arXiv:2301.01469v1 [eess.SP] 4 Jan 2023

基于机器学习的电阻抗断层成像心脏容积监测信号质量评估

Chang Min Hyun[1], **Tae Jun Jang**[1], **Jeongchan Nam**[2], **Hyeuknam Kwon**[3], **Kiwan Jeon**[4], **和 Kyunghun Lee**[5]¶

[1]延世大学数学与计算学院（计算科学与工程），大韩民国首尔。[2]BiLab，大韩民国板桥。[3]延世大学软件系，大韩民国原州。[4]国家数学科学研究所，大韩民国大田。[5]庆熙大学，大韩民国首尔。

摘要。 由于胸部电阻抗断层成像的最新进展，通过监测与每搏量和心输出量相关的心脏容积信号，可以无创、连续地实时估算患者的血流动力学功能。然而，在临床应用中，心脏容积信号的质量往往较低，主要是因为患者有意活动，或在临床干预过程中不可避免的运动。本研究旨在开发一种信号质量指数方法，用于评估运动伪影对瞬态心脏容积信号的影响。该评估针对每个心动周期进行，以充分利用心脏容积变化的周期性和规律性。利用同步心电图系统确定时间间隔。我们采用多种机器学习方法，可分为判别模型方法和流形学习方法。机器学习适用于我们的实时监测应用，因为该应用要求推理快速、自动化程度高且准确率高。在临床环境中，该方法可用于发出即时警报，使临床医生能够减少对患者状况的误判、降低临床资源使用，并提高对监测系统的信心。通过大量实际电阻抗断层成像数据实验，验证了机器学习能够实时、准确且自动地评估受运动伪影干扰的心脏容积信号。最佳模型的准确率为0.95，阳性和阴性预测值分别为0.96和0.86，敏感度为0.98，特异度为0.77，曲线下面积为0.96。

¶ 通信请联系（imlkh84@gmail.com）

1. 引言

数十年来，电阻抗断层成像（EIT）的持续发展克服了传统方法的局限性，例如通过血管进行心脏导管插入术 [3, 8, 18, 19, 28, 29, 37, 41, 57]，从而提升了实时心肺监测系统的临床能力。近年来，基于胸部电阻抗断层成像，通过监测利用EIT提取的信号——即心脏容积信号（CVS）——可以无创、连续地实时估算患者的血流动力学功能。该信号与每搏量和心输出量等关键血流动力学因素密切相关 [4, 27, 51]。然而，在临床应用中，心脏容积信号的质量往往较低，主要是因为患者有意活动，或在医疗和护理等临床干预过程中不可避免的运动。由于体位变化会导致胸部边界移动，而现有电阻抗断层成像求解器因时间差重建特性对此高度敏感 [1, 7, 32, 36, 44],，心脏容积信号中会产生运动诱发伪影，如图1所示。

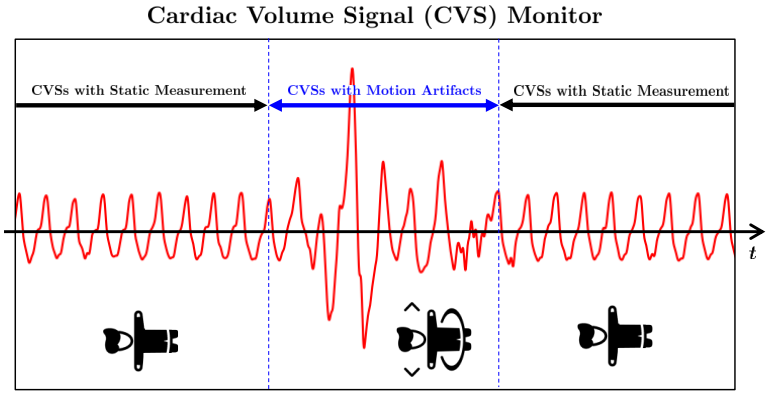


图1. 采用电阻抗断层成像进行心脏容积监测时的运动诱发伪影。患者有意的动作或临床干预过程中不可避免的运动，都会导致心脏容积信号出现严重伪影。

心脏容积信号提取是指从电阻抗断层成像电压数据中分离出心源性成分；这些电压数据由附着于人体胸腔各处电极的电流注入产生。近期研究表明， [27, 39], 在无运动测量中，成功实现了有效的心血管信号提取；此时电压数据主要受肺部、心脏和血管中的空气与血容量变化综合影响，而不受运动影响。相比之下，在受运动影响的测量中实现心源性成分分离，仍是一项长期挑战。电阻抗断层成像测量中的体位变化会使电压数据严重失真 [1, 56] ，并容易干扰相对微弱的心源性信号提取 [6, 33, 40]。

处理运动干扰一直是大多数旨在提升临床能力的电阻抗断层成像技术面临的巨大挑战，但迄今相关研究仍不多 [54]。Adler等 [1] 和 Zhang 等 [56] 研究了运动对电阻抗断层成像的负面影响。

Soleimani等 [43] 和 Dai等 [17]提出了一种运动诱发伪影减少方法，通过重建电极移动以及电导率变化来实现。Lee等 [36] 分析了电阻抗断层成像测量中的运动伪影，并提出了一种基于子空间的伪影抑制方法。Yang等 [54] 提出了一种基于离散小波变换的方法，可减少三种特定类型的运动伪影。然而，由于实际运动具有极大的多样性和复杂性，临床运动伪影仍未得到有效解决。因此，目前基于电阻抗断层成像的血流动力学监测系统倾向于优先过滤受运动影响的心血管信号，而非对其进行恢复。在临床环境中，这种过滤能够及时发出警告，使临床医生可以减少对患者状况的误判，降低临床资源使用，并提高对监测系统的信心 [16]。

本研究旨在开发一种信号质量指数（SQI）方法，用于评估运动伪影是否会影响瞬态心血管信号。为利用心脏容积变化的周期性和规律性，我们针对每个心动周期进行评估，并使用同步心电图（ECG）系统确定各周期的时间间隔。我们借助机器学习（ML），通过对复杂信号进行特征解耦，为各种生物信号相关任务提供有效解决方案 [5, 9, 14, 25, 34, 47, 48, 52]。机器学习适用于我们的实时监测应用，因为该应用需要快速推理、自动化以及高准确率。

我们采用了多种机器学习方法，可分为判别模型方法和流形学习方法。首先考虑判别模型方法，即利用 CVS 与其标签组成的配对数据集直接训练信号质量指数图 [12, 22, 45]。尽管这种方法在固定数据集上表现出色，但由于类别不平衡问题，在泛化能力或稳定性方面，模型存在对运动干扰的心血管信号数据过拟合的风险 [10, 15, 23, 49]。在现实情境中，运动伪影可能存在很大差异；然而，由于临床数据采集和标注成本高、劳动强度大，并涉及安全性和歧义问题，实际中难以收集大量受运动影响的 CVS 数据 [13, 46, 50, 58]。为应对这一潜在难题，我们考察了流形学习方法 [2, 24, 26, 30] 作为替代方案。该方法不学习运动干扰的心血管信号中不规则且变幻莫测的模式，而仅利用从未受运动干扰的 CVS 中学习到的特征。

我们使用实际电阻抗断层成像数据进行了大量实验。实证结果表明，判别模型和流形学习模型能够实时准确、自动地检测受运动影响的心血管信号。表现最佳的判别模型准确率为 0.95，阳性和阴性预测值分别为 0.96 和 0.86，敏感度为 0.98，特异度为 0.77，曲线下面积为 0.96。表现最佳的流形学习模型准确率为 0.93，阳性和阴性预测值分别为 0.97 和 0.71，敏感度为 0.95，特异度为 0.80，曲线下面积为 0.95。判别模型的信号质量指数表现更强；相比之下，流形学习模型

在训练集和测试集之间提供了稳定的结果。对于实际应用，选择哪种模型取决于监测系统在性能和稳定性方面需要侧重的目标。

2. 方法

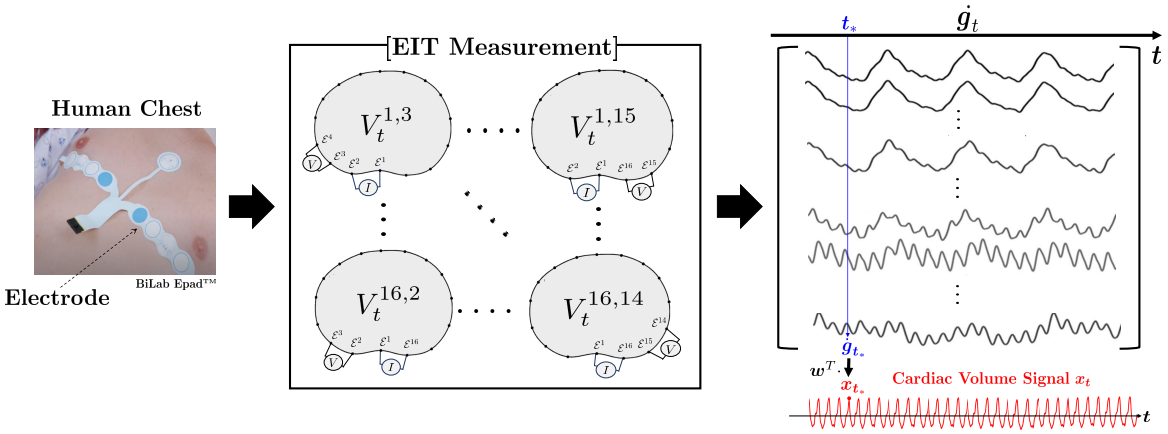


图2. 胸部电阻抗断层成像和心脏容积信号提取的16通道系统。电阻抗断层成像设备通过向沿人体胸腔布置的电极注入电流来测量电压差。通过对时差传导率 $\dot{\boldsymbol{g}}_t$施加适当的权重 $\boldsymbol{w}$ ，可提取心脏容积信号 $\boldsymbol{x_t}$ ；时差传导率由测得的电压数据定义。这里，$\boldsymbol{w}$ 称为导联形成向量，其设计目的是从叠加数据 $\dot{\boldsymbol{g}}_t$ [39]中分离出心源性传导率变化。

本研究采用胸部电阻抗断层成像的16通道系统，其中16个电极沿人体胸腔布置（见图2）。假设电阻抗断层成像系统与心电图系统同步，后者提供每个心动周期的时间间隔。电阻抗断层成像设备通过相邻电极对注入幅值为 I (mA) 的交流电，同时使所有其他电极保持绝缘，从而测量一组电压差。在采样时间 t，采集到以下电压：

$$\{V_t^{j,k} \ : \ V_t^{j,k} = U_t^{j,k} - U_t^{j,k+1}, j \in \mathcal{I}, k \in \mathcal{I} \backslash \{j, j+1\}\} \tag{1}$$

其中， $\mathcal{I}$是由 $\mathcal{I} = \{1、2、\cdots、16\}$定义的指标集， $\mathcal{E}_k$是第 k个电极，而 $U^{j、}{}_{t}{}^{k}$是在电流从 $\mathcal{E}_j$ 注入至 $\mathcal{E}_{j+1}$时， $\mathcal{E}_k$ 上的电势。为方便表示， $\mathcal{E}^0$和 $\mathcal{E}^{17}$可分别理解为 $\mathcal{E}^{16}$和 $\mathcal{E}^1$。对于某个 $j \in \mathcal{I}$，一旦电流从 $\mathcal{E}^j$ 注入至 $\mathcal{E}^{j+1}$ ，便会在相邻的16对电极 $(\mathcal{E}^k、\mathcal{E}^{k+1})_{k\in\mathcal{I}}$上分别测量电压。为减小皮肤-电极接触阻抗 [44]的影响，舍弃这16个电压中的 $V^{j、}{}_{t}{}^{j-1}$、 $V^{j、}{}_{t}{}^{j}$和 $V^{j、}{}_{t}{}^{j+1}$ 。由于我们进行了16次独立电流注入，总共获得 $208\ (=16\times13)$个电压，并用以生成心血管信号。

2.1. 使用电阻抗断层成像提取心血管信号及运动的影响

可根据电压数据(1)定义跨导（列）向量 $\boldsymbol{g}_t \in \mathbb{R}^{208}$ ，如下所示：

$$\boldsymbol{g}_t = \left[\frac{I}{\Re(V_t^{1,3})}, \cdots, \frac{I}{\Re(V_t^{1,15})}, \cdots, \frac{I}{\Re(V_t^{16,2})}, \cdots \frac{I}{\Re(V_t^{16,14})} \right]^T \tag{2}$$

其中， T 表示向量转置， $\Re$ 是用于提取复数实部的运算。此处， $\boldsymbol{g}_t$ 每 10 ms 更新一次。

心血管信号（记为 $\boldsymbol{x}_t \in \mathbb{R}$）可通过以下方式获得：

$$\boldsymbol{x}_t = \boldsymbol{w}^T \dot{\boldsymbol{g}}_t \tag{3}$$

其中， $\boldsymbol{w} \in \mathbb{R}^{208}$ 是加权向量（也称为导联形成向量）， $\dot{\boldsymbol{g}}_t$ 是 $\boldsymbol{g}_t$ 的时间差，定义如下：

$$\dot{\boldsymbol{g}}_t = \boldsymbol{g}_t - \boldsymbol{g}_{t_0} \text{ for reference time } t_0 \tag{4}$$

在没有运动的情况下，跨导 $\dot{\boldsymbol{g}}_t$ 可表示为：

$$\dot{\boldsymbol{g}}_t = \dot{\boldsymbol{g}}_t^{\text{air}} + \dot{\boldsymbol{g}}_t^{\text{blood}} \tag{5}$$

其中， $\boldsymbol{g}_t^{\text{air}}$和 $\boldsymbol{g}_t^{\text{blood}}$分别是与肺部和心脏中的空气及血容量变化相关的跨导向量。加权向量 $\boldsymbol{w}$ 旨在提供

$$\boldsymbol{w}^T \dot{\boldsymbol{g}}_t = \boldsymbol{w}^T (\dot{\boldsymbol{g}}_t^{\text{air}} + \dot{\boldsymbol{g}}_t^{\text{blood}}) = \boldsymbol{w}^T \dot{\boldsymbol{g}}_t^{\text{blood}} \tag{6}$$

参见图2。有关确定 $\boldsymbol{w}$的详细信息，请参阅 [39] 。尽管心脏信号 $\boldsymbol{g}_t^{\text{blood}}$很微弱，但仍可从数据 $\boldsymbol{g}_t$中准确分解出来。

鉴于 [36], 中的前述分析，以下说明了为什么运动会导致心血管信号的质量下降，如图1中部所示。存在运动时，跨导 $\dot{\boldsymbol{g}}_t$ 可近似表示为

$$\dot{\boldsymbol{g}}_t \approx \dot{\boldsymbol{g}}_t^{\text{normal}} + \dot{\boldsymbol{g}}_t^{\text{motion}} \tag{7}$$

其中， $\dot{\boldsymbol{g}}_t^{\text{normal}} = \dot{\boldsymbol{g}}_t^{\text{air}} + \dot{\boldsymbol{g}}_t^{\text{blood}}$ 和 $\dot{\boldsymbol{g}}_t^{\text{motion}}$ 是运动诱发效应。附录A给出了式（7）的详细内容。运动伪影 [39]会显著影响向量 $\boldsymbol{w}$ 本身的确定。此外，即使 $\boldsymbol{w}$ 满足式（6），我们仍有

$$\boldsymbol{x}_t = \boldsymbol{w}^T \dot{\boldsymbol{g}}_t \approx \boldsymbol{x}_t^{\text{normal}} + \boldsymbol{x}_t^{\text{motion}} \tag{8}$$

其中， $\boldsymbol{x}_t^{\text{normal}} = \boldsymbol{w}^T \dot{\boldsymbol{g}}_t^{\text{blood}}$ 和 $\boldsymbol{x}_t^{\text{motion}} = \boldsymbol{w}^T \dot{\boldsymbol{g}}_t^{\text{motion}}$ 。最后一项 $\boldsymbol{x}_t^{\text{motion}}$描述了心血管信号中的运动伪影。

*2.2. CVS*质量评估与数据预处理

本研究旨在评估心血管信号（$\boldsymbol{x}_t$）检测运动诱发的信号质量下降的能力。参见图3。可通过开发信号质量指数图$\boldsymbol{f}$ 来实现： $\boldsymbol{x}_t \mapsto \boldsymbol{y}_t$ 使得

$$\boldsymbol{f}(\boldsymbol{x}_t) = \boldsymbol{y}_t = \begin{cases} 1 & \text{if } \boldsymbol{x}_t^{\text{motion}} \approx 0 \\ 0 & \text{if } \boldsymbol{x}_t^{\text{motion}} \not\approx 0 \end{cases} \tag{9}$$

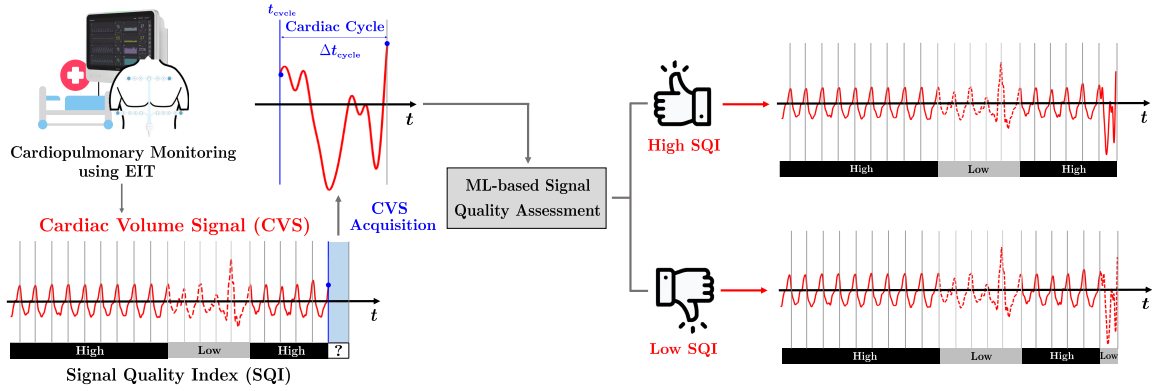


图3. 电阻抗断层成像中心脏容积监测的机器学习信号质量评估示意图。

然而，要实现（9）并不容易，因为该方法需要在每个采样时间对单个心血管信号进行评估。相反，我们利用心脏容积变化随心跳呈现的周期性和规律性。每个心动周期的时间间隔通过同步心电图系统确定。

我们对心血管信号的每个心动周期进行质量评估，其中，心动周期定义为以连续两个心电图R波峰为端点的时间间隔。对于给定时间 t_{cyc}，令区间 $[t_{\mathrm{cyc}}, t_{\mathrm{cyc}} + \Delta t_{\mathrm{cyc}}]$ 为对应的心动周期，其中假设 Δt_{cyc} 为 $\Delta t_{\mathrm{cycle}} = 10\mathrm{ms} \times (\boldsymbol{v} - 1)$，且 $\boldsymbol{v} \in \mathbb{N}\backslash\{1\}$为某个值。此处，$\mathbb{N}$ 表示正整数集合。将该周期内所有心血管信号汇集成向量，记为 $\boldsymbol{X}_{t_{\mathrm{cyc}}} \in \mathbb{R}^{\boldsymbol{v}}$，定义如下：

$$\boldsymbol{X}_{t_{\mathrm{cyc}}} = \left[\boldsymbol{x}_{t_{\mathrm{cyc}}}, \boldsymbol{x}_{t_{\mathrm{cyc}}+10\mathrm{ms}}, \cdots, \boldsymbol{x}_{t_{\mathrm{cyc}}+10\mathrm{ms}\times(\boldsymbol{v}-1)}\right]^T \tag{10}$$

式 (9) 中的映射 f 可以改写为

$$\boldsymbol{f}(\boldsymbol{X}_{t_{\mathrm{cyc}}}) = \boldsymbol{y}_t = \begin{cases} 1 & \text{for normal } \boldsymbol{X}_{t_{\mathrm{cyc}}} \\ 0 & \text{for motion-influenced } \boldsymbol{X}_{t_{\mathrm{cyc}}} \end{cases} \tag{11}$$

为求得式（11）中的 $\boldsymbol{f}$，我们利用机器学习，使其能够从由 N 数据对组成的训练数据集中学习正常及受运动影响的 CVS 的领域知识 $\{\boldsymbol{X}^{(i)}, \boldsymbol{y}^{(i)}\}_{i=1}^{N}$。在应用机器学习之前，需要解决 CVS 数据中的以下问题。首先，CVS 存在显著的个体间和个体内变异。这是因为心脏容积会因多种因素而变化，包括性别、年龄、身体状况、时间和体温。因此，需要进行尺度归一化，以提高机器学习的稳定性和性能，同时降低与尺度不变特征提取相关的高学习复杂度 [20,53]。其次，由于心率变异性 [11]，式（11）中输入心脏容积信号数据的维度彼此不一致（即，$\boldsymbol{v}$ 不是常数）。由于大多数现有机器学习方法都以维度一致的输入为基础，因此需要进行尺寸归一化。图4示意性地展示了整个流程。

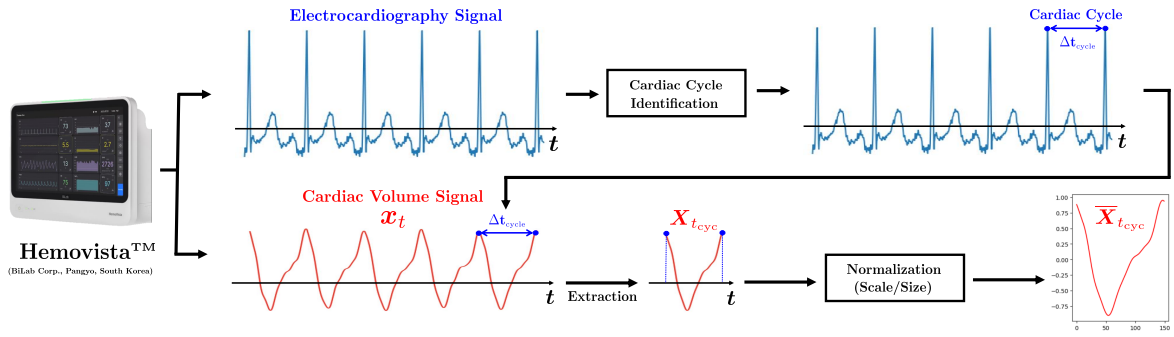


图4. 通过监测系统获取心电图和心脏容积信号。通过心电图数据识别心动周期（R波峰值检测），我们提取相应周期的心脏容积信号，最后对其进行尺度和大小归一化。

2.2.1. 尺度归一化 一种简单的尺度归一化方法是对每个心动周期的 CVS 数据进行重新缩放。具体而言，对于给定的 CVS 向量 $\boldsymbol{X}_{t_{\mathrm{cyc}}} \in \mathbb{R}^{v}$，缩放因子 $\mathcal{S}$ 通过以下方式获得

$$\mathcal{S} = \max_{i \in \mathcal{V}} \left| \boldsymbol{x}_{t_{\mathrm{cyc}}+10\times i(\mathrm{ms})} \right| \tag{12}$$

其中，指标集 $\mathcal{V}$由 $\mathcal{V} = \{0、1、\cdots、 \boldsymbol{v}-1\}$给出。归一化后的CVS数据记为 $\underline{\boldsymbol{X}}_{t_{\mathrm{cyc}}}$，其计算方式为

$$\underline{\boldsymbol{X}}_{t_{\mathrm{cyc}}} = \frac{\boldsymbol{X}_{t_{\mathrm{cyc}}}}{\mathcal{S}} \tag{13}$$

然而，出于以下原因，这种缩放可能不适用于我们的应用。CVS数据中的异常包括信号振幅突然增大或减小，以及形状轮廓的不规则变形。公式（13）中的归一化可能会导致快速振幅变化被忽略。

本研究采用以下受试者特异性尺度归一化策略。当使用电阻抗断层成像设备监测某位受试者时，假设设备在最初20秒的校准过程中测得可用于尺度归一化的正常CVS数据。令 $\mathcal{X}^{\mathrm{subject}}$ 为一组相应的心血管信号，表示为

$$\mathcal{X}^{\mathrm{subject}} = \{\boldsymbol{x}_{10\times i(\mathrm{ms})} : i = -1999, -1998, \cdots, -1\} \tag{14}$$

Us对于集合 $\mathcal{X}^{\mathrm{subject}}$，通过以下方式获得受试者特异性的缩放因子 $\mathcal{S}^{\mathrm{subject}}$

$$\mathcal{S}^{\mathrm{subject}} = \max_{\boldsymbol{x} \in \mathcal{X}^{\mathrm{subject}}} |\boldsymbol{x}| \tag{15}$$

在公式 (13) 中，使用比例因子 $\mathcal{S}^{\mathrm{subject}}$ 进行归一化，而不是公式 (12) 中简单的因子 $\mathcal{S}$ 。

2.2.2. 尺寸归一化 为了使 CVS 数据的维度保持一致，将 CVS 向量 $\boldsymbol{X}_{t_{\mathrm{cyc}}}$ 嵌入到 $\mathbb{R}^{\nu}$ 中，其中 $\boldsymbol{\nu}$为固定常数。在实证实验中，嵌入空间的维度设置为大于数据集 ($\boldsymbol{\nu} = 150$) 中 CVS 数据的任意维度。

考虑了两种归一化方法。第一种方法是使用线性插值，在 $\boldsymbol{X}_t$中将 $\boldsymbol{\nu}$个点重新采样为 $\boldsymbol{v}$ 个数据点。对于平稳区间$[0,\ 1]$，构造如下线性插值函数 $\mathcal{L}$：

$$\mathcal{L}(\frac{i}{\boldsymbol{v}-1}) = \underline{\boldsymbol{x}}_{t_{\mathrm{cyc}}+10(\mathrm{ms})\times(i-1)} \text{ for } i = 0, \cdots, \boldsymbol{v}-1 \tag{16}$$

随后，我们通过以下方式获得归一化向量 $\boldsymbol{X}_{t_{\mathrm{cyc}}} \in \mathbb{R}^{\boldsymbol{\nu}}$

$$\overline{\boldsymbol{X}}_{t_{\mathrm{cyc}}} = \left[\mathcal{L}(0), \mathcal{L}(\frac{1}{\boldsymbol{\nu}-1}), \mathcal{L}(\frac{2}{\boldsymbol{\nu}-1}), \cdots, \mathcal{L}(1) \right]^T \tag{17}$$

该方法将 CVS 数据的信号轮廓归一化为所需长度（$\boldsymbol{\nu}$），且不会造成显著损失，但会丢失采样时间信息。第二种方法是将$\boldsymbol{X}_{t_{\mathrm{cyc}}}$ 中的最后一个值（即$\boldsymbol{x}_{t_{\mathrm{cyc}}+10(\mathrm{ms})\times(\boldsymbol{v}-1)}$）填充至所需长度。通过这种常数填充，可得到向量$\boldsymbol{X}_{t_{\mathrm{cyc}}} \in \mathbb{R}^{\boldsymbol{\nu}}$，表示为

$$\begin{aligned} \overline{\boldsymbol{X}}_{t_{\mathrm{cyc}}} = [\ & \underline{\boldsymbol{x}}_{t_{\mathrm{cyc}}}, \cdots, \underline{\boldsymbol{x}}_{t_{\mathrm{cyc}}+10(\mathrm{ms})\times(\boldsymbol{v}-2)}, \underline{\boldsymbol{x}}_{t_{\mathrm{cyc}}+10(\mathrm{ms})\times(\boldsymbol{v}-1)}, & (18) \\ & \underline{\boldsymbol{x}}_{t_{\mathrm{cyc}}+10(\mathrm{ms})\times(\boldsymbol{v}-1)}, \cdots, \underline{\boldsymbol{x}}_{t_{\mathrm{cyc}}+10(\mathrm{ms})\times(\boldsymbol{v}-1)}\ ]^T & (19) \end{aligned}$$

其中，部分 (19) 对应于填充。与第一种方法相比，这种归一化能够保留与采样频率相关的时间信息，而 CVS 的核心轮廓则分布在不同的时间间隔上。

2.3. 机器学习应用

此时，我们可以应用机器学习来确定 SQI 函数 (11)。使用从不同受试者和心动周期中收集的数据，构建如下数据集：

$$\{\overline{\boldsymbol{X}}^{(i)}, \boldsymbol{y}^{(i)}\}_{i=1}^{N} \tag{20}$$

其中，$\boldsymbol{y}^{(i)}$ 是与 $\boldsymbol{X}^{(i)}$对应的 SQI 标签。我们注意到，$\boldsymbol{X}$ 是部分受试者一个心动周期的 CVS 数据，并且已在尺度和大小上进行了归一化。实际上，可用的训练数据集 (20) 极不平衡，其中负样本（受运动影响的 CVS）相对较少。

2.3.1. 判别模型方法判别模型方法按以下方式训练信号质量指数图 $\boldsymbol{f}$： $\boldsymbol{X} \mapsto \boldsymbol{y}$

$$\boldsymbol{f} = \underset{\boldsymbol{f}\in\mathbb{F}}{\operatorname{argmin}} \frac{1}{N} \sum_{i=1}^{N} \operatorname{dist}(\boldsymbol{f}(\overline{\boldsymbol{X}}^{(i)}), \boldsymbol{y}^{(i)}) \tag{21}$$

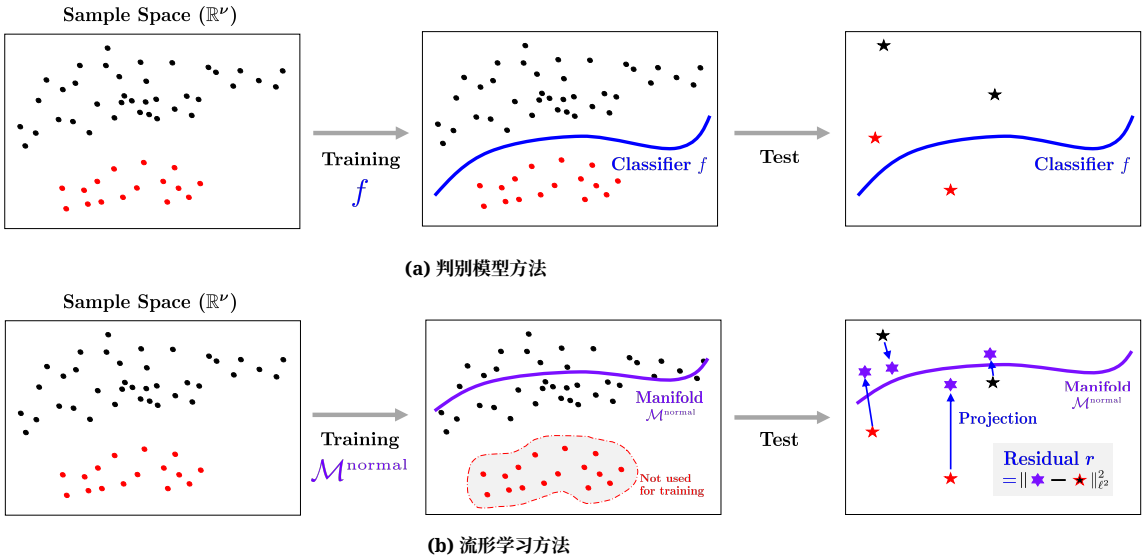


图5。 (a) 判别模型方法通过使用 CVS 数据和标签数据学习信号质量索引映射f 。(b) 流形学习方法首先通过寻找低维流形，学习正常 CVS 数据的共同特征 $\mathcal{M}_{\text{正常}}$。信号质量评估基于计算原始 CVS 数据与投影到学习流形上或附近的数据之间的残差。

其中， $\mathbb{F}$ 是给定机器学习模型的一组可学习函数，dist 是用于衡量机器学习输出 $f(\boldsymbol{X})$ 与标签 $\boldsymbol{y}$之间差异的度量指标。参见图5 (a)。在我们类别高度不平衡的应用中，可以使用以下加权交叉熵：

$$\text{dist}(\boldsymbol{f}(\overline{\boldsymbol{X}}), \boldsymbol{y}) = -\boldsymbol{\zeta}_{\text{pos}}\boldsymbol{y}\log(\boldsymbol{f}(\overline{\boldsymbol{X}})) - \boldsymbol{\zeta}_{\text{neg}}(1-\boldsymbol{y})\log(1-\boldsymbol{f}(\overline{\boldsymbol{X}})) \tag{22}$$

其中， $\boldsymbol{\zeta}_{\text{pos}}$ 和 $\boldsymbol{\zeta}_{\text{neg}}$ 分别为正样本和负样本的相对比例。可以使用多种分类模型，例如逻辑回归模型（逻辑回归） [12], 多层感知机（多层感知机） [22], 以及卷积神经网络（卷积神经网络） [45]。本研究中使用的详细模型见附录附录 B.1。

判别模型方法是在固定数据集上保证高性能的强大方法。然而，由于负样本高度多变，该方法在临床实践中可能难以提供稳定的信号质量指数结果。这是因为这些方法仅利用少量负样本所学习到的信息[10, 15, 23, 49]。为了实现稳定预测，可以改用流形学习方法 [13, 50, 58]。

2.3.2. 流形学习方法 流形学习方法从正样本（即正常心血管信号）中学习共同特征，并利用这些特征构建信号质量指数图。其余负样本则作为辅助依据，用于选择超参数。图5（b）展示了这一过程的示意图。

一组正样本记为 $\{\boldsymbol{X}^{(i)}{}_{\text{pos}}\}_{i=1}^{N_{\text{pos}}}$，其中 N_{pos} 表示正样本的数量。首先，通过训练编码器 $\mathcal{E}:\ \boldsymbol{X}_{\text{pos}} \mapsto \boldsymbol{z}$ 和解码器 $\mathcal{D}:\ \boldsymbol{z} \mapsto \boldsymbol{X}_{\text{pos}}$，按照以下方式学习 $\boldsymbol{X}_{\text{pos}}$的低维表示 [21, 26]:

$$(\mathcal{D}, \mathcal{E}) = \underset{(\mathcal{D},\mathcal{E})}{\operatorname{argmin}} \frac{1}{N_{\text{pos}}} \sum_{i=1}^{N_{\text{pos}}} \|\mathcal{D} \circ \mathcal{E}(\overline{\boldsymbol{X}}_{\text{pos}}^{(i)}) - \overline{\boldsymbol{X}}_{\text{pos}}^{(i)}\|_2^2 \tag{23}$$

其中，$\boldsymbol{z}$ 是一个低维潜向量，$\|\cdot\|_2$ 是标准欧几里得范数。架构 $\mathcal{D}$ 和 $\mathcal{E}$ 可用于 PCA [26], VAE [30], 和 β-VAE [24]。更多详情请参见附录 B.2。

借鉴 [2], 信号质量指数图 f 的思路，按如下方式构建信号质量指数图：对于任意类别中的给定 CVS 数据 $\boldsymbol{X}$，通过以下方式计算残差 $\boldsymbol{r}$：

$$\boldsymbol{r} = \|\overline{\boldsymbol{X}} - \mathcal{D} \circ \mathcal{E}(\overline{\boldsymbol{X}})\|_2 \tag{24}$$

解码器 $\mathcal{D}$ 经过训练，可生成类似正常 CVS 数据的输出。换言之，操作$\mathcal{D}\circ\mathcal{E}$ 利用正常 CVS 数据 [44,55]将$\boldsymbol{X}$ 变换至学习流形内或其附近。因此，残差 $\boldsymbol{r}$ 可视为异常分数: 若 $\boldsymbol{X}$ 是正常 CVS 数据，则 $\boldsymbol{r}$ 较小；若 $\boldsymbol{X}$ 是运动干扰的心血管信号数据，则 $\boldsymbol{r}$ 较大。对于某个非负常数 d，可使用以下方式构建信号质量指数图 $\boldsymbol{f}$：

$$\boldsymbol{f}(\overline{\boldsymbol{X}}_t) = \begin{cases} 1 & \text{if } \boldsymbol{r} \leqslant \boldsymbol{d} \\ 0 & \text{if } \boldsymbol{r} > \boldsymbol{d} \end{cases} \tag{25}$$

本小节余下部分将说明如何利用负样本和正样本确定阈值 $\boldsymbol{d}$ 。将 $\boldsymbol{d}$ 从 0 变到 8，即可计算受试者工作特征曲线（ROC 曲线）；曲线上的每个点均通过固定的 $\boldsymbol{d}$得到。我们选择 $\boldsymbol{d}$，使 Youden $\boldsymbol{J}$统计量最大化；该统计量被认为是在类别不平衡情况下无偏的度量指标 [42]。其值 $\boldsymbol{J}$ 为

$$\boldsymbol{J}^{\boldsymbol{d}} = \text{Sensitivity}^{\boldsymbol{d}} + \text{Specificity}^{\boldsymbol{d}} - 1 \tag{26}$$

其中

$$\text{Sensitivity}^{\boldsymbol{d}} = \frac{N_{\text{TP}}^{\boldsymbol{d}}}{N_{\text{TP}}^{\boldsymbol{d}} + N_{\text{FN}}^{\boldsymbol{d}}} \text{ and } \text{Specificity}^{\boldsymbol{d}} = \frac{N_{\text{TN}}^{\boldsymbol{d}}}{N_{\text{TN}}^{d} + N_{\text{FP}}^{\boldsymbol{d}}} \tag{27}$$

这里，$N^{\boldsymbol{d}}{}_{\text{TP}}$、$N^{\boldsymbol{d}}{}_{\text{TN}}$、$N_{\text{FP}}^{\boldsymbol{d}}$和 $N^{\boldsymbol{d}}{}_{\text{FN}}$分别表示根据选定阈值 $\boldsymbol{d}$ 得出的预测中真正例、真负例、假正例和假负例的数量。

3. 结果

3.1. 数据采集与实验设置

我们的数据集来自使用基于电阻抗断层成像的血流动力学监测设备（HemoVista, BiLab，韩国）的健康志愿者。同步的心电图数据

通过电阻抗断层成像获取，并用于识别心动周期。受试者躺在医院病床上时，被要求主动做出模拟临床病房中体位变化的动作。共获得了与心动周期相关的 16140 条心血管信号数据。

手动标注分别由具有两年和十年经验的生物信号专家（Nam 和 Lee）完成。随后，两位专家对结果进行审查，并通过协商一致最终判定心血管信号异常情况。最终标签被标注为三类：正常、模棱两可和受运动影响。当两位专家一致将其分类为正常或异常时，CVS 数据分别被标注为正常类或受运动影响类。模棱两可类表示其中很可能包含运动伪影，但专家未能就运动影响达成明确一致的 CVS 数据。分配的标签为：正常类为 $\boldsymbol{y} = 1$，其他类别为 $\boldsymbol{y} = 0$。因此，分别有 12928（80.09%）、1526（9.45%）和 1686（10.45%）个样本被标注为正常类、模棱两可类和受运动影响类。

对于机器学习应用，共有 16372 条 CVS 数据被划分为 13100 条（80%）、1520 条（10%）和 1520 条（10%），分别用于训练、验证和测试。数据划分确保同一受试者获取的 CVS 数据不会同时出现在这三个集合中。对于训练数据集，模棱两可类的标签被重新分配为 $\boldsymbol{y} = 0.25$。这样做是为了防止对模棱两可类的过度分类。

机器学习实验在配备 GeForce RTX 3080 Ti、Intel® CoreTM X系列处理器 i9-10900X 和 128GB DDR4内存的计算机系统上进行。机器学习的实现使用了 Python 及 scikit-learn 和 PyTorch 软件包。训练机器学习模型时，始终采用 Adam优化器，这是一种有效的自适应随机梯度下降方法 [31]。根据验证结果，采用启发式方法选择训练轮次和学习率等超参数。

*3.2. CVS*质量评估结果

我们使用六项度量指标比较基于机器学习的CVS质量评估结果：准确率、阳性预测值和阴性预测值（PPV和NPV）、敏感度、特异度以及曲线下面积。准确率、PPV和NPV定义如下：

$$\text{Accuracy} = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{TN}} + N_{\text{FP}} + N_{\text{FN}}}, \text{PPV} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}}, \text{ and NPV} = \frac{N_{\text{TN}}}{N_{\text{TN}} + N_{\text{FN}}} \tag{28}$$

曲线下面积为受试者工作特征曲线下的面积。由于类别高度不平衡（负样本较少），评估时应重点关注NPV、特异度和曲线下面积。

3.2.1. 判别模型 表1 (a) 和 (b) 的第一行和第二行展示了使用多种判别模型（逻辑回归、多层感知机和卷积神经网络）进行 CVS 质量评估的定量评价结果。表1 (a) 和 (b) 的结果在尺寸归一化方式上有所不同：(a) 采用线性插值，(b) 采用常数填充。

(a) 使用线性插值进行尺度和尺寸归一化的信号质量指数。

判别模型		LR	MLP1	MLP2	VGG16-3	VGG16-4	VGG16-5
Test	准确率	0.8665	0.9323	0.9348	0.9468	0.9468	0.9437
	PPV	1.0000	0.9790	0.9747	0.9525	0.9605	0.9679
	NPV	0.1097	0.7241	0.7445	0.9047	0.8591	0.8083
	敏感度	0.8643	0.9404	0.9479	0.9866	0.9776	0.9657
	特异度	1.0000	0.8860	0.8607	0.7215	0.7721	0.8185
	AUC	0.6615	0.9506	0.9558	0.9709	0.9645	0.9653
流形学习模型 PCA			VAE	β-变分自编码器	CVAE	β-条件变分自编码器	-
Test	准确率	0.8468	0.9066	0.9221	0.9292	0.9298	
	PPV	0.9510	0.9687	0.9672	0.9688	0.9739	
	NPV	0.4573	0.6181	0.6900	0.7100	0.7011	
	敏感度	0.8675	0.9218	0.9439	0.9486	0.9441	-
	特异度	0.7142	0.8095	0.7952	0.8047	0.8380	
	AUC	0.8735	0.9513	0.9489	0.9528	0.9603	

（b）采用常数填充进行尺度和尺寸归一化的信号质量指数。

判别模型		LR	MLP1	MLP2	VGG16-3	VGG16-4	VGG16-5
Test	准确率	0.8664	0.9487	0.9518	0.9455	0.9487	0.9500
	PPV	1.0000	0.9745	0.9767	0.9533	0.9655	0.9731
	NPV	0.0826	0.7851	0.8065	0.8870	0.8433	0.8185
	敏感度	0.8648	0.9651	0.9666	0.9844	0.9748	0.9681
	特异度	1.0000	0.8521	0.8652	0.7173	0.7956	0.8434
	AUC	0.6628	0.9725	0.9669	0.9782	0.9683	0.9757
流形学习模型 主成分分析			VAE	β-变分自编码器	CVAE	β-CVAE	-
Test	准确率	0.8809	0.8918	0.9214	0.9015	0.8861	
	PPV	0.9590	0.9660	0.9679	0.9731	0.9636	
	NPV	0.5333	0.5629	0.6694	0.5882	0.5467	
	敏感度	0.9014	0.9074	0.9407	0.9118	0.9029	-
	特异度	0.7450	0.7892	0.7941	0.8333	0.7745	
	AUC	0.9150	0.9206	0.9412	0.9170	0.9041	

表 1. 基于机器学习的CVS质量评估结果

多层感知机和卷积神经网络的表现优于逻辑回归，后者的阴性预测值和曲线下面积表现很差。多层感知机和卷积神经网络分别在特异度和阴性预测值方面优于对方，而在其他度量指标上的表现相当。不同尺寸归一化方式对性能没有造成显著影响。

一个有趣的观察结果如下：在我们的实验中，特异度与阴性预测值之间似乎存在此消彼长的关系，具体取决于对局部性和全局性的侧重。丰富 CVS 数据中的全局信息有助于提高特异度；相反，局部信息则有助于提高阴性预测值。随着 VGG16 的感受野大小增加（见附录 附录 B.1），特异度趋于上升，而阴性预测值趋于下降。在比卷积神经网络更灵活、更善于捕捉全局信息的多层感知机中，特异度最高，而阴性预测值最低。换言之，CVS 数据中的局部信息可能在减少假负例而非假正例方面发挥着关键作用。从实用角度来看，减少假负例更为可取；因此，采用能够充分利用局部性的 VGG16-3 或 VGG16-4 是一个绝佳选择。

3.2.2. 流形学习模型 验证集中的正样本用于在训练编码器和解码器时进行超参数选择。利用所有训练集和验证集的数据确定阈值。

图6展示了正常类和受运动影响类测试样本的流形投影结果。

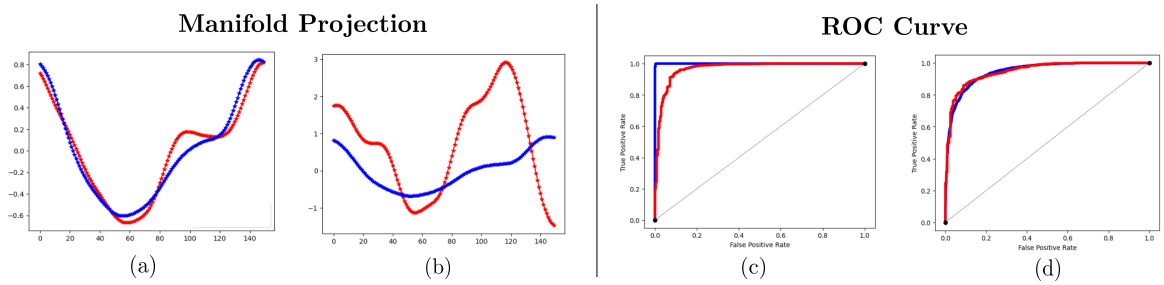


图6. (a) 正常和 (b) 运动干扰的心血管信号数据的测试样本及基于VAE的投影结果，其中红线表示原始心血管信号数据，蓝线表示由VAE投影得到的对应心血管信号数据。此外，还给出了 (c) VGG 16-4 和 (d) β-VAE 的ROC曲线，其中蓝线和红线分别表示使用训练集和测试集计算得到的曲线。

输入的心血管信号会被投影到正样本学习得到的流形上或其附近。符合预期的是，正常样本的残差（24）趋于较小，而受运动影响样本的残差则较大。

表1 (a) 和 (b) 的第三行和第四行展示了使用流形学习模型得到的最终评估结果。其性能与判别模型相当。值得注意的是，流形学习模型在分类器开发过程中从未学习过负样本。如图6 (d) 所示，该流形学习模型在训练集和测试集上的性能差距非常小。

流形学习模型的性能因尺寸归一化方式不同而略有差异。与另一种方式相比，线性插值能够略微提升准确率、阴性预测值和曲线下面积。对于常数填充，由于心血管信号数据的核心轮廓在不同区间内得到支持，学习复杂度可能会增加，因为需要针对这些区间进行不变特征提取。这可能导致性能略有下降。

在我们的数据集中，判别模型和流形学习模型都能准确检测受运动影响的心血管信号。判别模型的信号质量指数表现更强；相比之下，流形学习模型在训练集和测试集上表现稳定。对于实际应用，选择哪种模型取决于监测系统更侧重性能还是稳定性。也值得考虑将两者集成。

3.2.3. 尺度归一化的影响 表2展示了未进行尺度归一化时的最差情况。对于卷积神经网络，网络训练极不稳定，评估性能显著下降，尤其是准确率、阴性预测值、敏感度和曲线下面积。对于变分自编码器，CVS 数据的大尺度变化严重影响了流形投影的准确性，因此准确率、阴性预测值、敏感度和曲线下面积均显著下降。这验证了尺度归一化的影响。

	使用缩放		不使用缩放	
模型	**VGG16-3 VAE**		**VGG16-3 VAE**	
准确率	0.9468	0.9066	0.7862	0.7509
PPV	0.9525	0.9687	0.9763	0.9668
NPV	0.9047	0.6181	0.4038	0.3327
敏感度	0.9886	0.9218	0.7671	0.7373
特异度	0.7215	0.8095	0.8945	0.8380
AUC	0.9709	0.9513	0.9067	0.8906

表2. 采用与不采用尺度归一化的基于机器学习的CVS质量评估结果。

模型	**LR**	**MLP1**	**MLP2**	**VGG16-3**	**VGG16-4**
Time	0.633μ秒	1.265μ秒	0.700μ秒	1.897μ秒	3.162μ秒
模型	**VGG16-5 主成分分析**		**VAE**	**CVAE**	-
Time	3.562μs	48.412μs	3.703μs	15.192μs	-

表 3. 基于机器学习的 CVS 质量评估方法的测试推理时间。

3.2.4. 推理时间 在实时监测中，评估应快速完成。所提出方法的输入在电阻抗断层成像系统中每次心跳都会更新。假设受试者的心率恒定为 80 bpm，则 CVS 输入每 0.75 秒更新一次。大致而言，评估速度应快于约 10^{-2} 秒。表3显示了测试数据的推理时间，该时间通过对全部测试数据取平均值计算得出。机器学习模型的测试结果推理时间介于 100μ 秒（10^{-4} 秒）和 0.1μ 秒（10^{-7} 秒）之间。这证实了所提出的方法满足实时监测的速度要求。

4. 结论与讨论

我们开发了一种新颖的自动化信号质量指数方法，采用两种机器学习技术——判别模型和流形学习——来检测由运动引起的伪影所导致的异常 CVS。我们讨论了身体运动如何影响跨导数据，以及运动如何导致由此产生的 CVS 质量下降。大量实验支持这样一种观点：所提出的方法能够成功过滤 CVS 数据中由运动引起的不真实变化。

据我们所知，这是首次尝试评估 CVS 质量，以增强基于电阻抗断层成像的心肺监测系统的临床能力。从实践角度来看，所提出的方法能够在 CVS 受到干扰时向临床医生发出警报，从而最大限度地减少有关患者安全的错误信息，并促进对患者和医疗资源的妥善管理。所提出的方法可与现有电阻抗断层成像设备的软件系统结合使用。

训练过程中仅使用健康受试者数据，未能充分考虑受试者疾病对心血管信号的潜在影响。对于患有心律失常等疾病的患者，信号质量指数的性能可能会下降；这类疾病可能导致心血管信号出现不规则变形

，例如室性早搏造成的心血管信号不规则变形，并导致其被归类为低信号质量。不过，当训练过程中可以获取并加入患病患者的数据时，只需稍微修改信号质量指数，增加另一个标签类别，就能检测出疾病和运动。同时，使用心电信号可以轻松检测心律失常。

进一步收集 CVS 数据，或许有助于提升模型的泛化能力或稳定性，使其能够应用于实际监测系统。对于判别模型而言，即使收集更多数据，由于类别不平衡问题仍然存在或加剧，其泛化能力或稳定性也可能无法得到实质性改善。相比之下，随着正常CVS数据总量增加，流形学习模型能够准确推断共同特征（即数据流形），而不受类别不平衡的影响。此外，还可以将其扩展为半监督或无监督学习框架 $[2, 46]$，，从而降低对标注数据集的要求。因此，流形学习模型可能更为适用。

数据可用性

支持本研究结论的数据可向通讯作者 K. Lee 提出合理请求后获取。

致谢

本研究得到了韩国韩国产业通商资源部（MOTIE）通过产业战略技术开发计划提供的资助，资助编号 20006024。Hyun 获得了三星科学技术基金会的资助（编号：SRFC-IT1902-09）。我们由衷感谢 BiLab（韩国板桥）给予的帮助与合作。

利益冲突

作者声明不存在任何利益冲突。

附录A. 运动诱发效应对跨导的影响

在 16 通道电阻抗断层成像系统中，式（1）中的电压数据 $\{V^{j,\ t}{}^{k}\}_{j,\ k}$ 由以下完全电极模型 $[44]$决定：在时间 t，电势分布

（u_t^j）和电极上的电势（$U^{j,}{}_t{}^k$）满足

$$\begin{cases} \nabla\cdot(\gamma_t\nabla u_t^j) &= 0 \quad \text{in } \Omega\subset\mathbb{R}^3 \\ \gamma_t\nabla u_t^j\cdot n &= 0 \quad \text{on } \partial\Omega\backslash\bigcup_i^{16}\mathcal{E}^k \\ \int_{\mathcal{E}^k}\gamma_t\nabla u_t^j\cdot n &= 0 \quad \text{for } k\in\mathcal{I}\backslash\{j,j+1\} \\ u_t^j+z_k(\gamma_t\nabla u_t^j\cdot n) &= U_t^{j,k} \text{ on } \mathcal{E}^k \text{ for } k\in\mathcal{I} \\ \int_{\mathcal{E}^j}\gamma_t\nabla u_t^j\cdot nds &= -\int_{\mathcal{E}^{j+1}}\gamma_t\nabla u_t^j\cdot nds = I \end{cases} \tag{A.1}$$

其中，γ_t 是在 t时刻人体胸腔 Ω 中的电导率分布，n 是指向 $\partial\Omega$ 外侧的单位法向量，ds 是面元，z_k 是 $\mathcal{E}^k$上的皮肤-电极接触阻抗。注入区域 Ω 的电流量 I可以进行缩放，因此可假设其为 $I=1$。

若人体胸腔 Ω 因运动而随时间变化，则根据雷诺输运定理可得以下近似式 [39]:

$$\dot{V}_t^{j,k}\approx\dot{V}_t^{j,k,\text{normal}}+\dot{V}_t^{j,k,\text{motion}} \tag{A.2}$$

其中

$$\dot{V}_t^{j,k,\text{normal}}=-\int_\Omega\dot{\gamma}_t(\boldsymbol{r})\nabla u_t^j(\boldsymbol{r})\cdot\nabla u_t^k(\boldsymbol{r})d\boldsymbol{r} \tag{A.3}$$

$$\dot{V}_t^{j,k,\text{motion}}=-\int_{\partial\Omega}\boldsymbol{v}_n(\boldsymbol{r},t)\gamma_t(\boldsymbol{r})\nabla u_t^j(\boldsymbol{r})\cdot\nabla u_t^k(\boldsymbol{r})ds \tag{A.4}$$

此处，$\boldsymbol{v}_n$ 是 $\partial\Omega$ 的外法向速度，$\boldsymbol{r}\in\Omega$ 是 Ω 中的位置向量。项 $\dot{V}^{j,}{}_t{}^{k\,\text{normal}}$，和 $\dot{V}^{j,}{}_t{}^{k\,\text{motion}}$，可分别视为可通过正常的电阻抗断层成像测量和运动诱导推断获取的电压数据。

可推导出与式 (A.2) 类似的跨导关系如下：定义跨导相关值 $g^{j,}{}_t{}^k$ 为

$$g_t^{j,k}=\frac{I}{\Re(V_t^{j,k})} \tag{A.5}$$

对 $g^{j,}{}_t{}^k$ 关于 t求导，可得

$$\dot{g}_t^{j,k}=\frac{-I\Re(\dot{V}_t^{j,k})}{\left(\Re(V_t^{j,k})\right)^2}\approx\frac{-I(\Re(\dot{V}_t^{j,k,\text{normal}})+\Re(\dot{V}_t^{j,k,\text{motion}}))}{\left(\Re(V_t^{j,k})\right)^2} \tag{A.6}$$

近似式 (A.6) 可表示为

$$\dot{g}_t^{j,k}\approx\dot{g}_t^{j,k,\text{normal}}+\dot{g}_t^{j,k,\text{motion}} \tag{A.7}$$

其中

$$\dot{g}_t^{j,k,\text{normal}}=\frac{-I\Re(\dot{V}_t^{j,k,\text{normal}})}{(\Re(V_t^{j,k}))^2}\text{ and }\dot{g}_t^{j,k,\text{motion}}=\frac{-I\Re(\dot{V}_t^{j,k,\text{motion}})}{(\Re(V_t^{j,k}))^2} \tag{A.8}$$

我们注意到，在 (A.4) 中 $\boldsymbol{v}_n = \mathbf{0}$ 的情况下（即电阻抗断层成像测量不受运动影响），由于 $V^{j,}{}_{t}{}^{k\,\text{motion}} = 0$，关系式 (A.6) 变为 $\dot{g}^{j,}{}_{t}{}^{k} = \dot{g}^{j,}{}_{t}{}^{k\,\text{normal}}$。用跨导向量的形式表示，可得以下近似：

$$\dot{\boldsymbol{g}}_t \approx \dot{\boldsymbol{g}}_t^{\text{normal}} + \dot{\boldsymbol{g}}_t^{\text{motion}} \tag{A.9}$$

其中

$$\dot{\boldsymbol{g}}_t^{\text{normal}} = \left[\dot{g}_t^{1,3,\text{normal}}, \cdots, \dot{g}_t^{16,14,\text{normal}}\right] \text{ and } \dot{\boldsymbol{g}}_t^{\text{motion}} = \left[\dot{g}_t^{1,3,\text{motion}}, \cdots, \dot{g}_t^{16,14,\text{motion}}\right] \tag{A.10}$$

若 $\dot{\boldsymbol{g}}_t^{\text{normal}}$ 满足关系式 (5)，则可得

$$\dot{\boldsymbol{g}}_t \approx \dot{\boldsymbol{g}}_t^{\text{air}} + \dot{\boldsymbol{g}}_t^{\text{blood}} + \dot{\boldsymbol{g}}_t^{\text{motion}} \tag{A.11}$$

这里需要注意的是，随着运动（即 (A.4) 中的 $|\boldsymbol{v}_n|$）幅度增大，$\dot{\boldsymbol{g}}_t^{\text{motion}}$ 会变得更加显著。

附录 B. 机器学习模型

附录 *B.1.* 判别模型

逻辑回归（*LR*）一个 LR 模型 f_{LR} 由线性变换和 sigmoid 函数组成，如下所示：

$$f_{\text{LR}}(\overline{\boldsymbol{X}}) = \sigma(\mathbf{w}^T\overline{\boldsymbol{X}} + b) \tag{B.1}$$

其中 $\mathbf{w} \in \mathbb{R}^{150}$ 和 $b \in \mathbb{R}$ 分别为可学习的权重和偏置，σ 是由 $\sigma(x) = (1 + \exp(x))^{-1}$给出的 S 型函数。

多层感知机（*MLP*）与 LR 相比，多层感知机模型 f_{MLP} 具有带非线性的层次结构。每一层都由线性变换和非线性激活组成。在我们的多层感知机模型中，除最后一层外，其余各层均使用 ReLU，以避免梯度消失 [20]。表 B1 展示了本研究所用多层感知机的架构。

卷积神经网络（*CNN*）卷积神经网络模型 f_{CNN} 包含两条路径：1）特征提取路径；2）分类路径。本研究中的特征提取路径基于 VGG16 [45], ，如表 B1 所示。所得特征图经过展平后，传递至分类路径，该路径为一个多层感知机。

特征提取路径由两个卷积层和最大池化（或展平）层组成，其深度与最后一个卷积层中单元的感受野（RF）大小相关 [35]。根据该路径的长度，定义了 VGG16-3、VGG16-4 和 VGG16-5，其中 3、4 和 5 分别表示该路径中层的迭代次数。此处的感受野分别为 32、68 和 140。

(a) MLP1（MLP2）

层	输入维度	输出维度	激活函数
线性层	150（150）	150（150）	ReLU
线性层	150（150）	300（150）	ReLU
线性层	300 (150)	300 (100)	ReLU
线性层	300 (100)	150 (50)	ReLU
线性层	150 (50)	150 (25)	ReLU
线性层	150 (25)	150 (10)	ReLU
线性层	150 (10)	1 (1)	Sigmoid

(b) VGG16-5； [1]特征提取和 [2]分类网络

	层	输入维度	输出维度	卷积核	激活函数	RF
[1]	一维卷积	150×1	150×4	3×4	ReLU	3
	一维卷积	150×4	150×4	3×4	ReLU	5
	一维最大池化	150×4	75×4	2	ReLU	6
	一维卷积	75×4	75×8	3×8	ReLU	10
	一维卷积	75×8	75×8	3×8	ReLU	14
	一维最大池化	75×8	37×8	2	ReLU	16
	一维卷积	37×8	37×16	3×16	ReLU	24
	一维卷积	37×16	37×16	3×16	ReLU	32
	一维最大池化	37×16	18×16	2	ReLU	36
	一维卷积	18×16	18×32	3×32	ReLU	52
	一维卷积	18×32	18×32	3×32	ReLU	68
	一维最大池化	18×32	9×32	2	ReLU	76
	一维卷积	9×32	9×64	3×64	ReLU	108
	一维卷积	9×64	9×64	3×64	ReLU	140
	展平	9×64	576×1	-	-	-
[2]	线性层	576×1	576×1	-	ReLU	-
	线性层	576×1	1×1	-	Sigmoid	-

表 B1. 网络架构；多层感知机和 VGG16-6。

附录 *B.2.* 流形学习模型

本小节介绍了式（23）中的编码器 $\mathcal{E}$ 和解码器 $\mathcal{D}$ 的结构，这些结构用于第2.3.2节所述的流形学习方法。实验中，潜向量 $\boldsymbol{z}$ 的维度始终设为 10。

主成分分析（*PCA*）PCA 以如下方式学习主向量 $\{\boldsymbol{v}_i \in \mathbb{R}^{150}\}_{i=1}^{10}$：对于 $i = 1, \cdots, 10$,

$$\boldsymbol{v}_i = \underset{\|\boldsymbol{v}\|=1}{\operatorname{argmax}} \|\mathfrak{X}_i \boldsymbol{v}\|_2^2 \text{ and } \mathfrak{X}_i = \mathfrak{X}_{i-1} - \boldsymbol{v}_{i-1}\boldsymbol{v}_{i-1}^T \tag{B.2}$$

其中 $\mathfrak{X}_1 := [\boldsymbol{X}^{(1)}{}_{\text{位置}} \boldsymbol{X}^{(2)}{}_{\text{位置}} \cdots, \boldsymbol{X}^{(N_{\text{pos}})}{}_{\text{位置}}]^T$。为便于说明，假设 $\mathfrak{X}_1$ 为零均值。编码器 $\mathcal{E}_{\text{pca}}$ 和解码器 $\mathcal{D}_{\text{pca}}$ 定义如下：

$$\mathcal{E}_{\text{pca}}(\overline{\boldsymbol{X}}) = \boldsymbol{z} := \left[\langle \overline{\boldsymbol{X}}, \boldsymbol{v}_1 \rangle, \cdots, \langle \overline{\boldsymbol{X}}, \boldsymbol{v}_{10} \rangle\right] \text{ and } \mathcal{D}_{\text{pca}}(\boldsymbol{z}) = \sum_{j=1}^{10} \boldsymbol{z}_i \boldsymbol{v}_i \tag{B.3}$$

其中 $\boldsymbol{z}_i$ 是 $\boldsymbol{z}$的第 i个分量。

变分自编码器（*VAE*）表 B2 展示了 VAE 的编码器-解码器模型，其网络架构基于多层感知机或卷积神经网络。在 VAE 中，$\boldsymbol{z}$ 由以下采样过程给出：$\boldsymbol{z} = \boldsymbol{\mu} + \boldsymbol{\sigma} \odot \boldsymbol{z}_{\text{noise}}$ 和 $\boldsymbol{z}_{\text{noise}} \sim \mathcal{N}(\boldsymbol{0}, \boldsymbol{I})$，其中 $\boldsymbol{\mu}$ 和 $\boldsymbol{\sigma}$是由神经网络生成的重要输出，$\odot$ 是逐元素乘积，

(a) 变分自编码器

编码器			
层	输入维度	输出维度	激活函数
线性层	150	125	ReLU
线性层	125	75	ReLU
线性层	75	50	ReLU
线性层	50	10×2	-
采样	10×2	10	-
解码器			
线性层	10	50	ReLU
线性层	50	75	ReLU
线性层	75	125	ReLU
线性层	125	150	-

(b) 卷积变分自编码器

编码器				
层	输入维度	输出维度	卷积核	激活函数
一维卷积	150×1	75×8	3×8	ReLU
一维卷积	75×8	38×16	3×16	ReLU
一维卷积	38×16	19×24	3×24	ReLU
一维卷积	19×24	10×32	3×32	ReLU
展平	10×32	320×1	-	-
线性层	320×1	10×2	-	-
采样	10×2	10×1	-	-
解码器				
线性层	10×1	320×1	-	-
重塑	320×1	10×32	-	-
一维反卷积	10×32	19×24	3×24	ReLU
一维反卷积	19×24	38×16	3×16	ReLU
一维反卷积	38×16	75×8	3×8	ReLU
一维反卷积	75×8	150×8	3×8	ReLU
一维卷积	150×8	150×1	1×1	ReLU
线性层	150×1	150×1	-	

表 B2. VAE 网络架构。

以及 $\mathcal{N}(\mathbf{0},\ \boldsymbol{I})$ 是均值为$\mathbf{0}$、协方差为 $\boldsymbol{I}$的正态分布。这里，$\mathbf{0}$ 是零向量， $\boldsymbol{I}$ 是 10×10的单位矩阵。

对于 VAE 训练，将以下项添加到损失函数 (23) 中 :

$$\mathrm{KL}(\mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \| \mathcal{N}(\mathbf{0}, \boldsymbol{I})) = \frac{1}{2} \sum_{i=1}^{10} (\boldsymbol{\mu}_i^2 + \boldsymbol{\sigma}_i^2 - \log \boldsymbol{\sigma}_i - 1) \tag{B.4}$$

其中，KL 表示库尔贝克-莱布勒散度， $\boldsymbol{\Sigma}$是一个 10×10对角矩阵，其 (i, i)项为 $\boldsymbol{\sigma}_i$。此项使 VAE 能够学习在 $\mathcal{N}(\mathbf{0}, \boldsymbol{I})$ [30, 47, 55]内或附近的稠密且平滑的潜在空间嵌入。

β-变分自编码器（β-变分自编码器）β-VAE 与 VAE 的区别在于损失函数，但二者共享相同的模型架构。对于某些 $\beta \in \mathbb{R}$， $\beta \times$KL 项会加入损失函数 (23)，而不是 (B.4)（即，VAE 是 $\beta = 1$ 的情况）。这种简单的加权方式已被证明有助于对潜在因素进行解耦表征学习 [24]。我们通过实证确定了最优 β 。表 B3 展示了在应用了基于线性插值的尺度和尺寸归一化的数据集中，信号质量指数（SQI）性能随 β 的变化情况。

[1] A. Adler、R. Guardo、Y. Berthiaume，“肺通气阻抗成像：是否需要考虑胸廓扩张？”*IEEE* 生物医学工程汇刊，43，414-20，1996年。

		β-变分自编码器					β-条件变分自编码器				
		$\beta = \frac{1}{3}$	$\beta = \frac{1}{2}$	$\beta = 1$	$\beta = 2$	$\beta = 3$	$\beta = \frac{1}{3}$	$\beta = \frac{1}{2}$	$\beta = 1$	$\beta = 2$	$\beta = 3$
Test	**准确率**	0.9060	0.9092	0.9066	0.8951	0.9221	0.9208	0.9298	0.9292	0.9195	0.9189
	PPV	0.9694	0.9680	0.9687	0.9682	0.9672	0.9750	0.9739	0.9688	0.9663	0.9663
	NPV	0.6151	0.6282	0.6181	0.5802	0.6900	0.6617	0.7011	0.7100	0.6720	0.6693
	敏感度	0.9203	0.9255	0.9218	0.9084	0.9441	0.9322	0.9441	0.9486	0.9397	0.9389
	特异度	0.8142	0.8047	0.8095	0.8095	0.7952	0.8476	0.8380	0.8047	0.7904	0.7904
	AUC	0.9503	0.9439	0.9513	0.9426	0.9489	0.9531	0.9603	0.9528	0.9528	0.9471

表 B3. β-变分自编码器在不同 β 下的性能比较。

[2]J. An 和 S. Cho，“基于变分自编码器、利用重构概率进行异常检测”，IE专题讲座，2(1)，1-18，2015年。[3] A. Adler 和 A. Boyle，“电阻抗断层成像：从组织特性到图像测量”，IEEE生物医学工程汇刊，64(11)，2494-2504，2017年。[4] A. T. Askari 和 A. W. Messerli，《心血管血流动力学》，第2版，瑞士 Cham：Humana出版社，2019年。[5] M. Alfaras、M. C. Soriano 和 S. Ortin，“一种用于基于心电图的心跳分类和心律失常检测的快速机器学习模型”，《物理学前沿》，7，103，2019年。[6] B. H. Brown 等，“利用电阻抗断层成像进行血流成像”，《临床物理与生理测量》，第13卷，第175–179页，1992年。[7]A. Boyle 和 A. Adler，“电阻抗断层成像中形状变形情况下的电极模型”，《物理学杂志：会议系列》，第224卷，第1期，2010年。[8] J. B. Borges 等，“仔猪肺塌陷模型中利用电阻抗断层成像估算区域性肺灌注”，《应用生理学杂志》，第112卷，第225-236页，2012年。[9] D. Belo、J. Rodrigues、J. R. Vaz、P. Pezarat-Correia 和 H. Gamboa，“利用深度神经网络学习与合成生物信号”，《生物医学工程在线》，16(1)，1-17，2017年。[10] M. Buda、A. Maki 和 M. A. Mazurowski，“卷积神经网络中类别不平衡问题的系统研究”，《神经网络》，106，249-259，2018年。[11] Van Ravenswaaij-Arts、Conny MA 等，“心率变异性”，《内科学年鉴》，118(6)，436-447，1993年。[12] J. S. Cramer，“逻辑回归的起源”，廷伯根研究所工作论文，4，2002年。[13] O. Chapelle、B. Scholkopf 和 A. Zien，“半监督学习”，（Chapelle, O. 等编；2006年）[书评]。《IEEE神经网络汇刊》，20(3)，542-542，2009年。[14] S. Celin 和 K. Vasanth，“使用各种机器学习技术进行心电信号分类”，《医学系统杂志》，42(12)，1-11，2018年。[15] K. Cao、C. Wei、A. Gaidon、N. Arechiga 和 T. Ma，“通过标签分布感知边际损失学习不平衡数据集”，《神经信息处理系统进展》，2，2019年。[16] P. H. Charlton 等，“阻抗呼吸描记信号质量指数：设计、评估及其在呼吸频率监测中的应用”，《生物医学信号处理与控制》，第65卷，2021年，文章编号102339。[17] T. Dai、C. G´omez-Laberge 和 A. Adler，“基于电阻抗断层成像时间序列重构电导率变化和电极移动”，《生理测量》，29(6)，S77-S88，2008年。[18] J. M. Deibele、H. Luepschen 和 S. L. Leonhardt，“电阻抗断层成像中心肺变化的动态分离”，《生理测量》，第29卷，S1-S14页，2008年。[19]I. Frerichs、T. Becher 和 N. Weiler，“心肺系统的电阻抗断层成像”，《重症监护临床观点》，第20卷，第323-332页，2014年。[20] I. Goodfellow、Y. Bengio 和 A. Courville，《深度学习》，MIT出版社，2016年。[21]G. E. Hinton 和 R. R. Salakhutdinov，“利用神经网络降低数据维度”，《科学》，313(5786)，504-507，2006年。[22] G. E. Hinton，“学习多层表征”，《认知科学趋势》，11(10)，428-434，2007年。

[23] H. He 和 E. A. Garcia，“从不平衡数据中学习”，IEEE知识与数据工程汇刊，21(9)，1263-1284，2009年。[24] I. Higgins、L. Matthey、A. Pal、C. Burgess、X. Glorot、M. Botvinick 等，“beta-vae：通过受约束的变分框架学习基本视觉概念”，2016年。[25] C. M. Hyun、S. H. Baek、M. Lee、S. M. Lee 和 J. K. Seo，“基于深度学习的医学成像欠定逆问题可解性研究”，《医学图像分析》，69，101967，2021年。[26] I. T. Jolliffe 和 J. Cadima，“主成分分析：综述与最新进展”，英国皇家学会哲学汇刊 A辑：数学、物理与工程科学，374(2065)，20150202，2016年。[27] G. Y. Jang 等，“使用电阻抗断层成像无创、同步、连续测量每搏量和潮气量：动物实验可行性研究”，《科学报告》，第10卷，2020年。[28] W. G. Kubicek、R. P. Patterson 和 D. A. Witsoe，“阻抗心动描记法：一种无创监测心脏功能及心血管系统其他参数的方法”，《纽约科学院年刊》，第170卷，第724-732页，1970年。[29] N. Kerrouche、C. N. McLeod 和 W. R. B. Lionheart，“采用奇异值分解和傅里叶变换处理的电阻抗断层成像胸部图像时间序列”，《生理测量》，第22卷，第147-157页，2001年。[30] D. P. Kingma 和 M. Welling，“自编码变分贝叶斯”，arXiv预印本 arXiv:1312.6114，2013年。[31] D. P. Kingma 和 J. Ba，“Adam：一种随机优化方法”，arXiv:1412.6980，2014年。[32] WRB Lionheart，“边界形状与电阻抗断层成像”，《逆问题》，14，139-47，1998年。[33] S. Leonhardt 和 B. Lachmann，“电阻抗断层成像：通气与灌注监测的终极目标”，《重症医学》，第38卷，第1917–1929页，2012年。[34] Y. LeCun、Y. Bengio 和 G. Hinton，“深度学习”，《自然》，521(7553)，436-444，2015年。[35] W. Luo、Y. Li、R. Urtasun、R. Zemel，“理解深度卷积神经网络中的有效感受野”，arXiv:170.04128，2017年。[36] K. Lee、E. J. Woo 和 J. K. Seo，“一种用于稳健电阻抗断层成像的嵌入保真度的正则化方法”，IEEE医学影像汇刊，37(9)，1970-1977，2017年。[37] J. H. Lee、Y. R. Park、S. Kweon、S. Kim、W. Ji 和 C. M Choi，“一种利用移动物联网技术的医院内患者转运心肺监测系统：观察性验证研究”，《JMIR移动健康与泛在健康》，6(11)，2018年。[38] M. H. Lee、G. Y. Jang、Y. E. Kim、P. J. Yoo、H. Wi、T. I. Oh 和 E. J. Woo，“用于睡眠呼吸暂停和低通气监测的便携式多参数电阻抗断层成像：可行性研究”，《生理测量》，2018年。[39] K. Lee、G. Y. Jang、Y. Kim 和 E. J. Woo，“用于心肺监测的多通道跨阻抗导联形成：算法开发及基于活体动物数据的可行性评估”，IEEE生物医学工程汇刊，69(6)，1964-1974，2021年。[40] R. Pikkemaat 等，“电阻抗断层成像心输出量监测的最新进展与局限”，Anesth.Analg.，第119卷，第76–83页，2014年。[41] C. Putensen 等，“用于心肺监测的电阻抗断层成像”，《临床医学杂志》，第8卷，2019年。[42] M. D. Ruopp、N. J. Perkins、B. W. Whitcomb 和 E. F. Schisterman，“基于受检出限下限影响的观测值估算尤登指数和最佳截断点”，《生物统计学杂志：生物科学中的数学方法》，50(3)，419-430，2008年。[43] M. Soleimani、C. G´omez-Laberge 和 A. Adler，“电阻抗断层成像中的电导率变化和电极移动成像”，《生理测量》，27(5)，S103-S113，2006年。[44] J. K. Seo 和 E. J. Woo，《成像中的非线性逆问题》，奇切斯特，英国：威利，2013年。[45]K. Simonyan 和 A. Zisserman，“用于大规模图像识别的超深卷积网络”，arXiv预印本 arXiv:1409.1556，2014年。[46] T. Schlegl、P. Seeb¨ock、S. M. Waldstein、U. Schmidt-Erfurth 和 G. Langs，“无监督

采用生成对抗网络的异常检测以指导标志物发现”，医学影像信息处理国际会议，第146-157页，Springer，Cham，2017年。[47] J. K. Seo、K. C. Kim、A. Jargal、K. Lee 和 B. Harrach，“一种基于学习的病态非线性逆问题求解方法：肺部电阻抗断层成像模拟研究”，*SIAM*影像科学杂志，12(3)，1275-1295，2019年。[48]S. Sahoo、M. Dash、S. Behera 和 S. Sabut，“利用机器学习方法检测心电信号中的心律失常：综述”，*Irbm*，41(4)，185-194，2020年[49] G. Van Horn 和 P. Perona，“魔鬼藏在尾部：野外细粒度分类”，*arXiv*预印本 *arXiv:1709.01450*，2017年。[50] J. E. Van Engelen 和 H. H. Hoos，“半监督学习综述”，机器学习，109(2)，373-440，2020年。[51] N. Westterhof 等，《血流动力学快照》，第3版，Cham，瑞士：*Springer*，2019年。[52] M. Wasimuddin、K. Elleithy、A. S. Abuzneid、M. Faezipour 和 O. Abuzaghleh，“从传统信号处理到机器学习方法的分阶段心电图信号分析：综述”，*IEEE Access*，8，177782-177803，2020年。[53] Y. Xu、T. Xiao、J. Zhang、K. Yang 和 Z. Zhang，“尺度不变卷积神经网络”，*arXiv*预印本 *arXiv:1411.6369*，2014年。[54] L. Yang 等，“利用电阻抗断层成像去除通气监测中的临床运动伪影：方法介绍及模拟与患者数据验证”，医学前沿，2022年。[55] H. S. Yun、C. M. Hyun、S. H. Baek、S.-H. Lee、J. K. Seo，“一种利用计算机断层扫描自动识别三维头影测量标志点的半监督学习方法”，*PLoS ONE*，17(9)，e0275114，2022年。[56] J. Zhang 和 R. P. Patterson，“通气电阻抗断层成像图像：哪些因素会导致电阻率变化？”，《生理测量》，26(2)，S81-S92，2005年[57] S. Zlochiver 等，“用于监测心搏量的参数化电阻抗断层成像”，《生理测量》，第27卷，S139-S146，2006年。[58] X. Zhu 和 A. B. Goldberg，“半监督学习导论”，人工智能与机器学习综合讲座丛书，3(1)，1-130，2009年。