

机器学习在急诊医疗服务体系中的应用现状与展望*

李萍¹ 聂虎^{1△}

[关键词] 机器学习;急诊医疗服务体系;院前急救;院内急诊;危重症监护

doi:10.13201/j.issn.1009-5918.2020.06.018

[中图分类号] R459.7 [文献标志码] A

Application and outlook of machine learning in emergency medical service system

Summary Machine learning(ML), as a method of realizing artificial intelligence, has been applied in many fields of Medicine as a result of its powerful data processing capability, which increases the ability to process the huge medical data and the work efficiency of the medical staff. Overload running in emergency department, a common problem in many hospitals, as well as the severity and rapid change of the patients' condition necessitate the assist of ML to improve the imbalance between the number of the medical staff and the patients, to enhance the capacity of doctor to detect and manage critically ill patients. In this article, we will review the application of ML in different scenarios such as pre-hospital and in-hospital emergency care and critical care in the emergency medical service system.

Key words machine learning; emergency medical service system; pre-hospital care; in-hospital emergency; critical care

机器学习(machine learning, ML)是计算机通过模拟人类学习行为并获取处理数据的方法。ML作为人工智能(artificial intelligence, AI)的一个分支^[1],以精确快速处理大量数据为特点,目前已经应用到医学的很多领域,如医学影像、实验室检查、流行病学以及疾病的预测、识别与管理等。ML与传统统计方法相比,前者在处理大量复杂的数据,比如海量的医疗数据方面,表现出更佳的处理能力^[2]。

急诊医疗服务体系(emergency medical service system, EMSS)涵盖了院前急救、医院急诊和重症监护等过程,快速而准确的分拣、诊断及治疗是急诊工作的基本要求,然而,全球范围内急诊系统的超负荷运转已经成为一个重要的社会问题^[3]。急诊患者数量的增加,急诊科医务人员数量与患者数量的不平衡,对急诊诊疗水平和效率的提高提出了严峻挑战。因此,将 AI 方法应用到急诊医学上可以辅助医务人员早期有效识别急危重症、显著提

高医院应急系统的效能。本文将从 EMSS 的各个方面来阐述 ML 在急诊医学中的应用现状和前景。

1 ML 的分类

ML 共分为 3 类:监督 ML、无监督 ML 和强化 ML^[4]。监督 ML 是指通过一个或多个数学函数实现从标记数据到特定结果的映射^[4],该模型可以对数据进行分类或预测数值数据(图 1),常用的算法有:朴素贝叶斯算法(naive Bayesian, NB)、决策树(decision tree, DT)、k 近邻算法(k-nearest neighbor, KNN)、线性回归、回归树、神经网络(neural network, NN)、支持向量机(support vector machine, SVM)等。无监督 ML 是指在未标记的数据中查找隐藏的结构^[1],通过分析一系列数据找到隐藏的结果(图 2),常见的类型有主成分分析(Principal Component Analysis, PCA)、k 均值聚类。强化 ML 是根据完成任务所获得的奖励来学习数据中的最优决策序列^[4](图 3),即依据有利的结果不断加强该结果所对应的决策序列,反之亦然。

2 ML 在院前急救场景中的应用现状与展望

在院前急救中,由于急救资源的有限性,需要优先识别高危患者,同时确认不需要急救的患者,进而实现对院前急救的有效分层管理。

* 基金项目:四川大学华西医院新型冠状病毒科技攻关项目(No:HX2019nCoV026)

¹ 四川大学华西医院急诊科(成都,610041)

[△] 审校者

通信作者:聂虎, E-mail:456nh@163.com

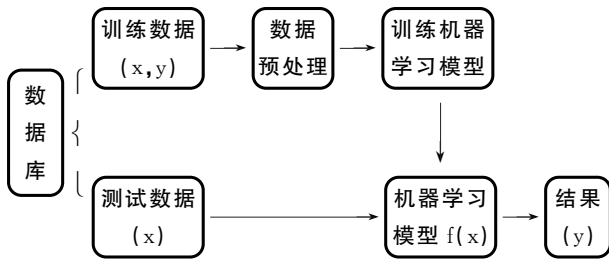


图 1 监督 ML 流程图




图 2 无监督 ML 示意图

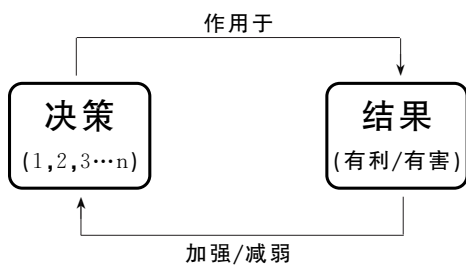


图 3 强化 ML 示意图

2.1 应用现状

2.1.1 日常院前急救 在日常院前急救中,依据求救者有限的信息准确评估病情是比较困难的。Blomberg 等^[5]通过分析求救电话中的音频构建识别院外心搏骤停的 ML 模型,将该模型的性能与急诊调度员对心搏骤停的识别率、识别所需时间进行了比较,发现 ML 具有较高的敏感度(84.1% vs. 72.5%, $P < 0.01$),较低的特异度(97.3% vs. 98.8%, $P < 0.01$),较短的识别所需时间(中位数 44 s vs. 54 s, $P < 0.01$)。Spangler 等^[6]利用调度中心和救护车的呼救者相关信息建立 ML 模型,用于预测呼救者的住院情况、是否需重症监护和两天死亡率,并将模型综合风险得分与国家早期预警得分(NEWS)和实际调度优先级进行比较,结果表明 ML、NEWS 和实际调度优先级的 AUC 分别为 0.79~0.89、0.66~0.85、0.51~0.66。这些研究表明,ML 可以利用求救者有限的院前信息快速高效识别病情危重程度,辅助急诊调度员进行决策。

2.1.2 灾难救援 在灾难救援中,目前几乎全凭

医务人员对伤者进行检伤,因此在医务人员有限的情况下很难实现有效检伤,这在很大程度上影响了伤者的存活率。已有研究利用可穿戴设备远程监测得到的生命体征、意识指数,对病员进行远程分诊,以患者在急诊科的生存或死亡情况为主要结局变量,结果表明修订创伤评分(RTS)、深度神经网络、逻辑回归、随机森林的 AUC 分别为 0.78(95% CI 0.775~0.785)、0.89(95% CI 0.882~0.890)、0.87(95% CI 0.862~0.870)、0.87(95% CI 0.862~0.872),提示 ML 可以自动高效地实现远程检伤,有望减少院前分检时间,提高大规模伤亡事件中伤员的生存率^[7]。此外,在灾难救援中,稳定而有效的应急通信系统显得尤为重要,现有的通信设备都表现出一定的局限性,Zongzhe 等^[8]基于 AlphaGo 智能算法提出了一种高效可靠的应急通信网络规划方法。但该方法尚未应用于实际工作中,还有待进一步研究。

2.2 展望

急诊就诊患者的病情以“急”为特征,因此需要快速识别、诊断和处理;而第五代移动通信技术(the 5th Generation Wireless System),简称 5G,以“快”为突出特点,与急诊的“急”相呼应。除此之外,5G 技术还具有低网络延迟、大网络容量与大规模多设备同时连接的特点。ML 模型在急诊医学上的应用必定需要具备实时监测和及时反馈的特性,若离开了 5G 技术,ML 在急诊医学上的广泛应用可能面临巨大挑战。

现有的研究大多是利用 ML 评估求救者病情危重程度,ML 还可以基于主诉、既往史和 5G 技术构建的“超级救护车”所提供的计算机断层扫描^[9]结果构建识别特定疾病如脑卒中的模型,根据结果把患者转运至有相应技术支持的医院。同时,5G 技术还可以通过识别最佳路线节约转运时间^[10],避免因转运导致超过治疗的黄金时间。

葛芳民等^[11]提出利用最可能受益于 5G 技术的虚拟现实(virtual reality, VR)和增强现实(augmented reality, AR)技术实现急诊远程诊疗——在院医务人员可以根据实时观察得到的急救现场或救护车情况、实时传输回来的患者数据指导出诊医生的诊疗活动。而 ML 可以基于这些实时数据构建算法,进而完成自主学习。

3 ML 在院内急诊场景中的应用现状与展望

急诊就诊患者人流量大,患者病情重、变化快,因此准确评估病情、及时干预有助于改善患者的结局。

3.1 应用现状

3.1.1 支持急诊分诊决策 分诊时收集到的信息可以用于分诊、预测临床结局^[12]和指导诊疗^[13]。Levin 等^[14]利用主诉和分诊时收集到的数据构建

ML模型,并与急诊病情严重指数(ESI)相比较,结果表明基于ML的电子分诊系统识别急诊患者病情严重程度的能力与ESI类似或更高。该模型还可以用于预测临床结局,Raita^[12]利用类似的预测因子预测患者的临床结局——需重症监护和收住院,并比较了4种ML模型(套索回归、随机森林、梯度提升决策树和深度神经网络),发现与以ESI为预测因子的逻辑回归相比,ML在预测重症监护和住院结果方面表现出卓越的性能,其中预测能力最佳的深度神经网络预测重症监护和住院的AUC分别为0.86(95%CI 0.85~0.87)、0.82(95%CI 0.82~0.83),而ESI的AUC分别为0.74(95%CI 0.72~0.75)、0.69(95%CI 0.68~0.69)。

基于分诊信息,ML还可以辅助医生进行临床诊疗,如根据主诉、生命体征和病史给出是否需立即行头部CT检查的建议,进而减少等待时间所致的病情延误^[15]。此外,ML联合自然语言处理构建针对急腹症的快速分诊系统可根据主诉、病史和查体构建可能的诊断,并给出必要的辅助检查建议^[16]。利用ML模型还可以识别感染性休克^[17]、上消化道出血^[18]、急性主动脉综合征^[19]。研究发现给予模型的信息数据越丰富,该模型所提供的预测结果越准确^[20],因此,进入急诊后可联合检验检查结果动态评估患者的结局。

3.1.2 评估病情严重程度 患者进入医疗区后,医生及时准确评估病情的严重性并决定下一步去向,可以减少急诊滞留时间,而急诊滞留时间与患者在院死亡率密切相关^[21]。

ML可以利用医疗数据预测某些急危重症的发生发展。目前已有研究将ML用于:预测疑诊或确诊的脓毒症患者的风险分层^[22]及疗效^[23];预测严重创伤^[24]或颅脑外伤患者^[25]的预后;预测急诊危重患者发生心脏猝死的风险^[26];预测急诊胸痛患者发生不良冠脉事件的风险和危险分层^[27];预测在急诊科发生急性肾损伤的风险^[28]等。

3.1.3 通过影像识别辅助临床决策 ML在影像学领域的使用已经比较广泛,Bertsimas等^[29]构建了一个ML模型用于评估从北美25个急诊科收集的42412例头部外伤且精神状态没有明显改变的儿童患者是否有必要进行或反复进行头颅CT检查,并将该结果同儿科急诊应用研究网络脑外伤决策规则(PECARN)相比较,结果表明应用ML模型可以减少儿童不必要的头部CT扫描。另外,深度神经网络可以协助急诊科医生识别腕关节骨折^[30],并且这种模型还可以识别其他类型的骨折或创伤。

3.1.4 识别传染性疾病的流行 传染病在临床早期阶段常不具有特征性表现,初诊时很难立即确

诊^[31]。Feldman等^[32]基于自然语言处理、ML和人类专家构建了一个全球范围的近实时的114种疾病和症状的传染病活动数据库,使我们能够更容易监控、记录和定量研究传染病。Chae等^[33]基于社交媒体大数据、搜索查询数据、温度和湿度构建预测疟疾、猩红热、水痘流行的ML模型,并将深度学习与传统统计方法自回归综合移动平均(ARIMA)的预测能力进行比较,发现与ARIMA相比,深度学习具有更佳的预测能力。Ye等^[34]构建了2个识别流感病例的模型(先用自然语言处理预处理两个地区的急诊科病例数据,然后用贝叶斯网络分类器推断病例诊断),发现2个模型识别流感与非流感的AUC均大于0.92。

3.2 展望

急诊影像学检查,如CT、超声对于明确患者的病因和严重程度都至关重要,但目前针对ML在急诊超声检查上的研究较少。超声检查具有能实时采集和显示图像的优点而在急诊科拥有广泛应用的前景,但过分依赖操作员的技能限制了超声在急诊科的应用。利用ML分析超声图像将有助于辅助急诊科医生进行快速诊断。同时,ML可以利用5G技术快速高质量传递数据的特点实现远程超声检查及诊断。我国幅员辽阔,不同地区医疗水平差异巨大,利用远程诊疗可以提升基层医疗服务能力,更好地造福于患者。

急诊科人流大、患者病情重,一旦发生传染病则传播迅速。目前2019新型冠状病毒(COVID-19)的流行对急诊科日常工作的开展提出了巨大的挑战,因此构建急诊传染病监测机器人用于识别急诊科潜在传染病流行情况,将对传染病的早期发现、预警和防控发挥重要作用。物联网(the Internet of Things, IoT)是指将众多设备终端通过互联网连接形成的巨大网络,可以实现通信和实时信息交换。ML可以基于IoT传感器设备、可穿戴设备实时监测得到的体温、既往病史等快速回顾和总结患者的疾病进展,协助医护人员发现疑似患者。

4 ML在危重病监护场景中的应用现状与展望

重症医学科医生所面临的挑战之一是如何有效分析和利用大量的医疗数据^[35],而AI的产生正好可以将大量复杂的数据转化成有用的信息辅助医生早期识别患者病情变化和预测疾病转归。

4.1 应用现状

ML可以分析并揭示大量医疗数据所暗含的患者疾病的进展变化。一项研究对比高乳酸血症患者液体复苏前后的中心静脉-动脉二氧化碳分压差与动脉-中心静脉氧含量差的比值($Pcv-aCO_2/Ca-cvO_2$)变化情况,发现该比值的变化率可以有效地预测高乳酸血症患者的器官功能改善状态和预

测此类患者院内死亡风险^[36]。此外,ML 基于心率变异性可以预测发生疑似败血症^[22]和谵妄^[37]的风险;基于连续心电图的改变,ML 模型可以预测重症监护室(ICU)儿童的院内死亡风险^[38];基于连续血压的监测,ML 模型可以在低血压事件显现出来前几分钟就可可靠地预测低血压的发生^[39]。

在急诊重症监护室(EICU)的患者由于多种因素的相互作用容易出现各种并发症。Cramer 等^[40]创建了一种可以预测在 ICU 发生压疮风险的模型,发现该模型的表现力远超过经常使用的 Braden 评分。Ouchi 等^[41]提出利用 ML 构建预测和识别老年人药物不良反应(ADE)事件的模型,以减少因 ADE 所致住院时间延长甚至死亡的发生率。Delahanty 等^[42]构建了预测 ICU 患者死亡风险的 ML 模型,其预测能力(AUC=0.94)远超过传统的评分如急性生理和慢性健康评分(APACHE-IV AUC=0.88)和死亡概率模型(MPM₀-III AUC=0.82)。Holmgren 等^[43]发现基于相同的临床数据,人工神经网络在入院后 1 h 内预测重症监护患者 30 d 病死率的灵敏度和特异度均优于简明急性生理学评分 3(AUC 0.89 vs. 0.85, $P < 0.01$)。

4.2 展望

ML 不仅可以在重症监护室监测患者的微小变化并预测疾病进展,还可以应用到其他需要密切监测患者生命体征、内环境变化的场景,如麻醉手术、血液透析、体外膜肺氧合(ECMO)、经皮冠状动脉介入治疗(PCI)等。

5 挑战

尽管 ML 具有强大的数据处理能力,但是其在临床中的应用仍面临着许多挑战。数据库的质量、地区人口流行病学差异、不同年龄段患者的生理差异等影响了模型的表现力和外推性。此外,由于急诊就诊患者的病情紧急,留给采集病史的时间有限,导致用于模型评估和预测的数据有限,模型的表现力也在一定程度上受到影响。

参考文献

- [1] Alanazi HO, Abdullah AH, Qureshi KN. A critical review for developing accurate and dynamic predictive models using machine learning methods in medicine and health care[J]. *J Med Syst*, 2017, 41(4): 69-79.
- [2] Van Calster B, Wynants L. Machine learning in medicine[J]. *N Engl J Med*, 2019, 380(26): 2588.
- [3] Stankiewicz S, Larsen C, Sullivan F, et al. Evaluation of a practice improvement protocol for patient transfer from the emergency department to the surgical intensive care unit after a level I trauma activation[J]. *J Emerg Nurs*, 2019, 45(2): 144-148.
- [4] Man TK, Glen WC, Anika M, et al. The efficacy and effectiveness of machine learning for weaning in mechanically ventilated patients at the intensive care unit: a systematic review[J]. *Bio-des Manuf*, 2019, 2(1): 31-40.
- [5] Blomberg SN, Folke F, Ersbøll AK, et al. Machine learning as a supportive tool to recognize cardiac arrest in emergency calls[J]. *Resuscitation*, 2019, 138: 322-329.
- [6] Spangler D, Hermansson T, Smekal D, et al. A validation of machine learning-based risk scores in the pre-hospital setting [J]. *PLoS One*, 2019, 14(12): 0226518.
- [7] Dohyun K, Sungmin Y, Soonwon S, et al. A data-driven artificial intelligence model for remote triage in the prehospital environment[J]. *PLoS One*, 2018, 13(10): e0206006.
- [8] Nie ZZ, Zhu W, Yang RP, et al. An intelligent network planning algorithm for emergency communication with deep learning[C]. // *Proceedings of 3rd International Conference on Mechatronics Engineering and Information Technology(ICMEIT 2019)*, 2019-4-20, Atlantis Press, 2019: 336-343.
- [9] Hyunmin K, Sung-Woo K, Eunjeong P, et al. The role of fifth-generation mobile technology in prehospital emergency care: An opportunity to support paramedics [J]. *Health Policy Technol*, 2020, 9(1): 109-114.
- [10] Heejung Y, Howon L, Hongbeom J. What is 5G? Emerging 5G mobile services and network requirements[J]. *Sustainability*, 2017, 9(10): 1848.
- [11] 葛芳民, 李强, 林高兴, 等. 基于 5G 技术院前-院内急诊医疗服务平台建设的研 究[J]. *中华急诊医学杂志*, 2019, 28(10): 1223-1227.
- [12] Raita Y, Goto T, Faridi MK, et al. Emergency department triage prediction of clinical outcomes using machine learning models[J]. *Crit Care*, 2019, 23(1): 64-76.
- [13] Hunter-Zinck HS, Peck JS, Strout TD, et al. Predicting emergency department orders with multilabel machine learning techniques and simulating effects on length of stay[J]. *J Am Med Inform Assoc*, 2019, 26(12): 1427-1436.
- [14] Levin S, Toerper M, Hamrock E, et al. Machine-learning-based electronic triage more accurately differentiates patients with respect to clinical outcomes compared with the Emergency Severity Index [J]. *Ann Emerg Med*, 2018, 71(5): 565-574. e2.
- [15] Klang E, Barash Y, Soffer S, et al. Promoting head CT exams in the emergency department triage using a machine learning model[J]. *Neuroradiology*, 2020, 62(2): 153-160.
- [16] 张薇, 孙明伟, 曾俊, 等. 基于人工智能构建急腹症快速分诊系统[J]. *实用医院临床杂志*, 2019, 16(1): 219-222.
- [17] Kim J, Chang H, Kim D, et al. Machine learning for prediction of septic shock at initial triage in emergency department[J]. *J Crit Care*, 2020, 55: 163-170.

- [18] Shung LD, Au B, Taylor AR, et al. Validation of a machine learning model that outperforms Clinical Risk Scoring Systems for upper gastrointestinal bleeding[J]. *Gastroenterology*, 2020, 158(1): 160–167.
- [19] Duceau B, Alsac J-M, Bellenfant F, et al. Prehospital triage of acute aortic syndrome using a machine learning algorithm[J]. *Br J Surg*, 2020.
- [20] Hong SW, Haimovich DA, Taylor AR, et al. Predicting hospital admission at emergency department triage using machine learning[J]. *PLoS One*, 2018, 13(7): e0201016.
- [21] Intas G, Stergiannis P, Chalari E, et al. The impact of ED boarding time, severity of illness, and discharge destination on outcomes of critically ill ED patients[J]. *Adv Emerg Nurs J*, 2012, 34(2): 164–169.
- [22] Chiew CJ, Liu N, Tagami T, et al. Heart rate variability based machine learning models for risk prediction of suspected sepsis patients in the emergency department[J]. *Medicine*, 2019, 98(6): 14197.
- [23] Perng JW, Kao IH, Kung CT, et al. Mortality prediction of septic patients in the emergency department based on machine learning[J]. *J Clin Med*, 2019, 8(11): 1906.
- [24] Rau CS, Wu SC, Chuang JF, et al. Machine learning models of survival prediction in trauma patients[J]. *J Clin Med*, 2019, 8(6): 799.
- [25] Feng JZ, Wang Y, Peng J, et al. Comparison between logistic regression and machine learning algorithms on survival prediction of traumatic brain injuries[J]. *J Crit Care*, 2019, 54: 110–116.
- [26] Liu N, Cao JW, Koh ZX, et al. Risk stratification with extreme learning machine: A retrospective study on emergency department patients[J]. *Mathematical Problems in Engineering*, 2014, 2014.
- [27] Daniel L, Martin H. Machine learning for improved detection of myocardial infarction in patients presenting with chest pain in the emergency department[J]. *J Am Coll Cardiol*, 2018, 71(11): A225.
- [28] Hinson JS, Martinez DA, Grams MS, et al. Prediction of acute kidney injury in the emergency department using electronic health record data and machine learning methods[J]. *Ann Emerg Med*, 2018, 72(4): S154.
- [29] Bertsimas D, Dunn J, Steele DW, et al. Comparison of machine learning optimal classification trees with the pediatric emergency care applied research network head trauma decision rules[J]. *JAMA Pediatr*, 2019, 173(7): 648–656.
- [30] Lindsey R, Daluiski A, Chopra S, et al. Deep neural network improves fracture detection by clinicians[J]. *Proc Natl Acad of Sci U S A*, 2018, 115(45): 11591–11596.
- [31] 孔质彬, 刘洁, 张平文, 等. 急诊科面对传染病的挑战[J]. *中华医院感染学杂志*, 2008, 18(8): 1078.
- [32] Feldman J, Thomas-Bachli A, Forsyth J, et al. Development of a global infectious disease activity database using natural language processing, machine learning, and human expertise[J]. *J Am Med Inform Assoc*, 2019, 26(11): 1355–1359.
- [33] Chae S, Kwon S, Lee D. Predicting infectious disease using deep learning and big data[J]. *Int J Environ Res Public Health*, 2018, 15(8): 1596.
- [34] Ye Y, Wagner MM, Cooper GF, et al. A study of the transferability of influenza case detection systems between two large healthcare systems[J]. *PLoS One*, 2017, 12(4): 0174970.
- [35] Núñez RA, Armengol de la Hoz MA, Sánchez GM. Big data analysis and machine learning in intensive care units[J]. *Med Intensiva*, 2019, 43(7): 416–426.
- [36] 倪主昂, 吕丹, 张柯基, 等. 中心静脉-动脉二氧化碳分压差与动脉-中心静脉氧含量差的比值(Pcv-aCO₂/Ca-cvO₂)变化率对急诊重症监护室脓毒症患者预后的评估价值[J]. *现代生物医学进展*, 2019, 19(16): 3073–3079.
- [37] Oh J, Cho D, Park J, et al. Prediction and early detection of delirium in the intensive care unit by using heart rate variability and machine learning[J]. *Physiol Meas*, 2018, 39(3): 035004.
- [38] Sánchez Fernández I, Sansevere AJ, Gaínza-Lein M, et al. Machine learning for outcome prediction in electroencephalograph (EEG)-monitored children in the intensive care unit[J]. *J Child Neurol*, 2018, 33(8): 546–553.
- [39] Saugel B, Kouz K, Hoppe P, et al. Predicting hypotension in perioperative and intensive care medicine[J]. *Best Pract Res Clin Anaesthesiol*, 2019, 33(2): 189–197.
- [40] Cramer EM, Seneviratne MG, Sharifi H, et al. Predicting the incidence of pressure ulcers in the intensive care unit using machine learning[J]. *EGEMS(Washington, DC)*, 2019, 7(1): 49.
- [41] Ouchi K, Lindvall C, Chai PR, et al. Machine learning to predict, detect, and intervene older adults vulnerable for adverse drug events in the emergency department[J]. *J Med Toxicol*, 2018, 14(3): 248–252.
- [42] Delahanty RJ, Kaufman D, Jones SS. Development and evaluation of an automated machine learning algorithm for in-hospital mortality risk adjustment among critical care patients[J]. *Crit Care Med*, 2018, 46(6): 481–488.
- [43] Holmgren G, Andersson P, Jakobsson A, et al. Artificial neural networks improve and simplify intensive care mortality prognostication: a national cohort study of 217, 289 first-time intensive care unit admissions[J]. *J Intensive Care*, 2019, 7(1): 44.