

引文格式:

马良, 熊富海, 颜延, 等. 基于相空间重建-卷积神经网络识别混合机械通气人机不同步 [J]. 集成技术, 2023, 12(5): 92-106.

Ma L, Xiong FH, Yan Y, et al. Identification for patient-ventilator asynchrony under hybrid mechanical ventilation based on convolutional neural network with phase-space reconstruction [J]. Journal of Integration Technology, 2023, 12(5): 92-106.

基于相空间重建-卷积神经网络识别混合机械通气人机不同步

马 良^{1,2} 熊富海¹ 颜 延¹ 黄志文³ 王 磊^{1*}

¹(中国科学院深圳先进技术研究院 深圳 518055)

²(中国科学院大学生命科学学院 北京 100049)

³(深圳迈瑞生物医疗电子股份有限公司 深圳 518057)

摘要 机械通气过程中人机不同步(patient-ventilator asynchrony, PVA)是常见问题。随着智能生理闭环通气成为呼吸机的主要发展方向, 机械通气过程将不再局限于传统的通气模式, 且针对 PVA 的智能识别模型, 现有技术存在弱泛化性和高复杂度的特点。为此, 该文的主要工作是: 首先, 将定压型与定容型通气模式的混合作为样本; 其次, 设置 Hold-out 和留一法两种交叉验证实验, 以验证混合通气模式下 PVA 的识别任务可行性。此外, 为提高 PVA 识别任务中模型的泛化性能, 该文提出了基于相空间重建的卷积神经网络(phase-space reconstruction-based convolutional neural network, PSR-CNN)模型, 通过交叉验证对现有公开报道的方法做模型选择。在模型构造过程中, 相空间重建的最优时间延迟参数和嵌入维度分别使用平均互信息和伪近邻算法估计; 在交叉验证过程中, 同时使用降采样和补零技术, 以保证实验的正常运行。结果显示, 就全局指标 accuracy 和 F1-score 而言, 该文提出的 PSR-CNN 模型, 分别高出对比模型约 7% 和 6%; 且 PSR-CNN 单个样本的平均训练耗时最短, 约 2 ms。综上所述, 该文探索了混合通气模式下 PVA 识别的可行性, 且在该任务的框架内提出了 PSR-CNN 模型, 提高了 PVA 分类任务中模型的泛化性能, 降低了模型的复杂度。该文的工作对呼吸机在工程上的智能化发展具有重要参考意义与应用价值。

关键词 相空间重建; 卷积神经网络; 机械通气; 人机不同步; 识别

中图分类号 TP 399 **文献标志码** A **doi:** 10.12146/j.issn.2095-3135.20221212001

收稿日期: 2022-12-12 修回日期: 2023-03-24

基金项目: 国家重点研发计划项目(2022YFC2403602, 2022YFC2403603); 深圳市新型冠状病毒肺炎疫情应急防治项目(JSGG20200807171603039); 深圳市技术攻关重点项目(JSGG2019111816401741)

作者简介: 马良, 硕士研究生, 研究方向为生理信号模式识别; 熊富海, 工程师, 研究方向为生理信号模式识别; 颜延, 助理研究员, 研究方向为拓扑数据分析; 黄志文, 工程师, 研究方向为智能化机械通气; 王磊(通讯作者), 研究员, 研究方向为人体传感器网络, E-mail: wang.lei@siat.ac.cn。

Identification for Patient-Ventilator Asynchrony under Hybrid Mechanical Ventilation Based on Convolutional Neural Network with Phase-Space Reconstruction

MA Liang^{1,2} XIONG Fuhai¹ YAN Yan¹ HUANG Zhiwen³ WANG Lei^{1*}

¹(Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)

²(College of Life Sciences, University of Chinese Academy of Sciences, Beijing 100049, China)

³(Shenzhen Mindray Bio-Medical Electronics Co., Ltd., Shenzhen 518057, China)

*Corresponding Author: wang.lei@siat.ac.cn

Abstract Patient-ventilator asynchrony (PVA) commonly occurs during mechanical ventilation. Considering the developing trend of physiological loop ventilation and weak generalization and high complexity of public methods, this paper firstly mixes different ventilation modes simultaneously as sample, and then two cross validations, Hold-out and Leave One Subject Out, are introduced to verify the feasibility of the task that classifying PVAs under hybrid ventilation modes. To solve the drawback of current models, the phase-space reconstruction-based convolutional neural network (PSR-CNN) model is proposed. During model selection, zero-padded and down sampling are applied in order to ensure that all experiments could be conducted smoothly. Results suggest that the performances of PSR-CNN have a higher accuracy and a F1-score than other algorithms. In addition, PSR-CNN shows a shorter time with regard to average training consumption. Overall, this study indicates that the proposed model has a stronger generalization and a decrease in the complexity, which shows application value and provides reference for the intelligent promotion of ventilators in engineering.

Keywords phase-space reconstruction; convolutional neural network; mechanical ventilation; patient-ventilator asynchrony; identification

Funding This work is supported by National Key Research and Development Program of China (2022YFC2403602 & 2022YFC2403603), Emergency Prevention and Control Project of novel coronavirus Pneumonia in Shenzhen and Key Technology Projects in Shenzhen (JSGG20200807171603039 & JSGG20191118161401741)

Ethical Statement This study was approved by the Ethics Committee of The Second People's Hospital of Shenzhen (20211109006-FS01)

1 引言

对于危重症患者的治疗而言, 机械通气是一种极其重要的支持手段^[1]。患者与呼吸机的交互是否顺畅, 是影响患者康复质量的重要因素^[2]。良好的人机交互可以减轻患者在治疗过程中的不适感和加快脱机进程, 而过多的人机不同步(patient-ventilator asynchrony, PVA)会延长机械通气的时间, 甚至危及患者生命安全^[3]。

如何识别和减少机械通气过程中的 PVA 现象, 已成为临床医生与呼吸机研发企业共同关注的问题之一。造成 PVA 现象的主要原因可归结为呼吸机提供的气体与患者对气体的需求不协调、不匹配^[4]。目前, 有许多关于 PVA 现象的报道与综述, 最为常见的有无效吸气努力(ineffective effort during expiration, IEE)、提前切换(premature cycling, PC)、双触发(double triggering, DT)和延迟切换(delayed cycling,

DC)^[5-7]等。表1为其中两种PVA波形的定义。在操作呼吸机前，临床专业人员通常需要接受面临人机不同步时的应对方案培训，主要是通过观察呼吸机波形，根据自己的知识与经验调整呼吸机的设置，达到改善人机交互的目的^[8]。

在机械通气的临床实践中，医生通常根据

患者病情及个人经验来确定通气模式。传统的通气模式主要分为两大类，定压型通气(pressure control ventilation, PCV)模式(包括压力控制模式和压力支持模式等)和定容型通气(volume control ventilation, VCV)模式(包括容量控制通气和容量控制辅助通气等)^[9]，如图1所示。在PCV模

表1 常见的人机不同步定义及其表现形式

Table 1 Common definitions of different patient-ventilator asynchrony and their morphological pattern

类型	定义及表现形式
IEE	定义：呼吸机因没有检测到患者的吸气努力而引起的通气不同步，其通常发生在患者的吸气努力未达到触发呼吸机送气的阈值之时 表现：波形表现为在呼气相时，压力波形下陷并伴随流速波形的一个快速减少
PC	定义：呼吸机未完成一个周期的送气过程，患者仍处于吸气相，而呼吸机切换到了呼气相 表现：波形表现为在流速波形呼气相早期，在达到峰值后，有一个短暂且快速的减小

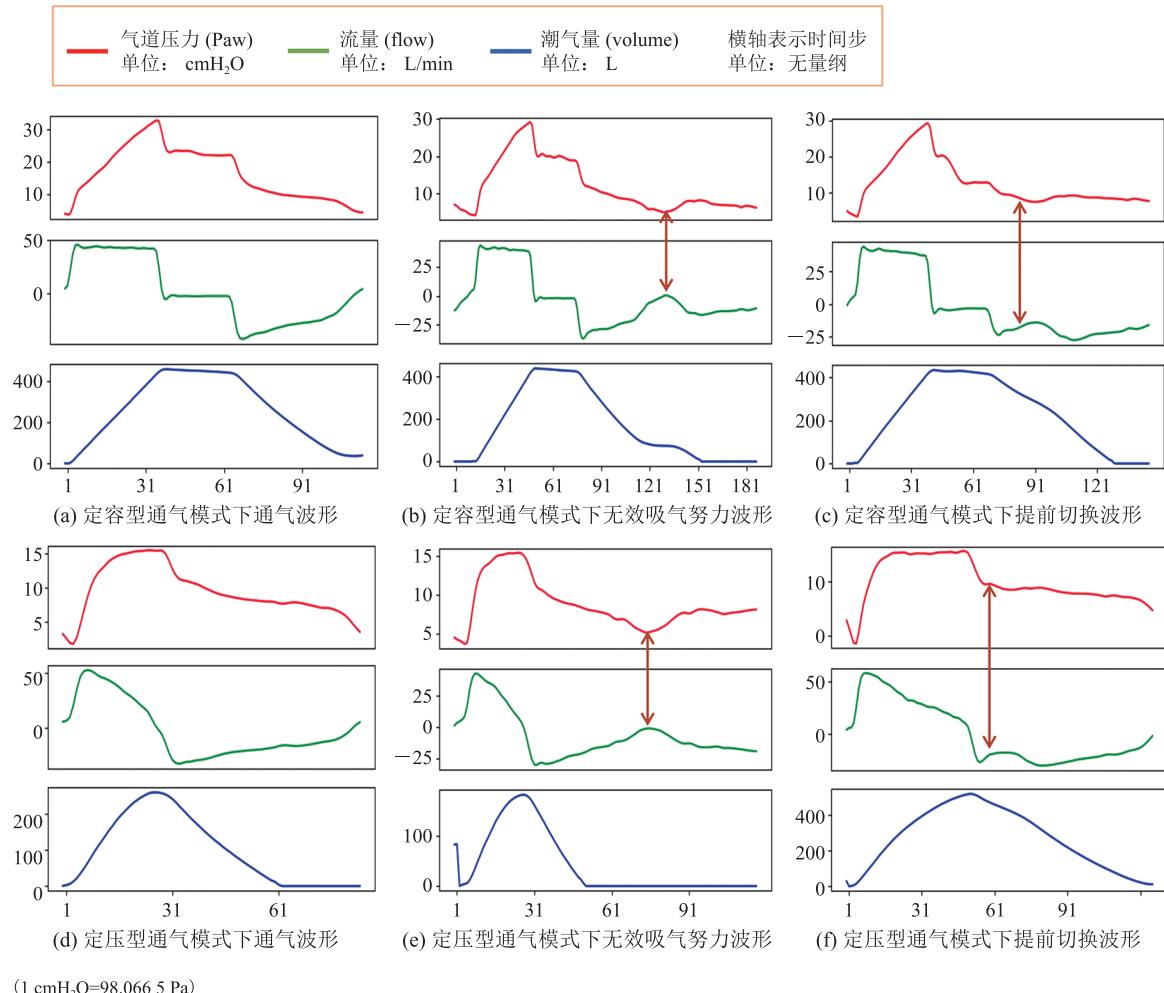


图1 机械通气波形

Fig. 1 Mechanical ventilation waveform

式下, 呼吸机以一个预设的气道压力为目标, 以递减的流速和设定的呼吸频率或吸气时间进行送气。在 VCV 模式下, 呼吸机以预设的潮气量为目标, 保持恒定的流速和呼气时间为患者送气。PCV 模式的优势是峰压较低, 不易出现气压伤, 但潮气量受系统顺应性和黏性组织的影响较大; 与之相反的是 VCV 模式能够保证潮气量的供给, 有利于呼吸机的休息, 但易导致气压伤^[10]。两种通气模式均有一定概率造成人机交互的不同步, 且迄今没有哪种模式更优的定论^[11]。此外, 市场上已有许多呼吸机应用了具有肺保护通气策略的通气模式, 如压力控制同步间歇指令通气模式 (pressure control-synchronized intermittent mandatory ventilation, PC-SIMV)、可变压力支持通气模式和容量控制同步间歇指令通气模式, 这些模式产生的波形特点是, 从形态学上考虑像定压型和定容型通气模式的混合^[1,10]。然而, 现有文献中的各种识别算法进行分类任务, 所利用的通气数据均采集于单一的通气模式, 对此, 本文进行了汇总, 如表 2 所示。因此, 探索将定压型与定容型通气模式下的呼吸波形混合, 进行 PVA 自动化识别模型的开发, 对呼吸机的智能化和生理闭环控制^[11]具有重要意义。

由于现场观察的方式无可持续性和连续性的局限, 因此, 采用算法模型自动识别 PVA 逐渐受到工程研究人员的关注。目前, 关于 PVA 的自动识别算法可分为三大类: 基于规则的识别算法、基于手工特征的分类算法和基于数据驱动的深度学习算法。基于规则的算法通常对呼吸波形

提取统计信息, 并据此设置阈值, 从而判别是否出现 PVA 现象, 如 Qestra 等^[12]和 Blanch 等^[18]的研究, 实现了对无效吸气努力和双触发的识别。基于规则的算法不具有强泛化性, 设置阈值时具有主观性和先验知识依赖性。而基于手工特征工程的方法^[12,17-18], 通过将提取到的通气波形时域特征、频域特征或熵分析特征输入到机器学习分类器中, 实现一种或多种 PVA 的分类识别, 该方法的缺点是提取特征的过程依赖经验, 需要结合患者的生理参数和机械通气参数, 且泛化性较弱。

近年来, 随着深度学习技术的广泛应用, 将大量临床数据应用于神经网络模型的方法逐渐流行。在 PVA 的自动识别领域^[13-14,16,25], 将大量正常人机交互周期与异常交互周期同时输入算法中进行训练, 可得到识别 PVA 的模型。这种方法的性能虽已得到良好验证, 但仍存在复杂度较高的缺点。

为克服上述问题, 本文的主要工作和贡献如下:

(1) 验证了混合通气模式下 PVA 自动识别的可行性。首先, 收集使用了 3 种通气模式 (PCV、VCV 和 PC-SIMV) 的临床通气波形。然后, 利用团队开发的 EasyPVA 手工交互标注软件 (注册号: 2022SR1571492), 对上述波形进行去异常、文件分块、可视化标注和自动分割, 最终共得到 16 760 个呼吸周期。交叉验证的结果表明, 混合通气模式下的 PVA 识别具有可行性。

(2) 提出具有相空间重构 (phase-space

表 2 公开文献使用数据的通气模式对比

Table 2 The comparison of different ventilation mode used in public literature

通气模式	文献
定容型	Qestra 等 ^[12] 、Rodriguez 等 ^[13] 、Rehm 等 ^[14] 、Casagrande 等 ^[15] 、Rehm 等 ^[16]
定压型	Casagrande 等 ^[15] 、Rehm 等 ^[16] 、陆云飞 等 ^[17] 、Blanch 等 ^[18] 、Zhang ^[19] 、Pan 等 ^[20] 、Chen 等 ^[21] 、Pham 等 ^[22] 、Sottile 等 ^[23] 、Pan 等 ^[24] 、Marchuk 等 ^[25]

注: Casagrande^[15]等和 Rehm^[16]等的研究中使用定压和定容两种通气模式, 但在各通气模式下独立进行识别分类任务; 无法辨明通气模式的文献未列在表中

reconstruction, PSR) 编码的卷积神经网络模型用于 PVA 的自动识别。本文基于平均互信息法和伪近邻法分别估计得到最优 PSR 的 PSR 参数。最优 PSR 编码后的呼吸数据通过两个简单的卷积层经全连接输出分类标签。结果显示, 就 accuracy 和 F1-score 两个综合指标而言, 本文模型的性能较优, 且复杂度更低。

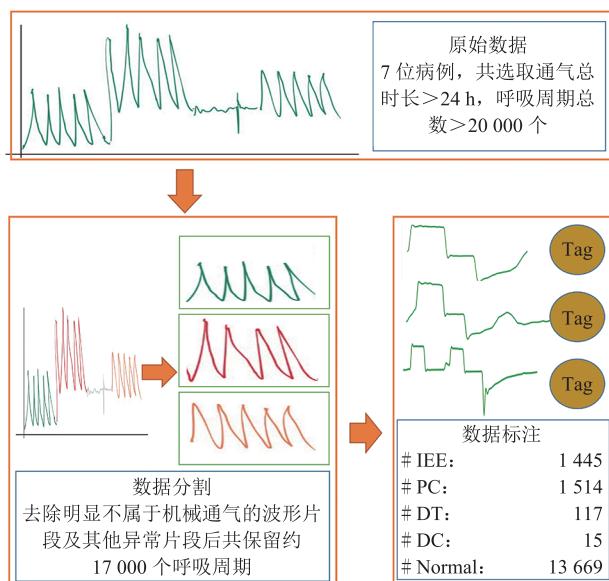
2 材料和方法

2.1 数据准备

首先, 本实验室联合深圳迈瑞生物医疗电子股份有限公司(以下简称“迈瑞”)与深圳市第二人民医院, 采集数例临床机械通气波形, 所使用的临床数据采集自迈瑞呼吸机(型号: SV800)对 7 例临床患者实施的机械通气过程。患者的基本信息与机械通气的部分参数记录如表 3 所示。数据采样频率为 50 Hz。7 例患者的机械通气总时长达数百小时, 为避免大量无效工作, 由迈瑞方挑选包含上述人机不同步的呼吸机波形约 24 h, 共约 20 000 个呼吸周期。该实验已通过深圳市第二人民医院临床科研伦理委员会审批(伦理号: 20211109006-FS01)。

在进行数据变换前, 需对呼吸波形数据预处理, 包括数据分割和数据标注, 如图 2 所示。

数据分割: 指将采集到的原始数据按呼吸周期进行分割。最终, 将对每个呼吸周期提取特征



注: IEE 指呼气间无效吸气努力; PC 为提前切换事件; DT 为双触发事件; DC 为延迟切换事件; Normal 指正常呼吸波形

图 2 数据准备

Fig. 2 Data preparation

或一个呼吸周期的数据视作样本, 并输入深度模型。首先, 为完成该任务, 利用本实验小组独立开发的可视化软件, 将明显的非机械通气波形去除; 其次, 为便于后续标注工作, 需将呼吸机不同参数设置产生的连续波形分割成每部分具有近似或相同的参数设置; 最后, 仍利用该软件进行数据标注, 标注后再自动分割为独立的呼吸周期。

数据标注: 为呼吸波形打标签(包括 IEE、PC、DT、DC 和 Normal)。数据标注经历两个阶段。首先将数据均等地分给经过培训的 5 名生物

表 3 患者基本信息及呼吸机部分参数

Table 3 The patients' basic information and part of parameters of ventilator during ventilation mode

信息	值
男性/女性	5/2
年龄(岁)	65.714±20.702
主要诊断	COPD、肺部感染、COPD 急性加重、昏迷、重症肺炎、胸部损伤
呼吸机设置	PCV: Δ吸气压力 15~16 cmH ₂ O、呼末正压 10 cmH ₂ O PC-SIMV: Δ吸气压力 14 cmH ₂ O、Δ支持压力 14 cmH ₂ O、呼末正压 3 cmH ₂ O VCV: 潮气量 480~500 mL、呼末正压 3 cmH ₂ O

注: COPD 指慢性阻塞性肺疾病; PC-SIMV 指压力控制-同步间歇指令通气模式

医学工程学员, 并进行第一阶段的标注工作。在第二阶段, 由 2 名分别来自迈瑞和深圳市第二人民医院的专业人员, 根据自身的工程和临床经验进行交叉审核, 即每人独立审核一半数据, 随后交换审核。若两名专家对同一数据的标注出现分歧, 则将其舍弃。最终共得到 16 760 个呼吸周期, 其中: 1 445 个 IEE、1 514 个 PC、117 个 DT 和 15 个 DC。

数据变换: 不同量纲的数据在输入模型前通常需要进行数据变换, 以保证模型的收敛性和收敛速度, 常用的数据变换方法包括归一化和标准化^[26]。本文使用的呼吸波形包括 3 个通道: 气道压力(单位: cmH₂O(1 cmH₂O=98.066 5 Pa))波形、流速(单位: L/min)波形和潮气量(单位: L)波形, 如图 1 所示。由于归一化对异常值较为敏感, 且无法使数据分布在变换前后保持一致。因此, 需对数据进行标准化变换, 如公式(1)所示。

$$x_i = \frac{x_i - \mu}{\sigma} \quad (1)$$

其中, μ 为时间序列 $X=\{x_1, x_2, \dots, x_i, \dots, x_n\}$ 的均值; σ 为 X 的标准差。

最终得到 DT 和 DC 两种不同步呼吸周期的数据量分别为 117 和 15。为避免样本类型分布不平衡而导致的分类结果偏差过大^[27], 同时为探索混合通气模式下 PVA 分类的可行性, 实验过程仅执行 IEE 和 Other(除 IEE 外的其他波形)二分类任务。

2.2 实验设置

本文设置了留出法(Hold-out)和留一法(leave one subject out, LOSO)两种交叉验证, 如图 3 所示。利用上述两种实验评估方法, 分别对比了包括时域特征-随机森林(Random Forest, RF)模型、频域特征-RF 模型, 以及多种深度模型在内的分类器性能。

Hold-out: 直接将数据集随机划分为正反例样本比例相近的两个互斥子集, 将模型在一个集

合上进行训练, 在另一个集合上进行测试, 以估计泛化误差^[26]。本项工作定义 IEE 为阳性样本, 非 IEE 为阴性样本。由图 2 可知, 阳性样本的数量约为阴性样本数量的 1/10。为减少模型的估计偏差, 以及确保得到的结果稳定可靠, 如图 3(a)所示, 本文对阴性样本使用了欠采样技术, 并重复上述过程 50 次。

LOSO: 留一法是一种特殊情况下的 k 折交叉验证。该方法要求留出一个样本作为测试集, 共重复 k 次, k 为样本个数。留一法的评估结果被认为较为准确, 且与 Hold-out 实验相比, 留一法更能证明模型的泛化能力^[26]。在实践中, 更为常见的做法是将一个对象的样本作为测试集, 其余对象的样本作为训练集, 以此来验证模型的跨对象识别能力, 该交叉验证的方式也被称为 LOSO, 如图 3(b) 所示。

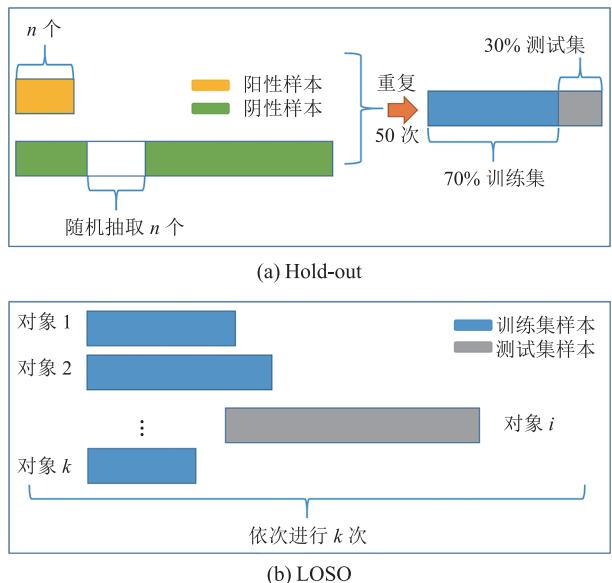


图 3 实验设置

Fig. 3 Experiment setting

实验过程中, 排除机械通气过程中出现阳性样本次数较少的病例, 仅将其作为训练集用例, 其他各病例作为测试集。

任务验证与模型对比: 首先, 基于特征的方法验证任务的可行性, 根据 Boonyakitanont 等^[28]

的综述文章中时间序列特征提取方法，对呼吸周期分别提取时域和频域特征(各特征及其公式见表4)，并将其作为RF分类器的样本，分别实施上述两种交叉验证实验；然后，利用CNN执行同样的任务；最后，对比本文提出的改进CNN模型——PSR-CNN在该任务的各项性能指标。

表4 对比模型中的各手工特征及其计算公式

Table 4 All manual features listed in this table and their formulas

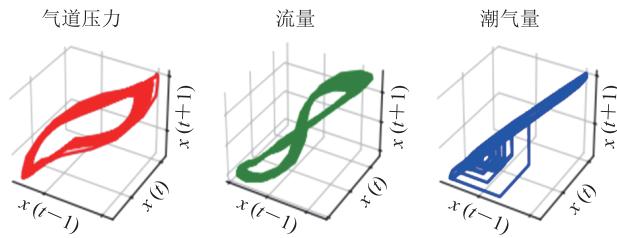
特征种类	特征	计算公式
时域	最大值	$\max(X)$
	最小值	$\min(X)$
	平均值	$\sum X(t)/N$
	中值	$(\max(X)+\min(X))/2$
	方差	$s^2 = \left(\sum (X_i - \bar{X})^2\right)/N$
	标准差	$SD = \sqrt{s^2}$
	均方根	$RMS = \sqrt{\sum X_i^2/N}$
频域	分位数	$Q_1 = X((N+1)/4)$ $Q_3 = X(3(N+1)/4)$
	PSD 最大值	$\max(PSD)$
	PSD 最小值	$\min(PSD)$
	PSD 平均值	$\sum PSD_i/N$
	PSD 标准差	$SD = \sqrt{\sum (PSD_i - \bar{PSD})^2/N}$
	PSD 能量	$Energy = \sum PSD_i^2$
	PSD 均方根	$RMS = \sqrt{\sum PSD_i^2/N}$

注： X 指一维时间序列， N 为 X 的长度； PSD 指功率谱密度

2.3 PSR-CNN 模型

2.3.1 相空间重建

PSR是混沌理论中研究非线性时间序列的重要工具。它指出，混沌系统中，任一变量的时间序列可以包含整个系统的长期演化信息，因此，系统的混沌行为可通过任一观测到的时间序列展开研究^[29]。Packard首次提出PSR的两种方法，即导数重构法和坐标延迟重构法。然而，前者由于对误差比较敏感，且Gibson证明，在一定条件下，前者是后者的旋转，因此，PSR的主流方法即Takens等人于1981年提出的延时嵌入^[30]。图4为以某例患者的无效吸气努力周期为例进行的相空间重建三维图。



注：以某例患者的无效吸气努力周期为例，令时间延迟为1，嵌入维度为3，最终得到3个通道的三维相空间

图4 延时嵌入重构相空间示意图

Fig. 4 Phase-space reconstruction with time-delay embedding

延时嵌入可描述为，假设观察到的一维时间序列 $X=\{x_1, x_2, \dots, x_i, \dots, x_n\}$ ，其长度为 N 。然后确定时间延迟 τ 和嵌入维度 m 。对 X 应用延时嵌入技术可以得到：

$$X_i = \{x_1, x_2, \dots, x_{i+(m-1)\tau}\}, \quad i \in [1, L] \quad (2)$$

其中， X_i 为 m 维相空间中的一个点，即延时向量； $L=N-(m-1)\tau$ 为该相空间中点的个数。最终可以得到下方所示的矩阵：

$$\begin{pmatrix} x_{11} & \cdots & x_{1m} \\ \vdots & & \vdots \\ x_{L1} & \cdots & x_{Lm} \end{pmatrix} \quad (3)$$

在实现相空间重建的过程中，需要考虑常用的两个参数 τ 和 m ，可利用Frasert等提出的平均互信息^[31]确定时间延迟，用伪近邻^[32]方法来估计嵌入维度。平均互信息方法将一维时间序列 $X(t)$ 和它的延时版本 $X(t+\tau)$ 的平均互信息 $I(\tau)$ 作为量化两序列独立性的指标，如公式(4)所示，Frasert等根据互信息的第一个最小点选取确定最优 τ 。

$$I(\tau) = \sum_{i,j} p_{ij}(\tau) \log \left(\frac{p_{ij}(\tau)}{p_i p_j} \right) \quad (4)$$

其中， i 为原序列的元素索引； j 为延时序列的元素索引； p_i 为原序列的概率密度； p_j 为延时序列的概率密度； p_{ij} 为原序列和延时序列的联合概率密度。

伪近邻的基本思想认为观测到的时间序列是高维相空间轨迹在一维上的投影。在投影过程中, 将高维中原本并不相邻的点投影在低维空间中邻近的点, 即伪近邻点。随着对时间序列的相空间重构, 混沌运动的轨迹逐渐恢复且轨道打开, 伪近邻点消失。其数学描述如公式(5)所示。

$$R_d(i)=\|X_i-X_i^{NN}\| \quad (5)$$

其中, d 为嵌入维度; X_i^{NN} 为最近邻点; $R_d(i)$ 为嵌入维度为 d 时迟延向量与最近邻点 X_i^{NN} 间的欧式距离。当嵌入维度增加到 $d+1$ 时, 在同样索引下, 两轨迹点的距离如公式(6)所示。

$$R_{d+1}^2(i)=R_d^2(i)+\|X(i+d\tau)-X^{NN}(i+d\tau)\|^2 \quad (6)$$

由公式(5)~(6)可知, 当 $R_{d+1}^2(i)$ 远大于 $R_d^2(i)$ 时, 邻近点为虚假的。为此可令:

$$E_d=\frac{\|X(i+d\tau)-X^{NN}(i+d\tau)\|}{R_d(i)} \quad (7)$$

当 E_d 大于阈值 R_τ 时, 即可得 X_i^{NN} 是 X_i 的伪最近邻点。随着嵌入维度的增加, 伪最近邻点的比例会逐渐减少, 直到该比例小于阈值时的嵌入维度, 即为最优估计。

本文利用上述方法最终确定时间延迟 τ 为 5, 嵌入维度 m 为 3。然后将经延时嵌入的相空间矩阵作为样本输入神经网络模型进行训练。

上述相空间重建的代码使用的编程环境为 Python3.8 及其 giotto 包。在平均互信息确定时间延迟和伪近邻确定嵌入维度方面, 本文利用 Wallot 等^[29]公开的 Matlab 代码完成。

2.3.2 PSR-CNN

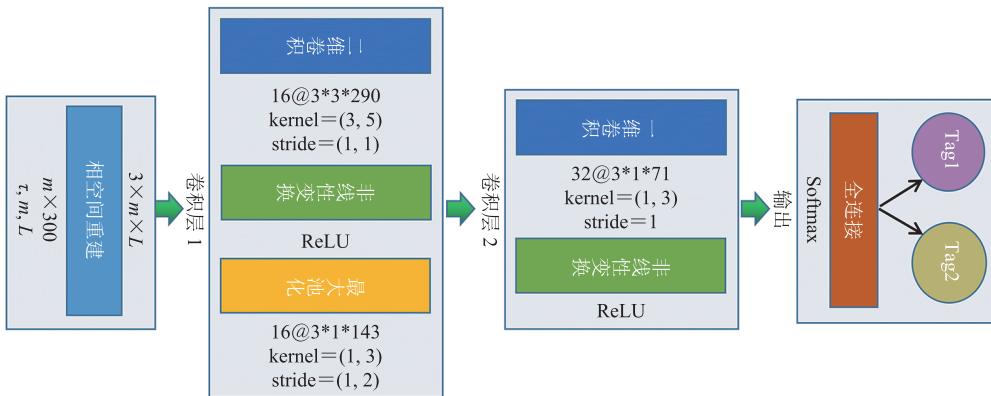
卷积神经网络模型具有良好的网格结构识别能力, 常被用于图片的分类分割等任务^[33]。本文希望利用卷积神经网络提取相空间关键特征, 并希望该特征能加速模型的分类。在输入卷积网络前, 为保证输入到模型的数据结构一致, 对数

据进行补 0 操作, 即在每个通道的末尾补上足够数量的 0, 使输入到卷积神经网络的数据大小相同, 补 0 之后的数据大小为 3×300 。经相空间重建后的输入数据大小为 $3 \times 3 \times 290$ 。

将呼吸周期波形经重构后得到的相空间输入卷积结构, 卷积层的设置需考虑卷积核的尺寸与卷积移动的步长。为保证卷积核可以捕捉到相空间所反映的系统演化信息, 需要在卷积的过程中对相空间中构成的轨迹点做特征捕获。经 PSR 编码后的呼吸波形的每个通道大小为 $m \times L$, 其中, m 为相空间中的每个点的维度。当 $m > 1$ 时, 即相空间中点的维度大于 1。此时, 若卷积核的大小为 $kh \times kw$, 其中, kh 为卷积核的高度, kw 为其宽度, 那么 kh 的大小应等于 m , 而 kw 则可以表示每次卷积相空间轨迹点的个数 Nt 。在调参过程中, 不需要调整 kh , 只需改变 kw 和卷积核移动的步长。经上述二维卷积后, 可得到一个关于相空间轨迹的一维特征向量, 此时, 只需设置一维卷积即可进一步提取相空间的时序依赖特征。因此, 本文的卷积神经网络共设置了两个卷积层, 用于提取特征: 第一个卷积层包括一个二维卷积、非线性变换和最大池化; 第二个卷积层包括一维卷积和非线性变换。两个卷积层使用的激活函数均为整流线性单元(rectified linear units, ReLU)。卷积层提取完特征后, 经一个全连接层输出分类标签。图 5 为 PSR-CNN 模型各层的连接关系及其输入与输出。

2.4 评价指标

在 PVA 分类任务中, 常采用的评价指标包括准确率(accuracy)、F1 分数(F1-score)、灵敏度(sensitivity)和特异性(specificity)^[15,18-20]。其中, accuracy 和 F1-score 是两个综合性指标, 可反映模型的综合性能。但 accuracy 对数据样本分布较为敏感, 易产生偏差, 而 F1-score 则综合考虑了精准度与召回率两个指标。sensitivity 和 specificity 是两个局部性指标, 分别表示模型对



注: ReLU 为整流线性单元; kernel 为卷积核; stride 为步长; Softmax 为归一化指数函数

图 5 PSR-CNN 结构

Fig. 5 The structure of PSR-CNN

阳性和阴性样本的筛选能力,从医学的角度而言,可分别反映漏诊率和误诊率的大小。

本文工作中的二分类任务采用上述 4 种指标进行衡量,计算公式如公式(8)~(11)所示。

$$\text{accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (8)$$

$$\text{specificity} = \frac{TN}{TN+FP} \quad (9)$$

$$\text{sensitivity} = \frac{TP}{TP+FN} \quad (10)$$

$$\text{F1-score} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (11)$$

其中, TP 为混淆矩阵中真阳性的数量; TN 为混淆矩阵中真阴性的数量; FP 为混淆矩阵中假阳性的数量; FN 为混淆矩阵中假阴性的数量。

表 5 各模型在 Hold-out 实验中的结果对比表

Table 5 Results comparison among different models under Hold-out experiment

模型	Accuracy	Sensitivity	Specificity	F1-score
PSR-CNN	0.9708 ± 0.005	0.9633 ± 0.008	0.9754 ± 0.008	0.9705 ± 0.005
Transformer	0.9623 ± 0.007	0.9481 ± 0.015	0.9763 ± 0.006	0.9615 ± 0.007
CNN-LSTM ^[21]	0.9673 ± 0.005	0.9596 ± 0.009	0.9749 ± 0.008	0.9669 ± 0.005
CNN ^[20]	0.9670 ± 0.006	0.9553 ± 0.160	0.9796 ± 0.010	0.9660 ± 0.006
时域特征-RF	0.9455 ± 0.005	0.9349 ± 0.001	0.9560 ± 0.009	0.9447 ± 0.005
频域特征-RF	0.9238 ± 0.008	0.9365 ± 0.007	0.9113 ± 0.013	0.9246 ± 0.008

注: $p < 0.01$

3 结果

Hold-out 和 LOSO 两种交叉验证的结果均采用 t 检验对结果进行统计分析, 显著性水平 $\alpha=0.01$ 。实验结果统一使用均值土标准差, 即 $(\mu \pm \sigma)$ 。

3.1 Hold-out 实验结果

利用 7 例临床患者共 16 760 个机械通气呼吸周期, 验证混合通气模式下人机不同步分类任务的可行性, 除比较了时域和频域特征分别使用 RF 分类器时的性能外, 还对比了 Zhang 等^[19]提出的 LSTM 模型、Pan 等^[20]提出的 CNN 模型、Chen 等^[21]提出的 Attention-based CNN-LSTM 模型以及本文构造的 Transformer 模型, 实验结果如表 5 所示。

由表 5 可知, 与其他 4 种模型相比, 本文提出的 PSR-CNN 模型的平均 F1-score 最高, 为 97.05%, 其次是 Chen 等^[21]提出的 Attention-based CNN-LSTM 模型, 为 96.69%, 以及 Pan 等^[20]提出的 CNN 模型, 为 96.60%。在 F1-score 指标下, 基于时域和频域特征的 RF 模型的结果分别为 94.47% 和 92.46%, 均低于深度模型。在平均 accuracy 指标下, PSR-CNN、CNN、时域特征-RF 和频域特征-RF 等 4 个模型的结果依次为 97.08%、96.70%、94.55% 和 92.38%。

与 Pan 等^[20]提出的 CNN 模型 (95.53%) 相比, 本文的 PSR-CNN 模型 (96.33%) 的平均 sensitivity 约高出 1%, 但本文模型 (97.54%) 的平均 specificity 指标却略低于 CNN 模型 (97.96%); 与 Chen 等^[21]的模型相比, 本文模型的各个指标均较高。就平均 sensitivity 和平均 specificity 两个指标上的性能而言, 基于特征的两种模型 (时域特征-RF 和频域特征-RF) 低于本文的深度模型。

整体来讲, 在 Hold-out 实验中, 基于特征的模型 (时域特征-RF 和频域特征-RF) 在各项指标上均低于基于深度的模型。而本文提出的 CNN 改进模型 PSR-CNN 的各项指标, 除平均 specificity 略低外, 其他指标均高于 Pan 等^[20]提出的 CNN 模型, 全部高于 Chen 等^[21]提出的 Attention-based CNN-LSTM 模型。

3.2 LOSO 实验结果

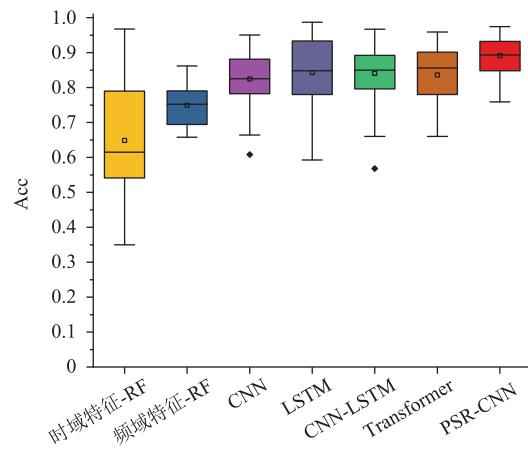
LOSO 实验将每个病例的数据集依次作为测试集, 其余各对象数据作为训练集。在该实验设置的基础上, 本文对比了基于特征和深度模型的 accuracy、sensitivity、specificity 和 F1-score 4 个指标的性能。表 6 为该实验中各模型的 sensitivity 和 specificity 指标的数值; 图 6 以箱线图的形式直观地对比了 7 个模型在 accuracy 和 F1-score 两个评价指标上的大小。

在 LOSO 实验中, 所有病例均被挑出来, 依次作为测试集, 其余病例作为训练集, 最后

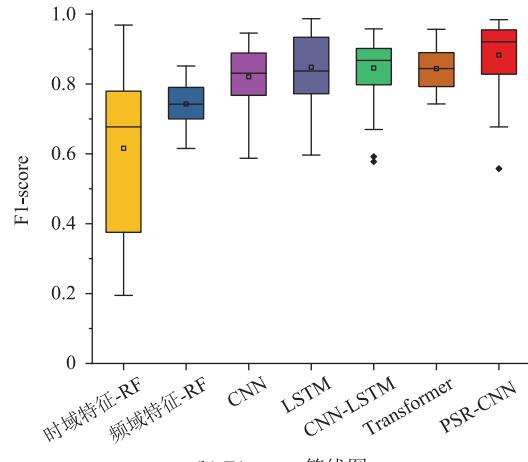
表 6 LOSO 实验中各模型的平均 sensitivity 与 specificity
指标结果表

Table 6 Listed results performed by 7 models in the
LOSO experiment

模型	Sensitivity	Specificity
PSR-CNN	0.921 8±0.066	0.868 9±0.104
Transformer	0.836 0±0.079	0.787 4±0.215
CNN-LSTM ^[21]	0.893 5±0.151	0.788 3±0.171
LSTM ^[19]	0.891 2±0.151	0.795 8±0.233
CNN ^[20]	0.867 5±0.169	0.782 4±0.174
时域特征-RF	0.720 8±0.326	0.540 6±0.363
频域特征-RF	0.772 6±0.173	0.726 5±0.226



(a) 准确率箱线图



(b) F1-score 箱线图

注: 箱体指结果 25%~75% 区间, 上下实线指 1.5 倍四分位间距内的范围, 中间黑色横线为中位数, 黑色小方框指均值, 菱形为异常值; $p < 0.01$

图 6 LOSO 实验中各模型结果箱线图

Fig. 6 Illustration for results of LOSO with boxplot

对所有结果取平均，得到表 6 所示结果。由表 6 可知，在 LOSO 实验中，PSR-CNN 模型的平均 sensitivity 比对比模型高出 2.83%~20.1%，而该模型的平均 specificity 高出对比模型 7.31%~32.83%；Zhang^[19]和 Chen^[21]等提出的模型结果相近(89.35% vs 89.12% 和 78.83% vs 79.58%)，均高于 Pan 等^[20]提出的 CNN 模型；结果最低的为时域特征-RF 模型，该模型实现了最低 72.08% 的平均 sensitivity 和最低 54.06% 的平均 specificity。

图 6 的箱线图中直观地反映了本文所提出的 PSR-CNN 模型实现了最好的 89.17% 的平均 accuracy 和 88.77% 的平均 F1-Score，均高于现有的模型。Chen 等^[21]提出的基于注意力机制的卷积长短记忆网络的平均 accuracy 为 84.06%，平均 F1-Score 为 84.52%，与 Zhang 等^[19]提出的 LSTM 模型效果相似，其平均 accuracy 为 84.33%，平均 F1-Score 为 85.13%，均高于 Pan 等^[20]提出的 CNN 模型(82.48% 和 82.64%)。基于特征的机器学习模型在该实验中仍然得到了最低的平均 accuracy 和平均 F1-Score：分别为频域特征下的 74.93% 和 74.97%，以及时域特征下的 63% 和 61.84%。

综上所述，在 LOSO 实验中，基于特征的方法的实验结果较低。在基于数据驱动的深度网络模型中，本文提出的 PSR-CNN 模型的 4 个指标平均评分均显著高于现有模型。

4 讨 论

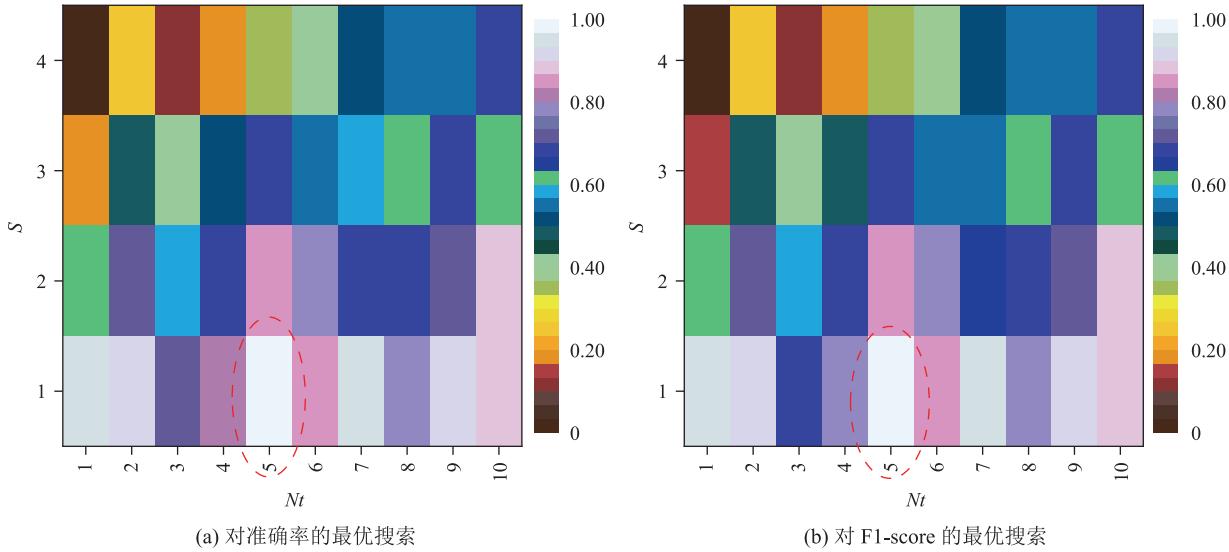
交叉验证的结果显示，无论是基于数据驱动的深度模型，还是基于手工特征的机器学习模型，均可用于解决混合通气模式下人机不同步的识别任务。在本文所用到的 4 个评价指标上，基于特征工程的模型性能均明显低于深度模型。在 Hold-out 实验中，本文提出的 PSR-CNN 模型

的性能虽总体高于现有的 Attention-based CNN-LSTM 模型的性能和 Pan 等^[20]提出的 CNN 模型的性能，但差别较小，甚至出现 CNN 模型的平均 specificity 略高于 PSR-CNN 模型的情况。

对表 5 中的结果进行分析，究其原因：

(1) 特征选择。由于时域特征-RF 模型和频域特征-RF 模型的特征均由手动选取，因此，选取的数量和质量均受选取人经验的影响。例如：在选取时域特征时，是否需要将样本点的个数作为其中一个特征；标准差与方差是否需要同时作为特征入选。同理，在选取频域特征时，是否需要选取 PSD 的中值和分位数。由于本文的主要工作并非筛选哪个手工特征更为有效，所以并未对基于特征的方法作主成分分析。而基于数据驱动的深度模型则只需设置部分超参数，便可由网络自动提取特征。通常，深度网络提取的特征数量远超手工提取的特征数量，而特征数量越多，越容易达到较好的分类效果，因此，深度模型的性能优于基于特征工程的模型。(2) Hold-out 实验设置本身。该实验理论上要求将所有数据混合，然后随机分成互斥的两个子集。在分类前，假定每个呼吸周期的数据不同，但在实际情况中，同一病例的呼吸波形在多数情况下，相似度较高。因此，可以认为信息泄露是 Hold-out 实验结果整体较好的原因。同时，可能由于部分周期标注错误，使得无论是 Chen 等^[21]提出的 Attention-based CNN-LSTM 模型，还是本文提出的 PSR-CNN 模型，在未出现过拟合的情况下，在该数据集上的测试误差无法继续减小，因而导致 PSR-CNN 模型与 CNN 模型的性能十分接近。

和 Hold-out 实验相比，LOSO 实验几乎不存在信息泄露的问题，而且更能反映模型的泛化能力，因此，LOSO 实验的结果更准确。由表 6 和图 6 可知，在 LOSO 实验中，基于深度的模型要显著优于基于特征方法的模型。同现有公开的模型进行对比后发现，本文提出的 PSR-CNN 模型



注: N 为卷积核的宽度, 反映每次卷积相空间轨迹点的个数; S 为卷积核移动的步长

图 7 最佳性能卷积参数搜索图

Fig. 7 Searching plot for optimal measurement by varying convolutional parameters

表 7 训练样本平均耗时对比表

Table 7 Table in terms of average time consumption

模型	平均耗时 (ms)
PSR-CNN	2.257 6
Transformer	9.242 1
CNN-LSTM ^[18]	13.827 5
2layer-LSTM ^[16]	27.516 0
CNN ^[17]	4.894 0

在 4 个评价指标上的表现较优。值得注意的是, 与 CNN 模型相比, 本文提出的模型除增加一个 PSR 层外, 其余结构相同。因此, 可认为增加的 PSR 层对提高 CNN 模型的性能有所帮助。

对 PSR 层帮助提高 CNN 模型性能的原因进行如下分析: PSR 过程是对原始呼吸波形按照最优嵌入维度估计进行重构, 重构后的空间被认为可以反映原非线性系统的演化过程。在进行卷积的过程中, 本文将卷积核设置为 $3 \times Nt$ (其中, 3 为嵌入维度的大小; Nt 为一次卷积空间轨迹点的个数), 该设置允许模型按照重构后的空间进行卷积, 使模型提取到有关非线性系统的演化信息, 原始呼吸波形无此特征。此外, Nt 的大小和

卷积核移动的步长对结果也会产生一定影响。在使用 PSR-CNN 模型执行 LOSO 实验的过程中发现, 当 Nt 为 5、卷积核移动的步长为 1 时, PSR 层得到的平均性能最好, 如图 7 所示。此外, PSR-CNN 模型的单位样本训练时间要明显低于其他模型, 如表 7 所示。PSR-CNN 模型的耗时最短, 不足 Pan 等^[20]提出的 CNN 模型的 1/2。其他模型的单个样本平均耗时均大于本文模型的 4~10 倍。因此, 与其他模型相比, PSR-CNN 模型具有更低的复杂性和更高的效率。该结果的原因是: 与原始信号相比, 原始序列的 PSR 中包含了更为丰富的系统变化信息。

总之, PSR 的加入使得卷积网络可以更快地提取到不同 PVA 的模式差异, 从而在保持较高泛化性能的同时, 减小模型复杂度, 提高训练效率。

然而, 本文工作的一个待改进和继续深入发掘的地方在于 PSR 过程中嵌入维度和时间延迟的选择。本文直接利用 Fraser 等^[31]提出的平均互信息算法和 Kennel 等^[32]提出的伪近邻算法得到延时嵌入参数。Lang 等^[34]对相空间重建这一

过程中两个参数的计算方法进行了讨论，该文献指出：在估计时间延迟的方法中，包括自相关法文献提出的平均距离法、复杂自相关法，以及本文所用到的平均互信息算法；估计嵌入维度的参数则有 Cao method、奇异值分解法和本文提到的伪近邻法。在多种混沌系统中，Lang 等^[34]对不同方法组合进行讨论，得到复杂自相关和伪近邻算法为最优算法组合的结论，即通过这两组算法求得的嵌入维度和时间延迟可以使得重建后的相空间与原始系统的相似度最高。因此，本文的工作在嵌入维度和时间延迟的方法选取方面值得进一步研究，具体包括：(1) 最优算法组合计算得到的相空间重建参数是否会在 Hold-out 实验和 LOSO 实验中表现最优？(2) 达到最好分类结果的相空间重建参数有什么规律，与最优算法组合计算得到的结果是否具有一致性，它们的关系是什么？

本文另一处值得完善的地方是增加更多的测试病例，以验证模型的泛化性能。本实验仅使用了 7 例患者的机械通气临床数据，共 15 000 个呼吸周期，与现有文献中数十万个呼吸周期样本相比，差距巨大。因此，在后续工作中，将收集更多的临床病例数据，进一步验证模型和完善算法。

5 结 论

机械通气过程中人机不同步现象是临床患者身上常见的问题。混合通气模式下的 PVA 识别对呼吸机的智能化和生理闭环具有重要意义。本文提出并验证了混合通气模式下 PVA 的分类识别任务。针对该任务，本文设置了 Hold-out 和 LOSO 实验，并对比了多个模型的性能。结果显示，在两种实验中，与基于特征的机器学习模型和其他一些现有的模型相比，本文提出的 PSR-CNN 模型的各项评价指标均有所提高，尤其是在 LOSO 实验中，各项指标水平有了显著的提升。这一结

果表明，PSR-CNN 模型具有良好的泛化性能，该方法可用于其他 PVA 或时间序列的分类任务中。

参 考 文 献

- [1] 李潘宇. 机械通气应用发展简述 [J]. 外科研究与新技术, 2019, 8(2): 130-134.
Li PY. Application and development of mechanical ventilation [J]. Surgical Research and New Technique, 2019, 8(2): 130-134.
- [2] Saavedra SN, Barisich PVS, Maldonado JBP, et al. Asynchronies during invasive mechanical ventilation: narrative review and update [J]. Acute and Critical Care, 2022, 37(4): 491-501.
- [3] Acho M, Kriner E, Sartain NN, et al. Impact of a mechanical ventilation curriculum on respiratory therapist recognition of patient-ventilator asynchrony [J]. Respiratory Care, 2022, 67(12): 1597-1602.
- [4] 孙娜, 孙英明, 刘学惠, 等. ICU 机械通气病人人机异步研究进展 [J]. 护理研究, 2021, 35(8): 1457-1460.
Sun N, Sun YM, Liu XH, et al. Research progress of patient-ventilator asynchrony of mechanical ventilation patients in ICU [J]. Chinese Nursing Research, 2021, 35(8): 1457-1460.
- [5] De Oliveira B, Mallat J. Personalized mechanical ventilation: improving quality of care [M]. Cham: Springer, 2022: 269-285.
- [6] See KC, Sahagun J, Taculod J. Defining patient-ventilator asynchrony severity according to recurrence [J]. Intensive Care Medicine, 2020, 46(4): 819-822.
- [7] Bailey JM. Management of patient-ventilator asynchrony [J]. Anesthesiology, 2021, 134(4): 629-636.
- [8] de Haro C, Ochagavia A, López-Aguilar J, et al. Patient-ventilator asynchronies during mechanical ventilation: current knowledge and research priorities [J]. Intensive Care Medicine Experimental, 2019, 7: 43.

- [9] 罗熙, 吴太虎, 陈锋, 等. 闭环机械通气控制技术应用及前景展望 [J]. 医疗卫生装备, 2021, 42(4): 76-80+108.
- Luo X, Wu TH, Chen F, et al. Application and prospect of closed-loop mechanical ventilation control technology [J]. Chinese Medical Equipment Journal, 2021, 42(4): 76-80+108.
- [10] 谢俊祥, 张琳. 呼吸机现状及发展趋势 [J]. 中国医疗器械信息, 2014, (2): 10-20.
- Xie JX, Zhang L. The current situation and prospects of mechanical ventilator industry [J]. China Medical Device Information, 2014, (2): 10-20.
- [11] 薛昊轩, 陈正龙, 李宪龙, 等. 呼吸机闭环控制技术研究进展及应用 [J]. 生物医学工程与临床, 2022, 26(1): 123-128.
- Xue HX, Chen ZL, Li XL, et al. Research progress of physiological closed loop control technology of ventilator [J]. Biomedical Engineering and Clinical Medicine, 2022, 26(1): 123-128.
- [12] Qestra M, Piero C, Annalisa C, et al. Automatic detection of ineffective triggering and double triggering during mechanical ventilation [J]. Intensive Care Medicine, 2007, 33(11): 2014-2018.
- [13] Rodriguez PO, Tiribelli N, Gogniat E, et al. Automatic detection of reverse-triggering related asynchronies during mechanical ventilation in ARDS patients using flow and pressure signals [J]. Journal of Clinical Monitoring and Computing, 2020, 34(6): 1239-1246.
- [14] Rehm GB, Han J, Kuhn BT, et al. Creation of a robust and generalizable machine learning classifier for patient ventilator asynchrony [J]. Methods of Information in Medicine, 2018, 57(4): 208-219.
- [15] Casagrande A, Quintavalle F, Fernandez R, et al. An effective pressure-flow characterization of respiratory asynchronies in mechanical ventilation [J]. Journal of Clinical Monitoring and Computing, 2021, 35(2): 289-296.
- [16] Rehm GB, Kuhn BT, Nguyen J, et al. Improving mechanical ventilator clinical decision support systems with a machine learning classifier for determining ventilator mode [J]. Studies in Health Technology and Informatics, 2019, 264: 318-322.
- [17] 陆云飞, 陆飞, 方路平, 等. 应用小波多尺度特征检测机械通气人机不同步 [J]. 小型微型计算机系统, 2020, 41(12): 2677-2682.
- Lu YF, Lu F, Fang LP, et al. Application of wavelet multi-scale characteristics to detect patient-ventilator asynchrony in mechanical ventilation [J]. Journal of Chinese Computer Systems, 2020, 41(12): 2677-2682.
- [18] Blanch L, Sales B, Montanya J, et al. Validation of the Better Care® system to detect ineffective efforts during expiration in mechanically ventilated patients: a pilot study [J]. Intensive Care Medicine, 2012, 38(5): 772-780.
- [19] Zhang LW, Mao KD, Duan KL, et al. Detection of patient-ventilator asynchrony from mechanical ventilation waveforms using a two-layer long short-term memory neural network [J]. Computers in Biology and Medicine, 2020, 120: 103721.
- [20] Pan Q, Zhang LW, Jia MZ, et al. An interpretable 1D convolutional neural network for detecting patient-ventilator asynchrony in mechanical ventilation [J]. Computer Methods and Programs in Biomedicine, 2021, 204: 106057.
- [21] Chen DF, Lin KW, Deng ZH, et al. Attention-based convolutional long short-term memory neural network for detection of patient-ventilator asynchrony from mechanical ventilation [J]. Biomedical Signal Processing and Control, 2022, 78: 103923.
- [22] Pham T, Montanya J, Telias I, et al. Automated detection and quantification of reverse triggering effort under mechanical ventilation [J]. Critical Care, 2021, 25(1): 60.
- [23] Sottile PD, Albers D, Higgins C, et al. The association between ventilator dyssynchrony, delivered tidal volume, and sedation using a novel automated ventilator dyssynchrony detection algorithm [J]. Critical Care Medicine, 2018, 46(2): e151-e157.
- [24] Pan Q, Jia MZ, Liu QJ, et al. Identifying patient-ventilator asynchrony on a small dataset using image-based transfer learning [J]. Sensors, 2021,

- 21(12): 4149.
- [25] Marchuk Y, Magrans R, Sales B, et al. Predicting patient-ventilator asynchronies with hidden Markov models [J]. *Scientific Reports*, 2018, 8(1): 17614.
- [26] 周志华. 机器学习 [M]. 北京: 清华大学出版社, 2016: 23-51.
Zhou ZH. Machine learning [M]. Beijing: Tsinghua University Press, 2016: 23-51.
- [27] Zheng A, Casari A. Feature engineering for machine learning [M]. Sebastopol: O'Reilly Media, Inc., 2018: 4-32.
- [28] Boonyakitanont P, Lek-Uthai A, Chomtho K, et al. A review of feature extraction and performance evaluation in epileptic seizure detection using EEG [J]. *Biomedical Signal Processing and Control*, 2020, 57: 101702.
- [29] Wallot S, Mønster D. Calculation of average mutual information (AMI) and false-nearest neighbors (FNN) for the estimation of embedding parameters of multidimensional time series in Matlab [J]. *Frontiers in Psychology*, 2018, 9: 1679.
- [30] Yan Y, Wu XK, Li CD, et al. Topological EEG nonlinear dynamics analysis for emotion recognition [J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2022, 15(2): 625-638.
- [31] Fraser AM, Swinney HL. Independent coordinates for strange attractors from mutual information [J]. *Physical Review A*, 1986, 33(2): 1134.
- [32] Kennel MB, Brown R, Abarbanel HDI. Determining embedding dimension for phase-space reconstruction using a geometrical construction [J]. *Physical Review A*, 1992, 45(6): 3403.
- [33] Goodfellow I, Bengio Y, Courville A. Deep learning [M]. Cambridge: MIT Press, 2016: 201-226.
- [34] Lang SH, Zhu H, Sun GD, et al. A study on methods for determining phase space reconstruction parameters [J]. *Journal of Computational and Nonlinear Dynamics*, 2022, 17(1): 011006.