

## 基于小波支持向量机的小鼠脑电波与呼吸的关系

唐莹莉,何世钧,李煜,谢圣东

上海海洋大学信息学院,上海 201306

**【摘要】目的:**以小鼠为实验对象,利用以Morlet小波支持向量机(Wavelet Support Vector Machine, WSVM)为神经元的神经网络模型研究小鼠的呼吸与脑电波之间的关系。**方法:**本文通过对在小鼠睡眠和清醒状态下测得的呼吸信号进行分析,得出两种状态下呼吸频率范围分别为:1.59 Hz~1.98 Hz、1.75 Hz~2.70 Hz,进而根据呼吸频率范围确定与呼吸有关的脑电波信号的频率段并将其分离出来,建立了以WSVM为神经元的神经网络模型。通过该模型定量分析了小鼠在两种状态下与呼吸相关的脑电波的相位变化率和呼吸频率之间的映射关系,得出该模型的最小留一法(Leave-One-Out, LOO)误差及对分离出的脑电波信号相位变化率的预测的均方误差(Mean Square Error, MSE),并传统以径向基函数为核函数的支持向量机(RBF-SVM)模型的最小LOO误差及预测精度进行对比分析。**结果:**以WSVM为神经元的神经网络模型的最小LOO误差为0.08907,低于RBF-SVM的最小LOO误差0.089272,因此具有更好的泛化性,且前者的预测MSE为0.286658,小于后者的MSE(0.291373)。**结论:**基于WSVM的神经网络在定量描述脑电波与呼吸之间的关系中是一种比较有效的方法,它为解释脑电波与其他复杂动作的关系从而实现人机互动提供了一种机制。

**【关键词】**呼吸频率;脑电波;小波支持向量机

**【中图分类号】**R318

**【文献标识码】**A

**【文章编号】**1005-202X(2015)03-0365-05

## Relationship between electroencephalogram and respiration of mouse based on wavelet support vector machine

TANG Ying-li, HE Shi-jun, LI Yu, XIE Sheng-dong

College of information, Shanghai Ocean University, Shanghai 201306, China

**Abstract: Objective** To study the relationship between Electroencephalogram (EEG) signals and respiration based on wavelet support vector machine (WSVM) taking the mouse as the experimental subject. **Methods** The respiratory signals of mice measured at asleep and awake were analyzed to obtain two kinds of respiratory frequency range which respectively were [1.59Hz, 1.98 Hz], [1.75Hz, 2.70 Hz]. And then the respiration-related EEG signals were filtered out according to the corresponding respiratory frequency. The neural network model based on WSVM was built to quantitatively analyze the relationship between respiratory frequency and respiration-related EEG signals. The model's minimum leave-one-out (LOO) error and mean square error (MSE) of the prediction on the rate of separated EEG signal phase change were obtained and compared with those of support vector machine with Radial Basis Function (RBF-SVM). **Results** The minimum LOO error of model based on WSVM was 0.08907, lesser than that of RBF-SVM which was 0.089272, so the former had a better generalization performance. And the prediction MSE of model based on WSVM was 0.286658, lesser than that of RBF-SVM which was 0.291373. **Conclusion** The neural network model based on WSVM is a more efficient and adaptable approach to quantitatively analyze the relationship between EEG signals and respiration. The model also provides a mechanism to explain the relationship between EEG signals and other complicated movements to realize the human-computer interaction.

**Key words:** respiratory frequency; Electroencephalogram (EEG) signals; wavelet support vector machine (WSVM)

**【收稿日期】**2015-02-08

**【基金项目】**上海市科委科研计划项目(10510502800)

**【作者简介】**唐莹莉(1989-),女,硕士,Tel:18721829025,E-mail: 563-498472@qq.com。

**【通信作者】**何世钧,E-mail: heshijun6@163.com。

中国医学物理学杂志 2015年5月 第32卷 第3期

## 前言

人类脑计划(Human Brain Project, HBP)是继人类基因组计划之后,又一国际性科研计划,其核心是神经信息学(Neuroinformatics)。该研究旨在努力探究数十亿个神经元的信息,以期对知觉、行动以及意

识等有更进一步的了解。大脑意识和神经冲动的基础都是电信号,一旦解释出这些电信号如何精确表达复杂动作,就可以实现人机互动<sup>[1]</sup>。控制某个特定行为或想法的脑电波是一系列众多神经放电的迭加<sup>[2]</sup>,只有将与某些特定行为相关的脑电波信号分离出来才能更好研究脑电波与该行为特征的关系。本文根据小鼠在睡眠和清醒状态下不同的呼吸频率范围,分离出不同频段的与呼吸有关的脑电波信号( $\delta$ 波),并对 $\delta$ 波与呼吸之间的关系进行了定量分析。

由于脑电信号为大脑神经元电活动产生的非平稳信号,结合小波对非平稳信号的逐级精细描述和特征提取的优良特性<sup>[3]</sup>以及脑电信号的生理特性,建立了以WSVM为单神经元的神经网络模型来分析EEG信号和呼吸之间的映射关系。

## 1 脑电波分析与处理

### 1.1 脑电信号描述

本文的实验数据由天津大学提供,数据分别为小鼠在睡眠状态和清醒状态下测得的呼吸曲线及大脑视觉皮层局部电位<sup>[4]</sup>。两种状态下采样频率均为1000 Hz,睡眠状态数据采样时间为20 s,清醒状态数据采样时间为30 s。其中,呼吸信号是通过热敏电极在鼻子附近记录的,用曲线的峰或谷的时间点标记呼吸过程。脑电信号来自小鼠大脑皮层的视觉感受区,5个电极(一排)同时记录,每个电极间距为0.25 mm,从而获得五道小鼠大脑视觉皮层局部电位,本文均用第一道脑电数据(Ch11)进行分析。

### 1.2 脑电波分析

根据呼吸原理,吸气神经元集群同步产生动作电位完成呼吸过程,此动作电位形成相应的脑电波<sup>[5-6]</sup>。因此与呼吸相关的脑电波 $\delta$ 波的具体频率范围 $f_1 \sim f_2$ 与呼吸频率 $f_1 \sim f_2$ 存在对应关系且小鼠的 $\delta$ 波段的须桶皮层神经元振荡和呼吸节律有锁相关系<sup>[7]</sup>。本文做出了小鼠在睡眠和清醒状态下脑电波的频谱图,见图1,实线与虚线分别表示睡眠和清醒状态下的脑电波。从图中可以看出,脑电波信号主要分布在低频段,两种状态下与呼吸相关的脑电波的低频段信号 $\delta$ 波的频率段有差异,于是我们在分离 $\delta$ 波时根据呼吸频率来确定其频段。

### 1.3 脑电波分离

根据小鼠睡眠状态和清醒状态下测得的呼吸曲线得出小鼠的呼吸频率曲线,从而确定小鼠在两种状态下的呼吸频率范围分别为:1.59 Hz~1.98 Hz,




图1 两种状态下小鼠脑电波的频谱图

Fig.1 Brain wave spectrum curves of mice in different states

1.75 Hz~2.70 Hz。在小鼠清醒状态下,将1.75 Hz~2.70 Hz频率段作为滤波器的输入频带分离出 $\delta$ 波,与呼吸曲线进行对比,如图2所示。图2a表示小鼠在清醒状态下的呼吸曲线,两波峰的时间间隔代表一个呼吸周期;图2b中曲线表示通过滤波器分离出来的在清醒状态下与呼吸相关的脑电波信号 $\delta$ 波,折线表示 $\delta$ 波所对应的相位。从图中可以看出 $\delta$ 波的周期与呼吸周期一一对应,且 $\delta$ 波的相位变化率与呼吸周期变化存在映射关系。为了定量分析这种关系,计算出清醒状态下与小鼠呼吸同频的脑电波的相位变化率( $2\pi$ 与 $\delta$ 波的周期长度之比),并与相应状态下的呼吸频率之间存在的映射关系进行了研究。在睡眠状态下,将 $\delta$ 频率段作为滤波器的输入频带,分离出睡眠状态下与小鼠呼吸有关的脑电波 $\delta$ 波,并对此 $\delta$ 波进行和清醒状态下同样的处理。




图2 小鼠清醒状态的呼吸曲线与分离出的 $\delta$ 波

Fig.2 Respiratory curve and  $\delta$  wave of the awake mouse

## 2 模型分析及评价

### 2.1 支持向量机回归原理

支持向量机(Support Vector Machine, SVM)方法是由 Vapnik<sup>[8]</sup>提出的,它在解决小样本、非线性及高维模式识别中表现出许多特有的优势,并具有很好的泛化能力。后来,Vapnik将 $\varepsilon$ 不敏感损失函数引入到SVM中,用于控制回归逼近误差管道的大小,得到了用于非线性回归估计的支持向量回归机,它的基本原理是由非线性变换 $\Phi(x)$ 把输入空间映射到一个高维空间,在高维空间中,对原空间的输入与输出的非线性关系进行描述。对于给定数据样本

$$\{(x_i, y_i), i = 1, \dots, l\} \in (R^n \times Y)^l$$

其中  $x_i \in R^n, y_i \in Y \subset R, l$  为样本个数,  $R^n$  代表输入空间,通过映射  $\Phi$  将  $X$  映射到特征空间中。满足 Mercer 定理的函数都可以作为核函数,其中核函数表示形式为:  $K(x_i, x_j) = \Phi(x_i)^T \Phi(x_j)$ , 常用的核函数是径向基核函数,其表达式为:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2),$$

支持向量机回归的目标就是求下列回归函数:

$$y = f(x, w) = w^T \Phi(x) + b \quad (1)$$

考虑以下最优化问题:

$$\begin{aligned} \min_{w, w_0} & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i + C \sum_{i=1}^l \xi_i^* \\ \text{s.t.} & \begin{cases} w^T \phi(x_i) + b - y_i \leq \varepsilon + \xi_i \\ y_i - w^T \phi(x_i) - b \leq \varepsilon + \xi_i^* \\ \xi_i \geq 0, i = 1, 2, \dots, l \end{cases} \end{aligned} \quad (2)$$

其中  $C$  是惩罚参数,用来控制模型复杂度和逼近误差的折中,  $C$  越大则对数据的拟合程度越高。引入拉格朗日乘子并转换为如下的对偶问题:

$$\begin{aligned} \min & \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j)(x_i \cdot x_j) \\ & \dots + \varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) - \sum_{i=1}^l y_i (\alpha_i^* - \alpha_i) \\ \text{s.t.} & \begin{cases} \sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0 \\ 0 \leq \alpha_i^{(*)} \leq C, i = 1, \dots, l \end{cases} \end{aligned} \quad (3)$$

得解  $\bar{\alpha}^{(*)} = (\bar{\alpha}_1, \bar{\alpha}_1^*, \dots, \bar{\alpha}_l, \bar{\alpha}_l^*)^T$

最终建立的模型形式(决策函数)为:

$$f(x) = \sum_{i=1}^l (\bar{\alpha}_i^* - \bar{\alpha}_i) K(x_i, x) + b \quad (4)$$

### 2.2 模型选择

小波核函数不仅具有核函数的非线性映射的特征,而且也继承了小波对非平稳信号的逐级精细描

述和特征提取的优良特性<sup>[9]</sup>,且 Morlet 小波函数的核函数被证明是满足 Mercer 定理的核函数<sup>[10]</sup>,而脑电信号是非平稳信号<sup>[11]</sup>,因此可采用 Morlet 小波作为核函数的支持向量机,对脑电波信号进行研究。由于研究的是小鼠脑电波与呼吸频率之间的关系,而脑电波是脑神经元的电生理活动在大脑皮层或头皮表面的总体反映。结合生理特性,可以建立以 WSVM 为神经元的神经网络模型,来定量分析脑电波  $\delta$  波的相位变化率与呼吸频率的关系。作为对比,分别使用 RBF-SVM 和 WSVM 作为神经网络的神经元。其中 Morlet 小波核函数的形式如下:

$$K(x_i, x_j) = \cos(1.75 \sqrt{2\gamma} \|x_i - x_j\|) \exp(-\gamma \|x_i - x_j\|^2)$$

泛化能力是评价一个学习机器性能的重要指标,由 SVM 原理知,期望风险最小的 SVM 判别函数会具有最好的泛化能力,但期望风险的值往往不易求得,有人证明了 LOO 误差是期望风险的一个几乎无偏估计<sup>[12]</sup>,因此我们可以用 LOO 误差来估计期望风险,从而判断 SVM 的泛化能力。

为了对 RBF-SVM 和 WSVM 的 LOO 误差进行比较,将小鼠清醒状态下的呼吸频率作为输入变量,  $\delta$  波的相位变化率作为输出变量,针对不同的结构参数  $C$  和  $g$ ,计算得到不同的 LOO 误差,比较两个模型的最小 LOO 误差。其中,  $g$  是核函数参数,对于 Morlet 小波核函数和 RBF 核函数,  $g = \gamma$ 。利用网格法,分别计算出两个不同核函数的 SVM 对应于每一对  $C$  和  $g$  的 LOO 误差( $C, g$  的范围分别设置为  $(-2^8, 2^8)$ ,步长为  $2^{0.8}$ )。并做出相应 3D 视图(图 3 和图 4)。

由图 3、图 4 对比可知,在搜索空间范围内, WSVM 的最小 LOO 误差( $Z=0.089066$ )低于 RBF-SVM 的最小 LOO 误差( $Z=0.089272$ )。为了更好的对比 RBF-SVM 和 WSVM 的 LOO 误差,令 WSVM 中  $g$  为




图3 WSVM的LOO误差

Fig.3 LOO errors of RBF-SVM






图4 RBF-SVM的LOO误差

Fig.4 LOO errors of WSVM

27.857 6(WSVM具有最小误差时, $g$ 的取值),RBF-SVM中 $g$ 为3.031 4(RBF-SVM具有最小误差时, $g$ 的取值),分别沿着 $C$ 值的变动,做出LOO误差曲线图,如图5所示。




图5 WSVM与RBF-SVM LOO误差对比

Fig.5 Comparison curves of LOO errors of different models of prediction

从图5可以很直观地看出,WSVM最小LOO误差小于RBF-SVM的最小LOO误差。由于LOO误差是期望风险的一个几乎无偏估计,于是Morlet-SVM的期望风险低于RBF-SVM的期望风险,从而Morlet-SVM具有较好的泛化性能。

### 2.3 模型建立与评价

为了定量分析小鼠呼吸与脑电波之间的关系,取出小鼠清醒状态下前40个呼吸周期相应的频率作为训练集的输入变量, $\delta$ 波相位变化率的前40个数据作为训练集输出变量,其余25个数据分别作为相应

的测试集。分别使用RBF-SVM和WSVM,利用5折交叉验证法对其进行参数寻优<sup>[13]</sup>,得出WSVM最优参数结果为: $C=0.574\ 35$ , $g=48.502\ 9$ 。利用训练出的模型对测试集进行了预测,WSVM预测出的 $\delta$ 波相位变化率与原始相位的变化率如图6所示。得到的预测值与真实值的均方误差 $MSE=0.286\ 658$ 。同样,RBF-SVM的5折寻优结果为 $C=1.741\ 1$ , $g=84.448\ 5$ ,其预测结果均方误差 $MSE=0.291\ 373$ ,大于WSVM的预测误差。可以看出,清醒状态下, $\delta$ 波相位变化率与呼吸频率关系的描述中,WSVM较传统的RBF-SVM具有更好的预测能力,从而更进一步验证了WSVM具有较好的泛化性能。




图6 WSVM预测值与实际值的比较

Fig.6 The WSVM model prediction results

利用WSVM建立小鼠睡眠状态下与呼吸相关的脑电波和呼吸频率的映射关系。取前20个数据作为训练集,余下13个数据作为测试集。取 $C=0.574\ 35$ , $g=84.448\ 5$ 训练出相应的模型,并对测试集进行预测,预测值与真实值的均方误差为 $MSE=0.016\ 898\ 6$ 。与小鼠清醒状态下的预测均方误差相比,睡眠状态下,均方误差明显小于清醒状态下。产生此现象的原因是,清醒状态下与呼吸有关的脑电波不仅包含低频段的 $\delta$ 分波,还包含高频段的脑电波分波<sup>[2]</sup>。这在从图1可以看出,清醒状态下脑电波曲线(虚线)在高频段有一个跃迁,这说明与呼吸有关的脑电波不仅包含低频段的 $\delta$ 分波,还包含高频段的脑电波分波,而睡眠状态下与呼吸有关的脑电波仅包含低频段的 $\delta$ 分波。在小鼠清醒状态下,我们只建立了呼吸频率与脑电波的 $\delta$ 分波的关系,故而预测精度较睡眠状态下的预测精度低。

### 3 结论

本文根据小鼠呼吸频率分离出了与呼吸相关的脑电波 $\delta$ 分波,利用以WSVM为神经元的神经网络模型,对小鼠的呼吸频率及滤出的脑电波的相关性进行了定量分析。与传统的RBF-SVM模型在泛化性能上进行了对比分析,发现基于WSVM的神经网络模型的泛化性能明显优于RBF-SVM,并进一步利用两个模型对与呼吸相关的 $\delta$ 波相位变化率进行了预测,结果显示WSVM为神经元的神经网络模型的MSE优于RBF-SVM模型。这表明WSVM为神经元的神经网络模型能很好地量化脑电波与呼吸或其他动作之间的映射关系,因此可以利用WSVM来解释出脑电波与复杂动作的关系,从而实现人机互动。

#### 【参考文献】

- [1] Timofeev I, Chauvette S. Thalamocortical oscillations: local control of EEG slow waves[J]. Curr Top Med Chem, 2011, 11(19): 2457-2471.
- [2] Buzsaki G. Rhythms of the brain[M]. New York: Oxford University Press, 2006: 81-100.
- [3] Zhang Q, Benveniste A. Wavelet networks[J]. IEEE Trans Neural Networks, 1992, 3(6): 889-898.
- [4] <http://gmcm.seu.edu.cn/6/list.htm>[EB/OL].
- [5] Albera L. Brain source localization using a fourth-order deflation scheme[J]. IEEE Trans Biom Eng, 2008, 55(2): 490-501.
- [6] Wang H, Tomikawa M, Jones MK, et al. Sequential expression of adrenomedullin and its receptor during gastric ulcer healing in rats [J]. Dig Dis Sci, 2000, 45(3): 591-598.
- [7] Ito J, Roy S, Liu Y, et al. Whisker barrel cortex delta oscillations and gamma power in the awake mouse are linked to respiration[J]. Nat Commun, 2014, 5: 3572.
- [8] Vapnik V. The Nature of Statistics Learning Theory[M]. New York: Springer Verlag, 1995: 18-21.
- [9] 陈仲英, 巫斌. 小波分析[M]. 北京: 科学出版社, 2007: 96-97.  
Chen ZY, Wu B. The wavelet ananlysis[M]. Beijing: Science Press, 2007: 96-97.
- [10] Zhan L, Zhou W, Jiao L. Wavelet support vector machine[J]. IEEE Trans Systems Man Cybernet, 2004, 34(1): 34-39.
- [11] Xu WL, Huang JX, Shen MF. Analysis of the EEG in schizophrenia based on wavelet packet decomposition[J]. Electr Meas Instr, 2004, 18(2): 35-40.
- [12] Joachims T. Estimating the generalization performance of a SVM efficiently [D]. Dortmund: University Dortmund, 2000.
- [13] 邓乃扬. 支持向量机—理论、算法与拓展[M]. 北京: 科学出版社, 2009: 152-154.  
Deng NY. SVM the-oryalgorithm and expand[M]. Beijing: Science Press, 2009: 152-154.