设备也在向智能化和自动化方向发展。2012 年，Hemmerling 等^[6]研发了首个气管插管机器人——开普勒系统(KIS)，验证了远程操控气管插管的可行性。瑞士苏黎世大学的 Biro 等^[7]在 2020 年研发了基于喉部影像识别的自动化内窥镜下气管插管装置 (REALITI)，该装置具有实时图像识别和远端自动定位功能，操作者手动控制内窥镜弯曲和前进方向，当图像识别检测声门开口后，可切换到自动模式，使内窥镜前端自动向声门开口的几何中心点移动，直至进入气道。尽管气管插管技术取得了诸多的研究进展，但大多仍基于单一的内窥镜图像成像方式进行识别。在插管的过程中，内窥镜图像的视角相对较小，图像对比度、目标距离、目标大小等都会发生变化，不利于医生快速锁定目标。另外，痰液及气道分泌物遮挡气管口、食道口等目标，对视觉图像造成干扰。

在清醒插管时患者保留自主呼吸，上呼吸道的 CO₂ 浓度大约在 5% 左右^[8-9]。研究表明，呼气末 CO₂ (end tidal carbon dioxide, ET_{CO}₂) 的检测可指导保留自主呼吸、纤支镜引导下的气管插管过程^[10]。受此启发，针对困难气道下单一内窥镜图像进行气管插管导航的局限性，融合图像和 CO₂ 浓度信息，提出了基于深度学习的多模态气管插管智能目标检测算法，实现对气管口的快速实时检测。

1 基于深度学习的多模态气管插管智能目标检测算法

在气管插管过程中，依据内窥镜图像识别声门开口是确定气管导管方向和位置的重要步骤。深度学习具有强大的目标图像特征提取能力，可实现更精确的特征识别。利用深度学习的方法对内窥镜图像进行声门开口的检测，从而辅助气管插管。

在深度学习网络中，卷积神经网络通过卷积核提取图像的特征，其卷积核的大小决定了感受野的大小，不同感受野对不同尺度目标的检测效果也不尽相同。YOLOv3 是目前常用的目标检测算法，可以在不降低检测精确度的情况下，实现快速目标对象检测。传统 YOLOv3 骨干网络中采用固定大小的卷积核，其感受野的范围固定，无法有效地提取内窥镜图像中的信息。特别是在检测尺度变化较大的声门开口目标时，不可避免地会错检和漏检。为此，本文提出了一种基于空洞卷积和特征融合的 YOLOv3 网络。在此基础上，根据多路 CO₂ 浓度差异，利用矢量化定位算法确定目标中心，以进一步校正 YOLOv3 得到的目标位置，提升目标检测精度。

1.1 基于空洞卷积和特征融合的 YOLOv3 网络

基于空洞卷积和特征融合的 YOLOv3 网络，如 图 1 所示。首先，改进了 YOLOv3 骨干网络 Darknet53，设计权重共享并行多分支空洞卷积残差模块 (multi-branch dilated convolution block, MD-Block)，以提取更丰富的图像特征, 如 图 2 所示。该模块使用不同扩张率的空洞卷积核对不同尺度的目标特征信息进行提取，同时借助上采样和张

量拼接技术增加特征图的数量，提升检测小目标的精度。将原来的残差块用 3 个并行的残差块代替，并在每个残差块的首部和尾部增加 1×1 的卷积核来确保通道数不变。同时，采用 3 个不同扩张率的 3×3 的空洞卷积代替原来的 3×3 的普通卷积，并且这 3 个并行的残差块中空洞卷积的权重是共享的。本研究将骨干网络 Darnet53 中的残差块全部替换为所设计的权重共享的并行 MD-Block。




图 1 基于空洞卷积和特征融合的 YOLOv3 网络

Fig.1 YOLOv3 network based on dilated convolution and feature maps fusion

其次，为进一步检测更浅层的特征，在保持 YOLOv3 原来输出层的基础上，通过特征金字塔网络生成另外两个不同尺度的特征图。具体过程如下：对输出的 52×52 尺寸的特征图进行上采样，并与骨干网络中的浅层 104×104 的卷积层输出进行张量拼接，输出 104×104 尺寸的特征图。类似的，对输出的 104×104 大小的特征图进行上采样，与骨干网络中 208×208 大小的卷积层输出进行张量拼接，输出 208×208 尺寸的特征图。

1.2 多路 CO₂ 浓度信号定位算法

依据测量得到的四路 ETCO₂ 浓度差异，通过矢量化定位算法确定目标的中心位置。具体算法如下：根据四路 CO₂ 传感器的安装位置，通过对每个传感器进行位置标定，建立坐标系。根据所

建立的坐标系按照如下式子可以计算出目标中心点的坐标位置 (x₀, y₀)。

$$x_0 = \frac{(\boldsymbol{O}_1 - \boldsymbol{O}_3)\cos\theta_1 + (\boldsymbol{O}_4 - \boldsymbol{O}_2)\sin\theta_2}{\delta} \tag{1}$$

$$y_0 = \frac{(\boldsymbol{O}_1 - \boldsymbol{O}_3)\sin\theta_1 + (\boldsymbol{O}_4 - \boldsymbol{O}_2)\cos\theta_2}{\delta} \tag{2}$$

式中：O₁、O₂、O₃ 和 O₄ 分别为传感器 1、传感器 2、传感器 3 和传感器 4 测得的 CO₂ 浓度向量；θ₁ 为 O₁ 和 O₃ 与 x 轴的夹角，θ₂ 为 O₂ 和 O₄ 与 y 轴的夹角；δ 为归一化因子。

1.3 多模态定位算法的融合

建立图像坐标系和 ETCO₂ 矢量化定位坐标系的转化关系，将 ETCO₂ 矢量定位算法计算出的目标中心位置映射到图像坐标系中，进一步将其与




图 2 权重共享并行多分支空洞卷积残差模块

Fig.2 Weight-sharing parallel multi-branch dilated convolution block

改进的 YOLOv3 网络模型计算得到的边界框的中心坐标进行加权融合, 最终得到准确的目标中心坐标。

具体步骤是通过改进的 YOLOv3 网络先为每个边界框预测 4 个偏移量 t_x, t_y, t_w, t_h , 这 4 个变量分别表示预测的目标对象的中心坐标、目标预选框的宽度和高度。此外, 网络也会输出衡量预选框中存在目标对象的概率值和目标对象所属的类别。假设目标对象所在的栅格从图像的左上角作偏移, 利用如下计算公式, 得到网络在图像坐标下预测的目标边界框的中心坐标 (b_{ix}, b_{iy}) 信息。

$$b_{ix} = \sigma(t_x) + d_x \quad (3)$$

$$b_{iy} = \sigma(t_y) + d_y \quad (4)$$

式中: d_x, d_y 分别为偏移的长度和宽度; σ 为 sigmoid 函数。

进一步将网络预测的目标边界框的中心坐标与通过矢量化定位算法计算出的目标中心位置映射到图像坐标系后得到的坐标进行加权融合, 最终得到目标边界框的中心坐标为

$$b_x = \alpha b_{ix} + \beta b_{cx} \quad (5)$$

$$b_y = \alpha b_{iy} + \beta b_{cy} \quad (6)$$

$$b_w = p_w e^{t_w} \quad (7)$$

$$b_h = p_h e^{t_h} \quad (8)$$

式中: b_x, b_y, b_w, b_h 分别为最终计算出的目标边界框的中心坐标、宽度和高度; b_{cx}, b_{cy} 为通过 ETCO₂ 浓度矢量化定位算法计算出的目标中心映射到图像坐标系中的坐标; b_{ix}, b_{iy} 为网络在图像坐标下预测的目标边界框的中心坐标; p_w, p_h 分别为预测框的宽度和高度; α, β 分别为权重因子。

2 损失函数的设计

本文对网络预测的边界框的中心坐标、宽度和高度采用均方误差损失。同时, 在分类时将 Softmax 分类函数用多个 logistic 回归代替, 利用二值交叉熵函数来计算边界框分类损失及置信度损失。假定得到的特征图的大小为 $S \times S$, 每个网格产生 B 个锚框, 每个预选框经过网络最终得到 $S \times S \times B$ 个边界框, 最终的损失函数 L_l 包含检测框中心坐标误差损失 L_{md} 、检测框高度和宽度误差损失 L_{mg} 、置信度误差损失 L_{cf} 和分类误差损失 L_{cl} 。定义某一个预选框和真实框的交并比大于其他的预选框, 则采用这个预选框来检测当前的目标。

$$L_{\text{md}} = \lambda_c \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^0 \left[(x_i^j - \hat{x}_i^j)^2 + (y_i^j - \hat{y}_i^j)^2 \right] \quad (9)$$

$$L_{\text{mg}} = \lambda_c \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^0 \left[\left(\sqrt{w_i^j} - \sqrt{\hat{w}_i^j} \right)^2 + \left(\sqrt{h_i^j} - \sqrt{\hat{h}_i^j} \right)^2 \right] \quad (10)$$

$$L_{\text{cf}} = - \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^0 \left[\hat{C}_i^j \log(C_i^j) + (1 - \hat{C}_i^j) \log(1 - C_i^j) \right] - \lambda_n \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^n \left[\hat{C}_i^j \log(C_i^j) + (1 - \hat{C}_i^j) \log(1 - C_i^j) \right] \quad (11)$$

$$L_{\text{cl}} = - \sum_{i=0}^{S^2} I_{ij}^0 \sum_{c \in O} \left[\hat{P}_i^j \log(P_i^j) + (1 - \hat{P}_i^j) \log(1 - P_i^j) \right] \quad (12)$$

$$L_t = L_{\text{md}} + L_{\text{mg}} + L_{\text{cf}} + L_{\text{cl}} \quad (13)$$

式中: $x_i^j, y_i^j, w_i^j, h_i^j$ 分别为网络输出的边界框的中心坐标、宽度和高度; $\hat{x}_i^j, \hat{y}_i^j, \hat{w}_i^j, \hat{h}_i^j$ 分别为真实框的中心坐标、宽度和高度; λ_c, λ_n 为各项的超参数; I_{ij}^0 为第 i 个网络的第 j 个预选框是否负责检测当前的目标, 取值为 1 或者 0; I_{ij}^n 为第 i 个网络的第 j 个预选框不负责检测该目标; $\hat{C}_i^j$ 为第 i 个网络的第 j 个预选框中真实存在目标的置信度; C_i^j 为第 i 个网络的第 j 个预选框中经过检测存在目标的置信度; O 为所有待检测种类的集合; c 为当前检测的类别; $\hat{P}_i^j$ 表示第 i 个网络的第 j 个预选框真实存在类别为 c 对象的概率; P_i^j 表示通过检测第 i 个网络的第 j 个预选框存在类别为 c 对象的概率。

3 训练参数设定

在对改进的网络进行训练的过程中, 对训练参数进行了相应的配置, 具体为: batch 的大小设置为 4, subdivisions 设置为 8, 将采集到的 80 张图片平均分配到 8 组分别进行训练, 权值衰减设置为 0.0005, 动量设置为 0.9。在训练的后期, 设置学习衰减策略为 step, 学习率变动因子设置为 0.1, 使用随机梯度下降法 (stochastic gradient descent, SGD) 对网络的参数进行更新。

4 模拟气道训练验证

基于深度学习的多模态气管插管智能目标检

测算法, 上海交通大学医学院附属第九人民医院麻醉科与上海理工大学光电学院共同研发了多模态气管插管辅助装置的初代样机, 并在模拟气道中验证其可行性。

4.1 材料与设备

模拟气道训练使用的设备和材料主要包括:

a. 气管插管装置, 见图 3, 包括多模态气管插管辅助装置第一代样机和纤支镜; b. 模拟气道装置, 见图 4, 为高仿真气管插管模拟人一套(上海柏教, BZ-51); c. 其他材料包括石蜡油、颈托固定器、CO₂ 产生装置(内含 CO₂ 气瓶)、模拟肺和连接管道。



图 3 气管插管装置

Fig.3 Endotracheal intubation device



图 4 困难气道气管插管模型

Fig.4 Endotracheal intubation model in difficult airway

困难气道插管模型的构建是利用颈托固定器限制模拟人颈部活动度, 以模拟困难气道; 然后通过连接管道将模拟肺与 CO₂ 产生装置相连, 按压该装置上方的按钮可以释放 CO₂, 以模拟清醒插管状态下呼气末 CO₂ 从气道内逸出的状态。

4.2 研究内容

比较 14 名麻醉科住院医师使用新型多模态气

管插管辅助设备和传统纤支镜在困难气道模拟人中的应用效果。所有参与研究的志愿者均无相关设备的使用经验。

首先由一名指导老师对参与研究的 14 名志愿者进行培训, 包括气管插管的基础知识和多模态气管插管辅助装置、纤支镜的使用方式, 同时在模拟人上进行操作示范。然后每位志愿者在该模型上分别使用纤支镜和多模态气管插管辅助装置各完成 5 次经鼻气管插管的操作, 记录每次操作的时间。

具体操作方式如下: 石蜡油润滑纤支镜和多模态气管插管辅助装置前端, 将引导装置缓慢经鼻腔送入, 调节手柄上的旋转把手以控制引导装置前端镜头的上下弯曲, 旋转操作手柄调节引导装置的左右转动, 从而调节视野范围。当使用纤支镜时, 根据内窥镜下的视觉图像寻找声门位置。当使用多模态气管插管辅助装置时, 助手按压 CO₂ 产生装置模拟清醒状态下气道内 CO₂ 的呼出, 通过多模态算法定位, 确定气道的中心位置并同步在显示屏上, 根据屏幕箭头指示方向调节引导装置前端方向, 向声门口移动。如图 5 所示, 根据箭头所指示的方向判断声门位置在右上方, 则应向图像右上方调整镜头。当引导装置进入声门后继续向下推进直至气管隆突, 以此标志作为进入气道内的评判标准。




图 5 多模态气管插管辅助装置的指示图

Fig.5 Indication diagram of multimodal endotracheal intubation assistant device

4.3 观察指标

记录每位志愿者每次的操作时间和结果, 操作时间定义为引导装置从鼻腔到气管隆突的时间。若在 120 s 内将引导装置成功置入气道, 则定义为操作成功, 其余为操作失败。

4.4 实验结果

参与研究的 14 名志愿者共完成了 70 次多模态气管插管辅助装置和 70 次纤支镜的操作, 结果见表 1。

表 1 多模态气管插管辅助装置和纤支镜的操作情况
Tab.1 Operation assessment of multimodal endotracheal intubation assistant device and fiberoptic bronchoscopy

名称	操作数/次	操作时间/s	成功率/%	P
多模态气管插管辅助装置	70	15.5(13~19)	97.3%	0.569
纤支镜	70	15(12~20)	96.0%	1.000

在 70 次多模态气管插管辅助装置的操作中, 两名志愿者分别有 1 次操作未进入气道中, 其余操作均进入气道且操作时间小于 120 s。在所有使用多模态气管插管辅助装置的成功操作中, 操作时间中位数为 15.5 s(13.0~19.0 s), 最短时间为 8 s, 最长时间为 58 s, 操作成功率为 97.3%(95%CI: 90.7%~99.7%)。在 70 次纤支镜的使用中, 共有 3 次操作失败, 其余操作时间均小于 120 s, 操作时间中位数为 15 s(12.0~20.0 s), 操作时间的范围为 9~39 s, 操作成功率为 96.0%(95%CI: 88.8%~99.2%)。两种设备在操作时间(P=0.569)和操作成功率(P=1.000)上的差异均无明显统计学意义。

4.5 实验分析

困难气道气管插管模拟操作表明, 这两种设备在该模型中的操作时间(15.5 s 和 15 s)和操作成功率(97.3% 和 96.0%)之间的差异不显著。

对困难气道的管理一直是麻醉医师关注的问题, 根据 2013 年美国麻醉医师协会指南推荐^[11], 常见用于管理困难气道的技术包括清醒气管插管、盲探气管插管、纤支镜引导气管插管、声门上气道工具、光棒以及视频喉镜。对于术前预期的困难气道, 保持患者自主呼吸状态下纤支镜引导的气管插管是保障患者安全的有效方式。但是纤支镜内镜视角小, 易受痰液、血液等分泌物的遮挡, 以及在一些气道结构出现改变的困难气道中, 难以辨认气道方向^[12]。虽然目前有不少国内外研究致力于通过人工智能算法辅助气管插管, 但多数仍是基于视觉图像, 仍有部分限制。

在气管插管过程中, 当气管导管接近声门口时, ET-CO₂ 分压迅速达到 15 mmHg 以上, 波形也愈发明显, 这对确定气道方向具有一定的指导意

义,也是本研究的理论基础^[13]。利用多路 CO₂ 浓度差异,通过矢量化算法确定浓度中心位置。同时,通过改进的 YOLOv3 网络对小目标进行高精度的提取,将多模态的算法进行加权融合,最终确定气道中心。本研究以此为基础,完成了新型多模态气管插管辅助装置的研发。

同时,在模拟困难气道中的操作效果分析上,与传统的纤支镜相比,多模态气管插管辅助装置在操作时间和操作成功率上均无显著的统计学差异。相关在困难气道训练模型中的研究表明,纤支镜进行气管插管的时间约为 56~72 s,成功率 40%~85% 不等^[14-15]。Piepho 等^[16]在困难气道模型中的研究表明,使用纤支镜进行经鼻气管插管时,纤支镜暴露声门的时间大约 33 s,成功率可达 81%。不同研究结果的差异与不同气道模型以及对操作成功的不同定义相关。本研究中未置入气管导管,这是因为本研究的主要目的是比较多模态气管插管辅助装置和纤支镜在操作上的差异,而气管插管过程会影响操作时间,干扰对多模态气管插管辅助装置应用效果的评估^[7]。同时,气道的识别和定位为气管插管的关键步骤,对气管插管的成功有着重要意义。因此,本研究中仅把将引导装置正确置入气道作为结局。与先前研究相比,本研究中的操作时间和操作成功率都取得了较为满意的结果,可认为多模态气管插管辅助装置是纤支镜的一种可行的替代方法。

另外由于本研究为仅在气道模拟人上进行了初步验证,无法完全模拟痰液、血液等真实的临床情况,该新型气管插管辅助装置的优势无法完全得到体现。同时,在模拟气道中取得较满意的应用效果并不能完全推广至临床应用中。今后,研究团队将对该装置进行下一步的改进和完善,实现在临床操作中的运用和推广。

5 结 论

为改善目前气道插管过程中图像视角较小、目标尺度变化大、相互遮挡等不足,提出了一种基于深度学习的多模态气管插管智能目标检测算法,融合内窥镜的图像信息和 ETCO₂ 浓度信息,辅助气管口的检测。首先,改进了传统 YOLOv3 的 Darknet53 主干网络,构建权重共享的并行多分支空洞卷积残差模块,提高了网络获取图像特征的能力;其次,在保留 YOLOv3 原来的输出层的

基础上,利用特征图像金字塔生成另外两种不同尺度的特征图,并对特征图进行上采样和张量拼接,提升了对小尺寸目标的检测效果。同时,利用四路 ETCO₂ 浓度差异进行矢量化算法定位目标中心位置。最终,将其得到的目标信息与图像得到的目标信息进行融合,设计出多模态气管插管智能目标检测算法,并研发了多模态气管插管辅助装置。该辅助装置在模拟人上进行气管插管的辅助引导是可行的,具有比较满意的操作时间和成功率。本研究证实了基于深度学习的多模态气管插管智能目标检测算法能够有效辅助气管插管操作,为多模态气管插管辅助装置的进一步发展提供了基础。

参考文献:

- [1] EDELMAN D A, PERKINS E J, BREWSTER D J. Difficult airway management algorithms: a directed review[J]. *Anaesthesia*, 2019, 74(9): 1175–1185.
- [2] XU Z P, MA W H, HESTER D L, et al. Anticipated and unanticipated difficult airway management[J]. *Current Opinion in Anaesthesiology*, 2018, 31(1): 96–103.
- [3] JOUGON J, CANTINI O, DELCAMBRE F, et al. Esophageal perforation: life threatening complication of endotracheal intubation[J]. *European Journal of Cardio-Thoracic Surgery*, 2001, 20(1): 7–11.
- [4] JOFFE A M, AZIZ M F, POSNER K L, et al. Management of difficult tracheal intubation: a closed claims analysis[J]. *Anesthesiology*, 2019, 131(4): 818–829.
- [5] COLLINS S R, BLANK R S. Fiberoptic intubation: an overview and update[J]. *Respiratory Care*, 2014, 59(6): 865–880.
- [6] HEMMERLING T M, TADDEI R, WEHBE M, et al. First robotic tracheal intubations in humans using the Kepler intubation system[J]. *British Journal of Anaesthesia*, 2012, 108(6): 1011–1016.
- [7] BIRO P, HOFMANN P, GAGE D, et al. Automated tracheal intubation in an airway manikin using a robotic endoscope: a proof of concept study[J]. *Anaesthesia*, 2020, 75(7): 881–886.
- [8] GEORGE S C, HLASTALA M P. Airway gas exchange and exhaled biomarkers[J]. *Comprehensive Physiology*, 2011, 1(4): 1837–1859.
- [9] RAZA A, FARRELL T, O'HALLORAN K D, et al. The effects of breath-holds and Muller manoeuvres on upper airway carbon dioxide concentration in humans[J]. *Respiration*, 2007, 74(5): 533–536.