

基于数据驱动的重症监护病房脱机拔管预测模型的研究

李松倍^{1,2}, 冉宏波³, 贺宏丽^{2,4}, 米金华³, 杨 陈², 沈 俊⁵, 杨皓巍^{2,6}, 卢 森²,
兰蕴平², 宋章伟⁷, 潘 纯², 黄晓波²

1. 成都中医药大学医学与生命科学学院, 四川 成都 611137; 2. 四川省医学科学院·四川省人民医院(电子科技大学附属医院)重症医学科, 四川 成都 610072; 3. 电子科技大学自动化工程学院, 四川 成都 611731; 4. 四川省人民医院蒲江医院·蒲江县人民医院重症医学科, 四川 成都 611630; 5. 青海大学临床医学院, 青海 西宁 810000; 6. 电子科技大学医学院, 四川 成都 610054; 7. 上海术木医疗科技有限公司, 上海 200232

【摘要】 目的 开发并评估一种基于数据驱动的重症监护病房脱机拔管预测模型。**方法** 收集重症监护病房有创机械通气患者的非时序数据、低频生命体征时序数据和高频机械通气时序数据, 采用决策树、朴素贝叶斯、支持向量机、分类集成、广义线性模型和神经网络等算法构建预测模型, 并进行性能评估。**结果** 共纳入 204 例患者, 其中脱机成功患者 122 例, 失败患者 82 例。含有 163 例高频机械通气时序数据的深度神经网络模型在预测脱机拔管成功率方面表现最佳, 准确度 94.2%, AUC 值 0.81, 灵敏度 100%, 特异性 80%。其他模型表现相对逊色, 分类集成模型的准确率 75%, AUC 值 0.76, 灵敏度 83.3%, 特异性 62.5%。**结论** 利用远程高频时序数据建立的深度神经网络模型在预测重症监护病房患者脱机拔管成功率上展现出卓越性能, 明显超越未采用此类数据的模型。

【关键词】 机械通气; 脱机; 机器学习; 神经网络; 深度学习; 时序数据; 远程监测

【中图分类号】 R56

【文献标志码】 A

【文章编号】 1672-6170(2024)04-0057-06

Research on data-driven predictive model for extubation in intensive care unit LI Song-bei^{1,2}, RAN Hong-bo³, HE Hong-li^{2,4}, MI Jin-hua³, YANG Chen², SHEN Jun⁵, YANG Hao-wei^{2,6}, LU sen², LAN Yun-ping², SONG Zhang-wei⁷, PAN Chun², HUANG Xiao-bo² 1. School of Medical and Life Sciences, Chengdu University of Traditional Chinese Medicine, Chengdu, 611137, China; 2. Department of Critical Care Medicine, Sichuan Academy of Medical Sciences · Sichuan Provincial People's Hospital (Affiliated Hospital of University of Electronic Science and Technology of China), Chengdu 610072, China; 3. School of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China; 4. Department of Critical Care Medicine, Sichuan Provincial People's Hospital Pujiang Hospital/Pujiang County People's Hospital, Chengdu 611630, China; 5. School of Clinical Medicine, Qinghai University, Xining 810000, China; 6. School of Medicine, University of Electronic Science and Technology of China, Chengdu 610054, China; 7. Shanghai Shumu Medical Technology Co., Ltd., Shanghai 200232, China

【Corresponding author】 HE Hong-li

【Abstract】 Objective To develop and evaluate a data-driven prediction model for extubation in intensive care unit (ICU). **Methods** Data was collected from ICU patients undergoing invasive mechanical ventilation. The data included non-sequential data, real-time monitored low-frequency vital signs time-series data, and high-frequency mechanical ventilation time-series data. Prediction models were constructed using algorithms such as decision trees, naive Bayes, support vector machines, ensemble classification, generalized linear models, and neural networks. The performance of these models was then evaluated. **Results** A total of 204 patients were included, in which 122 patients were successfully extubated and 82 failed extubation. High-frequency mechanical ventilation time-series data was available for 163 patients, which was used to construct a deep neural network model. This model demonstrated the best performance in predicting extubation success. The accuracy was 94.2%. The area under ROC curve (AUC) was 0.81. The sensitivity was 100%, and the specificity was 80%. Other models showed comparatively inferior performance. The accuracy of the classification ensemble model was 75%, the AUC value was 0.76, the sensitivity was 83.3%, and the specificity was 62.5%. **Conclusions** This study reveals that the deep neural network model, built with high-frequency time-series data, exhibits outstanding performance in predicting extubation success in ICU patients. It significantly surpasses other models without such data.

【基金项目】 四川省卫生健康委员会课题(编号:21PJ082); 四川省科技厅重点研发项目(编号:2022YFS0605)

【通讯作者】 贺宏丽, 女, 博士, 副主任医师, 硕士生导师。中国医师协会体外生命支持分会青年委员, 四川省医学会重症医学专委会青年委员会副主任委员, 四川省中西医结合学会重症医学专委会副主任委员。主要研究方向: 急性呼吸窘迫综合征的发病机制与治疗。

【Key words】 Mechanical ventilation; Extubation; Machine learning; Neural networks; Deep learning; Time-series data; Remote monitoring

有创机械通气在重症监护病房(intensive care unit, ICU)中是至关重要的生命支持手段。然而, 长期的有创机械通气可能会引发严重的并发症, 如

呼吸机相关性肺炎(ventilator associated pneumonia, VAP)和呼吸机诱发肺损伤(ventilator induced lung injury, VILI),同时也会增加患者在ICU的住院时间和医疗成本^[1]。因此,一旦患者原发疾病好转,尽早撤离呼吸机成为临床管理的重要策略。然而,脱机失败(即在脱机拔管后48小时内无法维持自主呼吸或需要重新插管^[2])仍然是一个临床上的重大挑战,其不仅增加了患者的死亡率,还会进一步增加医疗资源的消耗^[3]。

关于脱机拔管的最佳时机,目前存在着不少争议。早期的方法主要依赖于一些生理指标的预测,如吸气负压、呼气正压以及自主呼吸潮气量等,但这些指标不够可靠。自主呼吸试验(spontaneous breathing test, SBT)被广泛认可为有效的脱机策略。尽管如此,仍有高达24%的患者脱机失败,需要再次插管,而这些患者的病死率显著升高^[4]。因此,为了提高脱机成功率并减少脱机失败的风险,发展基于先进技术如人工智能和机器学习的新型预测模型显得尤为重要。这些模型能够综合分析患者的多种数据,包括生理指标、呼吸参数和病史等,以精准预测每位患者的脱机结局,从而为临床医生提供更可靠的决策支持。

本研究旨在开发并评估基于数据驱动的ICU脱机拔管预测模型。特别关注利用远程数据云平台提供的连续高频时序数据的优势,以实时监测患者的机械通气情况,提升预测模型准确性和实用性,从而改善ICU患者的治疗结果和生存质量,最大化临床受益。

1 资料与方法

1.1 一般资料 收集2021年9月至2024年3月在四川省人民医院重症医学中心系统中204例有创机械通气患者的资料。其中男119例,女84例,年龄平均(58.0 ± 15.6)岁。有创机械通气原因主要为:心脏手术94例(46.8%)、非心脏手术64例(31.4%)、脓毒症12例(5.9%)、急性呼吸窘迫综合征12例(5.9%)。纳入标准:①有创机械通气并按计划初次脱机拔管的患者;②使用Mindray监护仪和呼吸机进行实时生命体征监测和呼吸力学监测;③年龄>18岁。排除标准:①合并严重肺部疾病及慢性呼吸衰竭的患者;②非计划脱机或者自主拔管患者。脱机拔管成功定义为拔管后48小时内无需任何形式的通气辅助如无创/有创通气支持、经鼻高流量氧疗^[2]。本研究为单中心、回顾性、观察性研究,经过四川省人民医院伦理委员会批准。

1.2 方法

1.2.1 数据收集 从四川省人民医院医疗系统中

回顾性收集入组患者数据,大致分为时序数据和非时序数据,后者包括基础信息[性别、年龄、体重指数(BMI)、基础疾病(高血压、糖尿病、心脑血管疾病、呼吸系统疾病)]、机械通气原因[心脏手术、非心脏手术、脓毒症、急性呼吸窘迫综合征(acute respiratory distress syndrome, ARDS)、其他、心源性肺水肿、中枢性呼吸衰竭、上气道梗阻]、机械通气时长、拔管前1小时GCS评分及SOFA评分、拔管前24小时内的实验室检查[白细胞计数(WBC)、血细胞比容(Hct)、血红蛋白(Hb)、血小板计数(Plat)、总胆红素(TB)、直接胆红素(DB)、白蛋白(Alb)、谷丙转氨酶(ALT)、谷草转氨酶(AST)、血清肌酐(Cr)、凝血酶原时间(PT)、活化部分凝血活酶时间(APTT)、纤维蛋白原(Fib)、钠离子(Na^+)、钾离子(K^+)]、拔管前1小时、6小时、12小时及24小时的动脉血气分析[pH值、动脉氧分压(PaO_2)、动脉二氧化碳分压(PaCO_2)、标准碳酸氢根(HCO_3^-)、乳酸(Lac)、吸入氧浓度(FiO_2)、氧合指数(P/F)]。

时序数据包括低频的连续生命体征[体温、心率、血氧饱和度(SpO_2)、有创收缩压、有创舒张压]和呼吸机参数[呼气末正压(PEEP)、 FiO_2]、数据平均间隔1小时,还包括从远程数据管理平台中采集的高频呼吸机参数[呼吸机模式、 FiO_2 、潮气量、压力支持水平(PS)、总呼吸频率、PEEP],采样频率1Hz。

1.2.2 数据预处理 在进行特征提取之前,数据集往往需要经过精心的预处理,以确保数据分析的准确性和效率。这涉及多个关键步骤:首先,识别并处理异常值及趋势,将数据值与均值的差异用标准差衡量,以3个标准差为阈值,超出这个范围的值被视为异常值,使用中位数替换异常值。随后填补缺失数据,采用前向填充时间序列中的平稳变量,如呼吸机模式、 FiO_2 、PS、PEEP;接着,实施数据标准化,将所有数据进行对数变换以均衡分布,然后利用最大最小归一化将所有特征值规范到[0, 1]区间,加速模型收敛。这一系列措施共同作用,不仅消除了数据中的噪声和不一致性,还优化了数据结构,为后续的特征提取和模型建立创造了有利条件。

在机器学习中,面对类别特征,如性别、机械通气原因等,采用独热编码技术能准确无误地转换这些信息为模型可读的数值形式。例如,性别通过独热编码转化为两个特征:男性标记为[1, 0],女性为[0, 1],确保每个类别以唯一且无大小比较意义的向量表示,增强了模型处理类别特征的能力。

1.2.3 模型构建 本研究用三种方法进行模型构

建,训练 1 数据采用所有非时序数据和低频时序数据,用六种模型进行构建,采用 Matlab 2023b 软件实现;训练 2 在训练 1 的基础上进行特征筛选和优化,模型构建方法同训练 1;训练 3 数据采用患者所有非时序数据和低频时序数据和高频时序数据,用深度神经网络(DNN)进行模型构建,通过 Python 3.12 软件实现。所有模型构建用 80% 作训练集、10% 验证集数据优化模型超参数,然后在 10% 测试集数据评估模型性能,评估方法包括灵敏度(真阳性率)、特异性(真阴性率)、准确率、受试者工作特征曲线(ROC)与曲线下面积(AUC)。ROC 曲线显示了模型的真阳性率与假阳性率之间的权衡。曲线下的面积(AUC)是评估模型分类性能的重要指标,AUC 值越接近 1,表示分类器性能越好。

训练 1:此次训练所使用的数据包括所有的非时序数据,即患者基本信息、机械通气因素、实验室检测、动脉血气分析;对于低频时序数据如生命体征[体温、心率、血氧饱和度、有创收缩压、有创舒张压]和呼吸机参数[PEEP、FiO₂],提取其平均值、标准差、中位数及四分位间距统计量作为特征。共计 82 个特征变量。数据被分为 80% 训练集、10% 验证集、10% 测试集,并采用 10 折交叉验证结合贝叶斯优化进行超参数调优。模型开发涵盖了决策树、朴素贝叶斯、支持向量机、分类集成、广义线性模型和人工神经网络六种模型。

训练 2:在训练 1 的基础上,运用了三种经典的统计学方法进行特征选择:方差分析、卡方检验以及 Kruskal-Wallis H 检验,通过计算每个特征的 P 值并转换为对应的 $-\log(p)$ 分数以评估其重要性。通过这些方法各自选出最有预测价值的 25 个特征,汇总成 34 个不同的特征用于训练,其余与训练 1 的方法保持一致。这一策略旨在进一步精炼模型,提升预测性能与解释力。

训练 3:本次训练设计了一种高度定制化的多分支深度学习架构,涵盖了 163 名子人群的所有信息,包括非时序数据和时长不一的高低频时序数据,针对不同类型的数据源使用不同的算法及神经网络结构;如针对高频呼吸机参数使用双向 GRU (Gated Recurrent Unit) 循环神经网络结构,直接接收时间序列;对于低频时序数据,先使用快速傅里叶变换算法,通过频域分析将时序数据转换为固定维度的频谱特征后再输入一维卷积神经网络进行抽象特征提取;最后用全连接层进行多分支拼接。训练采用了 Adam 优化器,数据被分为 80% 训练集、10% 验证集、10% 测试集。

2 结果

2.1 患者特征 204 例患者中,脱机成功 122 例(59.8%),脱机失败 82 例(40.2%),在脱机失败组中,单用无创呼吸支持的患者 25 例(12.3%),单用高流量氧疗支持的患者 16 例(7.8%),同时需无创和高流量支持的患者 13 例(6.4%),再插管患者 28 例(13.7%)。

2.2 模型表现 训练 1 建立并测试了决策树、朴素贝叶斯、支持向量机、分类集成、广义线性模型和人工神经网络六种模型,图 1 展示了这六种预测模型在测试集上的 ROC 曲线及其对应的 AUC 值,其中分类集成模型表现最好,AUC 为 0.76,准确率为 75%,灵敏度为 83.3%,特异性为 62.5%。见图 2。




图 1 训练 1 各模型的 ROC 曲线




图 2 分类集成模型混淆矩阵

训练 2 相较于训练 1 采用了统一的模型架构与等量的样本数,其核心差异在于特征数量的减少。具体而言,训练 2 使用三种方法各选出 25 个具有预测价值的特征,结果如表 1 所示,按其评分高低逆向排序, p 代表统计显著性水平。最后,汇总后共计 34 个不重复特征用于构建模型,各模型的准确度与

AUC 显示在表 2 中。值得注意的是,尽管特征数量大幅度削减至初始特征集(82 个特征)的约 40%,这些模型的平均性能并未出现显著衰退。

训练 3 建立了一个深度神经网络模型,准确度为 94.2%, AUC 为 0.81,灵敏度 100%,特异性 80%。见图 3,见图 4。

表 1 训练 2 三种方法特征筛选结果(分数)

特征集 1	卡方检验-log(p)	特征集 2	Kruskal_Wallis-log(p)	特征集 3	方差分析-log(p)
SpO ₂ 标准差	10.4972	SpO ₂ 标准差	16.8454	性别	10.5976
性别	10.2771	性别	10.2280	SpO ₂ 四分位间距	8.4297
氧分压(24h)	6.4822	SpO ₂ 四分位间距	8.9805	PaCO ₂ (24h)	6.5351
PEEP 均值	6.3967	PEEP 均值	8.5051	FiO ₂ (12h)	5.6788
FiO ₂ 标准差	6.3272	SpO ₂ 均值	8.3254	FiO ₂ 均值	5.5696
SpO ₂ 四分位间距	6.0891	PaO ₂ (24h)	7.5960	Na	5.4997
FiO ₂ 均值	5.5079	Na	7.0278	PEEP 均值	5.2555
PaO ₂ (6h)	4.7405	FiO ₂ (12h)	6.7940	非心脏手术	4.7170
非心脏手术	4.6975	呼吸频率标准差	6.3512	PEEP 中位数	4.7038
PEEP 均值	4.6657	Fib	6.2511	SOFA 评分	4.2627
机械通气时长	4.2298	FiO ₂ 均值	6.1990	Fib	3.5544
Fib	4.2233	PEEP 中位数	5.5116	SpO ₂ 中位数	3.5092
FiO ₂ (12h)	4.1984	机械通气时长	5.0868	PEEP 中位数	3.4092
标准 HCO ₃ ⁻ (12h)	3.8519	FiO ₂ 中位数	4.7496	PEEP 标准差	3.3156
FiO ₂ 中位数	3.8385	非心脏手术	4.6768	APTT	3.1370
FiO ₂ 四分位间距	3.4713	FiO ₂ 标准差	4.6132	SpO ₂ 均值	3.1245
呼吸频率均值	3.4469	SpO ₂ 中位数	4.3217	呼吸频率标准差	3.1056
SpO ₂ 均值	3.2561	SOFA 评分	4.2480	PaO ₂ (6h)	2.8084
呼吸频率标准差	3.2106	有创舒张压四分位间距	4.1663	体温均值	2.7947
Lac(12h)	2.8049	BMI	4.1248	有创舒张压四分位间距	2.6748
Na	2.6971	PEEP 标准差	3.9208	PEEP 四分位间距	2.6720
APTT	2.5910	PEEP 四分位间距	3.3597	体温中位数	2.3962
标准 HCO ₃ ⁻ (12h)	2.3145	呼吸频率均值	3.0934	脓毒症	2.2688
脓毒症	2.2795	PaO ₂ (6h)	2.9381	FiO ₂ (6h)	2.2675
SOFA 评分	2.2270	PaO ₂ (12h)	2.9315	心率标准差	2.0609

表 2 各模型在测试集上的表现

模型	训练 1		训练 2	
	准确度(%)	AUC	准确度(%)	AUC
决策树	70	0.69	70	0.69
朴素贝叶斯	65	0.66	75	0.63
支持向量机	65	0.66	50	0.59
分类集成	75	0.76	75	0.75
人工神经网络	60	0.70	60	0.60
广义线性模型	70	0.69	60	0.63




图3 深度学习模型 ROC 曲线




图4 深度学习模型的混淆矩阵

3 讨论

在本研究中,我们成功展示了利用远程高频时序数据训练的深度学习(DNN)模型在预测ICU患者脱机拔管成功率方面的显著优势。与未采用此类数据的其他六种经典机器学习模型相比,DNN模型表现更为出色。值得注意的是,即使在去除48个特征后,其他模型的预测性能并未显著下降,这进一步证明了选择富含预测信息的特征对于提升模型预测性能的重要性,这与机器学习领域的共识相符^[5,6]。DNN模型之所以能够取得更好的表现,关键在于其直接融合了源自远程数据管理云平台的高频时序数据。这些数据包括呼吸机模式、FiO₂、潮气量、PS、呼吸频率等呼吸机参数,并以每秒一次的高频率采集,能够捕捉到反映病情微妙变化的关键信号,这是低频数据难以提供的。其次,除了数据本身,一个预测性能良好的模型还需要能够充分利用这些数据的算法和模型^[5]。本研究设计了一种高度定制化的多分支深度学习架构,对于高频时序数据,采用了双向GRU循环神经网络结构。该结

构擅长捕捉序列数据中的时间依赖关系,帮助模型更全面地理解序列的动态变化,这对于连续高频生理数据的分析尤为重要^[7]。

相比之下,诸如决策树、朴素贝叶斯、支持向量机、分类集成、广义线性模型和初步的人工神经网络等模型在特征构建时更多依赖于低频时序数据的简化统计描述,如生命体征和呼吸机参数的均值、标准差、中位数及四分位间距等。虽然这种统计摘要方法简便易行,有助于减少数据复杂度并简化模型训练过程,但其代价是可能遗漏数据内在的复杂时序结构和动态趋势,从而错失患者生理状态动态变化中的关键节点或周期性模式,而这些信息对于准确预测脱机拔管结果至关重要。因此,DNN模型通过对高频数据的细致分析,不仅彰显了连续实时高频监测数据在脱机拔管预测任务中的核心价值,也体现了先进深度学习技术在处理高维度、时间序列数据方面的卓越能力。

尽管本研究取得了成果,但也存在一些不足之处,包括样本量小、数据来源单一以及特征选择方法的局限性。本研究仅纳入了204名患者,样本量较小,可能影响模型的评价及泛化能力。而且数据仅来源于单一医院的ICU数据库,缺乏多中心数据的验证,这可能限制模型的适用性^[8]。未来研究应收集更多患者数据,通过与其他医院和研究机构合作,建立更大规模的多中心数据库,以提高模型的泛化能力。

未来研究还可以纳入更多有预测价值的特征^[9,10]。一项国外研究通过仅使用自发呼吸试验期间(固定30分钟)从呼吸机获得的大量呼吸机参数来预测脱机结果,模型的AUC达到了0.912^[11]。本机构的远程数据云平台实际上记录了有创机械通气患者的三种呼吸机波形数据(即压力-时间曲线、流速-时间曲线、容量-时间曲线),高频呼吸机参数即来源于此。未来研究可以从这些波形数据中提取更多有用的特征,甚至直接使用原始波形数据进行建模,从而提高模型的预测性能。这还可以减少许多不必要的特征,增强预测模型的临床实用性。另外,本研究的特征选择方法较为通用,没有针对不同的机器学习模型进行单独优化。这可能导致某些模型未能充分利用其结构和学习机制,从而未达到最佳性能。未来研究应采用多种特征选择方法如递归特征消除等,确保为每种模型选择最具代表性的特征,以优化其预测性能^[12]。

本研究中,脱机拔管后 48 小时的再插管率与其他研究相差无几^[2],但 NIV 和高流量吸氧的使用率较高。如果根据国际建议^[2]将这种非侵入性呼吸支持(NRS)在停机拔管后的使用视为失败,那么失败率可高达 40.2%。然而,许多研究并未如此定义,这可能是因为在现在普遍提倡在脱机拔管前预防性使用 NRS^[13],以降低 ICU 患者拔管后呼吸衰竭的发生率^[14]。这种预防性 NRS 在本机构 ICU 中广泛应用,导致 NIV 和高流量吸氧的占比较高。然而,未能明确区分主动和被动 NRS 使用的数据可能会使模型误将预防性 NRS 的使用视为拔管失败,从而影响模型性能。因此,在数据预处理阶段,应明确区分主动和被动使用 NRS 的情况,并在模型中将其作为独立标签处理,避免标签混淆。

此外,当前脱机拔管失败的定义存在不明确之处。拔管失败通常被定义为计划性拔管后数小时或数天内需要重新插管,但具体的时间间隔并不一致(如 48 小时、72 小时或 1 周)。NRS 的使用进一步增加了定义的复杂性。这些定义的不一致性可能导致数据的异质性,从而影响模型的训练、评估及预测值的解读,进而削弱其临床应用的有效性。因此,建议标准化拔管失败的定义,在模型训练和评估中采用统一的标准(如拔管后 48 小时内无需通气支持)以减少数据不一致性;或者引入多层次数据标签,记录拔管后不同时间段的呼吸支持需求和再插管时间,帮助模型更准确地捕捉患者拔管后的真实情况。

综上所述,本研究成功开发了一种基于远程数据云平台的脱机预测模型,通过机器学习技术,并利用实时采集的高频时序数据,在预测 ICU 脱机拔管成功率方面表现出色,显著优于其他传统模型。本研究不仅证明了连续高频监测数据在脱机预测中的重要性,还展示了高级深度学习算法在处理复杂时序数据方面的优势。此外,远程数据云平台的建立能够实时监测患者状态,为模型的自动预测提供有力支持,提高 ICU 的工作效率,减少医务人员的工作负担。未来的研究应扩大样本量,进行多中心验证,纳入更多有价值的特征,优化特征选择方法,并引入多层次标签,以进一步提升模型的能力和临床应用价值。

【参考文献】

- [1] Marini JJ, Rocco PRM, Gattinoni L. Static and dynamic contributors to ventilator-induced lung injury in clinical practice: pressure, energy, and power[J]. *Am J Respir Crit Care Med*, 2020,201:767-774.
- [2] Thille AW, Richard JCM, Brochard L. The decision to extubate in the intensive care unit[J]. *Am J Respir Crit Care Med*, 2013, 187:1294-1302.
- [3] Gershengorn HB. International variation in intubation and extubation practices and adverse events among critically ill patients receiving mechanical ventilation[J]. *JAMA*, 2021,325:1157.
- [4] Perdana Sakti P, Anjarwani S, Prasetya I, et al. Weaning failure in mechanical ventilation[J]. *HSJ*, 2023,4:3-7.
- [5] Deo RC. Machine Learning in Medicine[J]. *Circulation*, 2015, 132:1920-1930.
- [6] Zebari R, Abdulazeez A, Zeebaree D, et al. A comprehensive review of dimensionality reduction techniques for feature selection and feature extraction[J]. *JASTT*, 2020,1:56-70.
- [7] Zhang Y, Wu R, Dascalu SM, et al. A novel extreme adaptive GRU for multivariate time series forecasting[J]. *Sci Rep*, 2024, 14:2991.
- [8] Vabalas A, Gowen E, Poliakoff E, et al. Machine learning algorithm validation with a limited sample size[J]. *PLOS One*, 2019,14:e0224365.
- [9] Li W, Zhang Y, Wang Z, et al. The risk factors of reintubation in intensive care unit patients on mechanical ventilation: A systematic review and meta-analysis[J]. *Intensive Crit Care Nurs*, 2023, 74:103340.
- [10] Trudzinski FC, Neetz B, Bornitz F, et al. Risk factors for prolonged mechanical ventilation and weaning failure: a systematic review[J]. *Respiration*, 2022,101:959-969.
- [11] Park JE, Kim DY, Park JW, et al. Development of a machine learning model for predicting weaning outcomes based solely on continuous ventilator parameters during spontaneous breathing trials[J]. *Bioengineering*, 2023,10:1163.
- [12] Pudjihartono N, Fadason T, Kempa-Liehr AW, et al. A review of feature selection methods for machine learning-based disease risk prediction[J]. *Front Bioinform*, 2022,2:927312.
- [13] Oczkowski S, Ergon B, Bos L, et al. ERS clinical practice guidelines: high-flow nasal cannula in acute respiratory failure[J]. *Eur Respir J*, 2022,59:2101574.
- [14] Boscolo A, Pettenuzzo T, Sella N, et al. Noninvasive respiratory support after extubation: a systematic review and network meta-analysis[J]. *Eur Respir Rev*, 2023,32:220196.

(收稿日期:2024-06-02;修回日期:2024-06-09)

(本文编辑:侯晓林)