

# 基于序列连通度的睡眠分期算法研究

刘志勇, 孙金玮

(哈尔滨工业大学电气工程及自动化学院, 黑龙江哈尔滨 150001)

**摘 要:** 准确的睡眠分期有利于帮助人们改善睡眠质量. 本文提出了一种基于序列连通度分析的特征参数提取算法, 提取了连通度分布斜率, 连通距离均值, 平均连通距离均值以及改进的加权连通度均值等特征参数, 采用最小二乘支持向量机对其进行训练和学习, 建立了睡眠脑电的数学模型. 结果表明, 相对于目前已有的序列加权连通度算法, 本文算法对于不同睡眠状态的分期正确率提高了约 5.72%, 特别是对于浅睡眠状态的分类正确率提高约 9.65%.

**关键词:** 脑电信号; 序列连通度; 最小二乘支持向量机

**中图分类号:** R318      **文献标识码:** A      **文章编号:** 0372-2112 (2017)01-0225-07

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2017.01.031

## Sleep Staging from the Visibility Graph Algorithm of Series

LIU Zhi-yong, SUN Jin-wei

(Harbin Institute of Technology, School of Electrical Engineering and Automatic, Harbin, Heilongjiang 150001, China)

**Abstract:** Monitoring the sleep quality accurately can play an effective supporting role in helping people improve the quality of sleep. In the present study, a novel feature extraction algorithm is proposed based on the natural visibility graph and horizontal visibility graph methods. The slope of visibility degree distribution, the mean of visibility distance, the mean of averaged visibility distance and the mean of improved weighted visibility graph were extracted, and trained by the least square-support vector machines (LS-SVM) classifier. The mathematical model between electroencephalogram (EEG) and sleep state was established and verified by different samples. The results demonstrated that the classification accuracy of different states improved about 5.72% compared to the existing weighted visibility graph, the classification accuracy of shallow sleep states improved about 9.65%.

**Key words:** EEG (Electroencephalogram); visibility graph; LS-SVM (Least square-support vector machines)

## 1 引言

睡眠与人类健康息息相关<sup>[1]</sup>. 有效的睡眠监测能够帮助人们改善不良的睡眠状况. 彭振等采用脑电信号 (Electroencephalogram, EEG) 的奇异值第一主成分, 结合支持向量机 (Support Vector Machines, SVM) 进行了睡眠分期的研究, 准确率达到 84.40%<sup>[2]</sup>. 王歆媛等通过 EEG 的复杂度和近似熵以及 SVM 实现了睡眠的自动分期, 准确率达 85.67%<sup>[3]</sup>. 江朝晖等研究了心率变异与睡眠的关系, 实现了多参数综合睡眠分期<sup>[4]</sup>. 马千里等通过 EEG 的非线性, 采用多重分形算法实现了对 MIT-BIH 睡眠数据库中 slp01 号样本的睡眠状态拟合<sup>[5]</sup>. Syed 等提出了基于 8-16Hz 频带边缘频率的 EEG

特征提取算法<sup>[6]</sup>.

序列连通度是由 Lucas 等人于 2008 年提出的用于分析时间序列复杂性的一种新算法<sup>[7]</sup>. 该算法采用序列中各点间的连通关系及统计特性作为序列的特征参数. 随后, Lucas 等又提出了水平连通度分析方法, 并应用于混沌序列分析<sup>[8]</sup>. Zhu 等将平均相位锁定法与序列连通度方法相结合用于睡眠分期, 准确率达 86.7%<sup>[9,10]</sup>. 同时, Zhu 等还提出了快速加权水平连通度算法, 可以准确地识别发作期癫痫 EEG 与正常 EEG<sup>[11]</sup>. Bezsudnov 等以连通角度为阈值, 提出了参数化的自然连通度算法<sup>[12]</sup>. Shiyu 等提出了一种基于自然连通度的平均聚合算子<sup>[13]</sup>.

收稿日期: 2015-07-21; 修回日期: 2015-10-21; 责任编辑: 马兰英

基金项目: 哈尔滨工业大学理工医交叉学科基础研究培育计划 (No. HIT-IBRSEM.2013005); 哈尔滨市科技创新人才研究专项资金 (No. 2015RAXXJ038)

## 2 MIT-BIH 多导睡眠数据库

本文以 MIT-BIH 多导睡眠数据库为分析对象. 该数据库共包含 18 组来自 16 位不同实验者的有效睡眠样本. 所有实验者均为男性, 年龄从 32 到 56 岁, 平均年龄为 43 岁, 体重分布为 89 到 152 千克, 平均体重 119 千克<sup>[14]</sup>. 表 1 列出了其中最具有代表性的 6 组样本, 每个样本均包含了所有的睡眠状态. 睡眠状态包括: 清醒状态(W), 睡眠 1 期(S1), 快速眼动期(R), 睡眠 2 期(S2), 睡眠 3 期(S3) 和睡眠 4 期(S4). 分别用 0~5 表示, 数值越大表示睡眠越深.

表 1 MIT-BIH 多导睡眠数据库数据

样本序号	参考电压(mv)	电极位置	采集时间(h)
slp01	-6430	C4 - A1	5:00
slp02	-8300	O2 - A1	5:15
slp14	9310	C3 - O1	6:00
slp16	-13215.4	C3 - O1	6:00
slp45	-9653.33	C3 - O1	6:20
slp59	6284.92	C3 - O1	4:00

## 3 序列连通度睡眠分期算法

图 1 为序列连通度睡眠分期算法框图. 通过对 EEG 序列进行连通度分析, 提取了  $NVG(s_1, s_2, s_3, s_4)$  和  $HVG(s_1, s_2, s_3, s_4)$  等 8 个特征参数, 采用最小二乘支持向量机(LS-SVM)对其进行分类识别.




图 1 序列连通度睡眠分期算法框图

### 3.1 自然连通度算法

对于等间隔时间序列  $x(n), n = 1, 2, \dots, N$  中任意不相邻的点  $x(a)$  和  $x(b), a < b$ . 若  $a$  与  $b$  间任意点  $c$  均满足(1), 则称  $x(a)$  和  $x(b)$  为一组连通点,  $b - a$  为连通距离.

$$\frac{x(b) - x(c)}{b - c} > \frac{x(b) - x(a)}{b - a} \quad (1)$$

对于点  $x(n)$ , 其连通点数量总和称为该点的自然连通度  $NV(n)$ , 其连通距离总和为该点的自然连通距离  $ND(n)$ , 平均自然连通距离定义为,  $NMD(n) = ND(n)/NV(n)$ . 如图 2 所示时间序列  $[0.66, 0.52, 0.97, 0.65, 0.80, 0.45, 0.33, 0.90, 0.08, 0.13]$ . 该序列自然连通度为:  $[2, 2, 5, 2, 5, 3, 3, 6, 2, 2]$ , 概率分布为:  $[0,$

$0, 5/10, 2/10, 0, 2/10, 1/10]$ . 以  $x(5) = 0.80$  为例, 其自然连通度为 5, 自然连通距离为 9, 平均自然连通距离为  $9/5 = 1.8$ . 所有点的  $ND(n)$  均值即为  $NVG(s_2)$ , 所有点的  $NMD(n)$  均值即为  $NVG(s_3)$ .




图 2 自然连通度算法示例

### 3.2 水平连通度算法

对于等间隔时间序列  $x(n), n = 1, 2, \dots, N$  中任意不相邻的点  $x(a)$  和  $x(b), a < b$ , 若  $a$  与  $b$  间任意点  $c$  均满足(2), 则称  $x(a)$  和  $x(b)$  为一组连通点,  $b - a$  为连通距离.

$$x(a) > x(c), \&, x(b) > x(c) \quad (2)$$

对于点  $x(n)$ , 其连通点数量总和称为该点的水平连通度  $HV(n)$ , 其连通距离总和为该点的水平连通距离  $HD(n)$ , 平均水平连通距离定义为,  $HMD(n) = HD(n)/HV(n)$ . 图 3 中序列与图 2 为同一序列, 该序列水平连通度为:  $[2, 2, 5, 2, 4, 3, 2, 6, 2, 2]$ , 概率分布为:  $[0, 0, 6/10, 1/10, 1/10, 1/10, 1/10]$ . 仍以  $x(5) = 0.80$  为例, 其水平连通度为 4, 水平连通距离为 7, 平均水平连通距离为  $7/4 = 1.75$ . 所有点的  $HD(n)$  均值即为  $HVG(s_2)$ , 所有点的  $HMD(n)$  均值即为  $HVG(s_3)$ . 如图 4 所示, 当序列为单调序列时, 除端点外, 每个点的水平连通度都为 2, 不能反映任何有价值的信息.




图 3 水平连通度算法示例

### 3.3 改进的加权连通度均值

文献[8]中所提水平连通度算法中, 连通点之间的权值均为 1. 文献[11]提出式(3)所示的加权的水平连通度算法. 以图 2 中  $x(6), x(7)$  和  $x(8)$  为例, 如图 5 所




图4 水平连通度算法用于单调序列

示.  $x(6)$  与  $x(7)$ ,  $x(6)$  与  $x(8)$  为两组水平连通点. 按式(3)所示,  $|x_i - x_k| (i - k)$  即为图 5 中以  $ABCD$  为顶点的矩形面积.

$$\hat{w}_{i,k} = 1 + |(x_i - x_k)(i - k)| \quad (3)$$




图5 加权连通度算法示意图

本文在式(3)的基础上提出了改进的权值公式,如式(4)所示. 以  $\angle BDC$  的正切值作为权值代替矩形  $ABCD$  的面积. 当  $\angle BDC > 0$  时,  $x(6) < x(8)$ , 当  $\angle BDC < 0$  时,  $x(6) > x(8)$ . 改进后的权值公式, 不仅能够反映  $x(6)$  与  $x(8)$  数值绝对值之间的差异, 而且能够反映二者的大小关系.

$$w_{i,k} = 1 + (x_i - x_k)/(i - k) \quad (4)$$

### 3.4 分类器

最小二乘支持向量机 (LS-SVM) 采用最小二乘线性系统作为损失函数, 通过解一组线性方程降低了训练时间及复杂度, 提高了泛化能力. 采用 LS-SVM 进行睡眠分期, 首先通过马氏距离剔除界外样本. 马氏距离计算公式如(5)所示<sup>[15]</sup>.

$$MD_i = (t - \bar{t}) \cdot (\mathbf{T}_{cen}^T \cdot \mathbf{T}_{cen})^{-1} (t - \bar{t})^T \quad (5)$$

其中,  $MD_i$  为第  $i$  个样本的马氏距离,  $\mathbf{T}_{cen}$  为均值中心化的样本矩阵.

### 3.5 分类结果评价

采用式(6)所示分类正确率 (Accuracy percent, AP) 对结果进行评价, 并将分类结果与参考状态进行相关性检验, 相关系数的计算公式如(7)所示.

$$AP = \frac{NA}{N} \times 100\% \quad (6)$$

其中,  $N$  为样本数量,  $NA$  为分类结果与参考结果误差小

于 0.5 的样本数量.

$$r = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{\sqrt{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \sqrt{n \sum_{i=1}^n y_i^2 - (\sum_{i=1}^n y_i)^2}} \quad (7)$$

## 4 结果与分析

### 4.1 连通度分布

MIT-BIH 数据库中, EEG 采样率为 250Hz, 每 30s 给出一个参考睡眠状态. 首先, 以 7500 为分段长度对每个样本 EEG 进行分段. 其次, 在每个区间上进行连通度的相关计算. 图 6 为 slp01 样本某段 30s EEG. 对其进行自然连通度和水平连通度分析, 其 NV 和 HV 的概率分布如图 7 和 8 所示.

图 7 中, 当点数为 20 ~ 50 时,  $P(NV)$  与  $NV$  的对数曲线呈现较好的线性特征. 图 8 中,  $P(HV)$  在 5 ~ 15 时呈现较好的线性特征. 实验表明, 各睡眠状态的 EEG 在此两个区间均呈现出较好的线性特征. 因此, 本文以 20 ~ 50 点的  $P(NV)$  区间斜率为  $NVG(s1)$ , 以 5 ~ 15 点的  $P(HV)$  区间斜率为  $HVG(s1)$ .





图6 一段 30s 的清醒 EEG 数据

图7  $P(NV)$  分布图

### 4.2 特征参数提取

#### 4.2.1 改进的加权连通度均值

式(3)和(4)所示两种方法所提取的特征参数分别用  $NVG(\hat{s}4)$ ,  $HVG(\hat{s}4)$  和  $NVG(s4)$ ,  $HVG(s4)$  表示. 表 2 为两种方法所得特征参数与睡眠状态的相关系数.

由表 2 可知, 改进权值计算公式后所提取的特征参数与睡眠参考状态的相关性比改进前更强. 其中, 六组




图8  $P(HV)$ 分布图

样本改进权值后的自然连通度特征参数与睡眠状态的相关系数均值提高了约 7.67%，水平连通度特征参数与睡眠状态的相关系数均值提高了约 5.50%。

### 4.2.2 特征参数对比

slp01 样本的  $NVG(s1, s2, s3, s4)$  和  $HVG(s1, s2, s3, s4)$  等 8 个特征参数与参考睡眠状态的相关系数如表 3 所示,其中各参数的分布情况如图 9 所示。

表 2 两种权值算法所提取特征参数与参考状态相关系数  $r$  对比

样本序号	自然连通度		水平连通度	
	$r[NVG(s4)]$	$r[NVG(s4)]$	$r[HVG(s4)]$	$r[HVG(s4)]$
slp01	0.78	0.86	-0.80	-0.86
slp02	0.48	0.56	-0.56	-0.57
slp14	0.50	0.62	-0.57	-0.68
slp16	0.49	0.54	-0.53	-0.59
slp45	0.66	0.69	-0.54	-0.59
slp59	0.71	0.81	-0.76	-0.80

表 3 slp01 样本  $NVG(s1, s2, s3, s4)$  和  $HVG(s1, s2, s3, s4)$  参数与参考状态相关系数

特征参数	$NVG(s1)$	$NVG(s2)$	$NVG(s3)$	$NVG(s4)$	$HVG(s1)$	$HVG(s2)$	$HVG(s3)$	$HVG(s4)$
相关系数 $r$	0.65	0.82	0.85	0.86	-0.77	0.76	0.79	-0.86

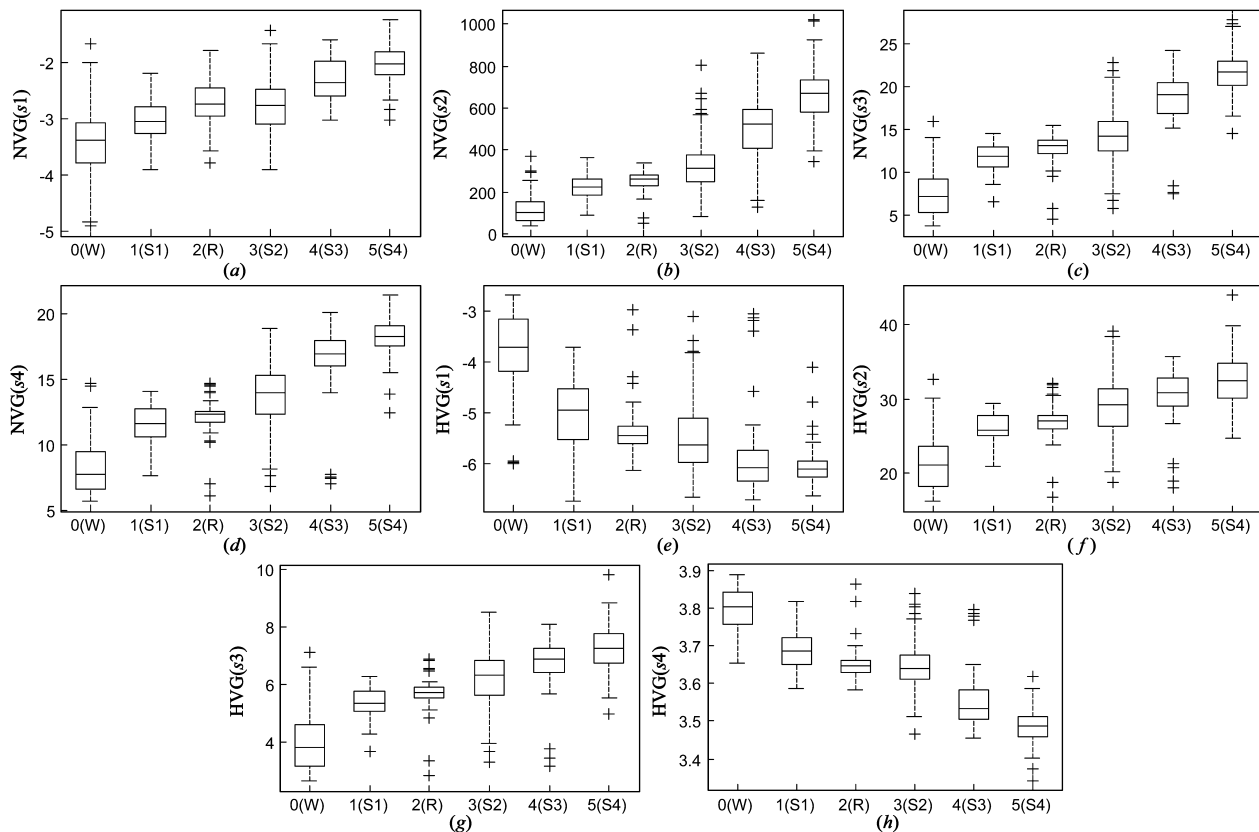


图9 slp01样本 $NVG(s1, s2, s3, s4)$ 和 $HVG(s1, s2, s3, s4)$ 参数分布图

由表 3 和图 9 可知,  $NVG(s1, s2, s3, s4)$  以及  $HVG(s2, s3)$  等 6 个参数与睡眠状态正相关,随着睡眠深度的增加,各参数的均值也逐渐增加.相反,  $HVG(s1, s4)$  与睡眠状态呈现负相关的特点,在深度睡眠时,其特征参数值也降至最低。

### 4.3 分类效果对比

本文设计了如下 6 组特征参数,分别采用 LS-SVM 分类器对其进行分类识别.6 组特征参数分别为:(1) EEG 中  $\delta, \theta, \alpha$  和  $\beta$  波的频带能量比;(2)非线性特征参数中的 L-Z 复杂度;(3)文献[7]和文献[8]所示原始自

然连通度和水平连通度分布,即  $NVG(s1)$  和  $HVG(s1)$ ; (4)未加入权值的序列连通度分布,连通距离均值以及平均连通距离均值,即  $NVG(s1, s2, s3)$  和  $HVG(s1, s2, s3)$ ; (5)在实验(4)的基础上增加文献[11]所提出的权值修正特征参数,即  $NVG(s1, s2, s3, \hat{s}_4)$  和  $HVG(s1, s2, s3, \hat{s}_4)$ ; (6)在实验(4)的基础上增加本文所提改进的权值修正特征参数,即  $NVG(s1, s2, s3, s4)$  和  $HVG$

$(s1, s2, s3, s4)$ . 表4为 slp01 样本6种对比实验的分类结果. 其中,  $r$  为相关系数,  $p$  为其显著性检验值. slp01 样本共包含600组数据,其中W期187组,S1期28组,R期38组,S2期234组,S3期47组,S4期66组. 通过马氏距离共剔除界外样本33组,其中,W期4组,S1期1组,R期1组,S2期4组,S3期5组,S4期18组.

表4 slp01 样本采用不同实验方法结合 LS-SVM 的分类正确率

序号	AP(%)	W(%)	S1(%)	R(%)	S2(%)	S3(%)	S4(%)	$r$	$p$
(1)	79.37	80.33	51.86	78.38	83.04	88.10	66.67	0.90	<0.01
(2)	77.95	74.32	62.96	64.86	80.87	83.33	91.67	0.88	<0.01
(3)	65.26	68.85	51.85	51.35	67.83	78.57	45.83	0.87	<0.01
(4)	82.36	84.15	51.85	86.49	85.22	78.57	72.92	0.89	<0.01
(5)	87.65	85.25	77.78	86.49	89.57	88.10	93.75	0.91	<0.01
(6)	92.77	93.99	88.89	89.19	94.35	83.33	93.75	0.92	<0.01

其中,实验(5)和实验(6)的分类结果明显优于其他四组实验. 因此本文重点对比了第5组和第6组特征参数的分类效果. 表5和表6为以 slp01 样本为建模样

本,分别采用第5组合第6组特征参数对其他5组样本进行交叉验证的结果.

表5 采用第5组特征参数的样本交叉验证分类正确率

	slp02		slp14		slp16		slp45		slp59	
	数量	正确率(%)	数量	正确率(%)	数量	正确率(%)	数量	正确率(%)	数量	正确率(%)
总体	630	71.58	714	76.19	694	80.84	760	81.18	458	71.62
W	151	79.47	321	78.19	316	84.81	119	78.99	140	78.57
S1	32	31.25	188	69.15	108	67.59	54	72.22	105	65.71
R	106	70.75	36	69.44	65	61.54	81	75.31	35	80.00
S2	334	72.16	127	86.61	181	88.40	403	89.58	98	60.20
S3	5	60.00	30	73.33	22	81.82	51	56.86	50	76.00
S4	2	100.00	12	50.00	2	100.00	52	63.46	32	75.00
$r$	0.82		0.82		0.85		0.87		0.82	
$p$	<0.05		<0.05		<0.05		<0.05		<0.05	



表6 采用第6组特征参数的样本交叉验证分类正确率

	slp02		slp14		slp16		slp45		slp59	
	数量	正确率(%)	数量	正确率(%)	数量	正确率(%)	数量	正确率(%)	数量	正确率(%)
总体	630	81.75	714	82.77	694	84.58	760	83.16	458	77.73
W	151	86.75	321	88.16	316	91.46	119	89.08	140	90.71
S1	32	56.25	188	79.79	108	78.70	54	79.63	105	80.95
R	106	84.91	36	72.22	65	72.31	81	80.25	35	71.43
S2	334	81.14	127	82.68	181	83.98	403	87.59	98	58.16
S3	5	80.00	30	66.67	22	59.09	51	62.75	50	80.00
S4	2	50.00	12	58.33	2	50.00	52	63.46	32	68.75
$r$	0.86		0.86		0.89		0.88		0.83	
$p$	<0.05		<0.05		<0.05		<0.05		<0.05	

## 5 讨论

序列连通度应用于睡眠 EEG 时,其分布呈分段线性特征. 图7中,点数为20~50的自然连通度分布与点数为5~15时的水平连通度分布,能够较好的区分不同的睡眠状态. 图9(a)和9(e)中,  $NVG(s1)$  和  $HVG(s1)$

在S1期,R期和S2期的分布重叠较多.  $NVG(s2, s3)$  和  $HVG(s2, s3)$  相比于  $NVG(s1)$  和  $HVG(s1)$ ,在与参考状态的相关性上有了显著提高.  $NVG(s1)$  与参考状态的相关系数仅为0.65,  $NVG(s2, s3)$  与参考状态的相关系数分别为0.82和0.85. 且 slp01 样本采用  $NVG(s1, s2, s3)$  和  $HVG(s1, s2, s3)$  的分类正确率比  $NVG(s1)$  和

图10 NVG( $s_4$ )分布图11 HVG( $s_4$ )分布

HVG( $s_1$ )提高了 17.10%.

由表 2 可知,改进权值公式后,NVG( $s_4$ )和 HVG( $s_4$ )与睡眠状态的相关性比 NVG( $\hat{s}_4$ )和 HVG( $\hat{s}_4$ )提高较为明显.图 9(d)和图 9(h)中的 NVG( $s_4$ )和 HVG( $s_4$ )相对于图 10 和图 11 中的 NVG( $\hat{s}_4$ )和 HVG( $\hat{s}_4$ ),在 S1 期,R 期和 S2 期的重叠度明显下降.表 4 中实验(1)和实验(2),EEG 的频域参数以及非线性参数的准确率分别为 79.37% 和 77.95%,在显著性  $p$  值小于 0.01 时,相关系数分别为 0.90 和 0.88,证明了 EEG 频域参数和非线性参数的有效性.实验(3)基于 NVG( $s_1$ )和 HVG( $s_1$ )特征参数的分类效果较差,准确率只有 65.26%.实验(4)中通过加入序列的连通距离均值,平均连通距离均值等特征参数,使得分类准确率上升至 82.36%.实验(5)和实验(6)在实验(4)的基础上增加了权值修正的序列连通度均值特征参数,分类正确率分别为 87.65% 和 92.77%.

表 5 和表 6 中,分类结果的相关系数均高于 0.80,其显著性  $p$  值均小于 0.05.充分证明了此两种特征参数结合 LS-SVM 的交叉验证分类结果与参考状态相关性较强,结果可信度较高.表 6 中,5 个样本 W 期,S1 期以及 R 期等三个睡眠阶段的总体分类正确率比表 5 平均提高了约 9.65%.总体分类正确率差别最大的为 slp02 样本的 10.17%,差别最小的为 slp45 样本的 1.98%.5 个样本的总体正确率差别平均约为 5.72%.

当序列较长时,判断两点之间是否连通,需要判断二者之间所有点是否满足式(1)或式(2).以图 6 中

EEG 为例,计算该序列的自然连通度耗时约 5.28s,水平连通度耗时约 1.15s.由图 7 和图 8 可知,序列自然连通度最大不超过 300,水平连通度最大不超过 40.因此对距离 1000 以内的点计算自然连通度时,对距离 100 以内的点计算水平连通度可提高计算速度而不影响准确度.加窗后,计算图 6 中信号自然连通度耗时约为 1.10s,水平连通度耗时约为 0.27s,运算时间分别缩短 79.17% 和 76.52%.

针对文献[7]所提连通度算法缺乏方向性的问题.本文随机选取 slp01 样本某段 30s EEG,分别计算每秒内 EEG 序列的总体,前向(即向右)以及后向(即向左)自然连通度之和,结果如图 12 所示.30s 内,序列的总体自然连通度与前向、后向自然连通度的变化趋势完全一致,且前向和后向的自然连通度总和均为总体自然连通度总和的一半.因此,在计算序列整体自然连通度时,可以用单向的自然连通度代替总体的自然连通度,并不影响序列的整体变化趋势.另外,序列的水平连通度也有同样的结论,如图 13 所示.




图12 序列自然连通度优化结果对比




图13 序列水平连通度优化结果对比

## 6 结论

本文提出的基于序列连通度分布,连通距离均值,平均连通距离均值以及改进的加权连通度均值结合 LS-SVM 分类器进行睡眠分期的算法,实现了对 MIT-BIH 多导睡眠数据库中 6 个代表性样本的睡眠分期建模.结果表明,相对于已有的序列加权连通度算法,本

文所提取的 NVG( $s_1, s_2, s_3, s_4$ ) 和 HVG( $s_1, s_2, s_3, s_4$ ) 对不同睡眠状态的分期正确率提高了约 5.72%, 特别是对浅睡眠状态的分类正确率提高了约 9.65%。最后, 本文还对序列连通度算法进行了优化, 提高了计算速度。下一步作者的主要研究内容将围绕以下三个方面展开: (1) 针对序列连通度算法的抗干扰, 抗噪声能力进行深入的研究; (2) 探索新的加权方式或新的特征提取算法; (3) 脑电信号包含了几乎所有与大脑相关的生理和病理信息, 仅采用单一分析域的算法势必不能充分提取其中所包含的有价值信息。探索结合现代信号处理技术的多元化特征参数联合提取算法进行睡眠分期研究也是非常必要的。

### 参考文献

- [1] 于立群, 高小榕, 刘伟国, 等. 基于脑电的睡眠与麻醉中失觉醒脑状态分析[J]. 清华大学学报(自然科学版), 2009, 49(2): 2013–2016.  
YU Liqun, GAO Xiaorong, LIU Weiguo, et al. EEG-based cerebral state analysis of loss of wakefulness during sleep and anaesthesia[J]. Journal of Tsinghua University(Science and Technology), 2009, 49(2): 2013–2016. (in Chinese)
- [2] 彭振, 等. 基于奇异值第一主成分的睡眠脑电分期方法研究[J]. 现代生物医学进展, 2014, 14(07): 1368–1372.  
PENG Zhen, et al. Study of sleep EEG staging method based on the first principal component of singular value[J]. Progress in Modern Biomedicine, 2014, 14(07): 1368–1372. (in Chinese)
- [3] 王歆媛, 汪丰. 基于 EEG 复杂度和近似熵的睡眠自动分期[J]. 软件, 2013, 34(02): 97–100.  
WANG Xinyuan, WANG Feng. Auto classification for sleep stage based on complexity and approximate entropy of EEG[J]. Software, 2013, 34(02): 97–100. (in Chinese)
- [4] 江朝晖, 李继伟, 冯焕清, 等. R-R 间期分析与睡眠分期[J]. 生物医学工程研究, 2003, 22(03): 17–20.  
JIANG Zhaohui, LI Jiwei, FENG Huanqing, et al. R-R intervals analysis and sleep scoring[J]. Journal of Biomedical Engineering Research, 2003, 22(03): 17–20. (in Chinese)
- [5] 马千里, 等. 脑电信号的标度分析及其在睡眠状态区分中的应用[J]. 物理学报, 2010, 59(7): 4480–4484.  
MA Qianli, et al. Scaling analysis on electroencephalogram and its application to sleep-staging[J]. Acta Physica Sinica, 2010, 59(7): 4480–4484. (in Chinese)
- [6] S A Imtiaz, R V Esther. A low computational cost algorithm for REM sleep detection using single channel EEG[J]. Annals of Biomedical Engineering, 2014, 42(11): 2344–2359.
- [7] L Lucas, B Luque, F Ballesteros, et al. From time series to complex networks; the visibility graph[J]. Proceedings of the National Academy of Sciences of the United States of America, 2008, 105(13): 4972–4975.
- [8] B Luque, L Lacasa, F Ballesteros, et al. Horizontal visibility graphs: exact results for random time series[J]. Physical Review E, 2009, 80(046103): 1–11.
- [9] G Zhu, Y Li, P P Wen. An efficient visibility graph similarity algorithm and its application on sleep stages classification[J]. Lecture Notes in Computer Science, 2012, 7670(1): 185–195.
- [10] G Zhu, Y Li, P P Wen. Analysis and classification of sleep stages based on difference visibility graphs from a single-channel EEG signal[J]. IEEE Journal of Biomedical and Health Informatics, 2014, 18(6): 1813–1821.
- [11] G Zhu, Y Li, P P Wen. Epileptic seizure detection in EEGs signals using a fast weighted horizontal visibility algorithm[J]. Computer Methods and Programs in Biomedicine, 2014, 115(2): 64–75.
- [12] I V Bezudnov, A A Snarskii. From the time series to the complex networks; the parametric natural visibility graph[J]. Physica A, 2014, 414(1): 53–60.
- [13] S Chen, et al. A visibility graph averaging aggregation operator[J]. Physica A, 2014, 403(1): 1–12.
- [14] Y Ichimaru, G B Moody. Development of the polysomnographic database on CD-ROM[J]. Psychiatry and Clinical Neurosciences, 1999, 53(2): 175–177.
- [15] J M M Montiel, L Montano. Efficient validation of matching hypotheses using Mahalanobis distance[J]. Engineering Applications of Artificial Intelligence, 1998, 11(3): 439–448.

### 作者简介



刘志勇 男, 1987 年 1 月出生, 河南延津人. 61135 部队助理工程师. 哈尔滨工业大学电气学院在读博士研究生, 研究方向为生物医学信号处理.  
E-mail: liuzhiyong563@hit.edu.cn



孙金玮(通信作者) 男, 1964 年 10 月出生, 黑龙江哈尔滨人. 哈尔滨工业大学电气学院教授, 博士生导师. 主要研究方向为: 生体与环境信息测量技术, 主动噪声控制技术.  
E-mail: jwsun@hit.edu.cn