

呼吸机管路积水故障自动监测 算法研究

周豹^{1*}, 张敬剑², 孙洁², 郑琴^{2#}

¹上海理工大学健康科学与工程学院, 上海

²上海市杨浦区市东医院呼吸与危重症医学科, 上海

收稿日期: 2024年4月24日; 录用日期: 2024年5月22日; 发布日期: 2024年5月31日

摘要

呼吸机管路中的积水会导致管路内径变窄, 增加气道阻力和患者的吸气做功, 且当呼吸机管路积水严重时, 甚至会造成患者发生窒息现象, 而监测呼吸机管路积水故障能够有效提高呼吸机使用的安全性。为此, 提出了呼吸机管路积水故障自动监测算法研究。利用小波变换去噪方法去除呼吸机管路信号中的噪声, 以VC维理论和SRM准则为基础, 建立支持向量机回归算法, 通过拉格朗日函数将其优化为多输出支持向量机回归算法, 采用改进的人工蜂群算法, 优化多输出支持向量机相关参数, 生成最优多输出支持向量机并加以训练。将去噪后信号输入至训练后的多输出支持向量机中, 输出故障监测结果, 实现呼吸机管路积水故障自动监测。实验结果表明, 所提方法的故障监测准确率始终高于90%, 证明该方法的故障监测精度较高, 具有良好的故障监测效果。

关键词

小波分析, 呼吸机, 管路积水, 故障自动监测, 多输出支持向量机

Research on Automatic Monitoring Algorithm for Water Accumulation in Ventilator Pipeline

Bao Zhou^{1*}, Jingjian Zhang², Jie Sun², Qin Jia^{2#}

¹School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai

²Department of Respiratory and Critical Care Medicine, Shidong Hospital of Shanghai Yangpu District, Shanghai

Received: Apr. 24th, 2024; accepted: May 22nd, 2024; published: May 31st, 2024

*第一作者。

#通讯作者。

文章引用: 周豹, 张敬剑, 孙洁, 郑琴. 呼吸机管路积水故障自动监测算法研究[J]. 建模与仿真, 2024, 13(3): 3470-3481. DOI: 10.12677/mos.2024.133316

Abstract

The accumulated water in the ventilator pipeline will cause the inner diameter of the pipeline to narrow, increase the airway resistance and the patient's work of inspiration, and when the ventilator pipeline has serious accumulated water, it may even cause the patient to suffocate. Monitoring the accumulated water fault in the ventilator pipeline can effectively improve the safety of the use of the ventilator. Therefore, the research on automatic monitoring algorithm of ventilator pipeline water logging fault is proposed. The wavelet transform denoising method is used to remove the noise in the ventilator pipeline signal. Based on VC dimension theory and SRM criterion, the support vector machine regression algorithm is established. It is optimized into a multi output support vector machine regression algorithm through Lagrange function. The improved artificial bee colony algorithm is used to optimize the related parameters of the multi output support vector machine, generate the optimal multi output support vector machine and train it. The de-noising signal is input to the trained multi output support vector machine, and the fault monitoring results are output to realize automatic monitoring of ventilator pipeline water logging fault. The experimental results show that the fault monitoring accuracy of the proposed method is always higher than 90%, which proves that the fault monitoring accuracy of the method is high and has a good fault monitoring effect.

Keywords

Wavelet Analysis, Ventilator, Pipeline Water, Automatic Fault Monitoring, Multi-Output Support Vector Machine

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

呼吸机是重症监护室中至关重要的生命支持医疗设备之一，但呼吸机的不当使用易导致管路积水等问题。不仅不利于治疗，而且还会对患者肺部造成伤害，使患者出现一系列并发症[1]。同时，呼吸机管路积水也会造成流量传感器和呼出阀等部件损坏的问题，导致呼吸机故障或失效，影响病患治疗效果。因此，对呼吸机管路积水故障进行监测具有重要意义[2]。

刘香君[3]等根据不同故障类别下端口时序性电信号及对应征兆现象，将预处理后的特征编码进行归一化处理并融合，筛选特征值并建立数据特征集，构建长短时记忆网络故障监测模型，将训练后多模态特征输入模型中，实现医疗设备故障智能诊断。陈艳[4]等分别收集造成呼吸机故障的多方面因素数据，采用收集到的数据训练搭建的 8 输入 3 输出粗糙神经网络，将待分析数据输入至训练后模型中，实现呼吸机故障监测。虽然上述方法均能够有效实现医疗设备和呼吸机故障的智能诊断和监测，但上述方法未对输入信号进行去噪处理，监测效果还需不断提升。

为了解决上述方法中存在的问题，本文提出了呼吸机管路积水故障自动监测算法研究。

2. 呼吸机管路信号去噪

监测呼吸机管路积水故障的前提是采集呼吸机相关信号数据，在采集信号过程中，外界环境和设备

自身因素会导致采集到的呼吸机管路信号中包含一定噪声，因此为保障后续故障信号监测效果，需要去除信号中的噪声，提升呼吸机管路信号的真实性和可靠性。

所提方法结合实际去噪需求，采用小波分析中的小波变换去噪法去除呼吸机管路信号中的噪声[5] [6]。假设 $\Phi(t)$ 表示母小波， $\psi(\omega)$ 表示 $\Phi(t)$ 的傅里叶变换[7] [8] [9]， $L^2(R)$ 表示平方可积实数空间， t 表示时间， ω 表示频率， R 表示空间半径， a 和 b 表示平移和伸缩因子，当 $\Phi(t)$ 满足 $\int_R |\psi(\omega)|^2 |\omega|^{-1} d\omega < +\infty$ 时，经平移和伸缩可得到小波序列 $\varphi_{a,b}(t)$ 如下所示：

$$\varphi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \varphi\left(\frac{t-b}{a}\right), a > 0, b \in R \quad (1)$$

假设存在待处理信号 $x(t) \in L^2(R)$ ，将该信号与 $\varphi_{a,b}(t)$ 做内积，可得到连续小波变换表达式 $WT_x(a,b)$ 如下所示：

$$\begin{aligned} WT_x(a,b) &= \langle x(t), \varphi_{a,b}(t) \rangle \\ &= a^{-\frac{1}{2}} \int_R x(t) \varphi_{a,b}\left(\frac{t-b}{a}\right) dt \end{aligned} \quad (2)$$

时频窗能够依据 a 和 b 进行自适应调整，通过小波变换实现信号高频和低频成分的自适应描述。

在小波变换去噪中，首先选取合适的小波函数将采集到的呼吸机管路信号分解，然后依据设定的阈值处理分解后信号参数，最后对参数执行逆小波变换，重构分解后信号，实现呼吸机管路信号去噪。小波分析去噪可以看作是信号的滤波问题，而小波降噪则是将低通滤波与特征提取相结合[10]。小波去噪和小波分解流程如图 1 所示。

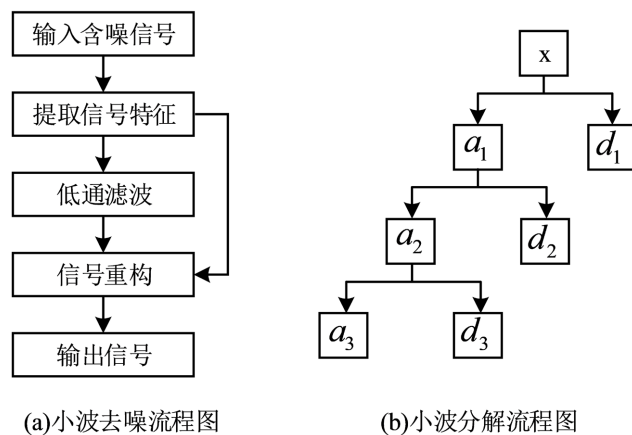


Figure 1. Flow chart of wavelet denoising and wavelet decomposition
图 1. 小波去噪和小波分解流程图

小波去噪主要流程如图 1(a)。用 $f(n)$ 代表信号， $x(n)$ 代表含噪信号， ε 代表噪声系数标准偏差， $\xi(n)$ 代表高斯白噪声[11]，则 $x(n) = f(n) + \varepsilon \times \xi(n)$ ，噪声通常表现为高频信号形式，而价值信号往往为低频或平稳信号形式，因此通过图 1(b)中小波分解处理信号能够达到信号去噪的效果，其中 a_1 、 a_2 、 a_3 表示低频信号， d_1 、 d_2 、 d_3 表示高频信号，对 d_1 、 d_2 、 d_3 作相应的小波系数处理并重构小波系数，即可实现呼吸机管路积水信号去噪。

3. 多输出支持向量机故障自动监测

将呼吸机管路积水信号进行去噪后, 对其进行故障监测。冷凝水处理不当、呼吸机整理和放置不合理、接水杯未及时倾倒、湿化罐水位超线、痰液堵塞、气道痉挛等因素是造成呼吸机管路积水的常见原因, 为了有效区分不同原因造成的呼吸机管路积水问题并及时解决, 所提方法采用多输出支持向量机构建呼吸机管路积水故障自动监测模型[12], 引入健康度指标量化呼吸机管路健康程度, 通过监测健康度的劣化过程评估呼吸机管路系统性能下降情况。

3.1. 支持向量机回归算法

支持向量机建立在 VC 维理论和 SRM 准则上[13], 是一种智能机器学习算法, 在提升泛化能力、避免陷入局部最优、解决维数灾难等方面均具有不俗效果。

用 $U = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ 表示训练集, 其中 $x = x_1, x_2, \dots, x_m$ 表示输入的去噪后信号指标向量, $\forall x_i, x_j \in x \in R^n$, $y = y_1, y_2, \dots, y_m$ 表示输出指标, $\forall y_i, y_j \in y \in R$, $i = 1, 2, \dots, m$, $U \in (R^n \times R)^m$, ω 表示法向量, b 表示位移项, $g(x)$ 表示预测值, 由此可将支持向量机回归问题视为采用 U 搜索 R^n 中实值函数 $y = g(x) = (\omega \cdot x) + b$ 问题, 进而实现全部输入指标向量对应输出指标的计算。

在支持向量机中引入 ε 不敏感损失函数, 设置不敏感损失系数 ε 取值, 若在 (x_i, y_i) 处存在 $|g(x_i) - y_i| \leq \varepsilon$, 则认为 $g(x_i)$ 为无损预测值。

依据 SRM 准则, 将松弛变量 $\xi^{(*)} = (\xi_1, \xi_1^*, \xi_2, \xi_2^*, \dots, \xi_m, \xi_m^*)$ 、惩罚因子 C 、 $\forall (\xi_i, \xi_i^*) \in \xi^{(*)}$ 添加到支持向量机中, 转化支持向量机优化问题为下式优化问题:

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \quad (3)$$

通过对偶理论将公式(3)所得最优值设定为原始问题最优值下界[14]。用 $\alpha^{(*)} = (\alpha_1, \alpha_1^*, \alpha_2, \alpha_2^*, \dots, \alpha_m, \alpha_m^*)$ 表示拉格朗日乘子[15] [16], $\forall (\alpha_i, \alpha_i^*), (\alpha_j, \alpha_j^*) \in \alpha^{(*)}$, 依据拉格朗日函数转化公式(3)问题为对偶问题, 如下所示:

$$\min_{\alpha_i^* \in R} \frac{1}{2} \sum_{i,j=1}^m (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) (x_i \cdot x_j) + \varepsilon \sum_{i=1}^m (\alpha_i^* - \alpha_i) - \sum_{i=1}^m y_i (\alpha_i^* - \alpha_i) \quad (4)$$

对上式的凸二次规划问题求解可得到最优解 $\bar{\alpha}^{(*)} = (\bar{\alpha}_1, \bar{\alpha}_1^*, \bar{\alpha}_2, \bar{\alpha}_2^*, \dots, \bar{\alpha}_m, \bar{\alpha}_m^*)^T$, $\forall (\bar{\alpha}_i, \bar{\alpha}_i^*), (\bar{\alpha}_j, \bar{\alpha}_j^*) \in \bar{\alpha}^{(*)}$, 结合 $\bar{\alpha}^{(*)}$ 求解法向量和位移项的最优解 $\bar{\omega}$ 和 \bar{b} , 如下所示:

$$\begin{cases} \bar{\omega} = \sum_{i=1}^m (\bar{\alpha}_i^* - \bar{\alpha}_i) x_i \\ \bar{b} = y_i - \sum_{i=1}^m (\bar{\alpha}_i^* - \bar{\alpha}_i) (x_i \cdot x_j) - \varepsilon \end{cases} \quad (5)$$

支持向量机多用于解决非线性回归问题, 引入核函数 $K(x_i \cdot x_j)$ 变换输入指标向量 x , 生成非线性回归函数, 如下所示:

$$y = g(x) = \sum_{i=1}^m (\bar{\alpha}_i^* - \bar{\alpha}_i) K(x_i \cdot x_j) + \bar{b} \quad (6)$$

选取合适的核函数和相关参数后构造支持向量机, 即可实现输入数据的准确识别。

3.2. 多输出支持向量机回归算法

准确识别输入数据后, 采用多输出支持向量机回归算法改进原有的支持向量机回归算法, 提高监测

精度。支持向量机多为多输入单输出的支持向量机，但呼吸机管路健康度是持续改变的过程值，多输出的支持向量机更利于呼吸机管路健康度的多步监测，因此所提方法改进支持向量机回归算法，将多输出支持向量机用于呼吸机管路健康度监测之中，从而实时掌控呼吸机管路的健康度下降情况。

与单输出支持向量机不同，多输出支持向量机采用矩阵替代单输出支持向量机参数，即将法向量 ω 转变为矩阵 W ，位移项 b 转变为矩阵 B ，且输出指标 y 为向量，多输出支持向量机回归函数 $y = g(x) = W \cdot x + B$ ，其中， $\forall W_i \in W$ ， $\forall x_i, x_j \in x$ ， $\forall y_i, y_j \in y$ ，在此基础上，利用 ε 值不敏感的损失函数来求解凸规划问题，如下所示：

$$\begin{aligned} \min_{W, B} & \frac{1}{2} \sum_{i=1}^l \|W_i\|_2^2 \\ \text{s.t.} & \begin{cases} (W \cdot x_i) - y_i + B \leq \varepsilon \\ y_i - (W \cdot x_i) - B \leq \varepsilon \end{cases} \end{aligned} \quad (7)$$

引入松弛变量 $\xi^{(*)}$ 和惩罚因子 C ， $\forall (\xi_{ij}, \xi_{ij}^*) \in \xi^{(*)}$ ，构造优化目标如下：

$$\min_{W, B} \frac{1}{2} \sum_{i=1}^l \|W_i\|_2^2 + C \sum_{j=1}^m \sum_{i=1}^l (\xi_{ij} + \xi_{ij}^*) \quad (8)$$

同样依据拉格朗日函数转化上式问题为对偶问题，用 $\alpha^{(*)}$ 表示拉格朗日乘子， $\forall (\alpha_{ik}, \alpha_{ik}^*), (\alpha_{jk}, \alpha_{jk}^*) \in \alpha^{(*)}$ ，得到对偶问题如下所示：

$$\begin{aligned} \min_{\alpha_i^* \in R} & \frac{1}{2} \sum_{k=1}^l \sum_{i=1}^m (\alpha_{ik}^* - \alpha_{ik})^2 (x_i \cdot x_j) + \varepsilon \sum_{k=1}^l \sum_{i=1}^m (\alpha_{ik}^* - \alpha_{ik}) - \sum_{k=1}^l \sum_{i=1}^m y_i (\alpha_{ik}^* - \alpha_{ik}) \\ \text{s.t.} & \begin{cases} \sum_{k=1}^l \sum_{i=1}^m (\alpha_{ik}^* - \alpha_{ik}) = 0 \\ 0 \leq \alpha_{ik}^{(*)} \leq C \end{cases} \end{aligned} \quad (9)$$

求解上式可得到最优解 $\bar{\alpha}^{(*)}$ ， $\forall \bar{\alpha}_k \in \bar{\alpha}^{(*)}$ 且 $\forall (\bar{\alpha}_{ij}, \bar{\alpha}_{ij}^*) \in \bar{\alpha}^{(*)}$ ， $i=1, 2, \dots, m$ ， $j=1, 2, \dots, l$ ，求解 W 和 B 的最优解 \bar{W} 和 \bar{B} ，如下所示：

$$\begin{cases} \bar{W} = \sum_{i=1}^m (\bar{\alpha}_{ij}^* - \bar{\alpha}_{ij}) x_i \\ \bar{B} = y_i - \sum_{i=1}^m (\bar{\alpha}_{ij}^* - \bar{\alpha}_{ij}) (x_i \cdot x_j) - \varepsilon, \bar{\alpha}_k \in (0, C) \end{cases} \quad (10)$$

用 $K(x_i \cdot x)$ 表示核函数，所提方法引入高斯径向基核作为核函数，用 σ 表示宽度参数，得到多输出支持向量机非线性回归函数如下所示：

$$\begin{cases} y = \sum_{i=1}^m (\bar{\alpha}_{ij}^* - \bar{\alpha}_{ij}) K(x_i \cdot x) + \bar{B} \\ K(x_i \cdot x) = \exp\left(-\frac{\|x_i \cdot x\|^2}{\sigma^2}\right) \end{cases} \quad (11)$$

由以上过程可以看出，多输出支持向量机的监测精度主要由 C 、 ε 和 σ 三个参数决定。

3.3. 多输出支持向量机参数优化

为了进一步提高监测算法的精准度，所提方法引入遗传算法[17] [18]改进人工蜂群算法[19] [20]，进而提升种群适应性和多样性，使算法快速收敛于全局最优解，将改进后人工蜂群算法用于多输出支持向

量机的 C 、 ε 和 σ 三个参数优化之中。

蜜源和参数最优解一一对应, 用 x_i^j 表示蜜源 i 的第 j 维位置, x_k^j 表示蜜源 k 的第 j 维位置, N 表示蜜源总数, $k=1,2,\dots,N$, D 表示蜜源维数, 即目标函数参数总数, $i,j=1,2,\dots,N$, 其中 $i \neq k$, r 表示在 $[-1, 1]$ 中均匀分布的随机数, 用于引领蜂搜索范围的调控, 引领蜂基于旧位置 x_i^j 生成临近竞争新蜜源位置 v_i^j 的规则如下所示:

$$v_i^j = x_i^j + r \times (x_i^j - x_k^j) \quad (12)$$

跟随蜂依据引领蜂在蜜源 i 处释放花蜜信息和花蜜量概率 p_i 选取蜜源, 用 f_i 表示蜜源 i 花蜜量, 即适应度值, n 表示当前循环次数, f_n 表示对应适应度值, 则 p_i 计算方式如下所示:

$$p_i = \frac{f_i}{\sum_{n=1}^N f_n} \quad (13)$$

用 k_{limit} 表示在上次迭代中侦查蜂获取到新蜜源位置经历的迭代次数, 依据 k_{limit} 确定侦查蜂是否需要搜索蜜源。 p_i 是否成功以适应度值更新成功次数在总循环次数中的占比决定。

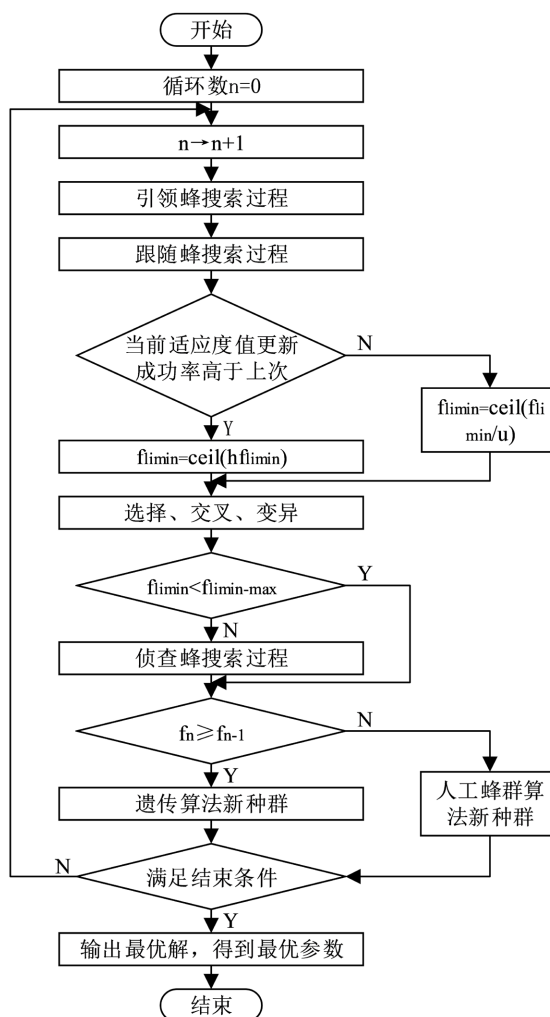


Figure 2. Improved artificial bee colony algorithm flowchart
图 2. 改进的人工蜂群算法流程图

改进的人工蜂群算法与人工蜂群算法不同,改进后侦查蜂首先在搜索新蜜源前依据遗传算法选择因子再次筛选跟随蜂选取的优质蜜源,选择最优蜜源直接遗传至下代,然后借鉴遗传算法中交叉因子将重组后父代某段结构互相替换,使后代蜜源同时继承上代双亲优点,提升搜索性能,最后在交叉操作趋近于最优解区域时,该方法利用遗传算法的变异运算,实现了局部优化,提高了算法的全局优化能力和收敛速度,并在一定程度上,保证了种群的多样性,避免了过早的收敛。

完成遗传算法相关操作后设定循环数 $k_{\text{limit-max}}$,若达到 $k_{\text{limit-max}}$ 次循环后 x_i^j 仍未得到优化,则舍弃 x_i^j ,由侦查蜂随机生成新蜜源替代原始蜜源,用 x_{max}^j 和 x_{min}^j 表示第 j 维变量上界和下界,新蜜源位置生成规则如下所示:

$$x_i^j = x_{\text{min}}^j + \text{rand}(0,1)(x_{\text{max}}^j - x_{\text{min}}^j) \quad (14)$$

最终,依据适应度的变化情况确定新种群。改进的人工蜂群算法主要流程如图 2 所示。

图 2 中, $\text{ceil}(\cdot)$ 表示取整函数, h 和 u 表示 k_{limit} 的更新步长。

通过改进的人工蜂群算法得到多输出支持向量机最优参数后对支持向量机加以训练,建立多输出支持向量机拟合监测信号与健康度变化之间的非线性映射关系,将呼吸机管路数据输入训练后的多输出支持向量机中,对呼吸机管路数据多步监测,输出健康度监测结果,实现呼吸机管路积水故障自动监测。

4. 实验与结果

为了验证呼吸机管路积水故障自动监测算法研究的有效性,设定多输出支持向量机参数取值范围分别为: $C \in [0,100]$ 、 $\varepsilon \in [0.0001,1]$ 和 $\sigma \in [0.001,10]$ 。在 MATLAB 环境下对改进的人工蜂群算法优化多输出支持向量机参数模型进行仿真,通过对训练样本进行训练,得到多输出支持向量机参数优化结果。




Figure 3. Waveform diagram of monitoring water accumulation faults in the ventilator pipeline using three methods

图 3. 三种方法的呼吸机管路积水故障监测波形图

为了验证所提方法对呼吸机管路积水故障监测效果,分别采用文献[3]方法和文献[4]方法与所提方法进行对比。若呼吸机管路内存在积水,则在呼吸机管路积水故障监测中,易出现高频波动噪声,压力幅值变化越大,说明检测到的噪声频率越大,表明方法的监测效果越好。三种方法的呼吸机管路积水故障监测波形如图3所示。

根据图3可知,文献[3]方法和文献[4]方法的故障监测压力幅值变化较小,而所提方法的故障监测压力幅值变化较大,说明所提方法能够有效、全面地监测到呼吸机管路中的积水。由此可知,所提方法的呼吸机管路积水故障监测效果较好。

进一步验证三种方法在不同信噪比下的故障监测精度,每次实验训练批次为20次,迭代次数为50次,每组实验在完成10次后,求取故障监测准确率均值,故障监测准确率越高,表明方法的故障监测精度越高。实验训练系统及三种方法在不同信噪比下故障监测准确率如图4、表1所示。

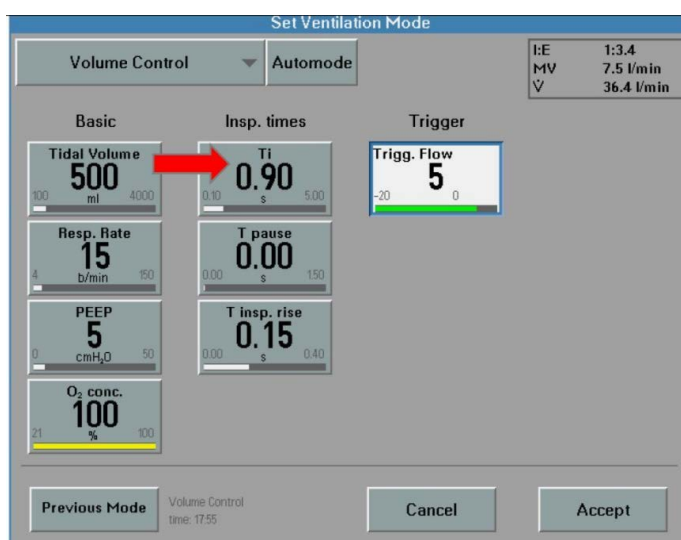


Figure 4. Screenshot of experimental training system
图4. 实验训练系统截图

由图4可以看出实验训练系统设定了声量控制器的参数。其中,基本参数包括:潮汐量(Tidal Volume)500 ml,呼吸率(Resp.Rate)为15 b/min,呼气暂停时间(PEEP)为5 cm H₂O,氧气浓度(O₂ conc.)为100%。吸入率的参数包括:吸气时间(Ti) 0.90 s,吸气暂停时间(T pause)为0.00 s,吸气上升时间(T insp.rise)为0.15 s。触发流量(Trigg.Flow)为5。

Table 1. Accuracy of fault monitoring for three methods under different signal to noise ratios
表1. 三种方法在不同信噪比下故障监测准确率

信噪比/dB	故障监测准确率/%		
	文献[3]方法	文献[4]方法	所提方法
-2	97.68	96.81	99.81
-4	95.12	93.25	99.75
-6	94.07	92.64	98.68
-8	93.23	90.12	98.52
-10	89.59	86.17	97.23

由表 1 可以看出,随着信噪比的降低,所提方法、文献[3]方法和文献[4]方法的呼吸机管路积水故障监测准确率均有所下降,但所提方法明显高于文献[3]方法和文献[4]方法。在信噪比为-10 dB 时,三种方法的故障监测准确率均达到最低值,但所提方法的故障监测准确率仍保持在 97%以上,而文献[3]方法和文献[4]方法的故障监测准确率已低于 90%,说明所提方法在噪声条件下具有更高的故障监测精度。因为所提方法在将采集到的呼吸机管路信号输入监测模型前通过小波变换去噪信号,滤除信号中噪声部分,将剩余有意义信号输入监测模型,从而有效提升故障监测准确率。

为了进一步验证所提方法、文献[3]方法和文献[4]方法的故障监测能力,将包含六种不同故障类型的实验样本信号特征降维至三维空间后作为三种方法的输入值,对比三种方法的故障监测能力,实验系统及实验结果如图 5-7 和图 8 所示。




Figure 5. Screenshot of the experimental monitoring system
图 5. 实验监测系统截图




Figure 6. Reference [3] method fault monitoring capability
图 6. 文献[3]方法故障监测能力




Figure 7. Reference [4] method fault monitoring capability
图 7. 文献[4]方法故障监测能力

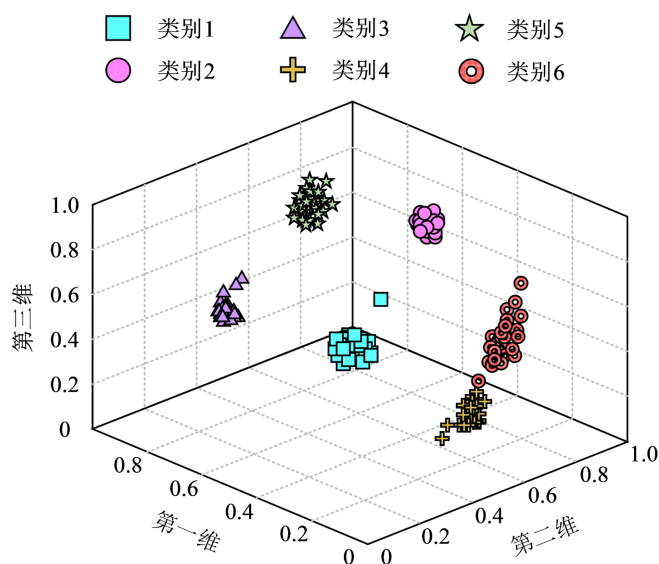


Figure 8. Fault monitoring capability of the proposed method
图 8. 所提方法故障监测能力

其中图 5 实验监测系统为监护仪界面，它显示了患者信息以及时间、病床号等基本信息。同时波形图区域展示的是患者的生命体征，包括心电图波形(绿色)、血氧饱和度波形(蓝色)、血流波形(红色)以及呼吸波形(黄色)等。这些波形能够直观地反映患者心脏活动、血氧供应、血流情况以及呼吸节律等生理状态。其中，参数区是监护仪界面上最为关键的部分，它实时显示患者的各项生命体征数据，如心率(HR)、血压(BP)、呼吸频率(RR)、血氧饱和度(SpO₂)、体温(TEMP)等。

由图 4、图 5 和图 6 可以看出，文献[3]方法无法清晰区分类别 1、类别 3 和类别 5，使三种类别之间存在混淆，类别 4 和类别 6 之间也存在类样本间间距较小情况，且类别 4 和类别 6 的类样本内间距较大。文献[4]方法对类别 1、类别 2、类别 3 以及类别 2、类别 3 和类别 5 的区分界限不够明显，类别之间存在

明显的连接, 类样本间间距过小, 类别 4 和类别 6 的类内间距过大, 且两者间也存在连接部分。而所提方法对六种故障类别的区分十分明显, 类样本间间距较大且类样本内间距较小。由此可知, 所提方法未出现误判问题, 具有较好的故障监测能力。

5. 讨论

本文研究了呼吸机管路积水故障自动监测算法, 利用小波分析中的小波变换去噪方法, 对呼吸机管路信号中的噪声进行去除, 从而提升呼吸机管路信号可靠性和故障监测准确率。通过构建多输出支持向量机, 结合改进的人工蜂群算法, 对其相关参数进行优化, 生成最优多输出支持向量机并加以训练。将去噪后信号输入至训练后多输出支持向量机中, 输出故障监测结果, 确保故障监测效果。

与文献[3]方法和文献[4]方法相比, 本次研究利用小波变换去噪方法, 去除了呼吸机管路中的噪声干扰, 采用改进的人工蜂群算法, 优化多输出支持向量机相关参数。而文献[3]方法和文献[4]方法仅对数据进行预处理, 将收集到的信息放入训练好的模型中, 容易存在监测误差。在不同信噪比下故障监测准确率测试中, 文献[3]方法和文献[4]方法的故障监测准确率最高值分别为 97.68% 和 96.81%, 而所提方法的故障监测准确率最高值为 99.81%, 高于文献[3]方法和文献[4]方法, 证明所提方法的故障监测效果更好。

本次研究仅对恺得 VADI 呼吸机进行监测, 在今后的工作当中, 需对不同型号的呼吸机进行监测, 以便取得更加准确的监测结果。

6. 结论

为了解决目前呼吸机存在的监测精度较低, 监测效果较差的问题, 提出呼吸机管路积水故障自动监测算法研究。通过采用小波变换去噪技术, 能够显著提高呼吸机管路积水故障的监测精度。这一改进有助于更准确地识别和预警潜在的故障, 从而提升呼吸机使用的安全性。同时采用多输出支持向量机模型, 并引用改进的人工蜂群算法对模型参数进行优化, 使得模型能够更好地适应和识别各种故障信号, 增强了其在实际应用中的可靠性。另外, 该算法为呼吸机的更安全、更稳定使用提供了有力保障。有助于减少因故障导致的停机时间, 提高设备的整体运行效率。

基金项目

上海市 2021 年度“科技创新行动计划”科学仪器和化学试剂项目申报指南/仪器共享配套操作与应用技术研究“大型多导睡眠监测仪模块拓展及共享配套应用技术研究”(21142203600)。

参考文献

- [1] 魏昊业, 柳青, 宗会迁. VELA 呼吸机潜在故障分析与维修[J]. 中国医疗设备, 2022, 37(3): 170-173.
- [2] 潘清, 马树, 张华青, 等. 基于小波的呼吸机管路积液自动检测算法研究[J]. 浙江工业大学学报, 2020, 48(1): 47-54.
- [3] 刘香君, 朗朗, 张诗慧, 等. 基于长短时记忆网络的医疗设备故障智能诊断研究[J]. 生物医学工程学杂志, 2021, 38(2): 361-368.
- [4] 陈艳, 王琪, 蒋佳旺. 基于数据挖掘技术的医疗设备故障监测与识别方法的探讨与研究[J]. 中国医疗设备, 2020, 35(8): 56-59.
- [5] 韩婷, 石宇强. 基于振动信号融合的 ACO-DCNN 多工况设备故障诊断[J]. 现代制造工程, 2021(9): 94-100.
- [6] 傅成豪, 潘庭龙. 基于改进阈值的风机齿轮箱故障信号小波去噪方法研究[J]. 可再生能源, 2020, 38(9): 1197-1202.
- [7] 杨静俭, 马鸿雁, 窦嘉铭. 基于聚类和傅里叶基 PSO-Elman 谐波检测研究[J]. 计算机仿真, 2022, 39(7): 117-123.
- [8] 孙丽君, 黄志远, 陈天飞. 基于傅里叶变换的 Gamma 因子快速自标定方法[J]. 光学学报, 2021, 41(24): 116-127.

-
- [9] 黄少锋, 高琦, 周宇聪, 等. 消除非周期分量影响的改进傅里叶算法[J]. 电力系统保护与控制, 2021, 49(14): 21-28.
- [10] 张瑞亮, 陈准, 刘森海, 等. 基于低通滤波的大功率型氢燃料电池重型货车自适应能量管理策略[J]. 汽车工程, 2021, 43(11): 1693-1701, 1729.
- [11] 薛继仁, 陈立群, 张业伟, 等. 单自由度NES在高斯白噪声随机激励下的响应分析[J]. 振动与冲击, 2020, 39(12): 235-241.
- [12] 叶韬, 司乔瑞, 申纯浩, 等. 基于支持向量机的离心泵初生空化监测[J]. 排灌机械工程学报, 2021, 39(9): 884-889.
- [13] 赵明清, 席甜甜. 基于SRM准则的线性EIV模型参数岭估计方法[J]. 数理统计与管理, 2020, 39(5): 874-883.
- [14] 张秋林, 林惠玲. 互补约束数学规划问题的二阶Mond-Weir型对偶理论[J]. 福建师范大学学报(自然科学版), 2021, 37(4): 8-13, 54.
- [15] 齐宗会, 汪晖, 刘永平. 连续可导函数类的最优拉格朗日插值[J]. 高等学校计算数学学报, 2020, 42(1): 87-96.
- [16] 李茂青, 刘建强, 高锋阳, 等. 基于受控拉格朗日函数的永磁同步电动机控制器设计[J]. 控制理论与应用, 2020, 37(6): 1406-1412.
- [17] 余朝军, 江驹, 徐海燕, 等. 基于改进遗传算法的航班-登机口分配多目标优化[J]. 交通运输工程学报, 2020, 20(2): 121-130.
- [18] 武钦芳, 吴张倩, 苏兆品, 等. 遗传算法优化时间卷积网络的手机来源识别[J]. 计算机工程与应用, 2022, 58(3): 151-158.
- [19] 王阳, 李志鹏, 刘灿, 等. 基于人工蜂群算法的供水泵站运行优化研究[J]. 流体机械, 2021, 49(2): 71-76.
- [20] 曹亚丽, 余牧舟, 杨俊峰, 等. 一种改进的人工蜂群算法研究[J]. 现代电子技术, 2020, 43(12): 133-137, 141.