

## 机器学习在麻醉学领域的应用前景

胡小义 王迪 纪木火 杨建军

**【摘要】** 机器学习(ML)技术已逐步被用于临床麻醉中,在围术期的应用及研究日益增多。ML在术前可以预警高危事件的发生,辅助困难气道的诊断以及超声显像;在术中可以预测低血压、低氧血症、心搏骤停以及麻醉深度等,帮助实现麻醉的精准和安全控制;在术后可以预测麻醉相关不良结局等。本文总结麻醉学领域常用的 ML 模型,回顾 ML 应用于围术期各个阶段的相关研究。ML 的应用可改善围术期麻醉管理,有助于预警高危事件的发生,降低麻醉相关风险。

**【关键词】** 机器学习;人工智能;围术期管理;疾病预测;麻醉学

**Application prospect of machine learning in field of anesthesiology** HU Xiaoyi, WANG Di, JI Muzhuo, YANG Jianjun. Department of Anesthesiology, the Second Affiliated Hospital of Nanjing Medical University, Nanjing 210000, China

Corresponding author: YANG Jianjun, Email: jianjunyang1971@163.com

**【Abstract】** Machine learning (ML) technology has been gradually applied in clinical anesthesia, and the application and research in the perioperative period are increasing. ML can warn occurrence of high-risk events, assist the diagnosis of difficult airway and ultrasound imaging in the perioperative period. Intraoperatively, ML can predict hypotension, hypoxemia, cardiac arrest, and depth of anesthesia to help achieve precise and safe control of anesthesia. Postoperatively, ML can predict anesthesia-related adverse outcomes. This article summarizes the ML models commonly used in the field of anesthesiology, and reviews the relevant studies of ML application in all stages of the perioperative period. The application of ML can improve the perioperative anesthesia management, help to warn the occurrence of high-risk events and reduce anesthesia-related risks.

**【Key words】** Machine learning; Artificial intelligence; Perioperative management; Disease prediction; Anesthesiology

人工智能(artificial intelligence, AI)正在以迅雷不及掩耳之势席卷全球,这很可能成为第4次工业革命的核心驱动力,彻底改变人们的生活。机器学习(machine learning, ML)是AI的主要技术手段,是从已有的数据中“总结”出一般性的规律,将其应用到未知样本上并进行预测的方法<sup>[1]</sup>。ML作为计算机科学和统计学的交叉领域,将高效的算法与数据结合,实现分类、预测及隐藏特征的挖掘<sup>[2]</sup>。科学预警、积极有效预防和快速正确诊断和处理是降低围术期危机事件的关键。在麻醉学领域中,由于电子监护仪的普遍使用,患者信息收集、存储和检索成本的不断降低,并产生海量的数据,这为ML在麻醉学领域的应用带来新机遇。本文对ML在麻醉

学领域中的研究现状、发展及存在的问题进行综述,以期今后的研究提供参考。

### ML 的分类和常见算法

ML在不同的标准下有不同的分类方式。根据学习方式的不同可以分为有监督学习、半监督学习和无监督学习。根据算法类型分类可以分为传统ML算法和深度学习算法。传统ML算法主要包括支持向量机、决策树和随机森林等,均基于严格数学推理,可解释性较强。深度学习算法均基于神经网络,主要包括卷积神经网络、循环神经网络和深度置信网络等。深度学习算法的特点在于隐藏层层数较深、可解释性较差,同时对数据量有一定的依赖。根据学习方式的不同进行分类是目前较为常见的分类方式,其有监督学习又可分为分类算法和回归算法两大类,无监督学习则可分为聚类算法和降维算法。在麻醉学领域中,分类算法是应用较多的算法,主要用于麻醉相关风险事件预测、术后

DOI: 10.12089/jca.2024.06.014

作者单位: 210000 南京医科大学第二附属医院麻醉科(胡小义、王迪、纪木火); 郑州大学第一附属医院麻醉与围术期医学部(杨建军)

通信作者: 杨建军, Email: jianjunyang1971@163.com

并发症等方面<sup>[3-4]</sup>。

### ML 在术前的应用

**困难气道** 气管插管失败是麻醉相关死亡和严重并发症的主要原因<sup>[5-6]</sup>。术前气道评估中, Mallampati 分级和甲颏距离主要用于评估气道的困难程度<sup>[7-8]</sup>。研究<sup>[9]</sup>表明, Mallampati 分级  $\geq 3$  级或甲颏距离  $\leq 3$  cm 预测困难气道的敏感性和特异性为 32% 和 85%。因此, 麻醉科医师需要更好的工具预测困难气道, 以减少与麻醉相关的并发症。Zhou 等<sup>[10]</sup>使用 ML 方法分析甲状腺手术患者插管困难的发生情况, 以性别、年龄、身高、体重和 BMI 进行建模, 梯度提升机模型 (gradient boosting) 在验证集中的受试者工作特征曲线下面积 (area under receiver operating characteristic curve, AUROC) 为 0.848, 其模型的准确度和精确度分别为 0.913、1.000。Tavolara 等<sup>[11]</sup>通过卷积神经网络提取 152 例患者面部冠状面图像特征, 然后构建了多示例学习模型, 其可在两种模式下运行: 一种是高敏感性和低特异性模式, 其敏感性为 0.908, 特异性为 0.447; 另一种是低敏感性和高特异性模式, 其敏感性为 0.368, 特异性为 0.961。

**神经阻滞** 超声成像没有侵入性, 并且提供了神经及其周围结构的准确位置。因此, 超声引导下的神经阻滞技术作为麻醉科医师的一项基本操作, 应得到广泛推广。但是, 在各种组织以及伪影等的干扰下, 超声可视化下神经图像的识别及穿刺操作的协调是最难学习的环节。Hatt 等<sup>[12]</sup>使用自适应增强算法来训练神经阻滞针的图像分割模型, 然后利用拉东变换 (Radon transform) 从分割后的图像中找到神经阻滞针的位置和方向。在临床数据中, 针头定位成功率为 99.8%。Gil González 等<sup>[13]</sup>将 ML 算法应用于超声图像中神经结构的自动分割, 该方法通过使用图形分割自动确定一个感兴趣的区域, 实现了神经结构的自动化识别, 准确性  $>95\%$ 。

### ML 在术中的应用

**低血压** 低血压是围术期主要风险事件<sup>[14]</sup>。术中低血压是术后不良结局的独立危险因素, 长期的低血压可能导致术后脑梗死、肾功能受损, 延长患者住院时间<sup>[15]</sup>。Kendale 等<sup>[16]</sup>采用 ML 方法分析患者麻醉诱导后低血压 (MAP  $<55$  mmHg) 的发生情况, 以年龄、BMI、ASA 分级、术前合并症、用药情况、术中生命体征等临床特征进行建模, 该研究将数据

随机分为训练集和验证集 (7:3) 进行模型训练和验证, 梯度提升机模型在验证集中的 AUROC 为 0.740 (95% CI 0.720 ~ 0.770), ML 算法可成功预测麻醉诱导后低血压的发生。然而, 梯度提升机模型在外部数据中的有效性尚不明确, 该模型是否可在临床上广泛使用仍不得而知。Choe 等<sup>[17]</sup>研究使用 18 813 例接受非心脏手术患者动脉波形作为输入的深度学习算法进行建模, 卷积神经网络和循环神经网络算法构建模型的精度-召回率曲线下面积分别为 0.698 (95% CI 0.690 ~ 0.705) 和 0.706 (95% CI 0.698 ~ 0.715), 其表现优于逻辑回归算法 0.673 (95% CI 0.665 ~ 0.682)。该研究开发的预测短期术中低血压的模型较卷积神经网络和循环神经网络算法表现更好 (AUC = 0.716, 95% CI 0.708 ~ 0.723)。

**低氧血症** 低氧血症可对患者造成严重伤害, 如心律失常、脑缺血甚至心搏骤停等并发症<sup>[18]</sup>。若能精准预测低氧血症, 则麻醉科医师可及时采取措施预防低氧血症, 从而将对患者的伤害降到最低。Lundberg 等<sup>[19]</sup>根据电子病历系统中麻醉数据构建 ML 系统, 预测麻醉中低氧血症的发生, 并探究全身麻醉期间低氧血症的危险因素, 结果表明患者 BMI、术前潮气量和脉搏是预测患者术中低氧血症的重要指标。若麻醉科医师可预测 15% 的低氧血症事件, 在 ML 系统的辅助下则可提高至 30%。ML 可通过分析预测风险, 实时发出警告, 优化麻醉操作。Xia 等<sup>[20]</sup>分析了 14 777 例患者的临床资料并构建基于 ML 的拔管后低氧血症的预测模型, 结果表明随机森林模型表现最好, 其 AUROC 为 0.792 (95% CI 0.771 ~ 0.814)。

**心搏骤停** 围术期心搏骤停 (perioperative cardiac arrest, POCA) 是一种罕见但极其危险的事件, 麻醉相关 POCA 的发病率为 0.000 4% ~ 0.08%, 死亡率为 20% ~ 60%<sup>[21]</sup>。准确预测 POCA 患者生存率并及时做出正确的决策对麻醉科医师提出了巨大的挑战。Shang 等<sup>[22]</sup>利用 5 种传统 ML 算法分析 150 例 POCA 患者的生存情况, 将 5 种传统 ML 算法集合后建立了集成 ML 模型, 其 AUROC 为 0.900 (95% CI 0.780 ~ 0.980)。

**麻醉深度** 麻醉过浅导致术中知晓会对患者造成心理阴影, 而麻醉过深可能会导致苏醒延迟或谵妄等并发症从而延长住院时间。准确、可靠的麻醉深度监测是临床亟需解决的问题。Ramaswamy 等<sup>[23]</sup>使用弹性网络从脑电图中提取特征, 然后进行

逻辑回归分析。在使用丙泊酚、七氟醚和右美托咪定进行镇静的患者中,其模型 AUROC 分别为 0.970 (95% CI 0.940 ~ 1.000)、0.740 (95% CI 0.500 ~ 0.990)、0.770 (95% CI 0.670 ~ 0.870)。Saadeh 等<sup>[24]</sup>从脑电图中提取了 6 个特征(频谱边缘频率、beta 比值和四个频谱能量波段)构建决策树模型,准确预测了四类麻醉深度的分类(深、中、浅麻醉状态与清醒状态)。Gu 等<sup>[25]</sup>通过人工神经网络提取脑电图中的频域和熵等特征评估麻醉深度,其可以很好地区分清醒状态和麻醉状态,而且与 BIS 的相关性较好。

### ML 在术后的应用

术后并发症 尽管逻辑回归和比例风险回归模型等对麻醉相关不良事件具有一定的预测能力,但其准确性和实用性有限<sup>[26]</sup>。ML 技术可结合时间序列数据并从中提取患者的数据特征,动态预测患者麻醉相关不良结局<sup>[27]</sup>。Xue 等<sup>[28]</sup>分析了 111 888 例手术患者的数据并构建了基于 ML 的术后并发症预测模型,使用逻辑回归、支持向量机、随机森林、梯度提升树和深度神经网络等算法,不同并发症的最佳表现模型分别是:肺炎模型 AUROC 为 0.905 (95% CI 0.903 ~ 0.907)、急性肾损伤 0.848 (95% CI 0.846 ~ 0.851)、深静脉血栓 0.881 (95% CI 0.878 ~ 0.884)、术后谵妄 0.762 (95% CI 0.759 ~ 0.765) 及肺栓塞 0.831 (95% CI 0.824 ~ 0.839)。

尽管目前麻醉相关的死亡率显著降低,但仍有 0.5%~3% 的择期手术患者在术后 30 d 内死亡<sup>[29]</sup>。急诊腹部手术后患者的生存率更差,其 30 d 死亡率为 4%~8%<sup>[30]</sup>。早期识别风险因素可以更好降低术后死亡率<sup>[31-32]</sup>。Fritz 等<sup>[33]</sup>采用卷积神经网络预测术后 30 d 的死亡率,结果表明 AUROC 为 0.867 (95% CI 0.835 ~ 0.899),其优于深度神经网络 0.825 (95% CI 0.790 ~ 0.860)、随机森林 0.848 (95% CI 0.815 ~ 0.882)、支持向量机 0.836 (95% CI 0.802 ~ 0.870) 和逻辑回归 0.837 (95% CI 0.803 ~ 0.871)。

### ChatGPT

ChatGPT 即“聊天生成预训练转换器”,它是由美国开放人工智能研究中心 (OpenAI) 研发的大型语言模型。以往医疗领域的 ML 模型大多只能处理单一模态数据,随着 ML 技术的不断更新,逐渐出现多模态数据的研究。临床研究者们逐渐将研究视

线转移到医学图片的研究中,然后又将数字数据和图片数据结合进行多模态数据的分析研究。ChatGPT 即应用深度学习将海量、多类型数据进行训练生成的模型。ChatGPT 将在医疗教育、研究和实践中被广泛应用,其合理的使用有可能加速医疗领域的创新,并且可通过克服语言障碍促进研究的多样性开展<sup>[34]</sup>。ChatGPT 训练的目标是通用认知能力的实现。因此,ChatGPT 并未专门针对医疗或医学领域应用进行训练,在麻醉学领域相关研究尚未有报道。目前 ChatGPT 展现出来的能力仅仅是采用互联网上公开数据进行训练的结果。ChatGPT 在撰写医疗记录、提供医疗咨询、诊断和教育的各种任务中都表现出较为不俗的能力。ChatGPT 还可阅读医学研究资料,并参与相关讨论,如简要总结内容、提供技术分析、确定相关前期工作、评估结论以及提出可能的后续研究问题。同样,在其他相关医疗领域皆证实了 ChatGPT 在临床决策和优化临床工作流程等方面拥有巨大的潜力<sup>[35-36]</sup>。

ChatGPT 也可能会发生错误,但也可以发现错误,且既可以发现 AI 的错误,也可以发现人类的错误。既往应用的 AI 是基于特定范围内的模型,并针对特定临床任务进行调整,此类模型受益于精确定义的使用范围。那么应如何评估 ChatGPT 的通用认知能力? 用户可以在多大程度上“信任” ChatGPT? 用户是否需要花费更多时间确认其所写内容的真实性? 除校对外,还需要做多少核查工作? ChatGPT 可以在多大程度上协助完成这项任务? 上述问题无疑将成为争论的话题。相信在不久的将来,AI 将会在麻醉学领域掀起一场史无前例的“革命”浪潮。

### ML 在麻醉学领域的不足

ML 可以集合多种类型、不同观测方法获得的数据指标,兼顾多种影响因素,减少主观误差,提高预测和诊断疾病方面的全面性、客观性和准确性。ML 模型的建立一方面可以通过大范围筛查,快速发现高风险疾病患者,尽早引起医务人员和其他相关人员的警觉;另一方面还可通过减少实验室、影像学检查等项目有效压缩诊断时间,从而降低治疗的等待时间。虽然 ML 在麻醉领域的相关研究已取得较大进展,但仍存在不足(图 1):(1)若未找到科学的临床问题,那么一味使用 ML 进行研究并非有益。如果不能梳理出混杂因素,确保数据正确,并理解观察结局和数据收集背后的临床问题,那么

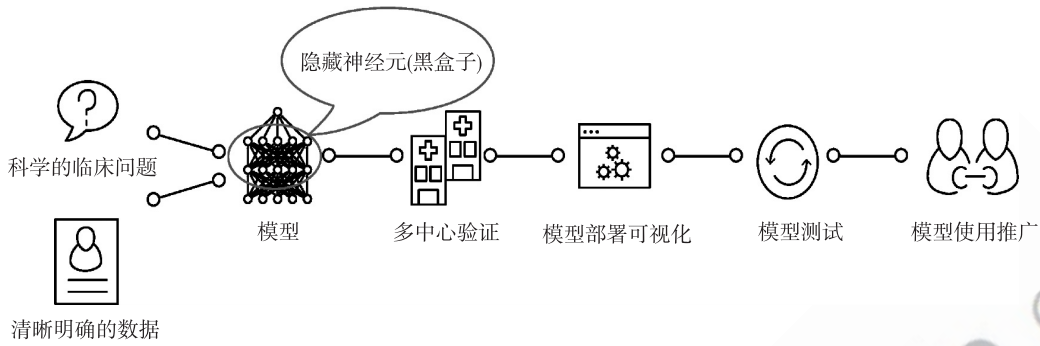


图 1 ML 构建模型的一般过程与难点

所得出的结论可能会产生误导性。(2)若存在高可变性、数据有限、数据质量差、患者群体代表性不足或错误的试验设计,可导致系统性偏倚。(3)现有 ML 分类指标形式多样,内容繁杂,缺少清晰明确的分类依据以及系统化和规则化的应用效果分析。(4)基于多模态的分类模型,在融合多元信息过程中混杂了更多与预测和诊断关联程度不高的信息,随着无关变量数量的增加,噪声体积变大,导致 ML 算法的预测性能降低,对预测和诊断疾病准确性有一定干扰<sup>[37-38]</sup>。(5)现有研究仍停留在模型构建的理论阶段,模型应用到实践中还需要慎重思考以下几个问题:一是研究样本对总体的代表性,二是模型的适用性和泛化性,三是算法的准确性和稳定性有待改善,四是模型可解释性不足,五是麻醉领域模型的认可度仍需提高。ML 模型能否得到真实有效的数据,预先设定的训练数据是否能完全覆盖使用对象,评估结果如何解释,评估结果如何应用于后续治疗,这些也是后续应该关注的问题。

虽然 ML 尚有诸多不足之处,但需坚信 AI/ML 在临床试验操作和临床试验数据分析方面具有变革性的影响。因此,就像过去的许多其他技术工具一样,ML 可以极大地改变我们的研究方式。在不久的将来,AI 衍生的应用很可能会帮助麻醉科医师腾出更多的时间来进行医学研究。

### 小 结

ML 在麻醉相关不良结局预测、麻醉深度监测以及术后并发症预测等方面展现出巨大潜力,ML 技术的发展和普及有望在麻醉管理中发挥重要作用。然而,ML 在麻醉领域的应用还存在诸多挑战。研究样本的代表性、模型的适用性和泛化性、算法的准确性和稳定性、模型的可解释性以及麻醉领域的认可度等方面仍需进一步优化和提升。随着

ML 技术的不断进步,越来越多的 ML 技术将可能应用于麻醉管理,有利于患者的病情评估和精准麻醉的实施,最终改善患者的临床预后。

### 参 考 文 献

- [1] Deo RC. Machine learning in medicine. *Circulation*, 2015, 132(20): 1920-1930.
- [2] Lee S, Mohr NM, Street WN, et al. Machine learning in relation to emergency medicine clinical and operational scenarios: an overview. *West J Emerg Med*, 2019, 20(2): 219-227.
- [3] Racine AM, Tommet D, D'Aquila ML, et al. Machine learning to develop and internally validate a predictive model for post-operative delirium in a prospective, observational clinical cohort study of older surgical patients. *J Gen Intern Med*, 2021, 36(2): 265-273.
- [4] Tseng PY, Chen YT, Wang CH, et al. Prediction of the development of acute kidney injury following cardiac surgery by machine learning. *Crit Care*, 2020, 24(1): 478.
- [5] Detsky ME, Jivraj N, Adhikari NK, et al. Will this patient be difficult to intubate? The rational clinical examination systematic review. *JAMA*, 2019, 321(5): 493-503.
- [6] Connor CW, Segal S. Accurate classification of difficult intubation by computerized facial analysis. *Anesth Analg*, 2011, 112(1): 84-93.
- [7] Roth D, Pace NL, Lee A, et al. Airway physical examination tests for detection of difficult airway management in apparently normal adult patients. *Cochrane Database Syst Rev*, 2018, 5(5): CD008874.
- [8] Shobha D, Adiga M, Rani DD, et al. Comparison of upper lip bite test and ratio of height to thyromental distance with other airway assessment tests for predicting difficult endotracheal intubation. *Anesth Essays Res*, 2018, 12(1): 124-129.
- [9] Connor CW, Segal S. The importance of subjective facial appearance on the ability of anesthesiologists to predict difficult intubation. *Anesth Analg*, 2014, 118(2): 419-427.
- [10] Zhou CM, Wang Y, Xue Q, et al. Predicting difficult airway intubation in thyroid surgery using multiple machine learning and deep learning algorithms. *Front Public Health*, 2022, 10: 937471.

- [11] 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. *Comput Biol Med*, 2021, 136: 104737.
- [12] Hatt CR, Ng G, Parthasarathy V. Enhanced needle localization in ultrasound using beam steering and learning-based segmentation. *Comput Med Imaging Graph*, 2015, 41: 46-54.
- [13] Gil González J, Álvarez MA, Orozco AA. Automatic segmentation of nerve structures in ultrasound images using graph cuts and gaussian processes. *Annu Int Conf IEEE Eng Med Biol Soc*, 2015, 2015: 3089-3092.
- [14] Monk TG, Bronsert MR, Henderson WG, et al. Association between intraoperative hypotension and hypertension and 30-day postoperative mortality in noncardiac surgery. *Anesthesiology*, 2015, 123(2): 307-319.
- [15] Krzych IJ, Pluta MP, Putowski Z, et al. Investigating association between intraoperative hypotension and postoperative neurocognitive disorders in non-cardiac surgery: a comprehensive review. *J Clin Med*, 2020, 9(10): 3183.
- [16] Kendale S, Kulkarni P, Rosenberg AD, et al. Supervised machine-learning predictive analytics for prediction of postinduction hypotension. *Anesthesiology*, 2018, 129(4): 675-688.
- [17] Choe S, Park E, Shin W, et al. Short-term event prediction in the operating room (STEP-OP) of five-minute intraoperative hypotension using hybrid deep learning; retrospective observational study and model development. *JMIR Med Inform*, 2021, 9(9): e31311.
- [18] Strachan L, Noble DW. Hypoxia and surgical patients--prevention and treatment of an unnecessary cause of morbidity and mortality. *J R Coll Surg Edinb*, 2001, 46(5): 297-302.
- [19] Lundberg SM, Nair B, Vavilala MS, et al. Explainable machine-learning predictions for the prevention of hypoxaemia during surgery. *Nat Biomed Eng*, 2018, 2(10): 749-760.
- [20] Xia M, Jin C, Cao S, et al. Development and validation of a machine-learning model for prediction of hypoxemia after extubation in intensive care units. *Ann Transl Med*, 2022, 10(10): 577.
- [21] Nunnally ME, O'Connor MF, Kordylewski H, et al. The incidence and risk factors for perioperative cardiac arrest observed in the national anesthesia clinical outcomes registry. *Anesth Analg*, 2015, 120(2): 364-370.
- [22] Shang H, Chu Q, Ji M, et al. A retrospective study of mortality for perioperative cardiac arrests toward a personalized treatment. *Sci Rep*, 2022, 12(1): 13709.
- [23] Ramaswamy SM, Kuizenga MH, Weerink M, et al. Novel drug-independent sedation level estimation based on machine learning of quantitative frontal electroencephalogram features in healthy volunteers. *Br J Anaesth*, 2019, 123(4): 479-487.
- [24] Saadeh W, Khan FH, Altaf M. Design and implementation of a machine learning based EEG processor for accurate estimation of depth of anesthesia. *IEEE Trans Biomed Circuits Syst*, 2019, 13(4): 658-669.
- [25] Gu Y, Liang Z, Hagihira S. Use of multiple EEG features and artificial neural network to monitor the depth of anesthesia. *Sensors (Basel)*, 2019, 19(11): 2499.
- [26] Del Toro MD, Peñas C, Conde-Albarraín A, et al. Development and validation of baseline, perioperative and at-discharge predictive models for postsurgical prosthetic joint infection. *Clin Microbiol Infect*, 2019, 25(2): 196-202.
- [27] Fritz BA, Chen Y, Murray-Torres TM, et al. Using machine learning techniques to develop forecasting algorithms for postoperative complications: protocol for a retrospective study. *BMJ Open*, 2018, 8(4): e020124.
- [28] Xue B, Li D, Lu C, et al. Use of machine learning to develop and evaluate models using preoperative and intraoperative data to identify risks of postoperative complications. *JAMA Netw Open*, 2021, 4(3): e212240.
- [29] International Surgical Outcomes Study group. Global patient outcomes after elective surgery: prospective cohort study in 27 low-, middle-and high-income countries. *Br J Anaesth*, 2016, 117(5): 601-609.
- [30] GlobalSurg Collaborative. Mortality of emergency abdominal surgery in high-, middle-and low-income countries. *Br J Surg*, 2016, 103(8): 971-988.
- [31] Moonesinghe SR, Mythen MG, Das P, et al. Risk stratification tools for predicting morbidity and mortality in adult patients undergoing major surgery: qualitative systematic review. *Anesthesiology*, 2013, 119(4): 959-981.
- [32] Bilimoria KY, Liu Y, Paruch JL, et al. Development and evaluation of the universal ACS NSQIP surgical risk calculator: a decision aid and informed consent tool for patients and surgeons. *J Am Coll Surg*, 2013, 217(5): 833-842.
- [33] Fritz BA, Cui Z, Zhang M, et al. Deep-learning model for predicting 30-day postoperative mortality. *Br J Anaesth*, 2019, 123(5): 688-695.
- [34] Sallam M. ChatGPT utility in healthcare education, research, and practice: systematic review on the promising perspectives and valid concerns. *Healthcare (Basel)*, 2023, 11(6): 887.
- [35] Ollivier M, Pareek A, Dahmen J, et al. A deeper dive into ChatGPT: history, use and future perspectives for orthopaedic research. *Knee Surg Sports Traumatol Arthrosc*, 2023, 31(4): 1190-1192.
- [36] Ismail A, Ghorashi NS, Javan R. New horizons: the potential role of OpenAI's ChatGPT in clinical radiology. *J Am Coll Radiol*, 2023, 20(7): 696-698.
- [37] Kolluri S, Lin J, Liu R, et al. Machine learning and artificial intelligence in pharmaceutical research and development: a review. *AAPS J*, 2022, 24(1): 19.
- [38] Adali T, Levin-Schwartz Y, Calhoun VD. Multi-modal data fusion using source separation: two effective models based on ICA and IVA and their properties. *Proc IEEE Inst Electr Electron Eng*, 2015, 103(9): 1478-1493.