

DOI: 10.19650/j.cnki.cjsi.J2006124

基于 PSO_GRNN 网络的肺内静态压力值预测方法^{*}

张玉欣¹, 金江春植^{1,2}, 白 晶¹, 周振雄¹

(1. 北华大学电气与信息工程学院 吉林 132021; 2. 日本纯真学园大学保健医学部 福岡 8150000)

摘 要:为了实现机械通气辅助医疗中依据病人个体差异控制呼吸机通气参量,分析了基于广义回归神经网络(GRNN)的呼吸系统力学模型,通过结合 PSO_GRNN 网络、数值积分和递推最小二乘法等实现呼吸系统模型的参数辨识。采用直接计算法实现单周期呼吸样本的肺静态压力值计算,并利用二阶多项式拟合体积值误差,计算 10 个吸气周期静态数据点的平均绝对值误差为 0.169 3 mL,计算 10 个呼气周期静态数据点的平均绝对值误差为 0.372 8 mL。采用 PSO_GRNN 网络实现多周期呼吸样本集的肺静态压力值预测,10 个呼吸周期样本集的训练集平均误差为 0.000 9 kPa,测试集平均误差为 0.040 7 kPa。仿真实验结果表明 PSO_GRNN 网络在收敛速度、平均误差、运算速度等方面均优于 PSO_BP 网络。所用方法在机械通气辅助治疗时可以为医生设置呼吸机通气参量提供有效的参考依据。

关键词:呼吸系统模型;参数辨识;GRNN 网络;粒子群算法;肺静态压力值

中图分类号: TH77 N945.14 **文献标识码:** A **国家标准学科分类代码:** 510.4020

The method of pulmonary static pressure value prediction based on PSO_GRNN network

Zhang Yuxin¹, Shunshoku Kanae², Bai Jing¹, Zhou Zhenxiong¹

(1. College of Electrical and Information Engineering, Beihua University, Jilin 132021, China;

2. Faculty of Health Sciences, Junshin Gakuen University, Fukuoka 8150000, Japan)

Abstract: It needs to control ventilator parameters according to individual differences of patient in the auxiliary treatment of mechanical ventilation. In this study, the mechanical model of a respiration system based on general regression neural network (GRNN) are analyzed. To identify parameters of the respiratory system model, a fusion method based on PSO_GRNN, numerical integration and recursive least square is proposed. The static lung pressure value of single-cycle respiratory samples is calculated by direct calculation and the second order polynomial is used to fit the volume error. The mean absolute error of static data points for ten inhalation cycles is 0.169 3 mL, and the mean absolute error of static data points for ten expiratory cycles is 0.372 8 mL. PSO_GRNN is used to predict the static lung pressure of the multi-cycle respiratory sample set. For the ten sample sets of respiratory cycle, the average error of the training set is 0.009 1 and the average error of the test set is 0.406 5. Simulation results show that PSO_GRNN is better than PSO_BP in terms of convergence rate, average error and computation speed. The proposed method can provide an effective reference basis for doctors to set ventilator parameters during the mechanical ventilation treatment.

Keywords: respiratory system model; parameter identification; general regression neural network (GRNN); particle swarm optimization (PSO); pulmonary static pressure value

0 引 言

当病人出现自主呼吸缺乏或者自主呼吸不足时,

要采用机械通气的方法进行治疗,即采用呼吸机。人的呼吸系统特性因人而异,其呼吸节奏和肺的弹性等因年龄、性别、体质、病情而各不同。目前临床上,医护人员按照病人体重设置呼吸机通气量,根据经验设置

收稿日期:2020-02-25 Received Date:2020-02-25

^{*} 基金项目:吉林市科技局项目(201731199)、吉林省发展和改革委员会项目(2019C058-1)资助

其他呼吸机参数的做法,无法满足个体的差异性。相同体重的病人,实际上呼吸特性并不同,但是设置相同的通气量、压力值等,可能发生病人气道内的气压过高带来肺泡破裂的危险,或者气道内的压力过低会产生供氧不足^[1]。因此,获得每个病人的呼吸系统特性并以此为依据设定呼吸机通气参数,是呼吸机辅助医疗的发展方向。

关于呼吸系统的认知,初期把肺当作具有固定弹性系数的气囊,用气压气流之间的比例关系进行模型化。在20世纪50年代Otis等^[2],Mead等^[3]和Mount等^[4]分别从不同的角度提出了各自不同的二阶线性微分方程式模型,在一定程度上反映了呼吸的动态过程。这些模型都可以归纳为一类二阶线性常微分方程式模型^[5]。在这些模型中代表肺弹性和气道阻尼的各项系数都规定为常数,因而不可能表示肺弹性和气道阻尼的非线性特性,更不可能确定以非线性的肺弹性导出的静态气压(P)-体积(V)关系曲线为依据的气压上限值。在其后的研究中意识到肺弹性和气道阻尼的非线性特性,从1990年—2000年初Peslin等^[6],Rousselot等^[7],Wensley等^[8],Muramatsu等^[9]提出了一类呼吸系统的非线性回归模型。在这个模型中用肺体积的多项式函数表示肺的弹性,用气流的流量多项式表示气道阻尼。但是这个模型没能充分的动态描述性能,不可能得出可以信赖的呼吸系统特性参数。易韦韦等^[10]提出单腔室集总参数模型,刘天亚等^[11]提出多腔室非线性集总参数模型,这两种模型均为一阶非线性模型。Shunshoku等^[12]和Masanori等^[13]提出了二阶非线性常微分方程的模型结构,其模型的肺弹性项和气道阻尼项用多项式、模糊逻辑等非线性函数系统描述,这样给出了表现呼吸过程的非线性动态过程的基本框架,给出了为人工呼吸建立数学模型的基本方向。

本文通过测量病人呼吸样本,建立了基于粒子群-广义回归神经网络(particle swarm optimization-general negression neural network, PSO_GRNN)的呼吸系统模型,并完成呼吸系统模型的参数辨识,得出病人的肺弹性系数、气道阻力参数等呼吸特性参数,并计算或预测病人的肺静态压力值。肺静态特性曲线是肺内部压力与体积的关系曲线。肺静态特性即肺的顺应性,表明病人的肺组织弹性情况,对呼吸机压力控制精度有显著影响^[14]。在医学界一般认为,肺的静态压力-体积曲线在上升的后一段呈现饱和,气道气压的上限值应该设在开始进入饱和的起始点^[15]。通过本文方法辨识出的呼吸系统模型、肺静态特性曲线及肺静态压力值,为病人设置符合自身生理病理特点的、恰当的呼吸机通气量、最大气压、吸气流速等参数值提供科学依据,同

时也为医生进行病理研究、生理研究以及临床诊断等提供了更多的理论支持。

1 呼吸系统模型

1.1 呼吸系统方程定义

二阶非线性常微分方程结构的呼吸系统方程为:

$$P_{ao}(t) + a \dot{P}_{ao}(t) = P_l(t) + P_r(t) + b \ddot{V}(t) + P_{eea} + e(t) \quad (1)$$

式中: $P_{ao}(t)$ 、 $V(t)$ 分别是呼吸机管道末端测得的气道压力、肺内气体体积; $\dot{P}_{ao}(t)$ 为 $P_{ao}(t)$ 的一阶导数; $\ddot{V}(t)$ 为 $V(t)$ 的二阶导数; $P_l(t)$ 为肺内部静态压力; $P_r(t)$ 为呼吸装置管道压力损耗; P_{eea} 为呼吸末端肺泡压力; $e(t)$ 为误差值,包含方程误差和测量噪声; a 和 b 为常数。

本文定义式(1)中 $P_l(t)$ 为:

$$P_l(t) = c \cdot f_g(V) \cdot V(t) \quad (2)$$

式中: $c \cdot f_g(V)$ 称为肺弹性系数, c 是常数系数, $f_g(V)$ 是变量系数。

式(1)中的 $P_r(t)$ 为:

$$P_r(t) = f_r(F)F(t) \quad (3)$$

式中: $f_r(F)$ 是气道阻力; $F(t)$ 是呼吸机管道末端测得的气体流量。

$$F(t) = \dot{V}(t) = \frac{d}{dt}V(t) \quad (4)$$

所以:

$$P_r(t) = f_r(\dot{V}) \dot{V}(t) \quad (5)$$

如果考虑到气体流量的二阶作用,则:

$$f_r(\dot{V}) = r_1 + r_2 |\dot{V}(t)| \quad (6)$$

其中 r_1 、 r_2 是常数。

$$\text{此时 } P_r(t) = (r_1 + r_2 |\dot{V}(t)|) \dot{V}(t) \quad (7)$$

将式(2)和(7)代入到式(1)的呼吸系统方程,可得:

$$P_{ao}(t) + a \dot{P}_{ao}(t) = c f_g(V) V(t) + (r_1 + r_2 |\dot{V}(t)|) \dot{V}(t) + b \ddot{V}(t) + P_{eea} + e(t) \quad (8)$$

再根据式(4)对上式进行改写,可得转换后的呼吸系统方程为:

$$P_{ao}(t) = -a \dot{P}_{ao}(t) + c f_g(V) V(t) + r_1 \dot{V}(t) + r_2 |F(t)| F(t) + b \ddot{V}(t) + P_{eea} + e(t) \quad (9)$$

1.2 矩阵表示法

为了方便表达,将式(9)的呼吸系统方程写成矩阵表达式:

$$P_{ao}(t) = \varphi_g^T(t) \theta_g + e(t) \quad (10)$$

$$\varphi_g(t) = \begin{bmatrix} -\dot{P}_{ao}(t) \\ f_g(V)V(t) \\ \dot{V}(t) \\ |F(t)|F(t) \\ \dot{F}(t) \\ 1.0 \end{bmatrix} \quad (11)$$

$$\theta_g = \begin{bmatrix} a \\ c \\ r_1 \\ r_2 \\ b \\ P_{eea} \end{bmatrix} \quad (12)$$

式中: $\varphi_g(t)$ 为已知量矩阵; θ_g 为待求量矩阵。

2 呼吸系统模型的参数辨识

2.1 PSO_GRNN 网络

广义回归神经网络 (general regression neural network, GRNN) 是径向基网络 (radial basis function, RBF) 的变形形式^[16-18], 结构简单, 且在计算过程中只需确定一个网络参数, 即光滑因子 σ 即可, 运算复杂度较低。与 BP 神经网络、支持向量机相比, GRNN 网络具有较强的非线性逼近能力, 高度的容错性和鲁棒性, 在样本数量较少时预测效果较好。光滑因子的选择直接关系到 GRNN 网络的泛化能力和精度, 对于 σ 值选择目前有人工赋值法、等步长交叉选择法、智能优化法等。这 3 类方法中, 智能优化法虽然计算相对复杂但准确率最高。

本文建立 PSO_GRNN 网络, 利用 GRNN 网络输出函数定义肺弹性变量系数 $f_g(V)$, 利用粒子群算法实现 GRNN 网络 σ 值寻优赋值。

GRNN 网络结构如图 1 所示, 由输入层、模式层、求和层和输出层 4 层构成。




图 1 GRNN 网络结构

Fig.1 GRNN network structure

设 PSO_GRNN 网络的输入为 $\mathbf{X} = [x_1, x_2, \dots, x_N]^T$, 输出为 $\mathbf{Y} = [y_1, y_2, \dots, y_M]^T$, $\hat{\mathbf{Y}}(\mathbf{X})$ 是输入为 $\mathbf{X}$ 的条件下 $\mathbf{Y}$ 的预测输出值。输入层神经元的数目等于学习样本中输入向量的维数。模式层是径向基层, 神经元数目等于学习样本的数目, 基函数一般采用高斯函数, 模式层神经元传递函数为:

$$P_i = \exp \left[-\frac{(\mathbf{X} - \mathbf{X}_i)^T (\mathbf{X} - \mathbf{X}_i)}{2\sigma^2} \right], i = 1, 2, \dots, N \quad (13)$$

式中: $\mathbf{X}$ 为网络输入变量; $\mathbf{X}_i$ 为第 i 个神经元对应的学习样本, 即中心点; σ 为光滑因子。

求和层神经元分为两种, 第 1 种神经元计算模式层各神经元的代数和, 称为分母单元, 其传递函数为:

$$S_D = \sum_{i=1}^n P_i \quad (14)$$

第 2 种神经元计算模式层神经元的加权和, 称为分子单元。权值为各训练样本的期望输出值, 其传递函数为:

$$S_{Nj} = \sum_{i=1}^n y_{ij} P_i, j = 1, 2, \dots, M \quad (15)$$

输出层神经元数目等于学习样本中输出向量的维数 k , 输出层将求和层的分子单元、分母单元的输出相除, 输出为:

$$y_j = \frac{S_{Nj}}{S_D}, j = 1, 2, \dots, M \quad (16)$$

PSO_GRNN 网络的预测输出为:

$$\hat{\mathbf{Y}}(\mathbf{X}) = \frac{\sum_{i=1}^n \mathbf{Y}_i \exp \left[-\frac{(\mathbf{X} - \mathbf{X}_i)^T (\mathbf{X} - \mathbf{X}_i)}{2\sigma^2} \right]}{\sum_{i=1}^n \exp \left[-\frac{(\mathbf{X} - \mathbf{X}_i)^T (\mathbf{X} - \mathbf{X}_i)}{2\sigma^2} \right]} \quad (17)$$

用 PSO_GRNN 网络的输出函数形式定义肺弹性变量系数 $f_g(V)$ 。

$$f_g(V) = \frac{\sum_{i=1}^N P_i \exp \left[-\frac{\|V - V_i\|}{2\sigma^2} \right]}{\sum_{i=1}^N \exp \left[-\frac{\|V - V_i\|}{2\sigma^2} \right]} \quad (18)$$

式中: P_i 和 V_i 分别是模式层第 i 个中心点对应的呼吸样本的 $P_{ao}(t)$ 值和 $V(t)$ 值。

PSO 算法在可解空间初始化一群粒子, 每个粒子用位置、速度、适应度值 3 项指标来表示。用户需要限定粒子速度区间和粒子位置区间, 设定种群规模、迭代次数、学习因子等参数。当用户设定的迭代次数到达或者粒子适应度值相对误差小于设定的期望值时, 停止迭代。粒子适应度值通过计算适应度函数得到, 其值的好坏表征粒子的优劣。

2.2 呼吸系统方程的数值积分运算

呼吸系统方程的矩阵表达式是连续时间函数模型,

而呼吸样本 $P_{ao}(t)$ 、 $V(t)$ 、 $F(t)$ 均为等时间间隔 T 的采样数据,因此,本方法在求解过程中采用数值积分运算进行处理。对式(10)左右两端进行积分,积分范围是 $[kT, (k-l)T]$,其中 $k=1,2,\dots,N$, N 是呼吸样本个数, l 是积分区间长度。

定义 $p(k)$ 为 $P_{ao}(t)$ 数值积分运算结果,

$$p(k) = \int_{(k-l)T}^{kT} P_{ao}(t) dt \approx \sum_{j=0}^l g_j P_{ao}(k-j) \quad (19)$$

其中 g_j 是利用复合梯形公式法进行数值积分时的系数,定义为:

$$g_j = \begin{cases} 0.5T, & j=0, l \\ T, & j=1, 2, \dots, l-1 \end{cases} \quad (20)$$

定义 $\phi_g(k)$ 为 $\varphi_g(t)$ 的数值积分运算结果,定义 $e(k)$ 为 $e(t)$ 的数值积分运算结果。

$$\phi_g(k) = \sum_{j=0}^l g_j \varphi_g(k-j) = \begin{bmatrix} -P_{ao}(k) + P_{ao}(k-l) \\ \sum_{j=0}^l g_j f_g(V) V(k-j) \\ V(k) - V(k-l) \\ \sum_{j=0}^l g_j |F(k-j)| F(k-j) \\ F(k) - F(k-l) \\ lT \end{bmatrix} \quad (21)$$

$$e(k) = \int_{(k-l)T}^{kT} e(t) dt \approx \sum_{j=0}^l g_j e(k-j) \quad (22)$$

因此,呼吸系统方程的数值积分运算方程为:

$$p(k) = \phi_g^T(k) \theta_g + e(k) \quad (23)$$

2.3 基于递推最小二乘法的呼吸系统方程参数辨识

在 $k=l+1, \dots, N$ 时,设 p 是 $p(k)$ 的转置矩阵,即 $p = [p(l+1), p(l+2), \dots, p(N)]^T$, Φ 是 $\phi_g(k)$ 的转置矩阵,即 $\Phi = [\phi_g(l+1), \phi_g(l+2), \dots, \phi_g(N)]^T$; e 是 $e(k)$ 的转置矩阵,即 $e = [e(l+1), e(l+2), \dots, e(N)]^T$,那么式(23)可以写为:

$$p = \Phi \theta_g + e \quad (24)$$

定义 $\hat{\theta}_g$ 是 θ_g 的最小二乘估计值,则:

$$\hat{\theta}_g = (\Phi^T \Phi)^{-1} \Phi^T p \quad (25)$$

其中 $(\hat{\theta}_g)^T = [\hat{a}, \hat{c}, \hat{r}_1, \hat{r}_2, \hat{b}, \hat{P}_{eea}]$ 。

最小二乘法估计误差 J 为:

$$J = (p - \Phi \hat{\theta}_g)^T (p - \Phi \hat{\theta}_g) \quad (26)$$

人体呼吸是连续的,且每个周期的呼吸数据并不完全相同,并且病人肺部状态随时可能发生变化,即呼吸方程是时变系统,因此采用含有加权因子的递推最小二乘法(recursive least squares, RLS)对呼吸系统方程进行递推运算,实现呼吸系统方程参数的在线辨识。递推最小二乘法计算公式为:

$$\begin{aligned} \hat{\theta}_g(k) &= \hat{\theta}_g(k-1) + L(k) [y(k) - \phi_g^T(k) \hat{\theta}_g(k-1)] \\ L(k) &= \frac{S(k-1) \phi_g(k)}{\lambda + \phi_g^T(k) S(k-1) \phi_g(k)} \\ S(k) &= \frac{1}{\lambda} [S(k-1) - \\ &\frac{S(k-1) \phi_g(k) \phi_g^T(k) S(k-1)}{\lambda + \phi_g^T(k) S(k-1) \phi_g(k)}] \end{aligned} \quad (27)$$

式中: λ 是遗忘因子,一般取 $0.9 < \lambda < 0.99$,初始化的参数估计值 $\hat{\theta}_g(0) = 0$,初始化的协方差矩阵 $S(0) = \delta^2 I$, δ 是一个足够大的实数,这里取 $\delta = 10^5$ 。


将每周呼吸样本计算得出的 $\hat{\theta}_g(k)$ 和 $f_g(V)$ 代入式(8),得到采集呼吸样本病人的呼吸系统方程,即完成了符合该病人自身呼吸特性的呼吸系统方程的在线辨识。同时可以确定该病人的肺内部压力值 $P_l(t)$,呼吸装置管道压力损耗值 $P_r(t)$,呼吸末端肺泡压力值 P_{eea} 等重要呼吸特性指标,为医生进行机械通气治疗提供重要的参考指标^[19]。

3 肺静态压力值预测实验及结果分析

3.1 呼吸样本

呼吸特征数据包括气道压力 $P_{ao}(t)$ 、肺内气体体积 $V(t)$ 、气体流量 $F(t)$ 和肺内部静态压力实测值 $P_l(t)$ 。每个病人采样10个周期的160组呼吸特征数据构成样本集。由于 $P_{ao}(t)$ 、 $V(t)$ 、 $F(t)$ 的采集简便,采样间隔 $T=0.005$ s,即采样频率200 Hz,每个呼吸周期采样点数 $N=229$ 。而样本 $P_l(t)$ 的采集相对困难,会引起病人身体不适,因此每个呼吸周期的229个采样点中只对其中16个点采样了 $P_l(t)$ 值。

人的呼吸数据每个周期并不完全相同,图2和图3所示为胎龄25周患有呼吸窘迫综合症的早产婴儿某一周期的呼吸数据。该呼吸周期的呼吸样本曲线如图2所示,其中吸气点数 $N_1 = 116$,呼气点数 $N_2 = 113$ 。该周期呼吸样本的 $P_{ao} - V$ 曲线如图3所示。






图2 呼吸样本曲线
Fig.2 Respiratory sample curve

3.2 直接算法

直接算法对单周期数据进行运算,完成呼吸方程的参数辨识和肺内静态压力值计算。下面以早产婴儿一个周期的呼吸样本为例,根据 PSO_GRNN 网络的计算原理,将一个周期的呼吸数据样本 $V(t)$ 代入式(18),分别计算出吸气样本和呼气样本的 PSO_GRNN 网络输出值,即计算出该呼吸周期的肺弹性变量系数 $f_g(V)$,式(18)中 P_i 和 V_i 分别是模式层第 i 个中心点对应的呼吸样本的 $P_{ao}(t)$ 值和 $V(t)$ 值。将 $f_g(V)$ 和递推最小二乘法辨识出






图3 呼吸样本 $P_{ao}-V$ 曲线
Fig.3 Respiratory sample curve of $P_{ao}-V$

来的参数 $\hat{c}$ 、实时测量的 $V(t)$ 值代入式(2),可求出对应的肺内部静态压力 $P_l(t)$ 的估计值 $\hat{P}_l(t)$ 。最小二乘法估计误差作为 PSO 算法的适应度函数,实现 GRNN 网络的 σ 值寻优。

呼吸样本是一维向量,所以 GRNN 网络输入层和输出层的神经元数目均为 1,设定求和层神经元数目为 2。每个呼吸周期的样本数是 229,如果模式层神经元数目等于呼吸样本数目,即模式层如果有 229 个中心点,必然会造成网络庞大,计算量过多。为了使中心点的选择涵盖整个呼吸周期,在吸气样本和呼气样本中各选择 7 个中心点,对吸气样本和呼气样本分别计算,即模式层神经元数目等于 7,每一个模式层神经元即为一个数据中心点。将 116 个吸气样本分成 7 个区间,其中包含 17 个样本的区间 4 个,16 个样本的区间 3 个;将 113 个呼气样本分成 7 个区间,其中包含 17 个样本的区间 1 个,16 个样本的区间 6 个。然后分别在各区间内随机选取一个数据点作为中心点。这里设定数值积分长度 $l=20$ 。

直接计算早产儿 10 个周期样本的肺内部静态压力估算值 $\hat{P}_l(t)$,其中 4 个吸气周期样本的 $\hat{P}_l(t)$ 估计曲线如图 4 所示,4 个呼气周期样本的 $\hat{P}_l(t)$ 估计曲线如图 5 所示。






图 4 吸气周期样本的 $\hat{P}_l(t)$ 曲线

Fig.4 Inspiratory cycle samples curve of $\hat{P}_l(t)$




图 5 呼气周期样本的 $\hat{P}_l(t)$ 曲线

Fig.5 Expiratory cycle samples curve of $\hat{P}_l(t)$

表 1 10 个周期样本的最小二乘法估计误差 J 值
Table 1 The least square estimation error value of ten periodic samples

周期	吸气样本 J	呼气样本 J
1	0.004 0	0.004 4
2	0.003 9	0.004 2
3	0.003 9	0.004 3
4	0.003 9	0.004 1
5	0.003 6	0.004 3
6	0.003 4	0.004 3
7	0.003 6	0.004 4
8	0.003 8	0.003 9
9	0.003 7	0.003 8
10	0.004 1	0.004 0
平均误差	0.003 8	0.004 2

图中的 8 个蓝色数据点是本吸气、呼气周期病人肺内部静态压力 $P_l(t)$ 的实测值。10 个周期的最小二乘法估计误差值如表 1 所示。

从图 4 和 5 可以看出,本方法计算出来的 $\dot{P}_l(t)$ 值曲线对肺静态压力真实值拟合较好。由于人体肺呼气时和吸气时的静态特性并不完全相同,图 4、5 的仿真实验结果显示的两条 $\dot{P}_l(t)$ 值曲线不是完全重合的曲线,也印证了这个特点。

3.3 直接计算法肺静态数据拟合及误差分析

对于直接计算法,以图 4 中吸气样本的 $\dot{P}_l(t)$ 值为例进行数据拟合和误差分析。由于吸气样本估算值共 116 个,数据点过多,全部用来进行曲线拟合计算量过大,且准确性降低。采用分段数据点参与的方式进行曲线拟合。以图 4 中的 8 个静态数据的 P_l 值为中心,分别选择 6 个 $\dot{P}_l(t)$ 点进行曲线拟合。以图 4 中静态点 A 为例,A 点实测的 $P_l = 0.74, V = 3.6$ 。在 116 个吸气样本的 $\dot{P}_l(t)$ 值中选择第 25 ~ 30 个数据点进行拟合,这 6 个点的 $\dot{P}_l(t)$ 值分别为 [0.624 20, 0.672 17, 0.719 42, 0.765 19, 0.808 67, 0.849 80], V 值分别为 [3.212 4, 3.412 7, 3.610 0, 3.801 1, 3.982 7, 4.154 4]。

采用二阶多项式进行曲线拟合,即 $V = a_0 + a_1P_l + a_2P_l^2$,代人这 6 个点数据得到的拟合多项式为 $V = 0.605 9 + 4.175 8P_l - 0.000 2P_l^2$ 。当 $P_l = 0.74$ 时,拟合得出的 $V = 3.695 9$ 。与 A 点的 V 实测值之间误差为 0.095 9。

其中 1 个吸气周期和 1 个呼气周期静态数据点的样本值、拟合数据及误差分别如表 2 和表 3 所示。计算 10 个吸

气周期的静态数据点 V 值平均绝对值误差为 0.169 3 mL, 10 个呼气周期的静态数据点 V 值平均绝对值误差为 0.372 8 mL。

表 2 吸气静态数据点误差值汇总表
Table 2 Summary of inspiratory static point error values

数据点	P_l 实测值 /kPa	V 实测值 /mL	V 拟合值 /mL	V 拟合误差 绝对值/mL
1	1.10	5.0	5.084 2	0.084 2
2	0.42	2.5	2.425 4	0.074 6
3	1.22	5.8	5.550 7	0.249 3
4	0.42	2.3	2.425 4	0.125 4
5	0.90	4.5	4.364 1	0.135 9
6	1.28	6.0	5.771 8	0.228 2
7	0.87	4.6	4.238 8	0.361 2
8	0.74	3.6	3.695 9	0.095 9

表 3 呼气静态数据点误差值汇总表
Table 3 Summary of expiratory static point error values

数据点	P_l 实测值 /cmH ₂ O	V 实测值 /mL	V 拟合值 /mL	V 拟合误差 绝对值/mL
1	1.15	5.8	5.165 1	0.634 9
2	0.71	4.0	3.781 6	0.218 4
3	0.95	4.6	4.593 6	0.006 4
4	0.29	0.6	1.358 6	0.758 6
5	0.57	3.2	3.191 4	0.008 6
6	1.05	5.2	4.887 8	0.312 2
7	0.47	1.9	2.675 9	0.775 9
8	0.93	4.8	4.532 7	0.267 3

3.4 PSO_GRNN 网络训练法

PSO_GRNN 适用于多周期大样本集,以上述早产婴儿呼吸样本集为例,前 9 个周期的 144 组数据作为训练集, $P_{ao}(t)$ 、 $V(t)$ 、 $F(t)$ 归一化后作为 PSO_GRNN 网络的输入数据, $P_l(t)$ 归一化后作为 PSO_GRNN 网络的输出数据训练网络,第 10 个周期的 16 组数据作为测试集。设定 PSO 算法的种群规模为 30,迭代次数为 20,粒子速度区间 [0, 1] 和粒子位置区间 [-5, 5], $c1$ 、 $c2$ 取值为 1.494 45,动态权重因子的最大值和最小值分别为 0.9 和 0.4,均方误差 MSE 作为适应度函数。训练集 PSO_GRNN 算法适应度曲线如图 6 所示,PSO 寻优结果为 $\sigma = 0.1$ 。将 $\sigma = 0.1$ 赋值给 GRNN 网络,测试集结果如图 7 所示,测试集预测值与真实值的平均误差为 0.040 7 kPa。训练集预测结果如图 8 所示,训练集预测值与真实值的

平均误差为 0.000 9 kPa。




图 6 PSO_GRNN 网络适应度曲线
Fig.6 Fitness curve of PSO_GRNN




图 7 PSO_GRNN 网络测试集预测结果
Fig.7 Test results for test sets of PSO_GRNN

建立 PSO_BP 网络进行对比^[20],BP 网络输入层、隐含层、输出层神经元个数分别为 3、5、1。相同的训练集数据训练网络,PSO 算法实现 BP 网络的权值和阈值寻优,用最优结果赋值给 BP 网络并对测试集进行测试。设置了 BP 网络的学习率等于 0.1,迭代步数是 100。此时 PSO 算法粒子速度区间 $[-1,1]$,其余参数与 PSO_GRNN 中的设置相同。训练集 PSO_BP 算法适应度曲线如图 9 所示,测试集结果如图 10 所示,测试集预测值与真实值的平均误差为 0.052 4 kPa。训练集预测结果如图 11 所示,训练集预测值与真实值的平均误差为 0.008 2 kPa。

从实验结果可知,PSO_GRNN 收敛速度更快,测试集平均误差更小。并且 PSO_GRNN 算法因为寻优参数少,运算速度明显快于 PSO_BP 算法。




图 8 PSO_GRNN 网络训练集预测结果
Fig.8 Test results for train sets of PSO_GRNN




图 9 PSO_BP 网络适应度曲线
Fig.9 Fitness curve of PSO_BP




图 10 PSO_BP 网络测试集预测结果
Fig.10 Test results for test sets of PSO_BP




图 11 PSO_BP 网络训练集预测结果

Fig.11 Test results for train sets of PSO_BP

3.5 实验结果与误差分析

对不同年龄、性别、病程的病人呼吸样本集进行上述两种实验,实验结果规律一致。实验表明,网络训练法中 PSO_GRNN 算法在收敛速度、计算时间、测试集平均误差方面都优于 PSO_BP 算法。直接算法计算过程比较复杂,但是计算得出的拟合平均误差小于 PSO_GRNN 网络训练法测试集的平均误差。

影响本文方法准确率的主要因素有:1)呼吸数据样本精度直接影响系统参数辨识和数据拟合结果。2)增加呼吸样本的数量和多样性会提高模型的普适性。3)由于人体每个周期的呼吸数据都不完全相同,存在不可忽视的扰动,训练集与测试集呼吸曲线存在区别,会引起测试集测试结果的误差。进一步研究不同病人呼吸特性随时间变化规律,将提高呼吸系统参数辨识准确率,降低误差。

4 结 论

本文从临床呼吸样本数据出发,建立基于 PSO_GRNN 神经网络的人体呼吸系统模型,通过数值积分运算和递推最小二乘法实现呼吸系统模型的参数辨识,得到符合呼吸样本来源病人自身呼吸特性的呼吸系统方程。进而得出病人的肺弹性系数、气道阻力参数等呼吸特性参数,以及病人的肺静态压力值。实验结果表明,本文方法在机械通气辅助治疗时可以为医生设置呼吸机参数提供有效的参考依据,同时也为医生进行病理研究、生理研究以及临床诊断等提供了更多的理论支持。如果能够丰富不同的年龄、性别、病情及进展等多种情况的呼吸样本,进一步提高呼吸模型及参数辨识的准确性,将为临床医护人员在机械通气辅助治疗过程中提供极大的方便。

参考文献

- [1] 王华,母得志.新生儿呼吸窘迫综合征的通气策略[J]. 中华妇幼临床医学杂志, 2017,13(1):10-13.
WANG H,MU D ZH.Ventilation strategies of the neonatal respiratory distress syndrome [J]. Chinese Journal of Obstetrics & Gynecology and Pediatrics, 2017, 13(1): 10-13.
- [2] OTIS A B, MEKERROW C B, BARTLETT R A, et al. Mechanical factors in distribution of pulmonary ventilation[J].Journal of Applied Physiology, 1956, 8(4): 427-443.
- [3] MEAD J, WHITTENBERGER J L. Evaluation of airway interruption technique as a method for measuring pulmonary air-flow resistance [J]. Journal of Applied Physiology, 1954,6(7):408-416.
- [4] MOUNT L E. The ventilation flow resistance and compliance of rat lungs [J]. Journal of Applied Physiology, 1955,127(1):157-167.
- [5] LORINO A M, LORINO H, HARF A. A synthesis of the otis, mead, and mount mechanical respiratory models[J]. Respiration Physiology, 1994,97(2):123-133.
- [6] PESLIN R, ROTGER M, FARRE R, et al. Assessment of respiratory pressure-volume nonlinearity in rabbits during mechanical ventilation [J]. Journal of Applied Physiology,1996, 80(5):1637-1648.
- [7] ROUSSELOT J M, PESLIN R, DUVIVIER C. Evaluation of the multiple linear regression method to monitor respiratory mechanics in ventilated neonates and young children [J]. Pediatric Pulmonol, 1992, 13(3): 161-168.
- [8] WENSLEY D F, NOONAN P, SEEAR M D, et al.Pilot study for the development of a monitoring device for ventilated children [J]. Pediatric Pulmonol, 1991, 11(3): 272-279.
- [9] MURAMATSU K, YUKITAKE K, NAKAMURA M, et al. Monitoring of nonlinear respiratory elastance using a multiple linear regression analysis [J]. European Respiratory Journal, 2001,17(6):1158-1166.
- [10] 易伟伟,张纪,王跃科.基于呼吸机的人工呼吸系统力学建模与仿真[J].系统仿真学报,2009,21(15):

- 4892-4895.
- YI W W, ZHANG F, WANG Y K. Mechanics modeling and simulation of artificial respiration system based on ventilator [J]. Journal of System Simulation, 2009, 21(15):4892-4895.
- [11] 刘天亚, 乔惠婷, 李德玉, 等. 非线性气道分级呼吸力学模型及健康成人自主呼吸模拟[J]. 生物医学工程学杂志, 2019, 36(1):101-106.
- LIU T Y, QIAO H T, LI D Y, et al. Simulation of spontaneous breathing for healthy adults using a nonlinear airway segmented model of respiratory mechanics [J]. Journal of Biomedical Engineering, 2019, 36(1):101-106.
- [12] SHUNSHOKU K, MASANORI N. An ant colony optimization method for fuzzy membership functions and its application to estimate the pulmonary elastance[C]. Proceedings of the 32th Chinese Control Conference (CCC 2013), 2013:13886656.
- [13] MASANORI N, SHUNSHOKU K. Estimation of pulmonary elastance by functional type SIRMs fuzzy reasoning method [C]. Proceedings of the 30th Chinese Control Conference (CCC 2011), 2011. DOI:10.1109/ECBS-EERC.2011.41.
- [14] 侯晓旭, 李佳戈, 任海萍. 气道阻力及肺的顺应性对呼吸机压力控制精度的影响[J]. 中国医疗设备, 2018, 33(8):38-41.
- HOU X X, LI J G, REN H P. Effect of airway resistance and lung compliance on the pressure control precision of ventilator [J]. China Medical Devices, 2018, 33(8):38-41.
- [15] 邵昕, 何奎华. 急性呼吸窘迫综合征综合征肺压力-容积曲线及其在通气设置中的应用[J]. 医学综述, 2010, 16(6):915-918.
- SHAO X, HE K H. Application of lung pressure volume curve in mechanical ventilation settings about ARDS [J]. Medical Recapitulate, 2010, 16(6):915-918.
- [16] 王小川, 史峰, 郁磊, 等. MATLAB 神经网络 43 个案例分析[M]. 北京: 北京航空航天大学出版社, 2013.
- WANG X CH, SHI F, YU L, et al. Neural networks 43 case studies based on MATLAB [M]. Beijing: Beihang University Press, 2013.
- [17] 陈明. MATLAB 神经网络原理与实例精解[M]. 北京: 清华大学出版社, 2013.
- CHEN M. Principles and examples of Neural networks based on MATLAB [M]. Beijing: Tsinghua University press, 2013.
- [18] 王慧莹, 吴亮红, 梅盼盼, 等. 果蝇优化广义神经网络的风电功率短期预测 [J]. 电子测量与仪器学报, 2019, 33(6):177-183.
- WANG H Y, WU L H, MEI P P, et al. Fruit fly optimization based generalized regression neural network for wind power short-term prediction [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(6):177-183.
- [19] CHEN Y Q, YUAN Y Y, ZHANG H, et al. Comparison of inspiratory effort, workload and cycling synchronization between non-invasive proportional-assist ventilation and pressure-support ventilation using different models of respiratory mechanics [J]. Medical Science, 2019, 25:9047-9058.
- [20] 李卫硕, 孙剑, 陈伟. 基于 BP 神经网络机器人实时避障算法[J]. 仪器仪表学报, 2019, 40(11):210-211.
- LI W SH, SUN J, CHEN W. Real-time obstacle avoidance algorithm for robots based on BP neural network [J]. Chinese Journal of Scientific Instrument, 2019, 40(11):210-211.

作者简介



张玉欣, 2002 年于长春大学获得学士学位, 2006 年于长春理工大学获得硕士学位, 2011 年于中国科学院长春光学精密机械与物理研究所获得博士学位, 现为北华大学副教授, 主要研究方向为信号处理与系统辨识。

E-mail: zhangyuxin@beihua.edu.cn

Zhang Yuxin received her B. Sc. degree from Changchun University in 2002, received her M. Sc. degree from Changchun University of Science and Technology in 2006, and received her Ph. D. degree from Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences in 2011. She is currently an associate professor at Beihua University. Her

main research interests include signal processing and system identification.



金江春植, 1983 年于大连理工大学获得学士学位, 1992 年于日本九州大学获得硕士学位, 1995 年于日本九州大学获得博士学位, 现为日本纯真学园大学教授, 北华大学柔性引进人才, 主要研究方向为呼吸系统建模与人工呼吸监控系统的分析与开发。

E-mail: kanae.s@junshin-u.ac.jp

Shunshoku Kanae received his B.Sc. degree from Dalian University of Technology in 1988, and received his M.Sc. degree and his Ph.D. degree both from Kyushu University in 1992 and 1995, respectively. He is currently a professor at Junshin Gakuen University. He is flexible introduction of talent at Beihua University. His main research interests include modeling of respiratory system and developing of artificial ventilation system.

白晶 (通信作者), 1987 年于东北大学获得学士学位, 1990 年于东北大学获得硕士学位, 2005 年于北京科技大学获得博士学位, 现为北华大学教授, 主要研究方向为电力电子与电力传动、智能控制。

E-mail: jlbyj@163.com



Bai Jing (Corresponding author) received her B.Sc. degree from Northeastern University in 1987, received her M.Sc. degree from Northeastern University of Science and Technology in 1990, and received her Ph.D. degree from University of Science and Technology Beijing in 2005. She is currently a professor at Beihua University. Her main research interests include power electronics and power transmission, and intelligent control.

周振雄, 1998 年于吉林工业大学获得学

士学位, 2007 年于大连理工大学获得硕士学位, 2013 年于长春理工大学获得博士学位, 现为北华大学电气与信息工程学院教授, 主要研究方向为电力电子技术。

E-mail: zzx701111@126.com



Zhou Zhenxiong received his B.Sc. degree from Jilin University of Technology in 1998, received his M.Sc. degree from Dalian University of Technology in 2007, and received his Ph.D. degree from Changchun University of Science and Technology in 2013. He is currently a professor at Beihua University. His main research interests include power electronics technology.