· 论著 ·

基于机器学习的充血性心力衰竭患者机械通气撤机结局预测模型构建与评估

安家判[1]　申红梅[1]　徐新琪[1]　杨婷玉[1]　李斌[2]　窦志敏[2]

[1]兰州大学第一临床医学院，兰州 730000；[2]兰州大学第一医院重症医学科，兰州 730000

通信作者：窦志敏，Email：ldyy_douzhimin@lzu.edu.cn

【摘要】 目的 利用机器学习方法构建充血性心力衰竭（CHF）患者机械通气撤机结局的预测模型，评估模型效能，并识别关键影响因素。**方法** 采用回顾性队列研究方法，收集美国重症监护医学信息数据库Ⅳ v3.1（MIMIC-Ⅳ v3.1）中 2008 至 2022 年首次入住重症监护病房（ICU）并接受有创机械通气的 CHF 患者的临床数据。根据撤机结局将患者分为撤机成功组和撤机失败组。通过结构化查询语言（SQL）提取人口统计学资料、生命体征、呼吸机参数、实验室指标等数据，并将数据集按照 7∶3的比例随机分为训练集和验证集。将单因素 Logistic 回归分析中筛选出的有统计学意义的变量纳入多因素 Logistic 回归分析，进一步筛选撤机失败的独立预测因子，并构建决策树（DT）、随机森林（RF）、极限梯度提升（XGBoost）、轻量梯度提升机（LightGBM）、支持向量机（SVM）及人工神经网络（ANN）6 种机器学习模型。以受试者工作特征曲线下面积（AUC）、准确率、精确率、敏感度及 F1 分数评估模型效能，并利用沙普利可加性解释（SHAP）对最优模型进行可视化解读，量化各特征对预测结果的贡献度。**结果** 最终共纳入 2 496 例首次入住 ICU 并接受有创机械通气的 CHF 患者，其中撤机成功组 1 367 例，撤机失败组 1 129 例，总体撤机失败率为 45.23%。经单因素及多因素 Logistic 回归分析，最终筛选出 8 个独立预测因子，其中行气管切开〔优势比（*OR*）=3.194，95% 置信区间（95%*CI*）为 2.169～4.704，*P*<0.001〕、机械通气时间延长（*OR*=1.002，95%*CI* 为 1.001～1.003，*P*<0.001）、肌酸激酶同工酶（CK-MB）升高（*OR*=1.009，95%*CI* 为 1.004～1.013，*P*<0.001）、心肌肌钙蛋白 T（cTnT）升高（*OR*=1.158，95%*CI* 为 1.033～1.298，*P*=0.012）及高龄（*OR*=1.010，95%*CI* 为 1.001～1.019，*P*=0.027）可以增加 CHF 患者撤机失败的风险，为撤机失败的危险因素；而氧合指数（PaO_2/FiO_2）升高（*OR*=0.999，95%*CI* 为 0.998～1.000，*P*=0.014）、24 h 尿量增加（*OR*=0.824，95%*CI* 为 0.760～0.894，*P*<0.001）、格拉斯哥昏迷评分（GCS）升高（*OR*=0.939，95%*CI* 为 0.914～0.966，*P*<0.001）则可以降低撤机失败风险，为撤机成功的保护因素。基于这 8 个预测因子构建的 6 种机器学习模型中，XGBoost 模型在验证集中综合表现最优（AUC=0.775，准确率为 69.8%，精准率为 67.8%，敏感度为 63.0%，F1 分数为 0.653）。SHAP 分析显示，机械通气时间和撤机前 24 h 尿量是影响模型预测的最关键因素，其次为气管切开、cTnT、CK-MB、GCS 评分、PaO_2/FiO_2 和年龄。**结论** 基于 XGBoost 构建的 CHF 患者机械通气撤机失败预测模型可通过机械通气时间、撤机前 24 h 尿量、气管切开、cTnT、CK-MB、GCS 评分、PaO_2/FiO_2 和年龄 8 项临床易获取指标，有效识别 CHF 机械通气患者中的撤机失败高危人群。

【关键词】 充血性心力衰竭；机械通气；撤机；预测模型；机器学习；极限梯度提升算法

DOI：10.3760/cma.j.cn121430-20260606-00273

Development and evaluation of a machine learning-based model for predicting weaning outcomes from mechanical ventilation in patients with congestive heart failure

An Jiapan[1], Shen Hongmei[1], Xu Xinqi[1], Yang Tingyu[1], Li Bin[2], Dou Zhimin[2]

[1]The First School of Clinical Medicine, Lanzhou University, Lanzhou 730000, China; [2]Department of Critical Care Medicine, The First Hospital of Lanzhou University, Lanzhou 730000, China

Corresponding author: Dou Zhimin, Email: ldyy_douzhimin@lzu.edu.cn

【Abstract】 Objective To develop a machine learning-based predictive model for weaning outcomes from mechanical ventilation in patients with congestive heart failure (CHF), evaluate its performance, and to identify key influencing factors. **Methods** A retrospective cohort study was conducted. Clinical data of CHF patients who were first admitted to the intensive care unit (ICU) and received invasive mechanical ventilation between 2008 and 2022 were extracted from the Medical Information Mart for Intensive Care-Ⅳ v3.1 (MIMIC-Ⅳ v3.1) database. Patients were divided into a successful weaning group and a failed weaning group according to weaning outcomes. Data on demographics, vital signs, ventilator parameters, and laboratory indicators were extracted using structured query language (SQL). The dataset was randomly split into a training set and a validation set at a ratio of 7∶3. Variables with statistical significance in univariate Logistic regression analysis were selected and then included in multivariate Logistic regression analysis to further screen the final predictors for weaning failure. Based on the selected variables, six machine learning models, including decision tree (DT), random forest (RF), extreme gradient boosting (XGBoost), light gradient boosting machine (LightGBM), support vector machine (SVM), and artificial neural network (ANN), were constructed. Model performance

was assessed using the area under the receiver operator characteristic curve (AUC), accuracy, precision, sensitivity, and F1-score. SHapley Additive exPlanations (SHAP) values were used to visually interpret the optimal model and quantify the contribution of each feature to the prediction. **Results** A total of 2 496 CHF patients who were first admitted to the ICU and received invasive mechanical ventilation were enrolled finally, including 1 367 in the successful weaning group and 1 129 in the failed weaning group, with an overall weaning failure rate of 45.23%. Through univariate and multivariate Logistic regression analyses, eight independent predictors were identified. Tracheostomy [odds ratio (*OR*)=3.194, 95% confidence interval (95%*CI*) was 2.169-4.704, *P*<0.001], prolonged mechanical ventilation duration (*OR*=1.002, 95%*CI* was 1.001-1.003, *P*<0.001), elevated MB isoenzyme of creatine kinase (CK-MB; *OR*=1.009, 95%*CI* was 1.004-1.013, *P*<0.001), elevated cardiac troponin T (cTnT; *OR*=1.158, 95%*CI* was 1.033-1.298, *P*=0.012), and advanced age (*OR*=1.010, 95%*CI* was 1.001-1.019, *P*=0.027) increased the risk of weaning failure, being considered as risk factors for failure weaning, while higher oxygenation index (PaO_2/FiO_2; *OR*=0.999, 95%*CI* was 0.998-1.000, *P*=0.014), increased 24-hour urine output (*OR*=0.824, 95%*CI* was 0.760-0.894, *P*<0.001), and higher Glasgow Coma Scale (GCS) score (*OR*=0.939, 95%*CI* was 0.914-0.966, *P*<0.001) reduced the risk of weaning failure, being considered as protective factors for successful weaning. Among the six machine learning models, the XGBoost model demonstrated the best comprehensive performance in the validation set (AUC=0.775, accuracy was 69.8%, precision was 67.8%, sensitivity was 63.0%, F1-score was 0.653). SHAP analysis revealed that mechanical ventilation duration and 24-hour urine output before weaning were the most critical factors influencing the model prediction, followed by tracheostomy, cTnT, CK-MB, GCS score, PaO_2/FiO_2, and age. **Conclusions** The XGBoost-based prediction model for weaning failure in CHF patients, incorporating eight readily available clinical indicators, including mechanical ventilation duration, 24-hour urine output before weaning, tracheostomy, cTnT, CK-MB, GCS score, PaO_2/FiO_2, and age, can effectively identify high-risk individuals among CHF patients on mechanical ventilation.

【Key words】 Congestive heart failure; Mechanical ventilation; Weaning; Prediction model; Machine learning; Extreme gradient boosting

DOI: 10.3760/cma.j.cn121430-20260606-00273

充血性心力衰竭（congestive heart failure，CHF）是诸多心脏疾病进展的终末期，是机体在静脉回流充足的情况下，因各种因素造成心脏舒缩功能异常，导致心排血量无法充分满足组织代谢正常需求的一种心脏循环障碍综合征[1]。机械通气是重症监护病房（intensive care unit，ICU）中挽救 CHF 患者生命的重要治疗手段，通过改善肺氧合及降低呼吸肌做功，进而减轻心脏负荷并缓解呼吸衰竭[2]。但是，延长机械通气时间不仅无法改善预后，反而会增加并发症的发生风险[3]。因此，应当在患者病情允许时尽早撤机[4]。但这需要建立在充分评估的基础上，过早撤机同样会导致不良结局，增加再插管率及死亡风险[5]。研究显示，撤机过程可占总机械通气时间的 40% 以上[6]，26%～39% 的机械通气患者在撤机时会出现撤机困难甚至失败[7]。撤机失败不仅容易诱发呼吸机相关性肺炎、膈肌萎缩等严重并发症[8-9]，更与患者病死率显著升高密切相关[10]。由此可见，避免通气依赖和过早撤机，精准把握撤机时机，是改善患者预后的关键。

由于基础泵血功能受损，CHF 患者的心肺储备功能严重下降，心肺交互关系极为脆弱，使撤机过程异常复杂且失败风险显著升高[11]。在撤机时，患者由正压通气转为自主呼吸，引发显著的血流动力学改变，胸腔负压的恢复增加了静脉回流，从而加重了心脏前负荷，左心室跨壁压增大进而增加了后负荷，极易诱发急性心功能失代偿[12-13]。研究证实，合并 CHF 是心源性撤机失败的独立危险因素，其撤机失败率是无心力衰竭患者的 2～3 倍[14]。尽管风险明确，但目前临床尚缺乏针对 CHF 这一特定高危人群的、系统且个体化的撤机评估方案，传统通用评估工具在预测 CHF 患者撤机结局时效能不足。

近年来，机器学习作为人工智能的核心分支，凭借其在处理高维数据、捕捉非线性关系方面的优势，在重症医学领域展现出超越传统统计模型的效能[15]。在机械通气撤机预测领域，已有研究构建了通用预测模型[16-17]，或针对脓毒症[18]、创伤性脑损伤[19]等特定人群开发了专项模型，并验证了其临床价值。然而，针对 CHF 这类有独特病理生理机制的患者，目前仍缺乏相应的精准撤机管理策略。因此，本研究旨在利用机器学习算法，整合 CHF 患者人口学特征、实验室指标、生命体征、呼吸机参数等临床信息，构建并验证患者机械通气撤机结局的预测模型，期望通过筛选关键预测因子并建立模型，辅助临床医生早期识别高危患者，优化撤机决策，提升 CHF 机械通气患者的撤机成功率并缩短机械通气时间。

1　资料与方法

1.1　数据来源：采用回顾性队列研究方法，数据来源于美国麻省理工学院与贝斯以色列女执事医疗中心联合开发的美国重症监护医学信息数据库Ⅳ v3.1（Medical Information Mart for Intensive Care-Ⅳ v3.1，

MIMIC-Ⅳ v3.1)[20]。该数据库对全球医学研究者免费开放,包含 2008 至 2022 年美国马萨诸塞州波士顿贝斯以色列女执事医疗中心 ICU 收治的 94 458 例患者的详细医疗数据。该数据库的建立已获得贝斯以色列女执事医疗中心及麻省理工学院机构审查委员会的伦理批准,原始数据采集过程中豁免患者知情同意,所有个人身份信息已进行匿名化处理,符合相关医学伦理规范。本研究严格遵循《赫尔辛基宣言》原则,并获得兰州大学第一医院伦理委员会审查批准(审批号:LDYYLL2026-746)。本研究作者已完成合作机构培训计划考核(认证编号:68949637),并获得该数据库使用权限。

1.2 研究人群:从 MIMIC-Ⅳ数据库中筛选出首次入住 ICU 并诊断为 CHF 的患者,这些患者均接受了有创机械通气并进行撤机。有创机械通气的定义为接受气管插管或气管切开连接呼吸机辅助通气。本研究将最终纳入的患者根据撤机结局分为撤机成功组和撤机失败组,并进行对照分析。依据目前国际重症医学界广泛采纳的 WIND 撤机失败定义[10]:普通患者停止有创通气后 7 d 内需要重新插管或死亡,或气管切开患者撤机后 7 d 内无法维持自主呼吸,均视为撤机失败;反之,则认为撤机成功。

1.2.1 纳入标准:① 年龄≥18 岁;② 首次入住 ICU,存在多次 ICU 住院记录者纳入首次入住记录;③ 依据国际疾病分类第 9 版 / 第 10 版编码诊断为 CHF;④ 接受有创机械通气治疗。

1.2.2 排除标准:① 有创机械通气时间不足 48 h;② 相应实验室检测结果或研究所需关键数据缺失。

1.3 数据提取:基于 MIMIC-Ⅳ v3.1 数据库,利用 Navicat Premium 16.3.2 软件编写结构化查询语言(structured query language,SQL)进行数据提取。患者的人口统计学变量及合并症提取自首次入 ICU 时;针对撤机前 24 h 的时间窗,生命体征及呼吸机参数取该时段的平均值,而疾病严重程度评分及实验室指标(凝血功能、肾功能、血常规及动脉血气分析指标)则依据临床意义取最差值(最大值或最小值),尿量记录为该时段内的总量,接受连续性肾脏替代治疗(continuous renal replacement therapy,CRRT)者按实际自然尿量计;心肌损伤标志物提取自入 ICU 至撤机前最后一次测量值;治疗干预及机械通气时间则覆盖首次入 ICU 至撤机前整个时间段。

1.4 数据处理及特征筛选:在数据预处理阶段,对原始数据进行清洗,剔除重复样本,将连续变量中超出均值 ±3 倍标准差范围的数值视为异常值并替换为缺失值,删除缺失率超过 40% 的变量。对于缺失率低于 40% 的变量,采用多重插补法进行数据填补,以减少因数据缺失可能导致的信息偏倚。完成数据清洗后,为评估模型泛化能力,将数据集按照 7∶3 的比例随机划分为训练集和验证集。在特征筛选过程中,以撤机结局为因变量,对所有候选变量进行单因素 Logistic 回归分析,筛选出有统计学意义的变量;进行多因素 Logistic 回归分析前,采用方差膨胀因子(variance inflation factor, VIF)评估候选变量间的多重共线性。将变量纳入多因素 Logistic 回归分析,筛选出有统计学意义的变量作为独立预测因子,以校正混杂因素干扰,最终用于构建预测模型。

1.5 模型的构建与评估:构建决策树(decision tree, DT)、随机森林(random forest, RF)、极限梯度提升(extreme gradient boosting, XGBoost)、轻量梯度提升机(light gradient boosting machine, LightGBM)、支持向量机(support vector machine,SVM)、人工神经网络(artificial neural network, ANN)6 种机器学习算法预测模型。为确保模型泛化能力并防止过拟合,建模过程中采用 5 折交叉验证策略对各模型超参数进行网格搜索与优化,通过将训练集随机等分为 5 份,轮流以 4 份训练、1 份验证,实现对模型效能的重复评估。

在验证集中对模型效能进行全面评估,主要指标包括受试者工作特征曲线下面积(area under the receiver operator characteristic curve, AUC)、准确率、精确率、敏感度及 F1 分数。进一步采用决策曲线分析(decision curve analysis, DCA)评估模型的临床实用性,量化不同阈值概率下的净收益;通过校准曲线验证预测概率与实际观察结果的一致性。最终基于上述多维度指标的综合表现,筛选出预测效能最优的模型。为评估模型在不同病因所致呼吸衰竭患者中的稳健性,根据是否合并慢性肺疾病,将验证集分为两个亚组进行敏感性分析;为评估 CRRT 对尿量预测的潜在混杂影响,将验证集按是否接受 CRRT 分组进行敏感性分析。

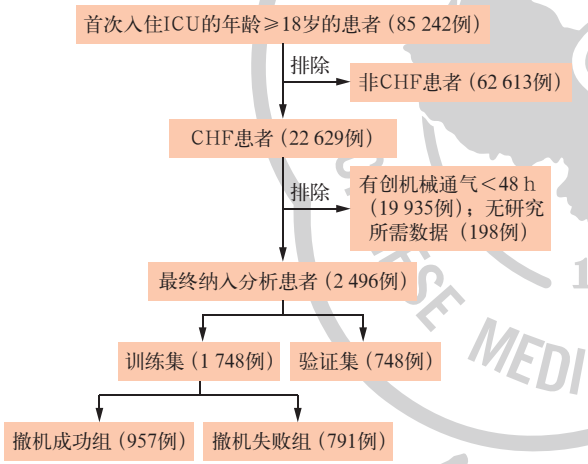
1.6 模型可视化解读:沙普利可加性解释(Shapley Additive exPlanation, SHAP)用于对最优模型的决策过程进行可视化解读,量化各特征对预测结果的贡献度,并展示其对个体患者预测的影响方向与大小,以增强模型的可解释性,为临床决策提供直观参考。

1.7 统计学分析:所有统计分析使用 R 4.5.1 软件完成,使用 Python 3.10.9 软件进行模型构建。连续变

量的正态性通过Kolmogorov-Smirnov检验判断，均为非正态分布，以中位数（四分位数）〔$M(Q_1, Q_3)$〕描述，组间比较采用 Mann-Whitney U 检验；分类变量以频数（百分比）表示，组间比较采用 χ^2 检验。均为双侧检验，检验水准 $\alpha=0.05$。

2　结　果

2.1　基线特征：最终纳入 2 496 例首次入住 ICU 并接受有创机械通气的 CHF 患者（图 1）。在整体纳入人群中，根据撤机结局，撤机成功组 1 367 例，撤机失败组 1 129 例，总体撤机失败率为 45.23%。表 1 显示，纳入的 CHF 患者以老年男性为主，合并慢性肺病和肾脏疾病比例较高，病情较重。与撤机成功组比较，撤机失败组患者年龄更大，肾功能更差，血流动力学更不稳定，呼吸支持条件更高，氧合及通气功能更差，意识水平更低，贫血及炎症反应更重，心肌损伤程度更高。



注：CHF 为充血性心力衰竭，ICU 为重症监护病房

图 1　基于机器学习的 CHF 患者机械通气撤机结局预测模型构建与评估研究对象筛选流程

2.2　特征筛选：在训练集中，将单因素 Logistic 回归分析中有统计学意义的变量进行共线性诊断，结果显示，VIF 值均低于常规警戒阈值（VIF=5），提示无严重多重共线性干扰。多因素 Logistic 回归分析显示（表 2），行气管切开、机械通气时间延长、肌酸激酶同工酶（MB isoenzyme of creatine kinase，CK-MB）和心肌肌钙蛋白 T（cardiac troponin T，cTnT）水平升高及高龄可以增加 CHF 患者撤机失败的风险，为撤机失败的危险因素；而氧合指数（PaO_2/FiO_2）升高、24 h 尿量增加、格拉斯哥昏迷评分（Glasgow Coma Score，GCS）升高则可以降低撤机失败风险，为撤机成功的保护因素。

2.3　机器学习模型效能评估与分析：基于筛选后的特征，在训练集中构建 6 种机器学习算法预测模型。在验证集中对 6 种机器学习模型的预测效能进行全面评估，结果显示，SVM 的 AUC 最高，XGBoost 和 RF 次之，三者区分能力相近；在准确率方面，RF 与 SVM 并列最高，XGBoost 与 ANN 表现接近；就 F1 分数而言，XGBoost、ANN 并列最优，显著优于 DT、LightGBM（表 3；图 2）。校准曲线显示，RF、XGBoost 的预测概率与实际观察结果一致性良好（图 3）；DCA 表明，XGBoost 和 RF 在较广的阈值概率范围内具有较高的临床净收益，且优于其他模型（图 4）。

综合考虑各模型的效能表现及临床实用性，以 XGBoost 最优，其对正类样本的识别能力最强，且在精确率与敏感度之间达到了最佳平衡；尽管 RF 的准确率略高，但 XGBoost 在校准曲线和 DCA 中均表现优异，预测概率可靠性高，临床净收益优于多数模型。亚组分析显示，XGBoost 模型在单纯心源性呼吸衰竭亚组中的 AUC 为 0.782，在心力衰竭合并肺部疾病亚组中的 AUC 为 0.792，提示该模型对两类患者的撤机结局具有较一致的预测能力。在非 CRRT 亚组中 XGBoost 模型 AUC 为 0.784（准确率 70.6%，敏感度 55.1%，F1 分数 0.615），在 CRRT 亚组中 AUC 为 0.779（准确率 70.4%，敏感度 69.0%，F1 分数 0.718），提示模型在两个亚组中的区分能力均保持稳健，且与全体人群结果一致，说明自然尿量本身即具备独立于 CRRT 状态的预测价值。因此，XGBoost 在区分能力、模型平衡性及临床决策支持方面具有更全面的优势，被确定为最优模型。

2.4　XGBoost 模型的可解释性：图 5 显示，机械通气时间和撤机前 24 h 尿量是影响模型预测的关键因素。图 6 进一步揭示了各特征对预测风险的影响方向：机械通气时间、cTnT 及 CK-MB 的高值主要分布在 SHAP 正值区域，这些因素数值越高，撤机失败风险越大；而撤机前 24 h 尿量和 GCS 评分的高值则对应 SHAP 负值区域，提示良好的肾功能和意识状态是撤机成功的保护性因素。

图 7 解析了特征值与 SHAP 值之间的非线性关系。随着机械通气时间延长，SHAP 值呈现快速上升后趋于平稳的趋势，表明长时间机械通气是撤机失败的强预测因子；撤机前 24 h 尿量则呈现相反的非线性下降趋势，当尿量低于特定阈值时，撤机风险显著增加。此外，cTnT 和 CK-MB 均显示出正向的非线性关联，即随着指标数值升高，模型预测的撤机失败风险也随之增加。

表 1　机械通气撤机成功与失败两组 CHF 患者基线特征比较

变量	全体（2 496 例）	撤机成功组（1 367 例）	撤机失败组（1 129 例）	统计量值	*P* 值
人口统计学					
年龄〔岁，$M(Q_1, Q_3)$〕	71.80（62.38，80.04）	71.04（61.19，80.33）	72.34（64.32，79.72）	$Z=-2.505$	0.012
性别〔例（%）〕				$\chi^2=2.910$	0.096
男性	1 446（57.93）	771（56.40）	675（59.79）		
女性	1 050（42.07）	596（43.60）	454（40.21）		
BMI〔kg/m^2，$M(Q_1, Q_3)$〕	28.96（24.41，34.88）	29.21（24.51，35.30）	28.52（24.34，34.49）	$Z=-2.086$	0.135
合并症〔例（%）〕					
脑血管疾病	434（17.39）	224（16.39）	210（18.60）	$\chi^2=2.111$	0.162
肾脏疾病	1 089（43.63）	569（41.62）	520（46.06）	$\chi^2=4.944$	0.029
严重肝病	115（4.61）	53（3.88）	62（5.49）	$\chi^2=3.667$	0.069
慢性肺病	1 023（40.99）	569（41.62）	454（40.21）	$\chi^2=0.458$	0.475
治疗干预〔例（%）〕					
气管切开	288（11.54）	69（5.05）	219（19.40）	$\chi^2=124.746$	<0.001
CRRT	543（21.75）	246（18.00）	297（26.31）	$\chi^2=25.090$	<0.001
机械通气时间〔h，$M(Q_1, Q_3)$〕	113.00（72.42，198.00）	96.17（66.00，159.00）	145.63（87.00，254.22）	$Z=-12.640$	<0.001
生命体征〔$M(Q_1, Q_3)$〕					
心率（次 /min）	84.10（73.72，95.74）	83.80（73.26，95.86）	84.60（74.36，95.56）	$Z=-1.178$	0.239
收缩压（mmHg）	114.99（105.60，126.72）	115.74（105.96，127.60）	114.00（105.30，125.72）	$Z=-1.764$	0.078
舒张压（mmHg）	57.96（51.28，64.88）	57.96（51.17，64.89）	58.12（51.46，64.83）	$Z=-0.106$	0.914
休克指数	0.73（0.61，0.86）	0.71（0.60，0.86）	0.74（0.62，0.86）	$Z=-2.127$	0.033
呼吸频率（次 /min）	19.82（17.17，22.82）	19.81（17.10，22.71）	19.85（17.27，22.88）	$Z=-0.988$	0.323
体温（℃）	36.97（36.72，37.24）	36.97（36.72，37.24）	36.97（36.72，37.24）	$Z=-0.371$	0.766
血氧饱和度	0.977（0.963，0.990）	0.977（0.962，0.990）	0.978（0.964，0.991）	$Z=-1.339$	0.164
呼吸机参数〔$M(Q_1, Q_3)$〕					
FiO_2	0.417（0.400，0.500）	0.412（0.400，0.500）	0.433（0.400，0.511）	$Z=-5.184$	<0.001
PEEP（cmH_2O）	5.00（5.00，7.78）	5.00（5.00，7.40）	5.00（5.00，8.00）	$Z=-4.786$	<0.001
VT（mL）	445.61（377.68，526.35）	448.20（381.06，531.73）	441.85（376.16，519.92）	$Z=-1.103$	0.151
24 h 尿量〔L，$M(Q_1, Q_3)$〕	1.56（0.68，2.77）	1.79（0.78，3.19）	1.28（0.58，2.30）	$Z=-7.075$	<0.001
病情严重程度评分〔分，$M(Q_1, Q_3)$〕					
SOFA 评分	10.00（7.00，12.00）	9.00（7.00，12.00）	10.00（8.00，13.00）	$Z=-4.666$	<0.001
GCS 评分	9.00（5.00，13.00）	10.00（6.00，14.00）	8.00（4.00，11.00）	$Z=-9.085$	<0.001
实验室指标〔$M(Q_1, Q_3)$〕					
SCr（μmol/L）	123.8（79.6，212.2）	123.8（79.6，203.3）	132.6（79.6，221.0）	$Z=-2.489$	0.013
BUN（mmol/L）	12.14（7.50，19.64）	11.42（7.14，18.92）	12.85（7.85，21.06）	$Z=-3.415$	0.001
WBC（$\times10^9$/L）	11.70（8.70，16.10）	11.30（8.50，15.35）	12.20（9.00，17.10）	$Z=-4.185$	<0.001
Hb（g/L）	90（80，102）	91（81，103）	89（79，102）	$Z=-2.372$	0.015
PLT（$\times10^9$/L）	176.00（111.75，248.00）	176.00（109.00，248.00）	176.00（117.00，245.00）	$Z=-1.156$	0.344
K^+（mmol/L）	4.20（3.90，4.60）	4.10（3.90，4.60）	4.20（3.90，4.70）	$Z=-2.460$	0.009
血糖（mmol/L）	7.71（6.42，9.59）	7.62（6.41，9.38）	7.84（6.44，9.92）	$Z=-1.804$	0.062
INR	1.30（1.20，1.70）	1.30（1.20，1.70）	1.40（1.20，1.70）	$Z=-1.994$	0.893
PT（s）	14.90（13.00，18.10）	14.70（12.90，17.90）	14.90（13.20，18.30）	$Z=-1.035$	0.129
APTT（s）	35.90（29.58，58.30）	35.80（29.50，57.20）	36.10（29.60，60.10）	$Z=-0.263$	0.622
Na^+（mmol/L）	140.00（137.00，144.00）	140.00（137.00，144.00）	140.00（137.00，144.00）	$Z=-0.270$	0.863
HCO_3^-（mmol/L）	25.59（23.33，28.29）	25.70（23.34，28.38）	25.50（23.30，28.13）	$Z=-1.098$	0.259
Ca^{2+}（mmol/L）	2.07（1.95，2.17）	2.07（1.95，2.17）	2.07（1.95，2.20）	$Z=-0.198$	0.930
HCT	0.278（0.249，0.315）	0.279（0.251，0.316）	0.276（0.247，0.314）	$Z=-1.376$	0.153
RBC（$\times10^{12}$/L）	3.06（2.69，3.51）	3.08（2.73，3.52）	3.04（2.64，3.50）	$Z=-2.117$	0.032
PaO_2（mmHg）	80.00（54.00，103.00）	81.00（62.00，104.00）	78.00（50.00，102.00）	$Z=-3.959$	0.001
PaO_2/FiO_2（mmHg）	186.00（115.00，255.42）	197.50（120.00，263.58）	176.00（110.00，245.00）	$Z=-4.244$	<0.001
pH 值	7.37（7.32，7.42）	7.38（7.33，7.43）	7.36（7.31，7.41）	$Z=-4.030$	<0.001
BE（mmol/L）	0（−3，3）	0（−3，4）	0（−4，3）	$Z=-2.552$	0.001
$PaCO_2$（mmHg）	45.00（39.00，53.00）	45.00（39.00，53.00）	45.00（39.00，54.00）	$Z=-1.261$	0.978
CK-MB（U/L）	5.00（3.00，11.00）	4.00（2.00，8.00）	6.00（3.00，17.00）	$Z=-9.292$	<0.001
cTnT（μg/L）	0.13（0.05，0.50）	0.10（0.04，0.31）	0.20（0.06，0.90）	$Z=-9.827$	<0.001

注：CHF 为充血性心力衰竭，BMI 为体质量指数，CRRT 为连续性肾脏替代治疗，FiO_2 为吸入氧浓度，PEEP 为呼气末正压，VT 为潮气量，SOFA 为序贯器官衰竭评分，GCS 为格拉斯哥昏迷评分，SCr 为血肌酐，BUN 为血尿素氮，WBC 为白细胞计数，Hb 为血红蛋白，PLT 为血小板计数，INR 为国际标准化比值，PT 为凝血酶原时间，APTT 为活化部分凝血活酶时间，HCT 为血细胞比容，RBC 为红细胞计数，PaO_2 为动脉血氧分压，PaO_2/FiO_2 为氧合指数，BE 为碱剩余，$PaCO_2$ 为动脉血二氧化碳分压，CK-MB 为肌酸激酶同工酶，cTnT 为心肌肌钙蛋白 T；1 mmHg=0.133 kPa，1 cmH_2O=0.098 kPa

GCS 评分和 PaO_2/FiO_2 与 SHAP 值呈负相关，提示更好的意识水平和氧合状态是撤机成功的保护性因素。气管切开与较高的 SHAP 值相关，合并气管切开状态患者撤机失败风险升高。年龄与 SHAP 值的关系呈现 U 型趋势，即过低或过高的年龄都可能增加撤机失败的风险，但整体影响相对平缓。

表 2　CHF 患者机械通气撤机失败危险因素的多因素 Logistic 回归分析

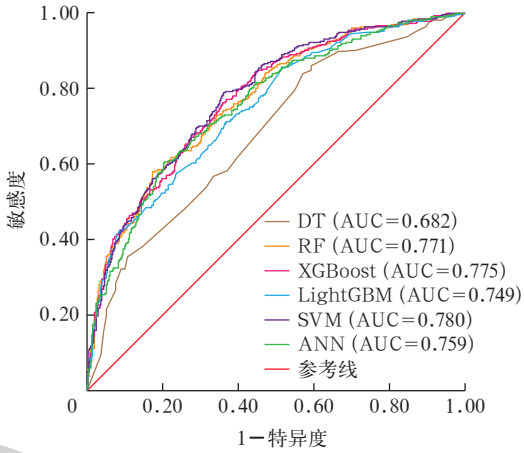
变量	*OR* 值	95%*CI*	*P* 值
高龄	1.010	1.001～1.019	0.027
BMI 升高	0.992	0.980～1.005	0.212
合并肾脏疾病	1.096	0.863～1.392	0.453
行气管切开	3.194	2.169～4.704	＜0.001
使用 CRRT	1.223	0.886～1.690	0.221
机械通气时间延长	1.002	1.001～1.003	＜0.001
FiO_2 升高	1.001	0.997～1.006	0.553
PEEP 升高	1.027	0.985～1.070	0.207
24 h 尿量增加	0.824	0.760～0.894	＜0.001
SOFA 评分升高	0.973	0.938～1.009	0.137
GCS 评分升高	0.939	0.914～0.966	＜0.001
SCr 升高	0.980	0.889～1.080	0.683
BUN 升高	1.003	0.998～1.008	0.183
WBC 升高	0.996	0.984～1.009	0.568
Hb 升高	1.010	0.950～1.074	0.747
PaO_2/FiO_2 升高	0.999	0.998～1.000	0.014
pH 值升高	1.493	0.376～5.937	0.569
BE 升高	1.006	0.981～1.032	0.648
CK-MB 升高	1.009	1.004～1.013	＜0.001
cTnT 升高	1.158	1.033～1.298	0.012

注：CHF 为充血性心力衰竭，BMI 为体质量指数，CRRT 为连续性肾脏替代治疗，FiO_2 为吸入氧浓度，PEEP 为呼气末正压，SOFA 为序贯器官衰竭评分，GCS 为格拉斯哥昏迷评分，SCr 为血肌酐，BUN 为血尿素氮，WBC 为白细胞计数，Hb 为血红蛋白，PaO_2/FiO_2 为氧合指数，BE 为碱剩余，CK-MB 为肌酸激酶同工酶，cTnT 为心肌肌钙蛋白 T，*OR* 为优势比，95%*CI* 为 95% 置信区间

表 3　不同机器学习算法模型对 CHF 患者机械通气撤机失败的预测价值

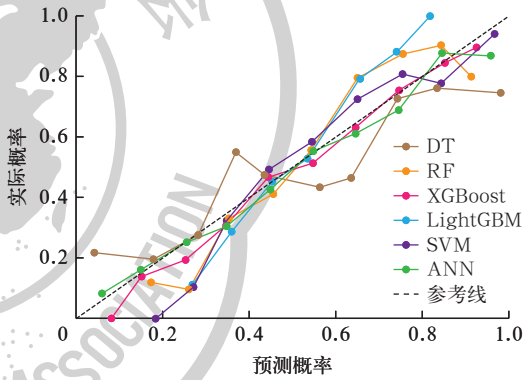
模型	AUC	95%*CI*	准确率（%）
DT	0.682	0.646～0.721	62.2
RF	0.771	0.735～0.805	70.2
XGBoost	0.775	0.741～0.809	69.8
LightGBM	0.749	0.713～0.785	67.5
SVM	0.780	0.748～0.813	70.2
ANN	0.759	0.726～0.793	69.5
模型	**精确率（%）**	**敏感度（%）**	**F1 分数**
DT	58.4	56.8	0.576
RF	70.5	58.6	0.640
XGBoost	67.8	63.0	0.653
LightGBM	69.9	49.4	0.579
SVM	73.9	52.7	0.615
ANN	67.2	63.6	0.653

注：CHF 为充血性心力衰竭，DT 为决策树，RF 为随机森林，XGBoost 为极限梯度提升，LightGBM 为轻量梯度提升机，SVM 为支持向量机，ANN 为人工神经网络，AUC 为受试者工作特征曲线下面积，95%*CI* 为 95% 置信区间



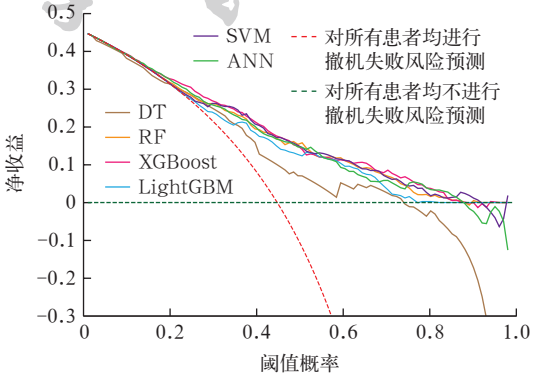
注：CHF 为充血性心力衰竭，ROC 曲线为受试者工作特征曲线，DT 为决策树，RF 为随机森林，XGBoost 为极限梯度提升，LightGBM 为轻量梯度提升机，SVM 为支持向量机，ANN 为人工神经网络，AUC 为 ROC 曲线下面积

图 2　不同机器学习模型预测 CHF 患者机械通气撤机失败的 ROC 曲线



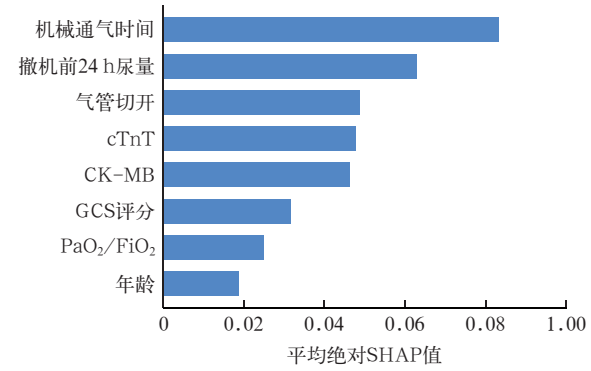
注：CHF 为充血性心力衰竭，DT 为决策树，RF 为随机森林，XGBoost 为极限梯度提升，LightGBM 为轻量梯度提升机，SVM 为支持向量机，ANN 为人工神经网络；曲线越接近参考线，表示校准度越好

图 3　不同机器学习模型预测 CHF 患者机械通气撤机失败的校准曲线



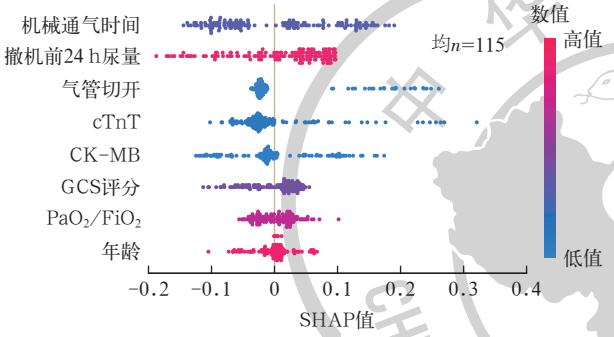
注：CHF 为充血性心力衰竭，DCA 为决策曲线分析，DT 为决策树，RF 为随机森林，XGBoost 为极限梯度提升，LightGBM 为轻量梯度提升机，SVM 为支持向量机，ANN 为人工神经网络；曲线越远离两条虚线，表示临床净收益越高

图 4　不同机器学习模型预测 CHF 患者机械通气撤机失败的 DCA 曲线



注：XGBoost 为极限梯度提升，CHF 为充血性心力衰竭，cTnT 为心肌肌钙蛋白 T，CK-MB 为肌酸激酶同工酶，GCS 为格拉斯哥昏迷评分，PaO_2/FiO_2 为氧合指数，SHAP 为沙普利可加性解释；SHAP 值越大，表示该特征对模型预测的影响越大

图 5　基于 XGBoost 构建的 CHF 患者机械通气撤机失败预测模型中预测特征重要性排序



注：XGBoost 为极限梯度提升，CHF 为充血性心力衰竭，SHAP 为沙普利可加性解释，cTnT 为心肌肌钙蛋白 T，CK-MB 为肌酸激酶同工酶，GCS 为格拉斯哥昏迷评分，PaO_2/FiO_2 为氧合指数；SHAP 正值表示撤机失败风险增加，负值表示撤机失败风险降低

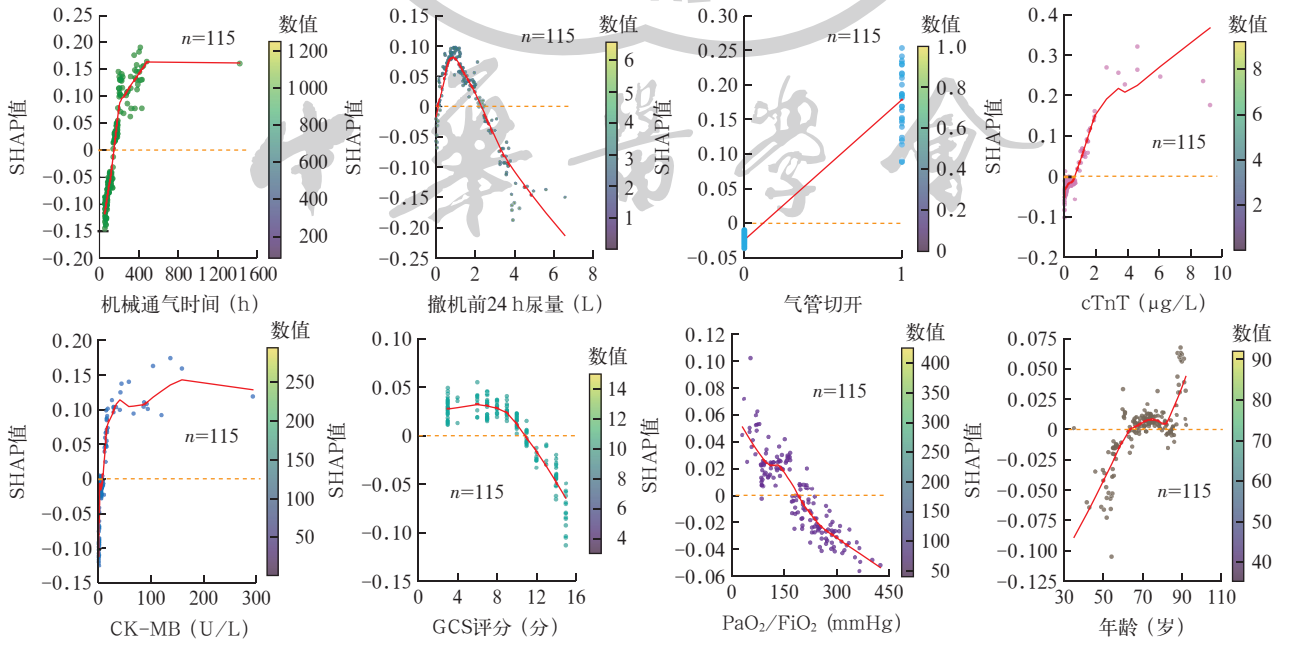
图 6　基于 XGBoost 构建的 CHF 患者机械通气撤机失败预测模型中预测特征的 SHAP 值摘要图

3　讨　论

本研究基于 MIMIC-Ⅳ v3.1 数据库，构建并验证了 DT、RF、XGBoost、LightGBM、SVM 及 ANN 6 种机器学习算法模型对 CHF 患者机械通气撤机结局的预测效能。结果显示，XGBoost 模型展现出最优的综合效能。XGBoost 作为一种基于梯度提升的集成学习算法，在处理高维异质性临床数据、捕捉非线性关系及防止过拟合方面具有显著优势。与传统逻辑回归模型相比，XGBoost 模型能够更精准地识别撤机失败的风险，为 CHF 这一撤机高危人群的临床决策提供了实用工具。

近年来，机器学习在机械通气撤机预测领域的应用日益增多，但现有研究多聚焦于普通 ICU 患者或脓毒症等特定人群，而针对 CHF 这一特殊高危人群的专项模型极为有限。无论是针对普通患者的通用机器学习模型，还是针对特定人群的模型，已有多项研究证实了 XGBoost 的优越性[16,18-19,21-22]。然而，这些研究或是未针对 CHF 患者的心肺交互特点进行优化，或是没有针对 CHF 亚组展开分析，或是未将 CHF 作为独立研究人群，或是预测因子未能充分反映 CHF 患者撤机时心功能代偿的核心矛盾，且上述模型纳入变量较多，临床可解释性相对有限，在实际床旁应用中亦面临一定障碍。

本研究中 XGBoost 模型在预测效能方面与通用模型存在差距，可能原因包括：CHF 患者撤机失败



注：XGBoost 为极限梯度提升，CHF 为充血性心力衰竭，SHAP 为沙普利可加性解释，cTnT 为心肌肌钙蛋白 T，CK-MB 为肌酸激酶同工酶，GCS 为格拉斯哥昏迷评分，PaO_2/FiO_2 为氧合指数；SHAP 正值表示撤机失败风险增加，负值表示风险降低；气管切开中，0 代表“否”，1 代表“是”

图 7　基于 XGBoost 构建的 CHF 患者机械通气撤机失败预测模型中预测特征的 SHAP 依赖图

率高达 45.23%，高于普通 ICU 人群的 26%～39%[7]，病理生理机制更为复杂；CHF 患者心肺交互关系脆弱，撤机失败常源于心源性因素，而现有模型多以呼吸参数为主，对心功能评估不足；本研究模型仅纳入 8 个预测因子，追求临床简洁性的同时，可能牺牲了一定预测精度。然而，本研究的优势在于针对 CHF 人群开展了多算法对比，并通过 SHAP 分析揭示了机械通气时间、撤机前 24 h 尿量、cTnT 等 CHF 特异性预测因子，为后续优化提供了明确方向。同时，亚组分析表明，模型在单纯心源性与合并肺部疾病的 CHF 患者中效能稳定，提示其适用性可能较广。

本研究中通过 SHAP 分析发现，机械通气时间是预测 CHF 患者撤机结局最关键的因素。SHAP 依赖图显示，当机械通气时间超过约 150 h 后，撤机失败风险显著升高。长时间机械通气可导致膈肌萎缩及收缩功能下降。有研究证实，高达 37% 的长期机械通气患者会发生膈肌功能障碍，且与撤机失败独立相关[23-24]。长期机械通气引起的 ICU 获得性肌无力可累及膈肌和辅助呼吸肌，使撤机失败风险增加 2.64～19.07 倍[25]。对于心肺储备差的 CHF 患者，这将显著增加撤机失败的风险。针对机械通气时间位于高风险区间的 CHF 患者，应当采取更为谨慎的撤机策略，并积极实施膈肌保护等干预措施，降低撤机失败风险。

本研究显示，撤机前 24 h 尿量是预测 CHF 患者撤机结局的第二大因素，且与撤机失败风险呈显著负相关。SHAP 依赖图显示，当撤机前 24 h 尿量低于 1.5 L 左右时，撤机失败风险显著上升，证实了容量管理在 CHF 患者撤机中的重要性。机械通气期间，正压通气通过增加胸腔内压减少了静脉回流，并降低了心脏前负荷，可能掩盖了潜在的心功能不全[26]。然而撤机过程中，胸腔负压恢复后，静脉回流导致前负荷升高，且左心室跨壁压增大使后负荷升高[11]。若患者在撤机前未能实现充分的液体负平衡，这种血流动力学的变化可能诱发急性心功能失代偿，进而导致心源性撤机失败。已有研究证实，液体过负荷与心力衰竭及心源性休克危重患者病死率独立相关[27-28]，而针对心肺功能受损患者实施限制性液体管理有助于提高拔管成功率[29]。因此，撤机前 24 h 尿量是判断患者能否承受撤机带来的血流动力学影响的指标。临床中应把尿量监测和液体平衡管理作为撤机前评估的环节。对于尿量偏少、液体呈正平衡的患者，应在撤机前主动通过利尿等方式优化容量状态，为撤机创造更有利的血流动力学条件。有研究证实，利尿剂联合治疗可降低此类患者的死亡风险，提示积极容量管理至关重要[30]。在接受 CRRT 的患者中，尿量受超滤影响，但自然尿量仍直接反映肾脏基础功能和心肾综合征严重程度。排除 CRRT 患者的敏感性分析显示模型 AUC 仍达 0.784，进一步支持了自然尿量对撤机结局的独立预测能力。心排血量下降导致肾灌注不足，肾脏对利尿剂反应减弱，心肾功能形成交叉恶化，这正是 CHF 患者撤机失败的核心病理生理机制之一。因此，模型中尿量的预测价值应被解读为综合了肾衰竭严重性、心肾交互恶化及容量稳态失调的多维信息，而非单纯的容量过负荷信号。同时，本研究未将 CRRT 净超滤量纳入分析，未来可尝试构建统一的“有效容量清除”指标，从而进一步提升模型的合理性。

本研究 SHAP 分析显示，随着 cTnT、CK-MB 水平升高，CHF 患者撤机失败风险也随之升高。撤机过程中，随着胸腔负压恢复，静脉回流与心脏负荷急剧增加，极易诱发心功能失代偿[13]。对于基础泵血功能已经受损的 CHF 患者，这种血流动力学变化可能诱发心肌氧供需失衡，导致心肌缺血甚至心肌损伤，进而引起心功能失代偿，最终导致撤机失败[31]。Konomi 等[32]研究发现，撤机失败组患者 CK-MB 较撤机成功组显著升高，且肌钙蛋白在合并舒张功能障碍的患者中明显升高。Frazier 等[33]在机械通气患者中使用连续心电图监测结合心肌酶谱检测发现，约 70% 在撤机期间出现 ST 段偏移，部分患者伴有 CK-MB 或 cTnI 临床显著性升高，且基线 ST 段改变者撤机失败风险可增加 60%。因此，cTnT 和 CK-MB 作为反映心肌损伤程度的敏感生物标志物，其应被纳入 CHF 患者撤机前的评估体系，从而识别撤机失败高危人群。

本研究中 SHAP 依赖图显示，气管切开与正向 SHAP 值明显相关，即气管切开状态增加了模型对撤机失败的判定倾向。气管切开状态患者可能存在长期通气依赖、气道保护能力受损、分泌物清除困难等情况[34-35]，而这些因素构成了撤机失败的核心病理生理基础。Bishnoi 等[36]研究发现，缺乏有效的咳嗽和吞咽反射及分泌物管理困难是导致撤机失败的常见直接原因。因此，气管切开患者撤机时需要全面评估呼吸肌力、气道保护能力和神经系统功能。

除上述风险因素外，本研究还显示出 GCS 评分升高作为 CHF 患者撤机成功保护性因素的作用。患

者存在意识障碍，即GCS评分低时，会出现呼吸中枢驱动不足、咳嗽反射减弱，导致排痰困难和撤机失败。Vidotto 等[37]研究发现，当患者 GCS 评分低于 8 分时，拔管成功率下降至 33%。随着 GCS 评分下降，咳嗽反射弧受到抑制，呼吸中枢对高碳酸血症和低氧血症的敏感度显著降低，撤机失败风险显著增加[38]。因此，应根据 GCS 评分加强对意识障碍患者的气道管理，并积极采取针对性的干预措施，从而降低撤机失败风险。

本研究显示，PaO_2/FiO_2 与撤机失败风险呈负相关，PaO_2/FiO_2 越低，撤机失败风险越高，说明更好的氧合状态是撤机成功的保护性因素。PaO_2/FiO_2 是评估肺换气功能及肺泡弥散能力的核心指标，可直接反映在给定的 FiO_2 下，肺脏将氧气转运至血液的效率[39]。对于 CHF 患者，心功能不全导致的肺静脉高压和间质性肺水肿是其氧合障碍的主要原因。较高的 PaO_2/FiO_2 提示肺间质水肿程度较轻，肺泡-毛细血管膜的换气功能较好，为患者撤机成功、恢复自主呼吸提供了生理基础；相反，若 PaO_2/FiO_2 持续偏低，则在撤机时更容易发生呼吸肌疲劳、呼吸衰竭等，最终导致撤机失败[40]。在评估 CHF 患者撤机时机时，应将 PaO_2/FiO_2 作为一项关键的呼吸功能筛查指标，积极通过干预手段，使 PaO_2/FiO_2 达到理想水平，从而为成功撤机创造更有利的条件。

本研究通过 SHAP 依赖图观察到年龄与撤机结局呈现 U 型关联趋势，即极高龄与相对低龄患者撤机失败风险均较高。随着年龄增长，人体机能逐渐衰退，导致呼吸储备减少，失代偿风险升高。随着年龄增加，膈肌中Ⅱ型肌纤维减少，并伴有线粒体功能障碍，导致呼吸肌耐力与力量下降，从而在自主呼吸试验中更容易出现膈肌疲劳[41]。老年患者常伴有心功能储备下降、动脉硬化、神经退行性疾病等，加剧了撤机失败风险[42]。对于相对年轻即需入住 ICU 并接受长时间机械通气的 CHF 患者，其撤机失败风险升高则可能更多归因于原发疾病的严重程度，年轻患者因终末期心肌病、暴发性心肌炎等接受机械通气时，可能疾病已进展至危重阶段。

本研究存在一定的局限性。在人群选择方面，本研究未排除术后患者，心脏术后等外科因素虽可能引入一定异质性，但也使模型更贴近真实世界的 CHF 撤机场景；对于已明确放弃治疗或仅接受临终关怀的姑息终末期患者，受限于数据库的回顾性特征，可能仍被纳入，其潜在影响尚有待进一步评估。此外，作为一项基于 MIMIC-Ⅳ数据库的回顾性研究，尽管进行了严格的纳入排除筛选，但仍可能存在选择偏倚；受限于数据库的结构化字段，部分对于心功能评估至关重要的动态参数〔如超声心动图的射血分数动态变化、脑钠肽（brain natriuretic peptide，BNP）或 N 末端脑钠肽前体（N-terminal pro-brain natriuretic peptide，NT-proBNP）的连续监测值〕缺失率较高或无法获取。最后，本研究为单中心数据库研究，尽管样本量充足，但不同医疗中心的撤机拔管标准与心力衰竭管理策略存在差异，因此模型在广泛应用于临床前，尚需在多中心前瞻性队列中进行外部验证。

4　结　论

本研究构建了基于 XGBoost 算法的 CHF 患者机械通气撤机结局预测模型，通过对比 6 种机器学习算法模型发现，XGBoost 模型表现最优，并识别出机械通气时间、撤机前 24 h 尿量、气管切开、cTnT、CK-MB、GCS 评分、PaO_2/FiO_2 和年龄 8 项临床常见且易于获取的影响撤机结局的临床指标，便于床旁实时评估，并通过 SHAP 分析实现了决策过程的可视化，能够有效识别 CHF 机械通气患者中撤机失败的高危人群，辅助临床医生优化撤机决策时机，为 CHF 患者个体化撤机管理提供了有效工具，具有重要的临床应用价值和实用意义。

利益冲突　所有作者声明不存在利益冲突

作者贡献声明　安家判：酝酿和设计实验、实施研究、采集数据、分析/解释数据、起草文章、对文章的知识性内容作批评性审阅、统计分析；申红梅：实施研究、采集数据、对文章的知识性内容作批评性审阅；徐新琪：实施研究、起草文章、对文章的知识性内容作批评性审阅、统计分析；杨婷玉：实施研究、采集数据、对文章的知识性内容作批评性审阅、统计分析；李斌、窦志敏：酝酿和设计实验，分析/解释数据，获取研究经费，行政、技术或材料支持，指导，支持性贡献

参考文献

[1] Ibănescu R, Mîţu DA, Goje ID, et al. History of heart failure definition[J]. Card Fail Rev, 2025, 11: e07. DOI: 10.15420/cfr.2024.22.
[2] ACC Critical Care Cardiology Working Group. Positive pressure ventilation in the cardiac intensive care unit[J]. J Am Coll Cardiol, 2018, 72(13): 1532-1553. DOI: 10.1016/j.jacc.2018.06.074.
[3] ARIAM Andalucía Group. Prolonged mechanical ventilation as a predictor of mortality after cardiac surgery[J]. Respir Care, 2018, 63(5): 550-557. DOI: 10.4187/respcare.04915.
[4] 中华医学会重症医学分会. 机械通气临床应用指南（2006）[J]. 中国危重病急救医学, 2007, 19(2): 65-72. DOI: 10.3760/j.issn:1003-0603.2007.02.002.
[5] Saiphoklang N, Auttajaroon J. Incidence and outcome of weaning from mechanical ventilation in medical wards at Thammasat University Hospital[J]. PLoS One, 2018, 13(10): e0205106. DOI: 10.1371/journal.pone.0205106.
[6] MacIntyre N. Discontinuing mechanical ventilatory support[J]. Chest, 2007, 132(3): 1049-1056. DOI: 10.1378/chest.06-2862.
[7] Ventila Group. Characteristics and outcomes of ventilated patients according to time to liberation from mechanical ventilation[J]. Am

J Respir Crit Care Med, 2011, 184(4): 430–437. DOI: 10.1164/rccm.201011–1887OC.
[8] Thille AW, Richard JC, Brochard L. The decision to extubate in the intensive care unit[J]. Am J Respir Crit Care Med, 2013, 187(12): 1294–1302. DOI: 10.1164/rccm.201208–1523CI.
[9] 秦英智 , 高心晶 . 机械通气脱机重要环节 [J]. 中华危重病急救医学 , 2024, 36(4): 337–339. DOI: 10.3760/cma.j.cn121430–20231120–00991.
[10] WIND (Weaning according to a New Definition) Study Group and the REVA (Réseau Européen de Recherche en Ventilation Artificielle) Network. Epidemiology of weaning outcome according to a new definition. The WIND study[J]. Am J Respir Crit Care Med, 2017, 195(6): 772–783. DOI: 10.1164/rccm.201602–0320OC.
[11] Vignon P. Cardiopulmonary interactions during ventilator weaning[J]. Front Physiol, 2023, 14: 1275100. DOI: 10.3389/fphys.2023.1275100.
[12] Moschietto S, Doyen D, Grech L, et al. Transthoracic echocardiography with Doppler tissue imaging predicts weaning failure from mechanical ventilation: evolution of the left ventricle relaxation rate during a spontaneous breathing trial is the key factor in weaning outcome[J]. Crit Care, 2012, 16(3): R81. DOI: 10.1186/cc11339.
[13] Teboul JL, Monnet X, Richard C. Weaning failure of cardiac origin: recent advances[J]. Crit Care, 2010, 14(2): 211. DOI: 10.1186/cc8852.
[14] Garatti L, Villanova L, Calini A, et al. Heart failure in weaning from mechanical ventilation: post–extubation respiratory failure and cardiac failure[M]//Hieda M, Kasai T, Marini M. Noninvasive ventilatory support in cardiac disorders: acute and long–term applications. Berlin: Springer, 2025: 345–358. DOI: 10.1007/978–3–031–97449–6_31.
[15] Song X, Liu XY, Liu F, et al. Comparison of machine learning and logistic regression models in predicting acute kidney injury: a systematic review and meta–analysis[J]. Int J Med Inform, 2021, 151: 104484. DOI: 10.1016/j.ijmedinf.2021.104484.
[16] Zappalà S, Scaravilli V, Rovati L, et al. Development and validation of a machine learning model for real–time prediction of invasive mechanical ventilation weaning readiness[J]. J Crit Care, 2025, 89: 155105. DOI: 10.1016/j.jcrc.2025.155105.
[17] NU SCRIPT Study Investigators. Developing and validating machine learning models to predict next–day extubation[J]. Sci Rep, 2025, 15(1): 27552. DOI: 10.1038/s41598–025–12264–4.
[18] Song W, Cai GL, Hu CB. Prediction of weaning in mechanically ventilated sepsis patients using interpretable machine learning methods[J]. Heart Lung, 2026, 76: 139–146. DOI: 10.1016/j.hrtlng.2025.11.021.
[19] Cheng YW, Kuo CH, Kuo YH, et al. Predictive value of hematologic indices on weaning from mechanical ventilation and 30–day mortality in patients with traumatic brain injury in an intensive care unit: a retrospective analysis of MIMIC–Ⅳ data[J]. Neurotherapeutics, 2025, 22(3): e00559. DOI: 10.1016/j.neurot.2025.e00559.
[20] Johnson AEW, Bulgarelli L, Shen L, et al. MIMIC–Ⅳ, a freely accessible electronic health record dataset[J]. Sci Data, 2023, 10(1): 1. DOI: 10.1038/s41597–022–01899–x. Erratum in: Sci Data, 2023, 10(1): 31. DOI: 10.1038/s41597–023–01945–2. Erratum in: Sci Data, 2023, 10(1): 219. DOI: 10.1038/s41597–023–02136–9.
[21] Lin MY, Chi HY, Chao WC. Multitask learning to predict successful weaning in critically ill ventilated patients: a retrospective analysis of the MIMIC–Ⅳ database[J]. Digit Health, 2024, 10: 20552076241289732. DOI: 10.1177/20552076241289732.
[22] Ahmed FR, Al–Yateem N, Nejadghaderi SA, et al. Harnessing machine learning for predicting successful weaning from mechanical ventilation: a systematic review[J]. Aust Crit Care, 2025, 38(3): 101203. DOI: 10.1016/j.aucc.2025.101203.
[23] RESCUE–2 Study Group Investigators. Randomized clinical study of temporary transvenous phrenic nerve stimulation in difficult–to–wean patients[J]. Am J Respir Crit Care Med, 2022, 205(10): 1169–1178. DOI: 10.1164/rccm.202107–1709OC.
[24] Virolle S, Duceau B, Morawiec E, et al. Contribution and evolution of respiratory muscles function in weaning outcome of ventilator–dependent patients[J]. Crit Care, 2024, 28(1): 421. DOI: 10.1186/s13054–024–05172–y.
[25] Menis AA, Tsolaki V, Papadonta ME, et al. A study on the diagnostic accuracy of tidal volume–diaphragmatic contraction velocity: a novel index for weaning outcome prediction[J]. Crit Care Med, 2025, 53(6): e1214–e1223. DOI: 10.1097/CCM.0000000000006660.
[26] de Carvalho EB, Battaglini D, Robba C, et al. Fluid management strategies and their interaction with mechanical ventilation: from experimental studies to clinical practice[J]. Intensive Care Med Exp, 2023, 11(1): 44. DOI: 10.1186/s40635–023–00526–2.
[27] Waskowski J, Michel MC, Steffen R, et al. Fluid overload and mortality in critically ill patients with severe heart failure and cardiogenic shock: an observational cohort study[J]. Front Med (Lausanne), 2022, 9: 1040055. DOI: 10.3389/fmed.2022.1040055.
[28] de Carvalho EB, Fonseca ACF, Magalhães RF, et al. Effects of different fluid management on lung and kidney during pressure–controlled and pressure–support ventilation in experimental acute lung injury[J]. Physiol Rep, 2022, 10(17): e15429. DOI: 10.14814/phy2.15429.
[29] Li T, Zhou DW, Zhao D, et al. Association between fluid intake and extubation failure in intensive care unit patients with negative fluid balance: a retrospective observational study[J]. BMC Anesthesiol, 2022, 22(1): 170. DOI: 10.1186/s12871–022–01708–3.
[30] 黄巧漫 , 邹志业 , 林义旭 , 等 . 白蛋白联合利尿剂治疗与既往存在充血性心力衰竭脓毒症患者死亡风险的关系 [J]. 中华危重病急救医学 , 2025, 37(10): 901–908. DOI: 10.3760/cma.j.cn121430–20240812–00693.
[31] de Meirelles Almeida CA, Nedel WL, Morais VD, et al. Diastolic dysfunction as a predictor of weaning failure: a systematic review and meta–analysis[J]. J Crit Care, 2016, 34: 135–141. DOI: 10.1016/j.jcrc.2016.03.007.
[32] Konomi I, Tasoulis A, Kaltsi I, et al. Left ventricular diastolic dysfunction: an independent risk factor for weaning failure from mechanical ventilation[J]. Anaesth Intensive Care, 2016, 44(4): 466–473. DOI: 10.1177/0310057X1604400408.
[33] Frazier SK, Brom H, Widener J, et al. Prevalence of myocardial ischemia during mechanical ventilation and weaning and its effects on weaning success[J]. Heart Lung, 2006, 35(6): 363–373. DOI: 10.1016/j.hrtlng.2005.12.006.
[34] Pierson DJ. Tracheostomy and weaning[J]. Respir Care, 2005, 50(4): 526–533. DOI: 10.4187/respcare.05500526.
[35] Calderone A, Filoni S, De Luca R, et al. Predictive factors of successful decannulation in tracheostomy patients: a scoping review[J]. J Clin Med, 2025, 14(11): 3798. DOI: 10.3390/jcm14113798.
[36] Bishnoi T, Sahu PK, Arjun AP. Evaluation of factors determining tracheostomy decannulation failure rate in adults: an Indian perspective descriptive study[J]. Indian J Otolaryngol Head Neck Surg, 2022, 74(Suppl 3): 4849–4854. DOI: 10.1007/s12070–020–01982–y.
[37] Vidotto MC, Sogame LC, Calciolari CC, et al. The prediction of extubation success of postoperative neurosurgical patients using frequency–tidal volume ratios[J]. Neurocrit Care, 2008, 9(1): 83–89. DOI: 10.1007/s12028–008–9059–x.
[38] da Silva AR, Novais MCM, Neto MG, et al. Predictors of extubation failure in neurocritical patients: a systematic review[J]. Aust Crit Care, 2023, 36(2): 285–291. DOI: 10.1016/j.aucc.2021.11.005.
[39] El Khoury MY, Panos RJ, Ying J, et al. Value of the PaO_2:FiO_2 ratio and rapid shallow breathing index in predicting successful extubation in hypoxemic respiratory failure[J]. Heart Lung, 2010, 39(6): 529–536. DOI: 10.1016/j.hrtlng.2009.10.020.
[40] Kao HC, Lai TY, Hung HL, et al. Sequential oxygenation index and organ dysfunction assessment within the first 3 days of mechanical ventilation predict the outcome of adult patients with severe acute respiratory failure[J]. ScientificWorldJournal, 2013, 2013: 413216. DOI: 10.1155/2013/413216.
[41] Yayan J, Schiffner R. Weaning failure in elderly patients: a systematic review and Meta–analysis[J]. J Clin Med, 2024, 13(21): 6429. DOI: 10.3390/jcm13216429.
[42] Michels–Zetsche JD, Röser E, Ersöz H, et al. Influence of age on outcomes in prolonged weaning from mechanical ventilation[J]. BMJ Open Respir Res, 2025, 12(1): e002730. DOI: 10.1136/bmjresp–2024–002730.

（收稿日期：2026–06–06）
（本文编辑：孙茜）