综述 DOI：10.13406/j.cnki.cyxb.003882

# 人工智能用于困难气道预测的研究进展

周桂林，邵建林
（昆明医科大学第一附属医院麻醉科，昆明　650000）

【摘　要】气道评估是气道管理的重要前提。困难气道（difficult airway，DA）是麻醉管理中的一大挑战，如果不能提前预测其发生，可能会导致插管失败和低氧血症等严重不良事件。术前准确评估和预测可能出现的DA至关重要。传统的评估系统依赖医生的经验来解释，灵敏度低，而且难以识别隐藏的解剖异常。人工智能（artificial intelligence，AI）依托强大的学习和数据分析能力，通过整合多模态数据，在机器学习（machine learning，ML）和深度学习（deep learning，DL）的基础上构建的DA预测模型，可以大大提高对气道异常解剖结构的识别效率和准确性，明显提升预测效率，从而制定针对性方案，实施有效管理，确保麻醉安全和质量。本文对近年来利用AI进行DA预测的研究进行了综述。

【关键词】气道评估；困难气道；预测模型；人工智能；深度学习；机器学习
【中图分类号】R614.1　　【文献标志码】A

## Research advances in artificial intelligence for difficult airway prediction

*Zhou Guilin*，*Shao Jianlin*
（*Department of Anesthesiology*，*The First Affiliated Hospital of Kunming Medical University*）

【**Abstract**】Airway assessment is an important prerequisite for airway management. Difficult airway（DA） is a major challenge in anesthesia management，and failure to predict DA in advance may lead to serious adverse events such as failed intubation and hypoxemia. Accurate assessment and prediction of possible DA before surgery is of vital importance. Traditional assessment systems rely on the experience of the physician experience for interpretation，with a low sensitivity and difficulties in identifying hidden anatomical abnormalities. Relying on powerful learning and data analysis capabilities，artificial intelligence（AI） establishes a predictive model for DA by integrating multimodal data on the basis of machine learning and deep learning，thereby improving the efficiency and accuracy of identifying abnormal anatomical structures in the airway，which helps to significantly improve prediction efficiency，develop a targeted regimen，implement effective management，and ensure the safety and quality of anesthesia. This article reviews the research on the application of AI in predicting DA in recent years.

【**Key words**】airway assessment；difficult airway；predictive model；artificial intelligence；deep learning；machine learning

气道管理是麻醉患者接受手术或诊断性操作时的必要环节，也是心肺复苏、重症监护等危及生命情况下的关键措施。气管插管的成功与否与患者的预后转归密切相关，对麻醉医师、急诊科医师及ICU医师来说，气道管理一直是最具挑战性的工作之一[1]。麻醉前精准快速地识别困难气道（difficult airway，DA）至关重要，提前制定好针对性预案及气道管理方案可有效避免因未识别的DA引发气道管理不良事件。传统的气道评估主要依靠体格检查，使用一些解剖和功能上的方法来评估气管内插管困难程度，以帮助提前预见DA，如：Mallampati分级、甲颏间距等[2]。但目前没有单一的检查可以100%的准确判断DA，即便经过精细化的术前气道评估，仍有部分DA病例难以被有效识别。

人工智能（artificial intelligence，AI）是指使用算法和模型使机器能够执行通常需要人类智能完成的任务[3]。它涵盖机器学习、自然语言处理、计算机视觉、推理决策等技术，能够处理复杂数据、识别模式、学习规律并作出预测或决策，旨在解决传统方法难以应对的复杂问题[4-5]。基于传统方法，开发了应用AI预测DA的技术，主要包括基于传统临床参数的机器学习模型、整合面部分析技术的方法以及基于解剖标志点定位与形态学分析等方法。这些方法主要获取与传统方法相同的参数，并通过开发的模型或算法进行分析。通过这种方式，分析能够以自动化且更快的速度进行，同时

作者介绍：周桂林，Email：Zlgl0926@163.com，
研究方向：围术期脑功能保护。
通信作者：邵建林，Email：shaojianlin@kmmu.edu.cn。
基金项目：国家自然科学基金地区科学基金资助项目（编号：82460252）；昆医联合专项-重点资助项目（编号：202201AY070001-037）。
优先出版：https://link.cnki.net/urlid/50.1046.R.20250611.1058.004（2025-06-11）

提高了预测的特异性和效能[6]。

## 1 DA的定义及评估

### 1.1 DA的定义

2013年美国麻醉医师协会将DA定义为受过常规培训的麻醉科医师遇到面罩通气困难，或气管插管困难，或两者兼有的临床状况[7]。多国麻醉学会指南均强调DA预测的重要性，并推荐清醒气管插管作为管理策略[8-9]。2008年至2009年NAP4项目显示，英国和爱尔兰地区麻醉中每2.2万例发生1例严重气道不良事件（共133例）、每18万例发生1例气道相关死亡（共16例），主要并发症包括死亡、脑损伤和紧急外科气道，且实际发生率或为统计值4倍以上。患者自身特征和医务人员判断失误是导致并发症的前两大因素[10]。未能预见DA可能会导致插管失败；如果同时存在通气困难，情况可能会演变成“无法通气、无法插管”的危急情况，进而引发缺氧缺血性脑损伤甚至死亡的风险。

### 1.2 DA评估的传统方法

气道管理是确保麻醉安全和质量的关键环节。文献显示，在手术室外进行气管插管时，DA的发生率约为11%~50%[11-13]。应尽可能在术前完成气道检查和评估，并评估与DA相关的任何体征。传统的床旁气道评估包括以下内容：张口度、Mallampati气道分级、甲颏间距和颈围等。

指示患者尽量张大嘴巴，测量上门牙到下门牙的距离。如果上门牙和下门牙之间的距离<3 cm（或2个横指），则表明插管可能比较困难[14]。1983年，Mallampati SR[15]描述了1种以舌头大小作为基本临床体征来预测困难气管插管分级的方法。随后，Samsoon GL和Young JR[16]提出了改良的Mallampati分级法，将其分为4个等级，也是目前麻醉科最常用的气道评估方法。具体分级如下，Ⅰ级：可见腭弓、悬雍垂和软腭；Ⅱ级：可见部分悬雍垂和软腭；Ⅲ级：可见软腭；Ⅳ级：仅可见硬腭。咽部结构的分级越高，表明喉镜观察越困难，Ⅲ~Ⅳ级提示存在DA。甲颏间距指患者头部最大限度后仰时，甲状软骨切迹上缘至下颌骨颏隆突之间的直线距离，该距离受许多解剖因素影响，成人正常值在6.5 cm以上。甲颏间距<6 cm或小于检查者三横指的宽度，提示下颌空间减小，可预测为插管困难[17]。病理性肥胖和体质指数（body mass index，BMI）≥ 30 kg/m$^2$的患者越来越多，虽然有些病理性肥胖患者的头颈部解剖结构正常，但有些患者的咽部组织增加，颈围增大，这些患者不仅可能面临气管插管困难的风险，还可能面临呼气囊及面罩通气困难[18]。颈围>17英寸（43 cm）与困难气管插管有一定关系[19]。

尽管以上这些检查指标还不能十分灵敏地检测困难插管，但这些指标阴性常常预示着气管插管相对容易。单一的气道检查灵敏度和阳性预测值较低，但结合多种评估方法可提高预测的准确性。

## 2 DA预测模型的构建

DA是麻醉管理中的一大挑战，其未能预见的发生可能导致插管失败、低氧血症甚至死亡[20]。尽管标准化的术前气道评估已成为麻醉科的标准操作程序，但临床数据显示，75%~93%的气管插管困难事件源于不可预见的DA，而传统的评估系统在识别解剖异常方面存在很大的局限性[21]。AI技术依托强大的数据挖掘和模式识别能力，可突破传统方法的灵敏度瓶颈，构建智能化DA预测模型，明显提高隐藏解剖变异（如颞下颌关节活动度异常、喉头抬高等）的筛查精度和效率[22]。表1总结了AI用于DA预测的方法。

### 2.1 基于传统临床参数的机器学习模型

传统的术前气道评估主要依靠医生的经验和解剖参数，但这些方法存在主观性强、灵敏度和特异性不足等问题，而且单一指标难以全面反映复杂的气道解剖特征[30]。近年来，机器学习（machine learning，ML）技术通过整合多维临床参数（如年龄、BMI、张口度、颈围等）构建综合预测模型，明显提高了DA的预测性能。

Kim JH等[23]开发并验证了一种困难喉镜检查的预测模型，采用颈部周径与甲颏高度作为困难喉镜检查的预测因子，采用5种算法[（logistic回归（logistic regression，LR）、多层

表1 AI用于DA预测的方法

| 参考文献 | 样本量（例） | 年龄（岁） | 验证方法 | 预测因子 | 使用算法 | 最优算法 | AUC/NME值 |
|---|---|---|---|---|---|---|---|
| [23] | 1 677 | 57（43，66） | 内部验证 | 颈周径、甲颏高度 | LR、MLP、RF、XGBoost和LightGBM | RF | AUC=0.790 |
| [24] | 622 | 43.1±14.1 | 内部验证 | 甲颏间距、颈部周径等24个预测因子 | LR、RF、KNN等7种算法 | KNN | AUC=0.870 |
| [25] | 970 | 53（17~92） | 内部验证 | 额位、侧位、张口和伸舌时面部特征 | DL | RF | AUC=0.810 |
| [26] | 202 | 63.9 ± 14.2 | 内部验证 | 不同体位的面部图像 | DL | CNN | AUC=0.864 |
| [21] | 10 727 | N/A | 外部验证 | 正面面部图像 | CNN | CNN | AUC=0.711 |
| [27] | 5849 | 38.7 ± 15.6 | 内部验证 | 7个面部解剖位点 | RF、SVM和CNN等7种算法 | CNN | AUC=0.779 |
| [28] | 17 103 | N/A | 外部验证 | 左眼、右眼、甲状腺切迹和胸骨上切迹等解剖标志点 | G2LCPS | G2LCPS | NME=3.588 |
| [29] | 623 | 62（50，71） | 内部验证 | 甲颏间距、颏胸间距等形态学特征 | LR、RF、XGBoost和SVM | XGBoost | AUC=0.766 |

注：N/A，表示数据未提供

感知机、随机森林（random forest，RF）、极限梯度提升机（extreme gradient boosting，XGBoost）和轻量梯度提升机（light gradient boosting machine，LightGBM）]进行训练，并通过测试集验证模型性能，其中RF模型表现最优，其受试者工作特征曲线下面积（area under the receiver operating characteristic curve，AUC）为0.790。该方法即使在气道评估受限患者中仍具适用性，具有很好的应用前景。Sezari P等[24]从32个传统临床参数中筛选出了24个预测因子，并使用7种不同的ML算法（LR、RF等）构建DA预测模型，并同步分析了甲颏间距、颈周径等12项解剖参数，其中K-最近邻（k-nearest neighbors，KNN）算法的表现最优（AUC=0.870），并且该模型可将困难插管漏诊率降低至5%以下。该研究还使用SMOTE技术以增强模型的检验效能，在使用SMOTE技术时，RF（AUC=0.760）能够产生与KNN算法（AUC=0.730）相同级别的准确性，因此建议采用“KNN初筛（敏感性92%）+RF复核（特异性89%）”的联合决策模式以提高预测的准确性，降低严重气道并发症的发生率。

基于传统临床参数的机器学习模型已显示出比传统评分系统更好的预测能力，但仍存在一些局限性，如：大多数研究的样本量较小。传统的ML模型虽然性能优异，但具有“黑箱特性”，阻碍了临床推广，如：临床医生很难理解颈围与指甲和下巴距离之间相互作用的权重分配逻辑。未来，通过跨学科合作和真实世界验证，有望突破数据规模、可解释性和多模态整合的瓶颈，实现从“辅助工具”到“临床决策核心”的转变，最终降低围术期气道相关并发症的风险。

### 2.2 基于面部图像的深度学习（deep learning，DL）方法

采集面部图像结合AI算法建立预测模型，进行DA的预测具有很高的精度，值得进一步探索。

Cuendet GL等[25]使用DL算法来训练和分析面部特征（例如额位、侧位、张口和伸舌）和困难气管插管的预测模型。该研究基于人脸识别技术建立了困难插管预警模型（AUC=0.81），提示结合AI的自动人脸扫描能更好地帮助判断DA。Hayasaka T等[26]使用16张不同身体位置的面部图像创建了一个评估模型，用于通过DL对困难气管插管进行分类。研究发现，对插管困难进行分类的最佳AI模型是在患者仰卧位闭口的情况下生成的（AUC=0.864）。Tavolara TE等[21]开发了1个DL模型，使用正面面部图像识别难以插管的患者。该研究使用了卷积神经网络（convolutional neural network，CNN）来训练采集到的名人面部图像数据，随后根据投票将图像数据简单分为易插管和难插管。虽然2项常规床边测试的AUC分别为0.604和0.466，但通过优化训练集数据，使用1组76例困难和76例易插管患者的数据进行训练，所提出的方法可将AUC提升至0.711。

面部图像可以通过简单、无创的方式收集，并进行自动、客观地分析，这为未来的数字化、智能化和远程气道评估提供了机会。然而，训练数据的质量、数量和特征直接决定了模型的性能、泛化能力和可靠性。因此，在使用面部图像数据进行机器学习时，应加强数据的有效性和准确性，以提高模型的预测功效。预计更多的大样本、多中心研究将阐明图像分析在DA评估中的价值。

### 2.3 基于解剖标志点定位与形态学分析

随着视频喉镜的引入，DA问题的发生率已有所下降，但可能使临床医师的警惕性降低[31]。既往基于面部特征构建的DA预测模型多来自直接喉镜检查的数据，这些基于直接喉镜的模型是否能应用于视频喉镜检查仍有待商榷。

Xia M等[27]构建了1个基于CNN的AI模型，通过整合基线特征、病史、床旁检查及7个面部解剖位点（正位、侧位、颏下位等）作为预测变量。采用残差网络进行图像特征提取，结合LR、RF及LightGBM等算法构建预测模型。发现AI面部特征解析技术可有效预测视频喉镜检查中的困难事件，基于DL的预测模型（AUC=0.779）较传统方法（AUC=0.736）展现出明显优势，为围术期气道精准管理提供了新型决策支持工具。然而，该研究也存在一定的局限性，虽然困难喉镜检查是DA最常见的情况之一，但并非所有视频喉镜检查困难的病例都会是DA[32]。传统DA评估依赖于面部和颈部特征，但颈部解剖标志点的检测尤为困难。Ren ZY等[28]提出了一种简单而有效的通用端到端半监督方法，即图到标签对比预测（graph-to-label contrastive prediction，G2LCPS），用于解剖标志点预测（如：左眼、右眼、甲状腺切迹和胸骨上切迹等）。该方法可明显提升解剖标志点定位的准确性，其归一化平均误差（normalized mean error，NME）为3.588，可筛选出颈部定位更精确的数据集，而以此数据集为基础构建的AI模型，其在以颈部解剖特征预测DA方面的准确性或许会得到明显提升。该研究创新性地提出全局-局部交叉伪监督策略，解决了小样本数据下的模型泛化问题。床旁气道评估的指标与气道形态学特征密切相关，如：甲颏间距、颏胸间距等[33]。近期1项基于形态学特征的ML用于困难气管插管预测的研究提出了4种定制化ML流程，结果发现4种基于形态学特征的ML流程表现出相似的区分能力：AUC中位数介于0.746~0.766，明显优于专家判断及所有先进方法（最高AUC为0.716）。其中最佳的方法为XGBoost算法，其在最优贝叶斯决策阈值下假阴性最少，经过校准，该模型可靠地预测了困难气管插管[29]。

在基于解剖标志点定位与形态学分析的DA预测模型构建中，面部图像数据的获取常面临质量缺陷问题。无论是公共数据库还是真实临床采集的数据，均普遍存在图像模糊、关键解剖标志点遮挡或结构不完整等情况。为确保模型训练的有效性，需对低质量数据进行严格筛选，但由此导致的数据集规模缩减可能明显降低样本多样性及临床代表性。数据多样性的不足将进一步制约模型的泛化能力，使其在复杂临床场景中的应用效能受限。

## 3 DA预测中的AI算法

AI算法体系庞大且多样化，主要可分为监督学习、无监督学习、强化学习、DL等核心类别，每种算法因其设计原理和应用场景不同而具备独特优势[34]。在医疗AI领域，模型构建的科学性与算法选择的合理性直接决定了预测效能与

临床应用价值。鉴于前文所述传统气道评估方法的局限性及AI技术在DA预测中的潜在优势，算法作为模型实现的核心技术载体，其原理特性、适用场景及性能差异将直接影响后续模型的构建逻辑与验证结果。为便于读者理解不同算法在特征处理、决策逻辑及优化目标上的差异，下文将详细介绍主要算法的原理与应用。

### 3.1 RF

RF是一种集成学习算法，通过从训练数据集中随机选择样本来构建一组决策树（decision tree，DT）模型，不同DT组的数据允许重复，构建多棵DT并结合其预测结果，降低单棵DT的过拟合风险，来提高模型的准确性[35]。

为了更准确地预测头皮水分含量，Mao HM等[36]设计了一种配备可穿戴和环境传感器的帽子形设备，该设备可收集头皮数据，结合移动水分计来收集不同条件下头皮水分的含量，头皮表面温度、核心体温、心跳等数据作为预测因子，使用了支持向量机（support vector machine，SVM）、RF等四种算法来构建机器学习模型，并对每个个人模型使用5倍交叉验证。其中，RF的平均绝对误差为3.29，均方根误差为3.97，在预测个体头皮水分含量方面表现更好。C统计量是评估模型分类性能的核心指标之一，其本质等同于AUC，其值越高表明该模型在区分不同类别（如：是否背痛）上的能力最优[37]。Yamanaka S等[38]采用急诊科接受气管插管的病例，开发了包括RF在内的7种机器学习模型预测DA的发生，并将这些模型与改良Lemon标准（Mallampati分级、颈部活动度等）的判别性能进行比较。发现通过RF构建的模型C统计量值（0.72）明显高于改良Lemon标准（0.62），且在7种机器学习模型中也处于较高水平。在急诊科临床场景中，基于RF算法构建的DA预测模型相较于传统评估方法展现出明显优势，可有效提升DA的预测准确性。

### 3.2 kNN

kNN算法是一种基于实例的监督学习算法，广泛应用于分类和回归任务，通过分析样本在特征空间中的邻近样本的类别或数值进行预测。在kNN中，可以使用欧几里得距离和曼哈顿距离等算法计算样本之间的距离。取k个邻居的目标值平均值作为预测值，距离按降序排序，并选择最接近当前点的k个点[39]。

近期1项研究评估了ML预测肝细胞癌生存率的能力，使用了如白蛋白、总胆红素等28项指标，并根据患者生存期长短及生存与否对数据进行了二元分类处理。随后，分别使用了加权KNN、立方KNN等几种不同的KNN模型进行训练，发现当k值为1且度量类型为欧氏距离时，可获得最佳结果（早期患者6个月生存期预测准确率为91%，进展期患者3年生存期预测准确率为92%）[40]。Sezari P等[24]的研究纳入了包括KNN在内的7种不同算法成功构建了DA预测模型，并全面评估不同方法的性能，其中KNN（AUC=0.87）凭借简单的距离度量在多项指标中领先。但需要注意KNN的局限性（如对高维数据和噪声敏感），本研究中特征筛选后的低维数据可能放大了其优势。

### 3.3 CNN

CNN是一种DL模型，专为处理具有网格结构的数据（如图像、音频频谱）设计。其核心组件包括卷积层、池化层和全连接层。

Chaves T等[41]采用了1个包含丰富真菌信息的数据库，并使用CNN进行训练和验证，从而获得了具有自主识别真菌物种的能力。之后，利用经过训练的CNN提供的图像识别功能，开发了1个能识别大型真菌物种的应用程序，可帮助公众识别、了解不同的真菌，并参与真菌知识的普及与传播。Cormack-Lehane（C-L）分级是在直接喉镜检查中用于评估声门暴露情况的一种分级系统，它对于判断喉镜操作的难易程度以及气道管理的风险具有重要意义。C-L 3级或4级视野代表着直接喉镜下声门暴露困难，属于DA的范畴[42]。Cho HY等[43]开发并测试一种基于CNN的DL模型，利用颈椎侧位X线片结果预测直接喉镜检查中声门的C-L分级为3级或4级视野。分析了5 939例甲状腺手术患者的颈椎侧位X线片，其中253例为C-L 3~4级视野，使用10组随机抽样数据集训练新模型。结果显示出很高的准确性，AUC达到0.965，该模型为麻醉前气道评估提供了高精度、低成本的影像智能工具，有望减少未预料DA导致的并发症风险。

### 3.4 XGBoost

XGBoost是一种基于DT的集成学习算法，XGBoost可被训练为基线模型，筛选出关键特征供DL模型训练，降低计算复杂度。近年来该算法因其计算速度快、泛化性好、预测性能高而越来越受欢迎[44]。

静脉血栓栓塞（venous thromboembolism，VTE）是危重患者的严重并发症，通常会导致死亡和长期残疾。为构建一个根据临床特征和实验室指标预测危重患者VTE发生的ML模型，Guan CF等[45]从1个公共数据库中提取数据，并使用逐步LR模型从VTE既往史、白蛋白等43个临床和生物学变量中筛选了24个变量作为预测终点。使用包括RF、XGBoost和SVM算法构建模型，为减少过度拟合，提高模型的稳健性，使用了五重交叉验证，最终比较不同模型对VTE预测的灵敏度和特异性。其中，XGBoost构建的模型具有最大的AUC（0.949）和灵敏度（0.781）。肥胖患者是DA的高危人群，Zhou CM等[46]利用公开数据库的回顾性二次分析研究，纳入了1 015例肥胖患者，数据集随机分为训练集（70%）和验证集（30%）。采用包括XGBoost、LR、RF等6种机器学习方法预测肥胖患者困难气管插管，其中XGBoost算法在测试组中兼具高精确率（100%）和较高的AUC（0.813），整体表现最佳。该研究为肥胖患者DA管理提供了基于ML的精准预测方案，未来可通过扩大样本与优化算法进一步提升临床实用性。

## 4 小结与展望

AI正在引领DA预测从传统的经验决策模式向数据智能驱动范式转型，其核心突破在于通过融合多源异构数据、解剖特征定量建模和动态风险概率计算，构建全维度风险评

估体系[47]。但AI算法目前也存在一定的弊端，其中“黑箱效应”导致决策过程不透明，难以通过人类可理解的逻辑追溯输入特征与输出结果的映射关系，在临床场景中难以得到医生和患者的信任。在之前对AI模型的研究中，主要关注点在预测性能上，相比于传统的预测方法，AI模型的预测性能也往往更出色，但“黑箱效应”制约了AI模型由理论研究向临床应用的发展[48]。如前所述，预测DA的模型若无法解释“舌骨周围影像特征”与“C-L分级”的关联，会使医生难以基于模型调整麻醉方案。即使是AUC达到了0.965，仍可能导致临床信任度降低[43]。AI在医疗领域的实用性突破，离不开透明化决策逻辑与医学领域知识的深度交融。唯有构建“开发者—医生—患者”协同参与的解释体系，让AI输出结果具备可追溯的逻辑链条，才能推动AI技术与临床实践的深度耦合，为医学进步注入新动能。

未来需要加强技术优化和创新，通过多模态联合建模，融合临床参数、图像、语音和动态生理信号，构建全息预测系统。例如，将术中实时呼吸波形与术前颈部超声特征相结合，加强动态风险评估。增强数据可解释性，使关键特征贡献可视化，增强临床医生的信任感。开发轻型设备，提高数据生成速度，支持术中动态决策。由于现有研究多为单中心研究，样本量较小。需要后续的多中心和大样本前瞻性研究来覆盖不同人群，并验证和加强模型的准确性。在ML和统计模型评估中，内部验证和外部验证是两种用于检验模型可靠性和泛化能力的重要方法，其核心区别在于验证数据与训练数据的关系[49]。内部验证确保模型在训练数据分布下无明显过拟合，性能达标。外部验证可防止模型因数据偏差在真实场景中失效，当前DA预测模型普遍仅通过内部验证，其跨临床环境的预测准确性存疑。未来研究需先通过内部验证证明算法合理性，再经多中心外部验证验证预测的准确性，以保障模型在不同医疗场景的可靠性。同时，在当前医工交叉研究的大背景下，跨学科合作尤为重要，可结合麻醉学、影像学和计算机科学团队，建立开放的气道图像和临床参数数据库，设计临床需求驱动的算法，促进算法迭代。

## 参 考 文 献


[1] Disma N, Asai T, Cools E, et al. Airway management in neonates and infants: European society of anaesthesiology and intensive care and British journal of anaesthesia joint guidelines[J]. Eur J Anaesthesiol, 2024, 41(1): 3-23.

[2] Marchis IF, Negrut MF, Blebea CM, et al. Trends in preoperative airway assessment[J]. Diagnostics(Basel), 2024, 14(6): 610.

[3] Theodosiou AA, Read RC. Artificial intelligence, machine learning and deep learning: Potential resources for the infection clinician[J]. J Infect, 2023, 87(4): 287-294.

[4] Rathore AS, Nikita S, Thakur G, et al. Artificial intelligence and machine learning applications in biopharmaceutical manufacturing[J]. Trends Biotechnol, 2023, 41(4): 497-510.

[5] Barat M, Gaillard M, Cottereau AS, et al. Artificial intelligence in adrenal imaging: a critical review of current applications[J]. Diagn Interv Imaging, 2023, 104(1): 37-42.

[6] Wu JZ, Yao Y, Zhang GC, et al. Difficult airway assessment based on multi-view metric learning[J]. Bioengineering(Basel), 2024, 11(7): 703.

[7] Law JA, Broemling N, Cooper RM, et al. The difficult airway with recommendations for management: part 1: difficult tracheal intubation encountered in an unconscious/induced patient[J]. Can J Anaesth, 2013, 60(11): 1089-1118.

[8] Frerk C, Mitchell VS, McNarry AF, et al. Difficult airway society 2015 guidelines for management of unanticipated difficult intubation in adults[J]. Br J Anaesth, 2015, 115(6): 827-848.

[9] Langeron O, Bourgain JL, Laccoureye O, et al. Difficult airway algorithms and management: question 5. société française d'Anesthésie et de réanimation[J]. Ann Fr Anesth Reanim, 2008, 27(1): 41-45.

[10] Cook TM, Woodall N, Frerk C, et al. Major complications of airway management in the UK: results of the fourth national audit project of the royal college of anaesthetists and the difficult airway society. part 1: anaesthesia[J]. Br J Anaesth, 2011, 106(5): 617-631.

[11] Griesdale DEG, Bosma TL, Kurth T, et al. Complications of endotracheal intubation in the critically ill[J]. Intensive Care Med, 2008, 34(10): 1835-1842.

[12] Jaber S, Amraoui J, Lefrant JY, et al. Clinical practice and risk factors for immediate complications of endotracheal intubation in the intensive care unit: a prospective, multiple-center study[J]. Crit Care Med, 2006, 34(9): 2355-2361.

[13] Schwartz DE, Matthay MA, Cohen NH. Death and other complications of emergency airway management in critically ill adults: a prospective investigation of 297 tracheal intubations[J]. Anesthesiology, 1995, 82(2): 367-376.

[14] Apfelbaum JL, Hagberg CA, Caplan RA, et al. Practice guidelines for management of the difficult airway: an updated report by the American Society of Anesthesiologists Task Force on Management of the Difficult Airway[J]. Anesthesiology, 2013, 118(2): 251-270.

[15] Mallampati SR. Clinical sign to predict difficult tracheal intubation (hypothesis)[J]. Can Anaesth Soc J, 1983, 30(3 Pt 1): 316-317.

[16] Samsoon GL, Young JR. Difficult tracheal intubation: a retrospective study[J]. Anaesthesia, 1987, 42(5): 487-490.

[17] Gadepalli C, Stepien KM, Tol G. Hyo-mental angle and distance: an important adjunct in airway assessment of adult mucopolysaccharidosis[J]. J Clin Med, 2021, 10(21): 4924.

[18] Kheirabadi D, Honarmand A, Rasouli MR, et al. Comparison of airway assessment tests for prediction of difficult intubation in obese patients: importance of thyromental height and upper lip bite test[J]. Minerva Anestesiol, 2022, 88(3): 114-120.

[19] Gonzalez H, Minville V, Delanoue K, et al. The importance of increased neck circumference to intubation difficulties in obese patients [J]. Anesth Analg, 2008, 106(4): 1132-1136.

[20] Liu YR, He YW, Wang X, et al. Advances in airway management in recent 10 years from 2013 to 2023[J]. Anesthesiol Perioper Sci, 2023, 1(4): 27.

[21] Tavolara TE, Gurcan MN, Segal S, et al. Identification of difficult to intubate patients from frontal face images using an ensemble of deep

learning models[J]. Comput Biol Med, 2021, 136: 104737.

[22] 赵美玉，王明亚，韩永正，等. 基于人工智能的气道管理优化策略与实践分析[J]. 重庆医科大学学报，2025，50(1)：1-5.
Zhao MY, Wang MY, Han YZ, et al. Optimization strategy and practice analysis of airway management based on artificial intelligence[J]. J Chongqing Med Univ, 2025, 50(1): 1-5.

[23] Kim JH, Kim H, Jang JS, et al. Development and validation of a difficult laryngoscopy prediction model using machine learning of neck circumference and thyromental height[J]. BMC Anesthesiol, 2021, 21(1): 125.

[24] Sezari P, Kohzadi Z, Dabbagh A, et al. Unravelling intubation challenges: a machine learning approach incorporating multiple predictive parameters[J]. BMC Anesthesiol, 2024, 24(1): 453.

[25] Cuendet GL, Schoettker P, Yüce A, et al. Facial image analysis for fully automatic prediction of difficult endotracheal intubation[J]. IEEE Trans Biomed Eng, 2016, 63(2): 328-339.

[26] Hayasaka T, Kawano K, Kurihara K, et al. Creation of an artificial intelligence model for intubation difficulty classification by deep learning (convolutional neural network) using face images: an observational study[J]. J Intensive Care, 2021, 9(1): 38.

[27] Xia M, Jin C, Zheng Y, et al. Deep learning-based facial analysis for predicting difficult videolaryngoscopy: a feasibility study[J]. Anaesthesia, 2024, 79(4): 399-409.

[28] Ren ZY, Dinh VS, Wong PM, et al. G2LCPS: End-to-end semi-supervised landmark prediction with global-to-local cross pseudo supervision for airway difficulty assessment[J]. Comput Biol Med, 2024, 183: 109246.

[29] García-García F, Lee DJ, Mendoza-Garcés FJ, et al. Reliable prediction of difficult airway for tracheal intubation from patient preoperative photographs by machine learning methods[J]. Comput Methods Programs Biomed, 2024, 248: 108118.

[30] Barclay-Steuart A, Großhennig HL, Sasu P, et al. Transnasal videoendoscopy for preoperative airway risk stratification: development and validation of a multivariable risk prediction model[J]. Anesth Analg, 2023, 136(6): 1164-1173.

[31] Meitzen SE, Benumof JL. Video laryngoscopy: positives, negatives, and defining the difficult intubation[J]. Anesth Analg, 2019, 128(3): 399-401.

[32] Apfelbaum JL, Hagberg CA, Connis RT, et al. 2022 American society of anesthesiologists practice guidelines for management of the difficult airway[J]. Anesthesiology, 2022, 136(1): 31-81.

[33] Roth D, Pace NL, Lee A, et al. Bedside tests for predicting difficult airways: an abridged Cochrane diagnostic test accuracy systematic review[J]. Anaesthesia, 2019, 74(7): 915-928.

[34] Howell MD, Corrado GS, DeSalvo KB. Three epochs of artificial intelligence in health care[J]. JAMA, 2024, 331(3): 242-244.

[35] Guo WJ, Liu J, Dong F, et al. Review of machine learning and deep learning models for toxicity prediction[J]. Exp Biol Med (Maywood), 2023, 248(21): 1952-1973.

[36] Mao HM, Tsuchida S, Terada T, et al. Estimating scalp moisture in a hat using wearable sensors[J]. Sensors (Basel), 2023, 23(10): 4965.

[37] Berg B, Gorosito MA, Fjeld O, et al. Machine learning models for predicting disability and pain following lumbar disc herniation surgery [J]. JAMA Netw Open, 2024, 7(2): e2355024.

[38] Yamanaka S, Goto T, Morikawa K, et al. Machine learning approaches for predicting difficult airway and first-pass success in the emergency department: multicenter prospective observational study[J]. Interact J Med Res, 2022, 11(1): e28366.

[39] Wei W, Li YX, Huang T. Using machine learning methods to study colorectal cancer tumor micro-environment and its biomarkers[J]. Int J Mol Sci, 2023, 24(13): 11133.

[40] Seven İ, Bayram D, Arslan H, et al. Predicting hepatocellular carcinoma survival with artificial intelligence[J]. Sci Rep, 2025, 15(1): 6226.

[41] Chaves T, Santos Xavier J, Gonçalves Dos Santos A, et al. Innovative infrastructure to access Brazilian fungal diversity using deep learning[J]. Peer J, 2024, 12: e17686.

[42] Hansel J, Rogers AM, Lewis SR, et al. Videolaryngoscopy versus direct laryngoscopy for adults undergoing tracheal intubation[J]. Cochrane Database Syst Rev, 2022, 4(4): CD011136.

[43] Cho HY, Lee K, Kong HJ, et al. Deep-learning model associating lateral cervical radiographic features with Cormack-Lehane grade 3 or 4 glottic view[J]. Anaesthesia, 2023, 78(1): 64-72.

[44] Fan ZY, Jiang JM, Xiao C, et al. Construction and validation of prognostic models in critically Ill patients with sepsis-associated acute kidney injury: interpretable machine learning approach[J]. J Transl Med, 2023, 21(1): 406.

[45] Guan CF, Ma FX, Chang SJ, et al. Interpretable machine learning models for predicting venous thromboembolism in the intensive care unit: an analysis based on data from 207 centers[J]. Crit Care, 2023, 27(1): 406.

[46] Zhou CM, Xue Q, Ye HT, et al. Constructing a prediction model for difficult intubation of obese patients based on machine learning[J]. J Clin Anesth, 2021, 72: 110278.

[47] Lonsdale H, Gray GM, Ahumada LM, et al. Machine vision and image analysis in anesthesia: narrative review and future prospects[J]. Anesth Analg, 2023, 137(4): 830-840.

[48] Marcus E, Teuwen J. Artificial intelligence and explanation: How, why, and when to explain black boxes[J]. Eur J Radiol, 2024, 173: 111393.

[49] Smith LA, Oakden-Rayner L, Bird A, et al. Machine learning and deep learning predictive models for long-term prognosis in patients with chronic obstructive pulmonary disease: a systematic review and meta-analysis[J]. Lancet Digit Health, 2023, 5(12): 872-881.

（收稿：2025-03-25；修回：2025-05-07；录用：2025-05-19）
（责任编辑：曾　玲）

本文引用格式：
周桂林，邵建林. 人工智能用于困难气道预测的研究进展[J]. 重庆医科大学学报，2025，50(10)：1379-1384.