

• 综 述 •

# 急性冠脉综合征不良心血管事件机器学习预测模型的研究进展\*

周仟慧 综述, 古满平<sup>△</sup> 审校

(重庆医科大学附属第一医院护理部, 重庆 400010)

**[摘要]** 急性冠状动脉(冠脉)综合征患者并发不良心血管事件会严重影响其预后。近年来,人工智能和大数据在医学领域的发展为该类人群的风险预测提供了新思路,目前,已有多种机器学习预测模型用于预测急性冠脉综合征患者的各类不良心血管事件。该文对机器学习预测模型的研究与应用现状进行了综述,并分析了模型的构建方法、数据来源和特点、模型验证方法和危险因素,为患者风险评估、早期预防与预后评估提供参考依据。

**[关键词]** 急性冠状动脉综合征; 机器学习; 主要不良心血管事件; 预测模型; 综述

DOI:10.3969/j.issn.1009-5519.2024.17.031 中图法分类号:R543.3+1

文章编号:1009-5519(2024)17-3023-05 文献标识码:A

## Research progress of machine learning prediction model for unintentional vascular events in acute coronary syndrome\*

ZHOU Qianhui, GU Manping<sup>△</sup>

(Department of Nursing, the First Affiliated Hospital of Chongqing Medical University, Chongqing 400010, China)

**[Abstract]** The adverse cardiovascular events in patients with acute coronary syndrome can seriously affect the prognosis. In recent years, the development of artificial intelligence and big data in the medical fields has provided new ideas for the risk prediction of such people. At present, a variety of machine learning prediction models have been used to predict various adverse cardiovascular events in patients with acute coronary syndrome. This article reviewed the research and application status of these machine learning prediction models, and reviewed the model construction methods, data sources and characteristics, model validation and risk factors, so as to provide references for patient risk assessment, early prevention and prognosis assessment.

**[Key words]** Acute coronary syndrome; Machine learning; Major adverse cardiovascular events; Risk prediction model; Review

急性冠状动脉(冠脉)综合征(ACS)是一种临床常见的心血管急危重症,包括 ST 段抬高型心肌梗死、非 ST 段抬高型心肌梗死和不稳定型心绞痛 3 种类型<sup>[1]</sup>。欧洲每年约有 180 万人死于冠心病<sup>[2]</sup>;而 ACS 是最危险和最致命的冠心病形式<sup>[3]</sup>。2020 年我国经认证的 1 672 家胸痛中心共收治了 1 869 010 例患者,其中 ACS 占 33.75%,随着我国老龄化程度不断加深,患病率还在逐年上升<sup>[4]</sup>。ACS 患者的主要不良心血管事件(MACE)包括全因死亡、心搏骤停、心源性休克、恶性心律失常、心力衰竭(心衰)、非致死性心肌梗死、复发心绞痛、非计划性血运重建等<sup>[5-6]</sup>。ACS 患者医院内 MACE 发生率约为 12%<sup>[7]</sup>,出院后 30~90 d 内因 MACE 再入院率为 38%<sup>[8]</sup>。并发 MACE 易引起病情加重、住院时间延长、死亡等风险增加,因此,早期进行疾病风险分层和病情评估至关重要<sup>[9]</sup>。

近年来,机器学习、人工智能和医疗信息化的快速发展为患者风险评估开拓了新思路,机器学习预测模型在预测 ACS 患者 MACE 风险方面相比传统评分表在预测性能方面表现更好,值得研究和进一步推广应用<sup>[10-12]</sup>。现将机器学习在 ACS 患者 MACE 预测中的研究和应用进展综述如下,旨在为临床医护人员评估患者风险和制定诊疗护理方案提供参考依据。

### 1 机器学习在 ACS 患者 MACE 预测中的研究与应用

**1.1 机器学习在 ACS 患者死亡风险预测中的应用** 亚太地区每年约 700 万人死于 ACS,造成了严重的经济负担<sup>[13]</sup>。机器学习预测模型可用于预测不同场景患者的死亡风险,有助于指导临床决策和患者的个性化管理<sup>[14]</sup>。KE 等<sup>[15]</sup>收集了 6 482 例急诊 ACS 患者病历资料,医院内死亡率为 1.88%,基于逻辑回归、梯度提升决策树、随机森林和支持向量机 4 种方

\* 基金项目:重庆市重点专科建设(临床护理)精品建设项目(0203[2023]47 号 202336);重庆医科大学研究生智慧医学专项研发计划项目(YJSZHYX202219);重庆医科大学附属第一医院 2024 年度护理科研创新项目(HLPY2024-14)。

<sup>△</sup> 通信作者, E-mail:366964157@qq.com。

法,开发了 ACS 患者院内死亡预测模型,4 种模型的受试者工作特征曲线下面积(AUC)分别为 0.884 [95%可信区间(95%CI) 0.869~0.899]、0.918 (95%CI 0.906~0.930)、0.913(95%CI 0.901~0.925)和 0.896(95%CI 0.884~0.908),最重要的 3 个预测因素是 N 端 B 型利钠肽原、D-二聚体和 Killip 分级。该研究样本量大,使用的预测因子临床容易获得,实用性较好,但未纳入患者心电图和超声心动图等重要信息,可能会降低实际预测效能。HERNESNIEMI 等<sup>[16]</sup>基于 9 066 例 ACS 患者数据,使用逻辑回归和 XGBoost 2 种方法分别建立了 ACS 患者 6 个月死亡风险预测模型,结果显示,患者 6 个月死亡率为 7.3%,逻辑回归的 AUC 为 0.867(95%CI 0.837~0.897),传统 GRACE 评分的 AUC 为 0.822(95%CI 0.785~0.859),XGBoost 模型的 AUC 为 0.890(95%CI 0.864~0.916),获得最佳性能,差异有统计学意义( $P<0.05$ )。该研究使用的 XGBoost 算法是一种集成学习方法,可将多个较弱模型集成构建为更强的预测模型,从而提高性能并使预测结果更加稳定。但该研究与 KE 等<sup>[15]</sup>研究均是回顾性的,因此,仍需通过前瞻性的临床试验进一步验证模型的泛化能力。LI 等<sup>[17]</sup>开发了 ACS 患者 3 年死亡率预测模型,3 年死亡率为 8.88%,并通过年龄、肌酐、血红蛋白、血小板、谷草转氨酶和左心室射血分数 6 个重要预测因子构建了预测公式,并进行了决策曲线分析以评价临床效用,该研究使用基于随机森林的缺失数据插补和模型推导能填补一定范围内的原始数据缺失和提高预测能力,但最终呈现的公式较为复杂,若能制作成可视化的计算器或小程序将具有更好的实用性。SHERAZI 等<sup>[18]</sup>和 HADANNY 等<sup>[19]</sup>建立的预测模型也保持了较好的预测性能,优于指南推荐的 GRACE 评分和 TIMI 风险评分。此外,使用递归特征消除法进行特征选择的模型在识别医院内有高危死亡风险的 ACS 患者方面均比专家进行特征选择的模型具有更高的准确性<sup>[20]</sup>。但在实际预测因子筛选时还是要充分考虑临床经验和实际情况,综合多种方法纳入危险因素。

**1.2 机器学习在 ACS 患者心搏骤停预测中的应用** 心搏骤停指心脏机械活动停止,循环征象消失,若未能及时心肺复苏将可能很快发展为生物学死亡,且心搏骤停后几乎不能自发逆转,因此,患者预后较差<sup>[21]</sup>。ACS 患者发生心搏骤停后的医院内死亡风险比未发生者高 7 倍<sup>[22]</sup>。因此,若能准确预测患者心搏骤停发生风险,并基于此采取预见性的防控措施将对 ACS 患者的生命安全和预后具有重要的临床意义。WU 等<sup>[23]</sup>收集了 ACS 患者心搏骤停前 24 h 获得的多变量临床特征,包括人口学资料、实验室检查、影像学 and 心电图等,开发了 8 个模型预测 ACS 患者的心搏骤停事件,并将其与 GRACE 评分、国家早期预警评分和改良早期预警评分 3 种常用传统模型进行了

比较,结果显示,XGBoost 模型准确性和鉴别能力最好,AUC 为 0.958(95%CI 0.938~0.978),特异度为 95.8%,灵敏度为 73.0%,优于 GRACE 评分[AUC 为 0.729(95%CI 0.659~0.780),特异度为 50.7%,灵敏度为 81.4%]、国家早期预警评分[AUC 为 0.687(95%CI 0.622~0.753),特异度为 43.1%,灵敏度为 84.1%]和改良早期预警评分[AUC 为 0.673 (95%CI 0.605~0.736),特异度为 92.4%,灵敏度为 36.5%],可对心搏骤停高危患者有效分层,在心搏骤停发生前不久实施监测警报系统和救生策略,帮助临床医护人员采取恰当的诊疗决策。因此,可将模型作为医疗决策的补充工具,用于 ACS 患者心搏骤停的早期预防。但在该研究中不是全部的机器学习模型均优于传统评分,因此,在临床工作中仍应根据实际情况选择工具。还有决策树模型可将患者分为心搏骤停高、中、低风险 3 组,其灵敏度为 76.2%,特异度为 88.2%,校正后的 AUC 为 0.823 (95%CI 0.786~0.860),该模型的预测变量包括 7 个临床常见且获取方便的客观指标,即 VitalPAC 早期预警评分、致命性心律失常史、Killip 分级、肌钙蛋白 I、血尿素氮、年龄和糖尿病,可用于医护人员在床旁评估患者风险,并根据所得出的风险等级制定个性化的诊疗计划<sup>[24]</sup>。但该研究舍去了一些原始资料缺失超过 60%但又对判断患者病情有意义的临床指标,如心电图特征、左心室射血分数等,因此,需再深入探究这些因素预测价值。

**1.3 机器学习在 ACS 患者心衰预测中的应用** 心衰是 ACS 的常见且可预防的并发症,然而在一项研究中发现,25 324 例住院 ACS 患者中 20%的患者合并心衰,通常具有年龄较大、女性更多、合并的疾病种类更多、住院时间更长等特点,ACS 患者发生心衰后的医院内病死率和 1 年病死率分别比未发生者高 5 倍和 4 倍<sup>[25]</sup>。因此,ACS 患者心衰的早期预测和预防有利于及时提供有效的医护措施和改善患者预后。相较于传统统计模型,机器学习算法能有效处理不平衡数据集、解决非线性问题,纳入和分析更多的预测因子,并通过不断调参来优化预测性能<sup>[11,26]</sup>。REN 等<sup>[27]</sup>开发了一种可解释的机器学习模型预测 ACS 患者的医院内急性心衰,通过 Shapley 附加解释值对 128 个临床特征进行重要性排序,选择前 20.0%构建平衡随机森林模型,结果显示,ACS 患者医院内急性心衰发病率为 17.0%,有持续性胸痛的患者急性心衰发病率更高,达到了 48.4%,该模型的 AUC、灵敏度、阴性预测值均分别比线性回归模型高 15.6%、3.0%、60.8%,可自动识别患者发生急性心衰的风险,并对干预措施进行优先排序,有利于 ACS 患者的精准管理。在实用性方面,该模型可集成到医院的胸痛中心数据录入系统中,直接进行相应的预测分析,无须额外花费时间录入数据。此外,尽管该模型的大部分预测因子是目前临床已研究和证实的危险因素或相关

因素,但仍分析出了一些尚未关注到的预测因子,如体温和甘油三酯。因此,在评估 ACS 患者心衰风险时不仅要关注经典的影响因素,更需对患者进行综合评估,以早期发现患者发生心衰的风险因素,早期干预,改善预后。但该模型的局限性在于其针对的是医院内 ACS 患者急性心衰的风险预测,而忽视了医院外患者,因此,可能会影响模型对这部分人群的预测性能,需进一步的研究来预测更多人群和更长时间的心衰风险。

**1.4 机器学习在 ACS 患者恶性室性心律失常预测中的应用** 恶性室性心律失常是指在短时间内引起血流动力学障碍,导致患者晕厥、意识丧失、呼吸骤停,甚至猝死的心律失常,是 ACS 患者的严重致死性并发症,具有发生迅速、缺乏显著临床特征、难以早期预防等特点。既往研究表明,大多数恶性室性心律失常发生在急性心肌梗死症状出现后 48 h 内<sup>[28]</sup>。发生恶性室性心律失常后患者的医院内心脏死亡风险可达 31%,且 30 d 存活率显著降低<sup>[29]</sup>。因此,ACS 患者的恶性室性心律失常风险需得到及时、准确的监测。陈日超等<sup>[30]</sup>通过逻辑回归法分析急性心肌梗死患者发生恶性室性心律失常的临床特征发现,饮酒史、体重指数、Killip 分级、肌酸激酶同工酶、尿酸为急性心肌梗死患者早期发生恶性室性心律失常的独立危险因素,并制作了可视化列线图预测模型,该模型的 AUC 为 0.893(95% CI 0.827~0.943),通过 Bootstrap 自抽样法进行内部验证后的 C 指数为 0.872,具有较好的区分度和临床适用性,可直观量化患者风险。提示在临床工作中应用预测模型识别有潜在风险的患者,通过对高危患者加强监护,早期采取预防措施,有助于降低患者不良结局发生率,使患者从科学、高效的病情监测中受益。但该研究样本量较小,共 198 例,可能使模型的预测结果不可靠;且影响因素纳入不全,如未考虑到患者用药情况,因此,实际预测效果需进一步证实。

**1.5 机器学习在 ACS 患者其他不良心血管事件预测中的应用** ACS 患者还存在复发或新发心肌梗死与心绞痛、脑卒中、非计划性血运重建等其他不良心血管事件。虽然冠脉疾病高发于老年人,但近几十年来发现,其在年轻人中的发病率正在增加<sup>[31]</sup>。因此,不仅要关注中老年人群,年轻 ACS 患者的不良心血管事件风险也应受到重视。JUAN-SALVADORES 等<sup>[32]</sup>针对 40 岁以下的 ACS 患者,比较了随机森林、支持向量机、朴素贝叶斯等 6 种监督机器学习算法与逻辑回归在识别接受冠脉造影的 ACS 患者全因死亡、脑卒中、反复心肌梗死和冠脉血运重建风险方面的准确性,结果显示,即使在小样本中机器学习模型仍具有良好的判别能力,尤其是随机森林算法表现最好,AUC 为 0.800(95% CI 0.710~0.890),灵敏度为 75%,特异度和准确度均为 72%,该模型产生的风险评估结果可帮助医护人员根据患者不良心

血管事件发生风险制定随访策略、采用最佳医疗决策,并有助于合理分配卫生资源。但该模型因其开发时使用的训练数据量较少且未进行外部验证,因此,仍需通过更大的队列研究进一步验证其预测准确性。

## 2 ACS 患者 MACE 风险预测模型比较分析

**2.1 模型构建的数据比较** 各预测模型的数据来源不同,样本量大小和数据的时间跨度等特点也各有差异。目前,有较多研究采用电子病历系统<sup>[15,20,24,30,32]</sup>和电子健康记录<sup>[16,23,27]</sup>获取患者的临床资料,并且这一方式因医院信息化的发展及其自身的便利性,正成为主要数据来源。其他方式还包括临床数据存储库<sup>[15,19,33]</sup>和电话调查<sup>[18,32]</sup>。虽然数据来源有所差异,但多数研究使用的数据是回顾性的<sup>[15-16,18,20,22,24,27,30]</sup>,仅有少数研究的数据是通过前瞻性随访获得<sup>[12,18,32-33]</sup>。回顾性数据虽然获得方便,但容易存在混杂偏倚,因此,需采用更高级的统计学方法处理。涉及的研究样本量最少为 198 例<sup>[30]</sup>,最多可达 21 337 例<sup>[24]</sup>,数据收集时间长短不一,时间跨度为 1.84~15.00 年<sup>[24,32]</sup>。且多数模型使用的是单中心数据<sup>[15-16,18,20,27,32]</sup>,少数研究使用的是全国性的疾病数据库<sup>[19,33]</sup>或大型国际队列<sup>[12]</sup>。相较于传统方法,机器学习常需使用大规模数据集,因此,建议后续研究可使用全国性的多中心疾病数据库,使样本更具有代表性的同时,也能获得足够多的数据量。此外,大多数训练数据中阳性事件量占总体的比例较小,可能与较为严重的 MACE 发生率较低有关,但均存在一定的数据不均衡问题,可能会使预测结果更偏向于样本量多的一方,不能真实描述临床 ACS 患者发生 MACE 的风险,使预测性能不可靠,因此,一方面,可采用合成少数过采样技术等经典方法预先处理数据;另一方面,也可进一步进行外部验证。

**2.2 模型构建方法比较** 以机器学习算法构建 ACS 患者 MACE 风险预测模型的研究正在不断进行,常用的算法有随机森林<sup>[12,15,18-20,23,27,32-33]</sup>、逻辑回归<sup>[15,16,20,23,30]</sup>、决策树<sup>[15,19,20,24]</sup>、支持向量机<sup>[15,20,24,32]</sup>、贝叶斯<sup>[12,23,27,32]</sup>、神经网络<sup>[19-20,23]</sup>、极限梯度提升(XGBoost)<sup>[16,23]</sup>、Lasso<sup>[18,32]</sup>和 K 最近邻(KNN)<sup>[12,23]</sup>。多为监督机器学习算法,使用带有标签的训练数据进行学习和预测,常用于解决回归和分类问题。虽然目前机器学习预测模型已逐渐成为研究热点,但机器学习算法是否在任何情况下预测效能均优于传统建模方法,仍无科学定论,尚无在任何情况下均是最准确的算法,因此,一方面,要综合使用传统评分工具和机器学习预测模型;另一方面,要从实际临床问题出发,充分考虑研究类型、数据规模和特点来选择最恰当的算法。

**2.3 模型验证方法比较** 就模型验证而言,多数研究划分了训练集和独立测试集<sup>[12,15-17,20,23,27,32-33]</sup>。训练集用于特征选择和模型训练,而独立测试集用于评估训练后的模型。在验证方法方面,为减少过度拟合

并提高模型精度部分研究,采用了四重分层交叉验证<sup>[19]</sup>、五倍交叉验证<sup>[16,33]</sup>、十倍交叉验证<sup>[15,18,20,24,32]</sup>和 Bootstrap 重抽样法<sup>[30]</sup>,可使用的验证方法比较多样化。在验证过程方面,多数模型仅进行了内部验证<sup>[15-16,18-20,23-24,27,30,32]</sup>,少有将模型应用在不同地区和不同人群的外部验证<sup>[12]</sup>。因此,所构建的模型大多数需进一步的外部验证后才能推广使用。就模型评价而言,使用较为广泛的评价指标是灵敏度、特异度和 AUC,其中 AUC 取值范围为 0.5~1.0,越接近 1.0 说明模型准确性越高。

**2.4 危险因素比较** 在筛选危险因素的方法方面,采用的有单因素和多因素逻辑回归分析<sup>[15-16,30]</sup>、递归特征消除法<sup>[20]</sup>、递归分配分析法<sup>[23]</sup>和 SHAP 值进行特征排序再选择的方法<sup>[27]</sup>。而 ACS 患者发生 MACE 的相关危险因素有年龄<sup>[15-16,18-20,24,27]</sup>、肌酐<sup>[16,18-20,22,32]</sup>、Killip III~IV 级<sup>[15,19,24,30]</sup>、肌钙蛋白<sup>[15,23-24,27]</sup>、N 端 B 型利钠肽原<sup>[15,23,27]</sup>,以及血红蛋白<sup>[16,18]</sup>、白细胞浓度<sup>[16,23]</sup>、高密度脂蛋白胆固醇<sup>[15,32]</sup>、左心室射血分数<sup>[18,27]</sup>、血尿素氮<sup>[23-24]</sup>、体重指数<sup>[30,32]</sup>、心率<sup>[19,23]</sup>、糖尿病史<sup>[20,24]</sup>、高血压和血脂异常<sup>[20]</sup>、血细胞比容和血小板<sup>[23]</sup>、饮酒史与高尿酸血症<sup>[30]</sup>、血糖<sup>[32]</sup>、诊断为非 ST 段抬高性心肌梗死、D-二聚体、肌酸激酶<sup>[15]</sup>、血小板和谷草转氨酶<sup>[18]</sup>等,基本都是临床常用且获取方便的指标。

### 3 小结与展望

基于机器学习算法和以电子病历系统为代表性的大数据建立预测模型具有可行性,但未来 ACS 患者 MACE 风险机器学习预测模型还需从以下方面进行改进:(1)考虑到 ACS 疾病分型的不同,对不同疾病开发更有针对性的预测模型;(2)扩大研究样本例数,发挥出机器学习相较于传统方法的优势;(3)从临床实际需求、数据规模和特点出发,选择合适算法;(4)对模型的科学性和准确性进行进一步的外部验证和临床前瞻性验证,并进行定期更新和评价;(5)模型可视化作为临床使用提供现实可行性。

### 参考文献

[1] ATWOOD J. Management of acute coronary syndrome[J]. Emerg Med Clin North Am, 2022,40(4):693-706.

[2] TOWNSEND N, WILSON L, BHATNAGAR P, et al. Cardiovascular disease in Europe: Epidemiological update 2016 [J]. Eur Heart J, 2016,37(42):3232-3245.

[3] KNUUTI J, WIJNS W, SARASTE A, et al. 2019 ESC guidelines for the diagnosis and management of chronic coronary syndromes [J]. Eur Heart J, 2020,41(3):407-477.

[4] 中国胸痛中心联盟,中国心血管健康联盟,苏州工业园区心血管健康研究院,等.《中国胸痛中心

质控报告(2020)》概要[J]. 中国介入心脏病学杂志,2021,29(6):313-317.

- [5] BOSCO E, HSUEH L, MCCONEGHY K W, et al. Major adverse cardiovascular event definitions used in observational analysis of administrative databases: A systematic review[J]. BMC Med Res Methodol, 2021,21(1):241.
- [6] NESTELBERGER T, BOEDDINGHAUS J, WUSLSLER D, et al. Predicting major adverse events in patients with acute myocardial infarction[J]. J Am Coll Cardiol, 2019,74(7):842-854.
- [7] YANG Q, WANG Y, LIU J, et al. Invasive management strategies and antithrombotic treatments in patients with Non-ST-Segment-Elevation acute coronary syndrome in China: Findings from the improving CCC project (care for cardiovascular disease in China)[J]. Circ Cardiovasc Interv, 2017,10(6):e004750.
- [8] SREENIVASAN J, ABU-HANIYEH A, HODA U, et al. Rate, causes, and predictors of 90-day readmissions and the association with index hospitalization coronary revascularization following non-ST elevation myocardial infarction in the United States [J]. Catheter Cardiovasc Interv, 2021,98(1):12-21.
- [9] 中华医学会急诊医学分会,中国医疗保健国际交流促进会胸痛分会.急性胸痛急诊诊疗专家共识 [J]. 中华急诊医学杂志,2019,28(4):413-420.
- [10] DIMOPOULOS A C, NIKOLAIDOU M, CABALLERO F F, et al. Machine learning methodologies versus cardiovascular risk scores, in predicting disease risk [J]. BMC Med Res Methodol, 2018,18(1):179.
- [11] SUZUKI S, YAMASHITA T K H, SAKAMA T, et al. Comparison of risk models for mortality and cardiovascular events between machine learning and conventional logistic regression analysis[J]. PLoS One, 2019,14(9):e0221911.
- [12] D'ASCENZO F, DE FILIPPO O, GALLONE G, et al. Machine learning-based prediction of adverse events following an acute coronary syndrome (PRAISE): A modelling study of pooled datasets[J]. Lancet, 2021,397(10270):199-207.
- [13] JAN S, LEE S W L, SAWHNEY J P S, et al. Catastrophic health expenditure on acute coronary events in Asia: A prospective study[J]. Bull World Health Organ, 2016,94(3):193-200.
- [14] CHEN L, HAN Z J, WANG J H, et al. The e-

- merging roles of machine learning in cardiovascular diseases: A narrative review [J]. *Ann Transl Med*, 2022, 10(10):611.
- [15] KE J, CHEN Y W, WANG X P, et al. Machine learning-based in-hospital mortality prediction models for patients with acute coronary syndrome[J]. *Am J Emerg Med*, 2022, 53: 127-134.
- [16] HERNESNIEMI J A, MAHDIANI S, TYNKKY-NEN J A, et al. Extensive phenotype data and machine learning in prediction of mortality in acute coronary syndrome - the MADDEC study[J]. *Ann Med*, 2019, 51(2):156-163.
- [17] LI Y M, LI Z L, CHEN F, et al. A LASSO-derived risk model for long-term mortality in Chinese patients with acute coronary syndrome [J]. *J Transl Med*, 2020, 18(1):157.
- [18] SHERAZI S W A, JEONG Y J, JAE M H, et al. A machine learning-based 1-year mortality prediction model after hospital discharge for clinical patients with acute coronary syndrome [J]. *Health Informatics J*, 2020, 26(2):1289-1304.
- [19] HADANNY A, SHOUVAL R, WU J H, et al. Predicting 30-day mortality after ST elevation myocardial infarction: Machine learning-based random forest and its external validation using two Independent nationwide datasets[J]. *J Cardiol*, 2021, 78(5):439-446.
- [20] LIMPRASERT S, PHU-ANG A. Data modeling using vital sign dynamics for in-hospital mortality classification in patients with acute coronary syndrome [J]. *Healthc Inform Res*, 2023, 29(2):120-131.
- [21] 杨可慧, 桑文涛, 潘畅, 等. 心搏骤停与复苏调查的现状 & 展望[J]. *中国实用内科杂志*, 2019, 39(10):842-846.
- [22] KONTOS M C, SCIRICA B M, CHEN A Y, et al. Cardiac arrest and clinical characteristics, treatments and outcomes among patients hospitalized with ST-elevation myocardial infarction in contemporary practice: A report from the National Cardiovascular Data Registry[J]. *Am Heart J*, 2015, 169(4):515-22.
- [23] WU T T, LIN X Q, MU Y, et al. Machine learning for early prediction of in-hospital cardiac arrest in patients with acute coronary syndromes[J]. *Clin Cardiol*, 2021, 44(3):349-356.
- [24] LI H, WU T T, YANG D L, et al. Decision tree model for predicting in-hospital cardiac arrest among patients admitted with acute coronary syndrome[J]. *Clin Cardiol*, 2019, 42(11):1087-1093.
- [25] KAUL P, EZEKOWITZ J A, ARMSTRONG P W, et al. Incidence of heart failure and mortality after acute coronary syndromes[J]. *Am Heart J*, 2013, 165(3):379-385.
- [26] WENG S F, REPS J, KAI J, et al. Can machine-learning improve cardiovascular risk prediction using routine clinical data? [J]. *PLoS One*, 2017, 12(4):e0174944.
- [27] REN H, SUN Y, XU C Y, et al. Predicting acute onset of heart failure complicating acute coronary syndrome: An explainable machine learning approach [J]. *Curr Probl Cardiol*, 2023, 48(2):101480.
- [28] MEHTA R H, STARR A Z, LOPES R D, et al. Incidence of and outcomes associated with ventricular tachycardia or fibrillation in patients undergoing primary percutaneous coronary intervention [J]. *JAMA*, 2009, 301(17):1779-1789.
- [29] TAKADA T K A, SHISHIDO K, HAYASHI T, et al. Impact of late ventricular arrhythmias on cardiac mortality in patients with acute myocardial infarction [J]. *J Interv Cardiol*, 2019, 2019:5345178.
- [30] 陈日超, 韦荣菊, 陈华, 等. 急性心肌梗死早期恶性室性心律失常风险预测模型的构建[J]. *中国医学工程*, 2023, 31(3):19-25.
- [31] MEIRHAEGHE A, MONTAYE M, BIASCH K, et al. Coronary heart disease incidence still decreased between 2006 and 2014 in France, except in young age groups: Results from the French MONICA registries [J]. *Eur J Prev Cardiol*, 2020, 27(11):1178-1186.
- [32] JUAN-SALVADORES P, VEIGA C, JIMÉNEZ DÍAZ V A, et al. Using machine learning techniques to predict MACE in very young acute coronary syndrome patients [J]. *Diagnostics (Basel)*, 2022, 12(2):422.
- [33] SHERAZI S W A, BAE J W, LEE J Y. A soft voting ensemble classifier for early prediction and diagnosis of occurrences of major adverse cardiovascular events for STEMI and NSTEMI during 2-year follow-up in patients with acute coronary syndrome [J]. *PLoS One*, 2021, 16(6):e0249338.