

DOI: 10.3969/j.issn.1671-024x.2025.04.002

基于呼吸波形特征参数时间序列的 AECOPD 预测方法

王慧泉^{1,2,3}, 赵伟标^{1,2,3}, 孟庆凯⁴, 马建新⁴, 童朝晖⁵, 曹志新⁵

(1. 天津工业大学 生命科学学院, 天津 300387; 2. 天津工业大学 纺织未来技术研究中心, 天津 300387; 3. 天津工业大学 天津市医疗器械质控与评价技术重点实验室, 天津 300387; 4. 北京怡和嘉业医疗科技股份有限公司, 北京 100041; 5. 首都医科大学附属北京朝阳医院, 北京 100020)

摘要: 为实现慢性阻塞性肺疾病急性加重(AECOPD)事件的早期预测, 搭建基于远程呼吸机的患者呼吸波形监测系统, 收集记录 29 名发生疾病加重事件的患者和 29 名处于疾病稳定期的患者所用呼吸机的日常参数, 从呼吸波形中提取能够反映患者呼吸节律的特征参数, 利用多天数的特征参数构成特征时间序列, 建立多个疾病加重预测模型, 并利用与患者住院日期间隔不同天数的特征时间序列对预测模型进行评估。结果表明: 随着预测窗口的增加, 模型对疾病加重事件的预测效果先上升后下降, 模型的有效预测时间窗口为 3~4 d, 在 3~4 d 后, 模型操作特性曲线(ROC)下的面积值(AUC 值)不再有统计学意义; 通过采用特征时间序列, 该模型可以在疾病加重早期做出预测, 为疾病的防治提供更多的干预机会。

关键词: 慢性阻塞性肺疾病(COPD); 机器学习; 时间序列; 远程医疗

中图分类号: TP391; R318

文献标志码: A

文章编号: 1671-024X(2025)04-0007-06

AECOPD prediction method based on respiratory waveform feature parameters time series

WANG Huiquan^{1,2,3}, ZHAO Weibiao^{1,2,3}, MENG Qingkai⁴, MA Jianxin⁴, TONG Zhaohui⁵, CAO Zhixin⁵

(1. School of Life Sciences, Tiangong University, Tianjin 300387, China; 2. Research Center for Future Textile Technology, Tiangong University, Tianjin 300387, China; 3. Tianjin Key Laboratory of Quality Control and Evaluation Technology for Medical Devices, Tiangong University, Tianjin 300387, China; 4. BMC Medical Co., Ltd., Beijing 100041, China; 5. Beijing Chao-Yang Hospital, Capital Medical University, Beijing 100020, China)

Abstract: To achieve early prediction of the events of acute exacerbation of chronic obstructive pulmonary disease (AECOPD), a patient respiratory waveform monitoring system based on remote ventilators was built. Daily parameters of ventilators used by 29 patients who experienced disease exacerbation events and 29 patients in stable disease periods were collected and recorded. Feature parameters reflecting the patient's respiratory rhythm were extracted from the respiratory waveforms. Multiple disease exacerbation prediction models were established using feature time series with different intervals from the patient's hospitalization date to evaluate the prediction models. The results showed that as the prediction window increased, the predictive performance of the model for disease exacerbation events first increased and then decreased. The effective prediction time window of the model was 3~4 d, and after 3~4 d, the area value (AUC value) under the receiver operating characteristic (ROC) curve of the model no longer had statistical significance; by feature time series, this model can make predictions in the early stages of disease progression, providing more intervention opportunities for disease prevention and treatment.

Key words: chronic obstructive pulmonary disease(COPD); machine learning; time series; telemedicine

慢性阻塞性肺疾病(chronic obstructive pulmonary disease, COPD)给患者的日常生活造成严重的困扰。

收稿日期: 2023-03-03

基金项目: 国家重点研发计划资助项目(2019YFC0119400); 北京市科学技术委员会临床诊断与治疗技术方案研究与应用项目(Z201100005520032)

第一作者: 王慧泉(1985—), 男, 博士, 教授, 主要研究方向为可穿戴医疗设备、生物医学信号分析与处理。E-mail: huiquan@tiangong.edu.cn

通信作者: 曹志新(1971—), 男, 主任医师, 主要研究方向为呼吸衰竭和机械通气。E-mail: czx13911005116@163.com

慢性阻塞性肺疾病急性加重(acute exacerbation of chronic obstructive pulmonary disease, AECOPD)是造成 COPD 患者死亡的主要原因,如果没有及时干预,会导致不可逆转的肺器官损伤^[1]。因此,准确预测 AECOPD 的发生能够为患者提供足够的时间进行干预,尤其是居家管理的患者,同时也为医护人员提供足够的时间进行临床决策。

文献综述表明,目前缺少对 COPD 疾病加重的预测方法,而大多数现有研究方法存在诸多限制。有些研究利用患者体内的生物指标分析 COPD 疾病造成的影响^[2-4],如文献[5]证实 IL-17A 是气道炎症的相关受体。尽管这些物质在 COPD 发病机制和影响中至关重要,但其在 AECOPD 的干预和预测中很难起到有效作用。有些研究利用量表和评分系统来对 COPD 患者的状态进行分析,如利用 6 min 步行测试评估 COPD 患者的功能状态和生活质量^[6],利用患者咳嗽计数量表结合问卷调查对 AECOPD 进行预警^[7]。但在这些研究中,由于缺乏足够的预测准确度,往往会造成系统结果的误判。在临床上,计算机断层扫描(computed tomography, CT)和磁共振成像(magnetic resonance imaging, MRI)影像是诊断 COPD 患者肺部状况的重要方法^[8],利用 CT 可以检测患者肺气肿的进展^[9],利用 CT 和 MRI 影像还可以解释患者不同的表型^[10]。此外,有研究发现 CT 在诊断重度 COPD 患者静息性肺动脉高压方面有很好的效果^[11]。基于 CT 和 MRI 等大型设备对 COPD 的研究能够很好地分析患者肺部结构的变化,但其只能在专业医生的指导下应用,无法达到在 AECOPD 早期进行及时预测的效果。

部分研究结合机器学习技术对疾病状况进行分析,但所提出方法的稳定性较差,并且缺少对方法在时间上的有效性分析。例如:通过探索 COPD 中的生物标志物^[12],如吸气峰值流量(peak inspiratory flow, PIF)^[13]和呼气峰值流量(peak expiratory flow, PEF)^[14],可以对 AECOPD 进行预测,但由于指标的单一性,在预测过程中易受到干扰,无法保证结果的准确性;利用患者使用的无创呼吸机数据确定呼吸模式的变化,进而预测 AECOPD^[15];将呼吸音结合机器学习方法对 COPD 疾病进行分类^[16];利用机器学习方法结合临床和 CT 影像对 COPD 患者的死亡率进行预测^[17]。这几项研究将机器学习方法应用到 COPD 疾病分析当中,为患者提供了更好的管理方法,但忽视了机器学习模型中数据时间窗口^[18]的问题,不同的时间窗口对模型的预测结果会有很大的影响。董秋月等^[19]利用患者年龄、支气管炎患病记录、吸烟史、肥胖状况等信息搭建逻辑回归模型,结果显示模型的 ROC 曲线下面积为

0.786。唐雨萌等^[20]利用流行病学资料以及逻辑回归模型所搭建的慢性阻塞性肺疾病预测模型的 ROC 曲线下面积为 0.80。通过这些研究中的逻辑回归模型和所使用的特征参数均无法准确可靠地预测出患者出现 AECOPD 的状况。

综上所述,传统的量表和评分系统无法保证预测的准确性,会造成患者病情持续加重,延误最佳干预时期;CT、MRI 影像不适用于日常生活中的 COPD 患者,因为这往往需要专业医生的支持,不能广泛应用;PIF、PEF 等指标过于单一,在实际应用中易受到干扰;在建立的 AECOPD 预测模型中,由于模型预测能力的时间窗口长度尚未确定,导致大多数研究中建立的 AECOPD 预测模型无法在患者出现疾病加重前做出有效的预测。为了获得更准确的预测结果,并分析预测模型的时间窗口,本文利用监测实验得到的呼吸机记录数据和呼吸波形提取的特征参数,组合成时间序列^[21-22],建立 AECOPD 预测模型,并用动态的时间窗口对模型的预测能力进行分析。

1 AECOPD 预测方法

1.1 数据来源

本研究利用北京怡和嘉业医疗科技股份有限公司的云平台,搭建基于远程呼吸机的患者呼吸波形监测系统,并设计了监测实验,自 2020 年对居家 COPD 患者进行长期的监测,以建立研究所需的数据库。数据库包括一个呼吸机统计参数数据库和一个呼吸波形数据库。所有患者在纳入实验之前的 2~3 个月内无疾病加重史,在监测过程中,记录患者在使用呼吸机期间发生的所有事件,对于不同的事件会采取相应的干预措施。

将因疾病加重发生住院事件的患者数据记录进对应的数据库中,以获取 COPD 患者由疾病稳定期向疾病加重期变化过程中的数据。在本文建立的数据库中,包含 29 名由疾病稳定期变为疾病加重期的患者(记为 C-A)和 29 名始终处于疾病稳定期的患者(记为 C-C)。其中,C-A 患者的数据为住院前(包含住院当天)12 d 的连续数据,C-C 患者的数据为疾病稳定期内 12 d 的连续数据。

1.2 时间窗口的动态规划

本研究将提取特征时间序列所用的数据天数长度定义为观察窗口(observation window, OW),将所用数据序列的截止日期与患者住院日期间隔的天数长度定义为预测窗口(prediction window, PW)。本文采用

动态规划以实现所描述的 PW 和 OW,如图 1 所示。模型的建立过程与患者发生的事件在时间上保持一致,将患者发生住院事件认定为 AECOPD 的发生,患者居家使用呼吸机的阶段认定为 COPD 稳定期。

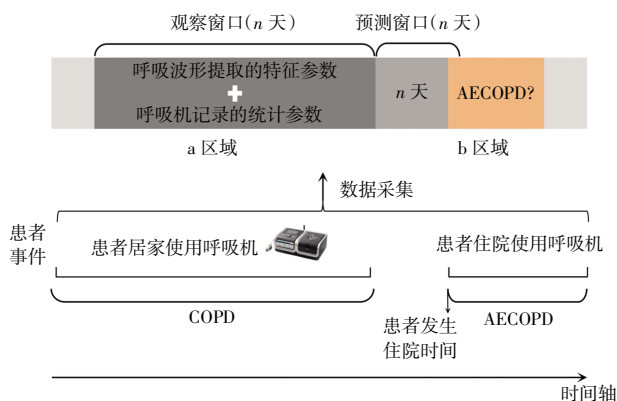


图 1 时间窗口的动态规划示意

Fig.1 Dynamic planning diagram of time window

窗口的动态规划包括以下 2 种不同的“动态”:

(1) 在 OW 的实现中, 本文通过改变时间窗口的窗口宽度, 以获得长度不等的 OW。对应图 1 中的 a 区域, 即控制 a 区域在时间轴上起始端的位置。

(2) 在 PW 的实现中, 本文通过改变 OW 的末端与住院日期的间隔天数, 以获得不等间隔天数的 PW。对应图 1 中的 b 区域, 即控制 a 区域末端与 b 区域末端之间 n 的大小。

通过构建的动态窗口, 分析固定 PW 和固定 OW 下预测模型对 AECOPD 事件发生的敏感度。利用不同时间窗口内的呼吸波形特征参数对 AECOPD 进行预测分析, 此方法能够有效地确定为达到精准预测疾病加重而采用的时间序列的长度, 为模型的搭建和实际应用提供可靠的数据结果分析。

1.3 特征时间序列的构建

多数研究中为预测 AECOPD 而采用的特征参数均无法准确反映患者的呼吸生理状况。本文为有效反映出患者由疾病稳定期到加重期的呼吸节律、周期的变化, 从呼吸波形中提取呼吸间隔序列的变化信息。基本步骤为: 检测患者呼吸波形的峰值点; 计算出峰值点的间隔序列和二阶差分后的序列; 计算出 2 个序列的均值、标准差、均方根误差、众数等 14 个特征参数。特征提取方式如图 2 所示。本文利用特征参数构成的特征时间序列搭建预测模型。

从呼吸机记录的参数中筛选吸呼比、最大潮气量、平均潮气量、最大分钟通气量等 13 个特征参数, 每个特征参数均从 COPD 患者一天的用机数据提取而来。将提取的特征按照时间顺序排列, 组成特征时




图 2 呼吸波形提取特征参数的示意

Fig.2 Schematic diagram of extracting characteristic parameters from respiratory waveform

间序列。本文列出主要特征参数, 如表 1 所示。

表 1 主要特征参数

Tab.1 Main characteristic parameters

编号	本研究所用的主要特征参数
1	峰值间隔序列的平均值
2	峰值间隔序列的标准差
3	峰值间隔序列的均方根
4	峰值间隔序列的变异系数
5	峰值间隔序列的样本熵
6	峰值间隔序列的方差
7	最大呼吸频率
8	平均呼吸频率
9	自主吸气比例
10	自主呼气比例

本文主要分析模型的预测能力, 为此, 利用不同的 PW 和 OW 在特征时间序列中划分出多个模型输入样本集, 以评估模型性能。本研究共划分出了 42 个模型输入样本集, 用于不同观察窗口和预测窗口下的预测分析。所有模型输入样本集中均包含 C-A 组和 C-C 组全部的患者。

1.4 预测模型的建立

为建立 AECOPD 预测模型, 本文利用不同的 PW 和 OW 在 C-A 组和 C-C 组患者提取的特征时间序列上进行分割, 获取不同的样本集, 建立不同的预测模型。以 PW 为 3 d、OW 为 3 d 时预测分析为例, 本文预测模型的建立和分析过程如图 3 所示。

(1) 利用 OW 为 3 d、PW 为 2 d 时窗口分割出训练样本集, 建立预测模型。

(2) 利用 OW 为 3 d、PW 为 3 d 时窗口分割出模型预测性能分析所用的预测样本集。

(3) 将预测样本集输入建好的预测模型中, 计算模型特性曲线下的面积值 (area under curve, AUC) 指标。

本研究使用经典机器学习算法逻辑回归 (logistic regression, LR), LR 模型在医学研究、疾病预测中应用

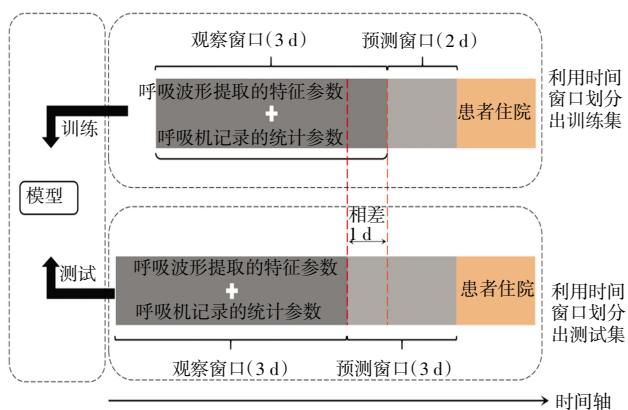


图 3 预测模型的建立示意

Fig.3 Schematic diagram of prediction model establishment

广泛。本文利用划分好的不同天数的训练集训练 LR, 得到能够输入固定时间窗口的特征矩阵的预测模型, 并用预测样本集评估模型接受者 AUC 指标。由图 3 可知, 模型训练所用样本集和预测所用样本集在时间间隔上相差 1 d, PW 和 OW 的范围均设定为 1~6 d。

1.5 预测模型指标的统计分析

本文计算预测模型 AUC 的 P 值, 来对模型结果进行统计学分析, P 值的含义为差异的来源是有抽样误差(随机误差)的可能性。 P 值多见于 2 组及以上的多组数据比较之中, 一般定义 P 值小于 0.05 表示具有统计学意义。在本研究中, ROC 曲线下的 AUC 值介于 0.5~1.0 之间, 其数值越大, 代表诊断效率越高, 当其值为 0.5 时, 可以说明该模型的评估结果没有任何诊断价值。

考虑到 AUC 本身有一定的抽样误差, 因此本文选择 AUC 为 0.5 的情况作为对比, 即比较不同预测模型的 AUC 和 0.5 之间的差异有无统计学意义。在本文的统计分析方法中, $P < 0.01$ 的含义为: AUC 等于 0.5 的可能性不足 1%, 此时可认为该 AUC 对应的预测模型的评估结果是有诊断价值的。

2 预测结果分析

本研究利用 PW 和 OW 分割样本集, 共分割出 42 个样本集用于预测模型的建立和预测性能分析。共建立了 36 个预测模型, 并利用不同的预测样本集输入建立好的模型中, 计算各个模型的 AUC 值, 结果如表 2 所示, 对应的 P 值结果如表 3 所示。

由表 2 可知, 预测模型在 PW 大于 3 d 以后, AUC 指标下降到最低, 并且计算出相应的 P 值大于 0.05, 不再具有统计学意义。当 OW 为 1 d, PW 为 3 d 时, 模型的 AUC 达到最佳, 为 0.84。

表 2 预测模型 AUC 值结果

Tab.2 Results of AUC value of prediction model

PW/d	OW/d					
	1	2	3	4	5	6
1	0.83	0.79	0.81	0.80	0.83	0.81
2	0.81	0.81	0.76	0.82	0.79	0.78
3	0.84	0.67	0.72	0.71	0.68	0.70
4	0.58	0.65	0.56	0.52	0.52	0.43
5	0.60	0.58	0.56	0.57	0.49	0.52
6	0.66	0.64	0.60	0.53	0.54	0.54

表 3 预测模型 AUC 值对应 P 值结果

Tab.3 Results of P value corresponding to AUC value of prediction model

PW/d	OW/d					
	1	2	3	4	5	6
1	0.000	0.000	0.000	0.000	0.000	0.000
2	0.000	0.000	0.001	0.000	0.000	0.000
3	0.000	0.026	0.004	0.006	0.016	0.011
4	0.290	0.046	0.465	0.744	0.834	0.343
5	0.179	0.301	0.423	0.355	0.913	0.786
6	0.038	0.063	0.184	0.669	0.570	0.570

为了更加清晰地显示不同的 OW 和 PW 交叉下模型的预测性能, 将各个模型的 AUC 值绘制 3D 热图, 并取其映射图, 如图 4 所示。图 4 将 AUC 值与对应的 hot 值进行映射, 图中色阶条最高为 0.84, 最低为 0.43。




图 4 不同 PW 与 OW 下预测模型的 AUC 值映射图

Fig.4 Map of AUC value of prediction model under different PW and OW

图 4 显示, 随着预测窗口的增加, 模型的预测能力逐渐下降。当 PW 为 1 d 时, 预测模型使用的样本集包含了发生住院事件当日的患者数据, 而预测样本为间隔 1 d 的数据。由此可得出, 本研究模型能够在患者疾病加重发生的前 3 d 时间内进行有效预测, 并且在 PW 为 3 d 时能够较准确的预测出患者可能出现的疾病加重事件。此外, 图 4 显示了预测模型的 AUC 值在 $PW \leq 4$ d 时, 模型的性能在图 4 的左上部分达到最佳。

现有的 AECOPD 预测模型需要专业医务人员和大型检测设备的支持, 因此不能应用于居家环境和其他自我管理的患者人群。为了实现更广泛的 AECOPD

预测应用,本文开发了仅使用无创呼吸机的数据和波形进行精准预测的方法。利用 LR 模型建立预测模型,并分析了不同观察窗口和不同预测窗口下模型的预测性能。与董秋月、唐雨萌等研究团队^[19-20]的同类型研究方法相比,本研究方法搭建的 LR 模型 ROC 曲线下的面积值达到 0.84,相比于这 2 个研究,结果分别提升了 0.05 和 0.04。本方法中由呼吸波形特征参数构建的特征参数时间序列对模型性能的提高起到了关键性作用。

文献调研表明,目前国内外针对 COPD 疾病加重的研究主要集中在预测所用特征参数类型、预测所用模型类型上,对所搭建的预测模型在患者疾病加重前预测时间窗口的分析较少。本研究比较了不同预测窗口对预测性能的影响。结果表明,随着预测窗口的增加,模型的预测性能下降,因为预测窗口的长度与输入特征所包含的患者病情信息成反比,当预测窗口增大到一定宽度后,窗口内不再包含患者疾病加重信息的数据,使得该预测窗口下建立的模型不能够判断出 AECOPD 事件。在本研究中,当预测窗口增加到 4 d 时,模型对 AECOPD 预测的结果不再具有统计学意义,并且随着预测窗口的持续增加,模型的预测性能不再具有规律性。

此外,本研究分析不同的观察窗口下模型的预测性能,结果表明,随着观察窗口的增加,预测模型的总体预测性能得到改善,因为更长的观察窗口包含更多信息,从而做出更精准的预测。然而,模型的预测性能并不是随着观察窗口的增加持续提高的。当特征数据所包含的信息超过某个阈值,信息的增加将不会有效地改善预测结果。

为了得到计算成本低、便于移植的预测模型,本文使用了 LR 模型。LR 模型适用于因变量为两项并且以疾病、死亡等结果发生的概率为因变量,影响疾病发生的因素为自变量建立回归模型。本文开发的模型与传统基于横断面的特征参数来做疾病判别不同,是基于特征时间序列,根据过去的变化趋势预测未来疾病是否加重,为未来 COPD 患者的智能管理提供了丰富的应用前景。

然而,本研究存在一些局限性。本研究的数据集较少,且为人工筛选,为确保数据的质量,应进行更多、更丰富数据集的研究探索。此外,本研究主要讨论 AECOPD 预测模型的预测性能和可行性。在未来的研究中,使用更复杂更多样化的神经网络模型可能是进一步提高 AECOPD 预测性能的关键。

3 结 论

本文利用呼吸波形提取出 COPD 患者的呼吸节律、周期信息,结合 LR 模型搭建疾病加重算法模型。通过提取特征参数将患者呼吸状况进行量化,利用多天数的特征参数构成的特征时间序列反映出疾病稳定期到加重期的变化过程。在模型搭建过程中,除所提取的特征参数之外,本文加入了呼吸机日常监护参数信息,扩增了特征时间序列的信息量,这些方法提升了预测模型的准确度,使模型的 ROC 曲线下面积值能够达到 0.84,相比于通过患者的统计量表、临床资料、生物标志物等信息预测疾病加重的方法,本文方法的预测性能有显著的提升。

为了尽可能降低专业人员的参与度,相比于利用 CT、MRI 等设备对疾病加重的评估,本方法基于家用呼吸机数据进行参数提取分析,增加了预测方法的适应性。此外,对于研究中搭建的预测模型随时间变化上的精度变化,多数研究中只得出了模型的性能指标,而并没有给出相关结果数据,对比分析可知,本方法搭建的预测模型能够在患者出现加重状况前的 3~4 d 内做出有效预测,以实现加重患者的及时干预,降低疾病对肺部造成的不可逆损伤。希望这项研究能够为 COPD 疾病患者的管理提供有价值的参考和指导,加速这一领域的发展。

参考文献:

- [1] SINGH D, AGUSTI A, ANZUETO A, et al. Global strategy for the diagnosis, management, and prevention of chronic obstructive lung disease: The GOLD science committee report 2019[J]. *European Respiratory Journal*, 2019, 53(5): 1900164.
- [2] SAULER M, LENG L, TRENTALANGE M, et al. Macrophage migration inhibitory factor deficiency in chronic obstructive pulmonary disease[J]. *American Journal of Physiology-Lung Cellular and Molecular Physiology*, 2014, 306(6): L487-L496.
- [3] MALTAIS F, BUHL R, KOCH A, et al. β -blockers in COPD A cohort study from the TONADO research program[J]. *Chest*, 2018, 153(6): 1315-1325.
- [4] LIESKER J J W, VAN DE VELDE V, MEYSMAN M, et al. Effects of formoterol (Oxis Turbuhaler) and ipratropium on exercise capacity in patients with COPD[J]. *Respiratory Medicine*, 2002, 96(8): 559-566.
- [5] YANAGISAWA H, HASHIMOTO M, MINAGAWA S, et al. Role of IL-17A in murine models of COPD airway disease[J]. *American Journal of Physiology Lung Cellular and Molecular Physiology*, 2017, 312(1): L122-L130.
- [6] ZENG G S, CHEN L C, FAN H Z, et al. The relationship between steps of 6MWT and COPD severity: A cross-sectional

- study[J]. *International Journal of Chronic Obstructive Pulmonary Disease*, 2018, 14: 141–148.
- [7] DEN BRINKER A C, VAN DINTHER R, CROOKS M G, et al. Alert system design based on experimental findings from long-term unobtrusive monitoring in COPD[J]. *Biomedical Signal Processing and Control*, 2021, 63: 102205.
- [8] QING K, TUSTISON N J, MUGLER J P, et al. Probing changes in lung physiology in COPD using CT, perfusion MRI, and hyperpolarized xenon-129 MRI[J]. *Academic Radiology*, 2019, 26(3): 326–334.
- [9] KONIETZKE P, WIELPÜTZ M O, WAGNER W L, et al. Quantitative CT detects progression in COPD patients with severe emphysema in a 3-month interval[J]. *European Radiology*, 2020, 30(5): 2502–2512.
- [10] HOFFMAN E A, LYNCH D A, GRAHAM BARR R, et al. Pulmonary CT and MRI phenotypes that help explain chronic pulmonary obstruction disease pathophysiology and outcomes[J]. *Journal of Magnetic Resonance Imaging*, 2016, 43(3): 544–557.
- [11] IYER A S, MICHAEL WELLS J, VISHIN S, et al. CT scan-measured pulmonary artery to aorta ratio and echocardiography for detecting pulmonary hypertension in severe COPD[J]. *Chest*, 2014, 145(4): 824–832.
- [12] GRANHOLM A C, LEDREUX A. Biomarkers show value of studying dementia in Down syndrome[J]. *Nature Reviews Neurology*, 2021, 17(10): 599–600.
- [13] MAHLER D A, HALPIN D M G. Peak inspiratory flow as a predictive therapeutic biomarker in COPD[J]. *Chest*, 2021, 160(2): 491–498.
- [14] CEN J, MA H Y, CHEN Z B, et al. Monitoring peak expiratory flow could predict COPD exacerbations: A prospective observational study[J]. *Respiratory Medicine*, 2019, 148: 43–48.
- [15] BLOUET S, SUTTER J, FRESNEL E, et al. Prediction of severe acute exacerbation using changes in breathing pattern of COPD patients on home noninvasive ventilation[J]. *International Journal of Chronic Obstructive Pulmonary Disease*, 2018, 13: 2577–2586.
- [16] HAIDER N S, SINGH B K, PERIYASAMY R, et al. Respiratory sound based classification of chronic obstructive pulmonary disease: A risk stratification approach in machine learning paradigm[J]. *Journal of Medical Systems*, 2019, 43(8): 255.
- [17] MOLL M, QIAO D D, REGAN E A, et al. Machine learning and prediction of all-cause mortality in COPD[J]. *Chest*, 2020, 158(3): 952–964.
- [18] ZHANG G, YUAN J, YU M, et al. A machine learning method for acute hypotensive episodes prediction using only non-invasive parameters[J]. *Computer Methods and Programs in Biomedicine*, 2021, 200: 105845.
- [19] 董秋月, 高丛丛, 刘才睿, 等. 山东省 ≥ 40 岁人群慢性阻塞性肺疾病患病风险列线图预测模型建立[J]. *中国公共卫生*, 2023, 39(5): 604–611.
- DONG Q Y, GAO C C, LIU C R, et al. Establishment of a nomogram-based risk prediction model for chronic obstructive pulmonary disease in residents aged 40 years and over in Shandong province[J]. *Chinese Journal of Public Health*, 2023, 39(5): 604–611 (in Chinese).
- [20] 唐雨萌, 张岚, 李茜, 等. 神经网络模型和 logistic 回归在预测慢性阻塞性肺疾病中的应用研究[J]. *公共卫生与预防医学*, 2021, 32(2): 12–16.
- TANG Y M, ZHANG L, LI Q, et al. Application of neural network model and logistic regression in the prediction of chronic obstructive pulmonary disease[J]. *Journal of Public Health and Preventive Medicine*, 2021, 32(2): 12–16 (in Chinese).
- [21] 任守纲, 张景旭, 顾兴健, 等. 时间序列特征提取方法研究综述[J]. *小型微型计算机系统*, 2021, 42(2): 271–278.
- REN S G, ZHANG J X, GU X J, et al. Overview of feature extraction algorithms for time series[J]. *Journal of Chinese Computer Systems*, 2021, 42(2): 271–278 (in Chinese).
- [22] 陈磊, 张晓涛. 基于时间序列的热门股票分析与推荐系统的设计与实现[J]. *现代计算机*, 2022, 28(20): 84–91.
- CHEN L, ZHANG X T. Design and implementation of popular stock analysis and recommendation system based on time series[J]. *Modern Computer*, 2022, 28(20): 84–91 (in Chinese).

本文引文格式:

- 王慧泉, 赵伟标, 孟庆凯, 等. 基于呼吸波形特征参数时间序列的 AECOPD 预测方法[J]. *天津工业大学学报*, 2025, 44(4): 7–12.
- WANG H Q, ZHAO W B, MENG Q K, et al. AECOPD prediction method based on respiratory waveform feature parameters time series[J]. *Journal of Tiangong University*, 2025, 44(4): 7–12 (in Chinese).