

# 人工智能技术辅助诊疗脓毒症专家共识

人工智能技术辅助诊疗脓毒症共识专家组

通信作者：洪玉才，浙江大学医学院附属邵逸夫医院，Email:3416234@zju.edu.cn；

马岳峰，浙江大学医学院附属第二医院，Email: 2193017@zju.edu.cn

DOI:10.3760/cma.j.issn.1671-0282.2022.12.003

脓毒症是一种常见的由感染引起的脏器功能障碍综合征，可显著增加致残率和病死率，同时，脓毒症也是患者入住 ICU 的一个重要危险因素<sup>[1]</sup>。脓毒症诊治难点在于疾病的异质性，即不同的脓毒症患者可表现为不同的临床表现以及对某种治疗的不同反应，这给临床诊疗和研究带来巨大挑战。脓毒症发生发展机制较为复杂，特别是急危重脓毒症患者，其临床诊治过程中会产生大量的数据，包括生命体征、呼吸力学、体液样本检验、影像学等数据，而人类直觉对于这些数据并不能很好地整合，因此可能无法及时发现潜在的风险。

人工智能是用来研究、开发用于模拟、延伸和扩展人类智能的理论、方法、技术的一门新的技术科学。目前，人工智能已经在各行各业发挥了重要作用。在医学方面，人工智能技术在影像诊断、病理诊断中表现出了超过高年资医生的诊断水平<sup>[2-3]</sup>，因此具有重要的应用前景。人工智能技术在脓毒症患者诊疗方面也具有较好的应用前景，例如文献<sup>[4]</sup>表明，基于人工智能或规则的脓毒症早期预警能显著缩短抗菌药物使用时间，从而降低住院病死率。在脓毒症液体复苏方面，基于人工智能技术的液体推荐也初步表现出了较好的结果。虽然已经有大量文献报道应用人工智能技术来辅助脓毒症的诊断与治疗，但临床医师对于这类技术缺乏深刻认识，因此我们联合国内权威专家制定本共识，以期提供最佳的临床实践证据。

## 1 共识制定过程与推荐依据

本共识由来自全国急诊医学、重症医学、流行病学、循证医学、医学信息学等学科的专家组成多学科团队，结合国内外最新研究进展和相关指南及共识，通过函审、现场讨论会等方式，反复讨论、修改，最终定稿。专家组首先进行系统的文献检索，按照 PICO (population, intervention, control, outcome) 标准，对于每条推荐项目均按照人群 (population)、干预 (intervention)、对照 (control)、结局 (outcome) 四个角度进行文献检索，其中 P 定义为脓毒症人群，干预定义为一些人工智能辅助下的诊疗策

略，对照组为常规治疗，结局定义为病死率、ICU 住院时长、机械通气时间等。数据库包括 PubMed、Scopus、Embase®、Cochrane Central Register of Controlled Trials (CENTRAL)、Web of Science, MedRvix、万方数据库、中国知网 (CNKI) 等。检索关键词包括脓毒症、机器学习、人工智能、预后、早期预警、强化学习等。详细检索策略可参考专家组前期发表的系统评价<sup>[5]</sup>，该系统评价遵循 PRISMA (preferred reporting items for systematic reviews and meta-analyses) 报告规范。收集使用人工智能辅助诊疗脓毒症的相关文献，包括系统评价、论著 (包括 RCT 及观察性研究)，必要时进行荟萃分析以合并证据。根据 GRADE (grading of recommendations assessment, development and evaluation) 标准对每条推荐意见制定证据质量表格，文献证据分为 A、B、C、D 种 (表 1)，同时结合证据质量通过 Delphi 法达成共识并形成强 (1) 或弱 (2) 推荐。共识专家组通过 3 轮的专家在线讨论或书面收集建议，每一轮讨论均附上上一次讨论后共识的结果，最后每条建议通过 80% 以上专家认可即进行推荐。

表 1 GRADE 证据级别分类标准

质量等级	定义
A	非常确信真实的效应接近估计效应。
B	对效应估计值有中等程度信心，真实值有可能接近估计值，但仍存在二者大不相同的可能。
C	对效应值估计值确信程度有限，真实值可能与估计值大不相同。
D	对效应估计值几乎没什么信心，真实值很可能与估计值大不相同。

## 2 人工智能技术在脓毒症早期预警中的应用

在 Sepsis-3 中，脓毒症被定义为由于宿主对感染的反应失调而导致的危及生命的器官功能障碍<sup>[6]</sup>。如果能在脓毒症早期进行预警并且进行个体化干预，则可以有效降低脓毒症患者病死率。目前多种临床变量和工具可用于脓毒症筛查<sup>[7]</sup>，如全身炎症反应综合征 (SIRS) 标准、快速序贯器官衰竭评分 (qSOFA) 或序贯器官功能衰竭评估 (SOFA) 标准、国家早期预警评分 (NEWS) 或改良早期预警评分

(MEWS) 等, 但这些风险评分对于脓毒症的早期筛查缺乏足够的敏感性和特异性, 因此需要开发新的用于脓毒症早期筛查的工具或方法。

### 2.1 人工智能技术对急诊科患者脓毒症的早期预警

急诊科通常接收患有不同专科疾病的患者, 因此人群异质性较大。急诊科通常较为拥挤, 医务人员工作负荷较重, 一些细微的生命体征变化容易被忽视, 因此有学者开发了能够嵌入于电子病历的早期预警系统来辅助医生早期快速识别脓毒症患者。这类系统包括基于机器学习的预警系统和基于规则的预警系统: 前者采用各类生命体征的变化来辅助预测脓毒症发生, 因此这类预测方法通常在脓毒症还未发生时提供预警; 后者通常根据脓毒症诊断标准, 如 SIRS 标准、qSOFA 标准, 进行预警, 预警时脓毒症尚未发生。

通过系统检索文献, 共获得了 12 项评估脓毒症早期预警系统在急诊科应用的研究, 其中包括 1 项 RCT<sup>[8]</sup> 和 11 项前后对照研究<sup>[9-19]</sup>。对所有文献进行了荟萃分析, 并形成 GRADE 证据表格 (表 2), 同时通过评估早期预警系统对急诊患者住院病死率和住院时间的影响来作出推荐意见。发现, 急诊科脓毒症早期预警能显著降低住院病死率 ( $OR = 0.68$ ;  $95\%CI: 0.51\sim 0.90$ ), 缩短 ICU 住院时间 ( $MD = -0.15$ ,  $95\%CI: -0.59\sim 0.29$  d) 和总住院时间 ( $MD = -2.65$ ;  $95\%CI: -5.81\sim 0.51$  d)。由于这些文献主要是基于前后对照研究, 混杂因素不能排除, 且 RCT 实施过程中盲法不能很好遵循, 因此我们评估该推荐证据质量为 C 级, 为弱推荐。

**推荐意见 1** 建议在急诊科进行脓毒症早期预警 (2C)。

### 2.2 人工智能技术对 ICU 患者脓毒症的早期预警

相对于急诊科患者, ICU 患者可以获得更多的监护数据, 因此更有利于机器学习等算法的实施应用, 但针对 ICU 患者进行脓毒症预警是否能改善患者病死率尚有争议, 各个研究之间异质性较大。检索到 6 项探讨 ICU 病房实施脓毒症早期预警系统的研究<sup>[20-25]</sup>, 并形成 GRADE 证据表格 (表 3), 但这些研究未发现脓毒症早期预警能显著改善患者病死率 ( $RR=0.9$ ;  $95\%CI: 0.73\sim 1.11$ )、ICU 住院时间和总住院时间。另外, 应用脓毒症预警系统可导致频繁报警, 导致医务人员产生警报疲劳, 影响正常医疗工作, 因此, 基于现有证据不建议在 ICU 应用脓毒症早期预警系统。

**推荐意见 2** 不建议对 ICU 患者应用脓毒症早期预警系统 (2C)。

### 2.3 人工智能技术对普通病房患者脓毒症的早期预警

通过系统检索文献, 一共获得 10 项评估脓毒症早期预警系统在普通病房患者中应用的前后对照研究<sup>[26-35]</sup>。对所有文献进行了荟萃分析, 并形成 GRADE 证据表格 (表 4)。通过评估早期预警系统对于普通病房患者住院病死率、住院时间的影响来作出推荐意见。结果发现, 普通病房脓毒症早期预警能显著降低住院病死率 ( $RR = 0.71$ ;  $95\%CI: 0.66\sim 0.76$ ), 缩短 ICU 住院时间 ( $MD = -0.08$ ;  $95\%CI: -0.17\sim 0.01$  d) 和住院时长 ( $MD = -0.81$ ;  $95\%CI: -1.19\sim 0.43$  d)。由于这些文献主要是基于前后对照研究, 混杂因素不能排除, 因此专家组评估该推荐的证据质量为 C 级, 为弱推荐。

**推荐意见 3** 建议对普通病房患者应用脓毒症早期预警系统 (2C)。

表 2 脓毒症早期预警对急诊科患者疗效的证据质量评价

参数	确定性评估							患者例数		疗效		确定性	重要性
	研究数量 (项)	研究设计	偏倚风险	不一致性	间接性	精确性	其他考虑因素 (注意事项)	干预	对照	相对	绝对		
										95% CI	95% CI		
病死率	12	观察性研究	严重 <sup>a</sup>	非常严重 <sup>b</sup>	不严重	不严重	强烈怀疑存在发表偏倚 所有可能的残余混杂因素可降低真实效果 <sup>c</sup> 有较强的关联 (强相关)	339/6 671 (5.1%)	959/15 056 (6.4%)	比值比 0.68 (0.51~0.90)	每 1 000 人减少 19 人死亡 (-30 到 -6)	⊕○○○	关键
ICU 住院时长	1	随机试验	不严重	不严重	不严重	不严重	所有可能的残余混杂因素可降低真实效果	285	313	-	MD -0.15 <sup>d</sup> (-0.59 到 0.29)	⊕⊕⊕⊕	不重要
住院时长	8	观察性研究	严重 <sup>d</sup>	严重 <sup>e</sup>	不严重	不严重	有较强的关联 (强相关)	10 192	18 691	-	MD -2.65 <sup>d</sup> (-5.81 到 0.51)	⊕⊕⊕○	重要

注: CI: confidence interval; MD: mean difference; OR: odds ratio;<sup>a</sup> 这些纳入 Meta 分析的研究主要是前后对照研究, 多数研究纳入患者基线资料不均衡; <sup>b</sup> 研究之间有较大的异质性 ( $I^2=87\%$ ;  $P<0.01$ ); <sup>c</sup> 轮廓强化的漏斗图发现发表偏倚; <sup>d</sup> 研究前后队列人群选择存在较大偏倚; 患者无盲法, 治疗上也会产生偏倚; <sup>e</sup> 研究之间异质性较大 ( $I^2=88\%$ ;  $P<0.01$ )

表 3 脓毒症早期预警对 ICU 患者疗效的证据质量评价

参数	确定性评估							患者例数		效果		确定性	重要性
	研究数量(项)	研究设计	偏倚风险	不一致性	间接性	精确性	其他考虑因素(注意事项)	干预	对照	相对 95% CI	绝对 95% CI		
病死率	6	观察性研究	严重 <sup>a</sup>	不严重	不严重	不严重	无	291/1 765 (16.5%)	257/1 460 (17.6%)	危险比 0.90 (0.73 ~ 1.11)	每 1 000 人减少 16 人死亡 (-44 ~ 17)	⊕⊕⊕○	关键
住院时长	4	观察性研究	严重 <sup>b</sup>	严重 <sup>c</sup>	不严重	严重 <sup>d</sup>	所有可能的残余混杂因素可降低真实效果	1 772	1 483	-	MD -3.24 <sup>d</sup> (-8.56 ~ 2.09)	⊕⊕○○	重要
ICU 住院时长	5	观察性研究	严重 <sup>a</sup>	严重 <sup>c</sup>	不严重	严重 <sup>d</sup>	强烈怀疑存在发表偏倚 所有可能的残余混杂因素可产生虚假效应,而不能观察~效果 <sup>e</sup>	1 772	1 483	-	MD -4.55 <sup>d</sup> (-11.53 ~ 2.44)	⊕○○○	重要

注: CI: confidence interval; MD: mean difference; OR: odds ratio; <sup>a</sup>前后对照研究患者基线水平不一致,有较多混杂因素; <sup>b</sup>混杂因素较多,有些研究报道存在偏倚; <sup>c</sup>根据统计量  $I^2=99%$ ,说明研究之间异质性较大; <sup>d</sup>合并结果的置信区间较大; <sup>e</sup>:潜在发表偏倚,漏斗图不对称

表 4 脓毒症早期预警对住院患者疗效评估研究的证据质量评估

参数	确定性评估							患者例数		效果		确定性	重要性
	研究数量(项)	研究设计	偏倚风险	不一致性	间接性	精确性	其他考虑因素(注意事项)	干预	对照	相对 95% CI	绝对 95% CI		
病死率	10	观察性研究	严重 <sup>a</sup>	非常严重 <sup>b</sup>	不严重	不严重	所有可能的残余混杂因素可降低真实效果 所有可能的残余混杂因素可降低真实效果 <sup>c</sup>	2 222/69 933 (3.2%)	1 719/24 167 (7.1%)	相对危险度 0.73 (0.60 ~ 0.91)	每 1 000 人减少 19 人死亡 (-28 ~ -6)	⊕⊕○○	关键
住院时长	4	观察性研究	严重 <sup>b</sup>	非常严重 <sup>c</sup>	不严重	不严重	有较弱的关联(强相关) 所有可能的残余混杂因素可降低真实效果	5 556	4 610	-	MD -0.08 d (-0.17 ~ 0.01)	⊕⊕⊕○	关键
ICU 住院时长	6	观察性研究	严重 <sup>a</sup>	非常严重 <sup>d</sup>	不严重	不严重	有较弱的关联(强相关)	5 721	4 866	-	MD -0.81 d (-1.19 ~ -0.43)	⊕⊕○○	重要

注: CI: confidence interval; MD: mean difference; OR: odds ratio; <sup>a</sup>纳入分析的研究主要是前后对照研究,并且研究中较多的混杂因素难以控制; <sup>b</sup>  $P < 0.0001$ ;  $I^2 = 79%$ ,说明报道研究之间异质性较大; <sup>c</sup>  $P < 0.00001$ ;  $I^2 = 97%$ ,说明报道研究之间异质性大; <sup>d</sup>  $P = 0.0004$ ;  $I^2 = 78%$ ,说明报道研究之间异质性大

### 3 脓毒症亚型诊断

脓毒症的异质性给临床诊疗和研究设计带来了巨大挑战,因此有很多研究针对脓毒症患者进行了亚型区分。根据不同的数据类型(如临床生化检测数据、蛋白质组学数据等),将脓毒症分成不同的亚型。基于免疫相关的转录组学测序数据,采用深度学习结合非监督学习技术,脓毒症

可以分为高炎症反应型和免疫抑制型<sup>[36]</sup>,其中糖皮质激素的使用会增加免疫抑制型脓毒症的病死率。根据常规收集的临床电子病历数据,脓毒症可以分为 4 个亚型,其中前 48 h 给予较多的液体对于亚型 III 患者能降低病死率<sup>[37]</sup>。根据临床研究队列数据,并基于非监督学习算法可以将脓毒症分为  $\alpha$ 、 $\beta$ 、 $\gamma$  和  $\delta$  四个亚型,其中  $\delta$  亚型患者病死率可达 40%,而  $\alpha$  亚型病死率为 5%。根据计算机模拟技

术显示, α 型患者对于早期目标指导性治疗 (EGDT) 获益更明显, 而 δ 患者使用依立托仑可能会增加病死率<sup>[38]</sup>。目前并未见关于脓毒症分型的前瞻性随机对照疗效研究, 因此并没有直接证据表明采用机器学习策略进行脓毒症分型能改善患者预后。通过 GRADE 评价后其证据等级较低, 建议弱推荐。

**推荐意见 4** 建议采用非监督学习算法对脓毒症进行亚型区分, 以协助预测预后及指导治疗 (2D)。

#### 4 人工智能技术在脓毒症治疗中的应用

脓毒症确诊后需要根据病情进行一系列干预治疗, 例如在急诊科需要进行集束化治疗, 包括早期使用抗生素、留取血培养、早期液体复苏、乳酸监测, 并且提出 EGDT (early goal directed therapy) 概念。目前在脓毒症的整个治疗过程中, 有几个较为重要治疗方向, 包括脓毒症集束化治疗策略、容量反应性预测、个体化的液体治疗方案、抗生素的精准选择与使用、脓毒症凝血病血栓调节蛋白的使用、以及个体化机械通气。目前在这几个方面都已有较多人工智能应用的报道, 但文献的质量不一, 结论异质性较大, 在本指南中, 专家组对文献进行了收集和总结, 梳理 GRADE 证据质量表格, 并形成专家推荐意见。

##### 4.1 计算机辅助决策对脓毒症确诊患者集束化治疗的预警

在繁忙的临床工作中, 医护人员有时难以在每个重要时间节点完成相应治疗, 容易贻误治疗, 采用电子病历辅助预警系统帮助改善集束化治疗的依从性有一定的价值。通过

系统检索文献, 共纳入 8 项探讨通过计算机辅助决策系统改善脓毒症集束化治疗实施依从性的研究<sup>[11, 14, 16, 18-19, 21, 24-25]</sup>。通过荟萃分析, 发现干预组呈现较低的病死率 ( $RR=0.63$ ,  $95\%CI: 0.43 \sim 0.94$ ), 且差异有统计学意义, 但 ICU 和住院时间并没有显著改善 (表 5)。综合其他一些研究结果表明, 脓毒症集束化策略执行较差会导致不良结局, 因此推荐使用计算机辅助决策系统以改善治疗的依从性。

**推荐意见 5** 对于已经诊断脓毒症的患者, 推荐使用计算机辅助决策系统以改善治疗的依从性, 从而改善临床预后 (1D)。

##### 4.2 人工智能技术对脓毒症患者液体容量反应性的预测

液体复苏是脓毒症, 特别是脓毒性休克治疗的一项重要内容。合适的液体复苏是降低脓毒症病死率的关键。目前, 虽然诊疗指南要求最初 3 h 的初始复苏液体量为 30 mL/kg, 但是不同患者对液体治疗反应是不同的。通过单一的指标并不能预测液体复苏的反应性, 而人工智能技术能够充分挖掘患者特征, 从而能比较精确地预测液体复苏疗效。从理论上来说, 对于预测有反应的患者, 可以增加液体量, 而对于预测无反应的患者可能需要其他干预措施, 如改善心功能、加用血液净化治疗等。目前已经有较多的文献研究了采用人工智能技术预测脓毒症患者的容量反应性。Bataille 等<sup>[39]</sup>发现, 基于经胸心脏超声获得的血流动力学参数, 通过构建不同的机器学习模型, 并构建临床决策系统 (CDSS), 可以有效预测脓毒症患者的液体容量反

表 5 脓毒症集束化治疗策略依从性的研究的证据质量评估

参数	确定性评估							患者例数		效果		确定性	重要性
	研究数量 (项)	研究设计	偏倚风险	不一致性	间接性	精确性	其他考虑因素 (注意事项)	干预	对照	相对	绝对		
										95% CI	95% CI		
病死率	8	观察性研究	非常严重 <sup>a</sup>	非常严重 <sup>b</sup>	不严重	不严重	所有可能的残余混杂因素可产生虚假效应, 而不能观察~效果 <sup>c</sup> 所有可能的残余混杂因素可产生虚假效应, 而不能观察~效果 <sup>c</sup> 所有可能的残余混杂因素可降低真实效果	886/9 588 (9.2%)	17 625/1 786 (986.8%)	相对危险度 0.63 (0.43 ~ 0.94)	每 1 000 减少 20 人死亡 (-32 ~ -6)	⊕○○○	关键
住院时长	6	观察性研究	非常严重 <sup>a</sup>	非常严重 <sup>b</sup>	不严重	严重 <sup>d</sup>	所有可能的残余混杂因素可产生虚假效应, 而不能观察~效果 <sup>c</sup> 所有可能的残余混杂因素可降低真实效果	9 790	17 735	-	MD -3.13 d (-7.51 ~ 1.26)	⊕○○○	不重要
ICU 住院时长	2	观察性研究	非常严重 <sup>a</sup>	非常严重 <sup>b</sup>	不严重	严重 <sup>d</sup>	无	1 226	962	-	MD 0.87 d (-1.24 ~ 2.99)	⊕○○○	重要

注: CI: confidence interval; MD: mean difference; OR: odds ratio; <sup>a</sup> 前后对照研究有较多的混杂因素难以控制; <sup>b</sup> 研究之间的异质性较大 ( $P<0.01$ ); <sup>c</sup> 漏斗图提示分布不均衡; <sup>d</sup> 置信区间较宽

表 6 基于机器学习的机械通气策略研究的证据质量评估

参数	确定性评估							患者例数		效果		确定性	重要性
	研究数量(项)	研究设计	偏倚风险	不一致性	间接性	精确性	其他考虑因素(注意事项)	干预	对照	相对 95% CI	绝对 95% CI		
脱机成功率	5	观察性研究	严重 <sup>a</sup>	不严重	不严重	严重 <sup>b</sup>	强烈怀疑存在发表偏倚 所有可能的残余混杂因素可降低真实效果 <sup>a</sup>	146/170 (85.9%)	0.00%	比值比 1.47 (0.81 ~ 2.67)	每 1 000 人减少 0 (0 ~ 0)	⊕⊕○○ 低	关键
48 h 再插管率	6	观察性研究	严重 <sup>a</sup>	不严重	不严重	严重 <sup>b</sup>	强烈怀疑存在发表偏倚 所有可能的残余混杂因素可降低真实效果 <sup>a</sup>	14/164 (8.5%)	17/161 (10.6%)	比值比 0.78 (0.37 ~ 1.66)	每 1 000 人减少 21 (-64 ~ 58)	⊕⊕○○ 低	不重要
VAP 发生率	5	观察性研究	非常严重 <sup>a</sup>	不严重	不严重	非常严重 <sup>c</sup>	强烈怀疑存在发表偏倚 <sup>a</sup>	24/114 (21.1%)	0.00%	比值比 0.59 (0.32 ~ 1.11)	每 1 000 人减少 0 (0 ~ 0)	⊕○○○ 很低	重要
机械通气时长	4	观察性研究	非常严重 <sup>a</sup>	严重 <sup>d</sup>	不严重	不严重	强烈怀疑存在发表偏倚 <sup>a</sup>	100	91	-	MD -2.65 <sub>a</sub> (-4.79 ~ -0.51)	⊕○○○ 很低	重要

注：CI: confidence interval; MD: mean difference; OR: odds ratio; <sup>a</sup> 样本量较小且有较多的混杂因素难以控制; <sup>b</sup> 95% 可信区间过线; <sup>c</sup> 可信区间过宽且 RR<0.75; <sup>d</sup> : P<0.01; I<sup>2</sup> = 78%，研究之间异质性较大

应性，其 AUC 数值达到了 0.93 (95% CI : 0.85~1.00)。另外一项利用常规电子病历数据和监护体征训练了五种机器学习模型，其中随机森林的预测精准性最佳 (AUC =0.84)<sup>[40]</sup>。上述研究采用评估心输出量作为容量反应评估的金标准，也有研究用尿量的恢复作为金标准评估容量反应性，结果提示随机森林较传统的广义线性模型能显著提高预测精准度<sup>[41]</sup>。这些模型虽然能提供较高的预测精准度，但是大都缺乏外部验证，其外推性能尚有待于进一步明确。其次，Bataille 等<sup>[39]</sup>推荐的方法需要反复测量标准心超数据，每次测量均需要有超声资质的医师才能实现，需要耗费较大的人力物力，因此在临床上不太容易实现。最后，基于这些预测模型的临床决策系统能否改善患者预后尚未进行研究。综上所述，专家组认为基于机器学习模型的临床决策系统所预测的证据等级不高；目前临床上已有较多简单操作的方法<sup>[7]</sup>，如被动抬腿结合心输出量 (CO) 测量，快速补液后观察每搏量 (SV)、收缩压或脉压的变化，以及针对胸内压变化的 SV 增加进行容量反应性判断等，在临床实际操作效果比较好，因此专家组并不推荐常规使用基于机器学习的临床决策系统来预测脓毒症的液体容量反应性。建议未来开展机器学习预测脓毒症的液体容量反应性的模型优化的研究及并进行验证，并对基于该模型的临床决策系统开展 RCT 研究进行有效性评价。

**推荐意见 6** 不建议常规使用机器学习方法来预测脓毒症患者的液体容量反应性 (2D)。

### 4.3 根据强化学习算法制定最佳液体治疗方案

强化学习是机器学习领域之一，受到行为心理学的启发，主要关注智能体如何在环境中采取不同的行动，以最大限度地提高累积奖励。在脓毒症患者治疗过程中，计算机智能体可以根据患者状态制定最佳液体策略，治疗完成后患者的状态会发生改变，对于新状态计算机机会给出奖励信号。随后，智能体根据新的状态和环境反馈的奖励，按照一定的策略执行新的动作。上述过程为智能体和环境通过状态、动作、奖励进行交互的方式。

目前已经有较多的研究探讨利用计算机推荐最佳液体复苏策略。Komorowski 等<sup>[42]</sup>研究发现，基于强化学习算法的液体复苏策略与医生处方给出的液体复苏策略相比能显著提高系统奖励 (患者获益)。其他研究也证实，当患者接受的液体方案与算法给出的方案相吻合时，其病死率最低<sup>[43-44]</sup>。但目前该类研究主要集中在液体量及血管活性药物的使用，并未报道具体液体种类的选择。这些研究主要采用计算机模拟得出结果，稳定性欠佳<sup>[45]</sup>，该领域尚未开展随机对照临床研究，因此证据质量等级较低，目前无法作出相关推荐。

**推荐意见 7** 基于目前证据，尚无法对强化学习模型来指导脓毒症液体复苏的临床决策系统作出推荐。

### 4.4 根据机器学习算法制定抗生素使用策略

抗生素治疗是脓毒症救治成功的关键<sup>[46]</sup>。抗生素合理使用包括抗生素使用时机、剂量、种类、耐药监测等方面。

机器学习能够充分挖掘各个临床数据之间的复杂关系,较早提示感染的可能,并提示可能的病原菌,因此基于机器学习模型的临床决策系统对于抗生素使用的各个环节均展示出了较好的应用前景。

目前机器学习在预测感染病原体、抗生素耐药等方面表现出了较高的精准度。脓毒症诊治的难点之一在于难以早期预知感染病原体,一般采用经验性治疗,而经验性治疗往往难以第一时间选择合理的抗生素。有研究报道,机器学习算法利用收集的临床数据、以最后培养结果作为金标准,能够将预测精准度提高(AUC=0.93),这为早期合理使用抗生素治疗菌血症提供了重要依据<sup>[47]</sup>。利用临床电子病历信息构建机器学习模型,能够较早准确预测碳青霉烯耐药的发生(AUC=0.846)<sup>[48]</sup>。研究人员也开发了预测真菌感染的机器学习模型,发现其具有较高的敏感性和特异性(C-statistics=0.874±0.003,敏感性84.24%±0.67%,特异性91.00%±2.63%)<sup>[49]</sup>。这些模型缺乏广泛的外部验证,且尚未进行随机对照研究,因此不能确定基于模型的临床决策系统制定的抗生素治疗策略是否能改善患者临床结局以及由此导致的不良并发症。

**推荐意见 8** 根据目前证据,还不能对基于机器学习的抗生素使用策略作出推荐。

#### 4.5 根据非监督学习算法指导血栓调节蛋白的使用

正常血管内皮作为一个屏障,可防止凝血因子、血小板与内皮下的成分接触,从而避免凝血系统的激活和血小板的活化。血管内皮细胞膜上存在着如血栓调节蛋白(thrombomodulin, TM)等生理性抗凝物质, TM与凝血酶结合后可降低凝血酶的凝血活性,而加强其对蛋白C的激活作用。由于激活的蛋白C具有抗凝作用,因此TM是使凝血酶由促凝转向抗凝的重要血管内凝血抑制因子。脓毒症常常合并有凝血功能障碍,导致脓毒症相关性凝血病。目前已有临床研究采用非监督学习算法识别脓毒症亚型,进而研究TM在不同亚型中的作用。研究发现,脓毒症能够分为四个亚型,其中dA型脓毒症临床表现为多系统功能不全和凝血病,而TM对于dA型脓毒症能降低病死率[校正的风险差(RD)=-17.8%(95%CI:-28.7~-6.9%)],该研究结果在另外的队列中也获得了验证<sup>[50]</sup>。另外一项系统评价也发现, TM对于脓毒症相关凝血病患者具有较好的疗效(RR=0.80; 95%CI: 0.65~0.98),而对于普通脓症患者则无显著疗效(RR=0.88; 95%CI: 0.74~1.04)<sup>[51]</sup>。这些研究提示,脓毒症亚型的识别对于TM的使用具有重要的意义,因此建议使用非监督学习算法进行脓毒症亚型的区分,但目前并未有采用前瞻性随机对照研究来评估疗效,以及当前用于TM类的药物在国内上市应用的数量较少,因此证据质

量较差。

**推荐意见 9** 建议采用非监督学习算法识别脓毒症相关凝血病亚型,从而实现TM的精准化治疗(2C)。

#### 4.6 基于机器学习协助脓毒症患者呼吸机脱机

呼吸衰竭是脓毒症患者非常常见的并发症之一,20%~40% ICU脓毒症患者需要机械通气<sup>[52]</sup>。治疗机械通气患者一个重要目标就是如何脱机,目前已有较多的对照研究集中在如何使用基于人工智能模型的临床决策系统协助呼吸机脱机。

一项RCT研究将入住呼吸治疗中心的患者随机分配到常规治疗和人工智能辅助决策治疗组(干预组)。结果发现,人工智能辅助能显著缩短机械通气时间[(38.41±3.35)d vs. (43.69±14.89)d, P<0.001],同时有效降低均次住院费用<sup>[53]</sup>。在另外一项小样本的研究中也发现<sup>[54]</sup>,采用智能化脱机系统能够显著缩短机械通气时间和ICU住院时间,同时未观察到显著并发症发生。虽然上述研究均为RCT研究,但由于纳入的人群为普通危重症患者,并非只针对脓毒症,其证据的直接性有所不足。通过国内文献检索平台收集到7项疗效研究<sup>[55-61]</sup>中,形成GRADE证据表格(表6),结果发现,基于机器学习辅助脓毒症患者脱机的系统能缩短机械通气时长(MD=-2.65; 95%CI: -4.79~0.12),所以该条推荐为弱推荐。

**推荐意见 10** 推荐使用人工智能辅助系统来协助呼吸机脱机(2C)。

## 5 结论

本共识通过系统复习相关文献,并对原始研究开展证据质量评价,通过专家讨论作出每项推荐意见。本共识从脓毒症早期预警诊断、确诊后的集束化策略实施、治疗过程中液体复苏、容量反应性,以及利用强化学习算法进行液体治疗与抗生素使用策略等方面进行了全面探讨。我们认为,大多数针对机器学习在脓毒症中应用的研究只进行了模型训练,很少进行有效的外部验证;而只有极少数前瞻性研究使用了基于这些模型的临床决策系统,因此总体证据质量等级较低,很多条目尚不能作出推荐。我们期待未来更多的基于机器学习模型的临床决策系统用于临床,并开展高质量的RCT研究,为人工智能应用提供高质量证据,从而改善脓毒症患者的临床诊疗结局。另外,目前大多数机器学习模型只给出了变量与结局之间的相关性,未能得出因果关系,也阻碍了机器学习技术在临床上的使用,因此,如何对ML模型进行可解释性的探索成为未来研究方向之一。

**执笔人：**章仲恒、杨杰（浙江大学医学院附属邵逸夫医院）

**专家组成员（排名不分先后）：**马岳峰（浙江大学医学院附属第二医院） 隆云（北京协和医院重症医学科） 彭志勇（武汉大学中南医院重症医学科） 朱长举（郑州大学第一附属医院急诊科） 张东山（中南大学湘雅二医院急诊医学科） 王春亭（山东第一医科大学附属省立医院重症医学科） 马晓春（中国医科大学附属第一医院重症医学科） 吴剑锋（中山大学附属第一医院重症医学科） 杨旻（安徽医科大学第二附属医院重症医学二科） 宋振举（复旦大学附属中山医院急诊科） 张西京（空军军医大学第一附属医院重症医学科） 马林浩（上海长征医院急诊、重症医学科） 廖雪莲（四川大学华西医院重症医学科） 徐峰（山东大学齐鲁医院急诊科） 章仲恒（浙江大学医学院附属邵逸夫医院） 孙鑫（四川大学华西医院循证医学中心） 邢吉红（吉林大学第一医院急诊科） 徐平（自贡市第四人民医院急诊科） 毛智（解放军总医院第一医学中心） 江慧琳（广州医科大学附属第二医院） 苏龙翔（北京协和医院重症医学科） 王昊（山东大学齐鲁医院 ICU） 余跃天（上海交通大学附属仁济医院 ICU） 邵金莲（南方医科大学附属珠江医院） 赵刚（华中科技大学同济医学院附属协和医院急诊科） 韩小彤（湖南省人民医院急诊科） 洪玉才（浙江大学医学院附属邵逸夫医院） 李茜（浙江省人民医院急诊科） 柯路（中国人民解放军东部战区总医院 ICU） 刘国辉（吉林大学第一医院急诊外科） 胡才宝（浙江医院 ICU） 赵光举（温州医科大学附属第一医院急诊科） 詹庆元（中日友好医院呼吸与危重症医学科） 靳英辉（武汉大学中南医院循证与转化医学中心） 雷健波（北京大学医学信息学中心）

**利益冲突** 所有作者均声明不存在利益冲突

#### 参 考 文 献

- [1] 张锦鑫, 沈括, 胡大海, 等. 脓毒症早期诊断和治疗进展 [J]. 中华损伤与修复杂志 (电子版), 2022, 17(1): 76-80. DOI: 10.3877/cma.j.issn.1673-9450.2022.01.014.
- [2] 倪炯, 王培军. 医学影像人工智能的现状与未来 [J]. 中华医学杂志, 2021, 101(7): 455-457. DOI:10.3760/cma.j.cn112137-20201213-03351.
- [3] 徐琰, 胡保全. 浅谈人工智能在乳腺癌领域的应用进展 [J]. 中华乳腺病杂志 (电子版), 2017, 11(5): 257-261. DOI:10.3877/cma.j.issn.1674-0807.2017.05.001.
- [4] 袁琪茜, 陈宇, 杨晓玲, 等. 人工智能决策系统在脓毒症管理中的应用前景 [J]. 中华危重症医学杂志 (电子版), 2021, 14(5): 416-419. DOI: 10.3877/cma.j.issn.1674-6880.2021.05.013.
- [5] Zhang ZH, Chen L, Xu P, et al. Effectiveness of automated alerting system compared to usual care for the management of sepsis[J]. NPJ Digit Med, 2022, 5(1): 101. DOI:10.1038/s41746-022-00650-5.
- [6] Yin J, Chen Y, Huang JL, et al. Prognosis-related classification and dynamic monitoring of immune status in patients with sepsis: a prospective observational study[J]. World J Emerg Med, 2021, 12(3): 185-191. DOI:10.5847/wjem.j.1920-8642.2021.03.004.
- [7] Evans L, Rhodes A, Alhazzani W, et al. Surviving sepsis campaign: international guidelines for management of sepsis and septic shock 2021[J]. Intensive Care Med, 2021, 47(11): 1181-1247. DOI:10.1007/s00134-021-06506-y.
- [8] Tarabichi Y, Cheng A, Bar-Shain D, et al. Improving timeliness of antibiotic administration using a provider and pharmacist facing Sepsis early warning system in the emergency department setting: a randomized controlled quality improvement initiative[J]. Crit Care Med, 2022, 50(3): 418-427. DOI:10.1097/CCM.0000000000005267.
- [9] Gatewood MO, Wemple M, Greco S, et al. A quality improvement project to improve early sepsis care in the emergency department[J]. BMJ Qual Saf, 2015, 24(12): 787-795. DOI:10.1136/bmjqs-2014-003552.
- [10] Narayanan N, Gross AK, Pintens M, et al. Effect of an electronic medical record alert for severe sepsis among ED patients[J]. Am J Emerg Med, 2016, 34(2): 185-188. DOI:10.1016/j.ajem.2015.10.005.
- [11] Arabi YM, Al-Dorzi HM, Alamry A, et al. The impact of a multifaceted intervention including sepsis electronic alert system and sepsis response team on the outcomes of patients with sepsis and septic shock[J]. Ann Intensive Care, 2017, 7(1): 1-10. DOI:10.1186/s13613-017-0280-7.
- [12] Berger T, Birnbaum A, Bijur P, et al. A computerized alert screening for severe sepsis in emergency department patients increases lactate testing but does not improve inpatient mortality[J]. Appl Clin Inform, 2010, 1(4): 394-407. DOI:10.4338/ACI-2010-09-RA-0054.
- [13] Ferreras JM, Judez D, Tirado G, et al. Implementation of an automatic alarms system for early detection of patients with severe sepsis[J]. Enferm Infecc Microbiol Clin, 2015, 33(8): 508-515. DOI:10.1016/j.eimc.2015.01.002.
- [14] Hayden GE, Tuuri RE, Scott R, et al. Triage sepsis alert and sepsis protocol lower times to fluids and antibiotics in the ED[J]. Am J Emerg Med, 2016, 34(1): 1-9. DOI:10.1016/j.ajem.2015.08.039.
- [15] Machado SM, Wilson EH, Elliott JO, et al. Impact of a telemedicine eICU cart on sepsis management in a community hospital emergency department[J]. J Telemed Telecare, 2018, 24(3): 202-208. DOI:10.1177/1357633X17691862.

- [16] Song J, Cho H, Park DW, et al. The effect of the intelligent sepsis management system on outcomes among patients with sepsis and septic shock diagnosed according to the Sepsis-3 definition in the emergency department[J]. *J Clin Med*, 2019, 8(11): E1800. DOI:10.3390/jcm8111800.
- [17] Shah T, Sterk E, Rech MA. Emergency department sepsis screening tool decreases time to antibiotics in patients with sepsis[J]. *Am J Emerg Med*, 2018, 36(10): 1745-1748. DOI:10.1016/j.ajem.2018.01.060.
- [18] Threatt DL. Improving Sepsis bundle implementation times: a nursing process improvement approach[J]. *J Nurs Care Qual*, 2020, 35(2): 135-139. DOI:10.1097/NCQ.0000000000000430.
- [19] Honeyford K, Cooke GS, Kinderlerer A, et al. Evaluating a digital sepsis alert in a London multisite hospital network: a natural experiment using electronic health record data[J]. *J Am Med Inform Assoc*, 2020, 27(2): 274-283. DOI:10.1093/jamia/ocz186.
- [10] Shimabukuro DW, Barton CW, Feldman MD, et al. Effect of a machine learning-based severe sepsis prediction algorithm on patient survival and hospital length of stay: a randomised clinical trial[J]. *BMJ Open Respir Res*, 2017, 4(1): e000234. DOI:10.1136/bmjresp-2017-000234.
- [21] Semler MW, Weavind L, Hooper MH, et al. An electronic tool for the evaluation and treatment of Sepsis in the ICU: a randomized controlled trial[J]. *Crit Care Med*, 2015, 43(8): 1595-1602. DOI:10.1097/CCM.0000000000001020.
- [22] Hooper MH, Weavind L, Wheeler AP, et al. Randomized trial of automated, electronic monitoring to facilitate early detection of sepsis in the intensive care unit[J]. *Crit Care Med*, 2012, 40(7): 2096-2101. DOI:10.1097/CCM.0b013e318250a887.
- [23] Idrees M, MacDonald SP, Kodali K. Sepsis Early Alert Tool: early recognition and timely management in the emergency department[J]. *Emerg Med Australas*, 2016, 28(4): 399-403. DOI:10.1111/1742-6723.12581.
- [24] Croft CA, Moore FA, Efron PA, et al. Computer versus paper system for recognition and management of sepsis in surgical intensive care[J]. *J Trauma Acute Care Surg*, 2014, 76(2): 311-319. DOI:10.1097/TA.0000000000000121.
- [25] Lipatov K, Daniels CE, Park JG, et al. Implementation and evaluation of sepsis surveillance and decision support in medical ICU and emergency department[J]. *Am J Emerg Med*, 2022, 51: 378-383. DOI:10.1016/j.ajem.2021.09.086.
- [26] Austrian JS, Jamin CT, Doty GR, et al. Impact of an emergency department electronic sepsis surveillance system on patient mortality and length of stay[J]. *J Am Med Inform Assoc*, 2018, 25(5): 523-529. DOI:10.1093/jamia/ocx072.
- [27] Benson L, Hasenau S, O' Connor N, et al. The impact of a nurse practitioner rapid response team on systemic inflammatory response syndrome outcomes[J]. *Dimens Crit Care Nurs*, 2014, 33(3): 108-115. DOI:10.1097/DCC.0000000000000046.
- [28] Burdick H, Pino E, Gabel-Comeau D, et al. Effect of a sepsis prediction algorithm on patient mortality, length of stay and readmission: a prospective multicentre clinical outcomes evaluation of real-world patient data from US hospitals[J]. *BMJ Health Care Inform*, 2020, 27(1): e100109. DOI:10.1136/bmjhci-2019-100109.
- [29] Giannini HM, Ginestra JC, Chivers C, et al. A machine learning algorithm to predict severe sepsis and septic shock: development, implementation, and impact on clinical practice[J]. *Crit Care Med*, 2019, 47(11): 1485-1492. DOI:10.1097/CCM.0000000000003891.
- [30] Guirgis FW, Jones L, Esma R, et al. Managing sepsis: electronic recognition, rapid response teams, and standardized care save lives[J]. *J Crit Care*, 2017, 40: 296-302. DOI:10.1016/j.jcrc.2017.04.005.
- [31] McRee L, Thanavaro JL, Moore K, et al. The impact of an electronic medical record surveillance program on outcomes for patients with sepsis[J]. *Heart Lung*, 2014, 43(6): 546-549. DOI:10.1016/j.hrtlng.2014.05.009.
- [32] Na SJ, Ko RE, Ko MG, et al. Automated alert and activation of medical emergency team using early warning score[J]. *J Intensive Care*, 2021, 9(1): 73. DOI:10.1186/s40560-021-00588-y.
- [33] Sawyer AM, Deal EN, Labelle AJ, et al. Implementation of a real-time computerized sepsis alert in nonintensive care unit patients[J]. *Crit Care Med*, 2011, 39(3): 469-473. DOI:10.1097/CCM.0b013e318205df85.
- [34] Umscheid CA, Betesh J, VanZandbergen C, et al. Development, implementation, and impact of an automated early warning and response system for sepsis[J]. *J Hosp Med*, 2015, 10(1): 26-31. DOI:10.1002/jhm.2259.
- [35] Westra BL, Landman S, Yadav P, et al. Secondary analysis of an electronic surveillance system combined with multi-focal interventions for early detection of sepsis[J]. *Appl Clin Inform*, 2017, 8(1): 47-66. DOI:10.4338/ACI-2016-07-RA-0112.
- [36] Zhang ZH, Pan Q, Ge HQ, et al. Deep learning-based clustering robustly identified two classes of sepsis with both prognostic and predictive values[J]. *EBio Medicine*, 2020, 62: 103081. DOI:10.1016/j.ebiom.2020.103081.
- [37] Zhang ZH, Zhang GS, Goyal H, et al. Identification of subclasses of sepsis that showed different clinical outcomes and responses to amount of fluid resuscitation: a latent profile analysis[J]. *Crit Care*, 2018, 22(1): 347. DOI:10.1186/s13054-018-2279-3.
- [38] Seymour CW, Kennedy JN, Wang S, et al. Derivation, validation, and potential treatment implications of novel clinical phenotypes for sepsis[J]. *JAMA*, 2019, 321(20): 2003-2017. DOI:10.1001/jama.2019.5791.

- [39] Bataille B, de Selle J, Moussot PE, et al. Machine learning methods to improve bedside fluid responsiveness prediction in severe sepsis or septic shock: an observational study[J]. *Br J Anaesth*, 2021, 126(4): 826-834. DOI:10.1016/j.bja.2020.11.039.
- [40] Kamaleswaran R, Lian JY, Lin DL, et al. Predicting volume responsiveness among sepsis patients using clinical data and continuous physiological waveforms[J]. *AMIA Annu Symp Proc*, 2020, 2020: 619-628.
- [41] Zhang ZH, Ho KM, Hong YC. Machine learning for the prediction of volume responsiveness in patients with oliguric acute kidney injury in critical care[J]. *Crit Care*, 2019, 23(1): 112. DOI:10.1186/s13054-019-2411-z.
- [42] Komorowski M, Celi LA, Badawi O, et al. The artificial intelligence clinician learns optimal treatment strategies for sepsis in intensive care[J]. *Nat Med*, 2018, 24(11): 1716-1720. DOI:10.1038/s41591-018-0213-5.
- [43] Ma PL, Liu JT, Shen F, et al. Individualized resuscitation strategy for septic shock formalized by finite mixture modeling and dynamic treatment regimen[J]. *Crit Care*, 2021, 25(1): 243. DOI:10.1186/s13054-021-03682-7.
- [44] Peng XF, Ding Y, Wihl D, et al. Improving sepsis treatment strategies by combining deep and kernel-based reinforcement learning[J]. *AMIA Annu Symp Proc*, 2018, 2018: 887-896.
- [45] Lu MY, Shah N, Sow D, et al. Is deep reinforcement learning ready for practical applications in healthcare? A sensitivity analysis of dual-DDQN for hemodynamic management in sepsis patients[J]. *AMIA Annu Symp Proc*, 2020, 2020: 773-782.
- [46] 喻文, 罗红敏. 急诊科不同阶段脓毒症患者抗菌药物使用起始时间与其相关临床结局的关系: 一项前瞻性多中心研究 [J]. *中华危重病急救医学*, 2015(9): 780.
- [47] Garnica O, Gómez D, Ramos V, et al. Diagnosing hospital bacteraemia in the framework of predictive, preventive and personalised medicine using electronic health records and machine learning classifiers[J]. *EPMA J*, 2021, 12(3): 365-381. DOI:10.1007/s13167-021-00252-3.
- [48] McGuire RJ, Yu SC, Payne PRO, et al. A pragmatic machine learning model to predict carbapenem resistance[J]. *Antimicrob Agents Chemother*, 2021, 65(7): e0006321. DOI:10.1128/AAC.00063-21.
- [49] Ripoli A, Sozio E, Sbrana F, et al. Personalized machine learning approach to predict candidemia in medical wards[J]. *Infection*, 2020, 48(5): 749-759. DOI:10.1007/s15010-020-01488-3.
- [50] Kudo D, Goto T, Uchimido R, et al. Coagulation phenotypes in sepsis and effects of recombinant human thrombomodulin: an analysis of three multicentre observational studies[J]. *Crit Care*, 2021, 25(1): 114. DOI:10.1186/s13054-021-03541-5.
- [51] Valeriani E, Squizzato A, Gallo A, et al. Efficacy and safety of recombinant human soluble thrombomodulin in patients with sepsis - associated coagulopathy: a systematic review and meta - analysis[J]. *J Thromb Haemost*, 2020, 18(7): 1618-1625. DOI:10.1111/jth.14812.
- [52] Yang T, Shen YC, Park JG, et al. Outcome after intubation for septic shock with respiratory distress and hemodynamic compromise: an observational study[J]. *BMC Anesthesiol*, 2021, 21(1): 253. DOI:10.1186/s12871-021-01471-x.
- [53] Hsu JC, Chen YF, Chung WS, et al. Clinical verification of a clinical decision support system for ventilator weaning[J]. *Biomed Eng Online*, 2013, 12(Suppl 1): S4. DOI:10.1186/1475-925X-12-S1-S4.
- [54] 马玉杰, 杨晓军, 曹相原, 等. 智能化撤机和经验性撤机的前瞻性随机对照研究 [J]. *中华结核和呼吸杂志*, 2010, 33(3): 174-178. DOI:10.3760/cma.j.issn.1001-0939.2010.03.007.
- [55] 董春丽, 罗莉, 骆立夫. 智能脱机模式与自主呼吸试验在慢性阻塞性肺疾病撤机过程的比较 [J]. *中国临床研究*, 2014, 27(4): 417-418. DOI:10.13429/j.cnki.cjcr.2014.04.012.
- [56] 郭炜妍, 王宝华, 白静, 等. 三种不同脱机方式在慢性阻塞性肺疾病急性加重期中的应用研究 [J]. *中国临床新医学*, 2014, 7(5): 404-407. DOI:10.3969/j.issn.1674-3806.2014.05.06.
- [57] 李德全. 智能化撤机模式在重症患儿中的应用 [J]. *临床麻醉学杂志*, 2014, 30(2): 169-170. DOI:10.3969/j.issn.1001-9057.2005.01.003.
- [58] 梁宏开, 李建伟, 李斌, 等. Smartcare 智能脱机模式在慢性阻塞性肺疾病患者中的运用评价 [J]. *岭南急诊医学杂志*, 2011, 16(3): 218-219. DOI:10.3969/j.issn.1671-301X.2011.03.028.
- [59] 刘旭. 智能脱机模式在外科术后患者的脱机效果观察 [J]. *吉林医学*, 2017, 38(8): 1581-1582. DOI:10.3969/j.issn.1004-0412.2017.08.102.
- [60] 桑岭, 黎毅敏. 智能化与程序化两种撤机模式在慢性阻塞性肺疾病患者中的应用比较 [C]. 中华医学会呼吸病学年会——2013 (第十四次全国呼吸病学学术会议), 中国辽宁大连, F, 2013
- [61] 于湘友, 钟琳. 重症患者两种撤机方式的比较 [J]. *临床麻醉学杂志*, 2011, 27(4): 360-361.

(收稿日期: 2022-11-11)

(本文编辑: 邵菊芳)