基于奇异谱分析方法的孤独症儿童脑电信号特征提取及分类

赵杰¹, 宋佳佳¹, 陈贺², 李小俚², 康健楠^{1*}

1. 河北大学电子信息工程学院, 保定 071000;

2. 北京师范大学认知神经科学与学习国家重点实验室, 北京 100875

* 联系人, E-mail: kangjiannan81@163.com

2018-11-02 收稿, 2018-12-05 修回, 2018-12-05 接受, 2019-02-01 网络版发表

国家自然科学基金(61761166003)资助

摘要 孤独症谱系障碍是一种复杂的神经发育障碍, 其早期发现和精确诊断非常重要. 脑电图由于其具有较高的时间分辨率, 是一种常用的神经成像技术. 本文提出奇异谱分析方法对脑电信号进行伪迹去除和节律提取, 通过从正常儿童和孤独症儿童脑电信号中提取统一 α 节律AFu, 求其能量并使用支持向量机方法进行分类比较结果; 进一步, 使用加权重心点探究个体化 α 峰值频率PAF及节律AFi, 使用SSA方法提取AFi后重复上述进行分类比较. 结果显示, 未经SSA处理的脑电数据提取AFu相对能量作为特征, 分类准确率为81.36%, 而使用SSA预处理后, 分类准确率提升至89.83%, 验证了SSA方法伪迹去除的有效性; 使用个体化 α 节律AFi相对能量作为特征, SVM分类准确率降低至81.36%, 而将个体化 α 节律AFi相对能量和 α 峰值频率PAF作为共同特征可得到94.92%的分类准确率. 此结果揭示孤独症儿童脑电节律异常体现为两个方面: 频段分布和功率调制, 即孤独症儿童 α 节律出现了低频偏移及相对能量的降低. 本研究从方法验证及病理揭示的角度为孤独症儿童的辅助诊断提供了有力的技术手段和科学依据.

关键词 孤独症, 脑电, 奇异谱分析, α 峰值频率

孤独症谱系障碍(autism spectrum disorder, ASD)是一种严重的神经发育障碍疾病, 其核心症状包括交流和社交障碍及刻板行为^[1]. 当前孤独症的发病率在全球急剧上升, 美国疾病控制与预防中心的数据表明, 截至2014年, 对美国所有出生于2002年的孩子进行筛查统计, 孤独症发病率为1/68^[2]. 孤独症的发病原因尚不明确, 其诊断也主要依靠量表和行为观察, 具有主观性, 因此, 寻找客观指标进行精准评估至关重要.

在孤独症的研究中, 脑电图(electroencephalography, EEG)由于其具备毫秒级的时间分辨率, 是分

析和评估孤独症大脑发育的有力工具^[3]. 静息态脑电信号的频域一般划分为4个波段^[4]: delta波段(1~4 Hz)、theta波段(4~8 Hz)、alpha波段(8~13 Hz)和beta波段(13~30 Hz). α 振荡是静止和清醒状态下大脑最显著的动力学特征之一, 自1929年Berger^[5]首次发现以来, α 振荡一直是神经科学的研究内容^[6]. α 振荡一般存在于放松的清醒大脑中, 与感觉和认知抑制的时间相关^[7], 在认知加工中起着重要和积极的作用^[8], 显示明确定义的发育特征. 之前的研究显示, 与正常儿童相比, ASD患者的 α 功率谱显著降低^[9,10]. 最近也有研究发现, α 峰值频率(peak alpha frequency,

引用格式: 赵杰, 宋佳佳, 陈贺, 等. 基于奇异谱分析方法的孤独症儿童脑电信号特征提取及分类. 科学通报, 2019, 64: 1159–1167

Zhao J, Song J J, Chen H, et al. Feature extraction and classification of EEG signals in autistic children based on singular spectrum analysis (in Chinese). Chin Sci Bull, 2019, 64: 1159–1167, doi: 10.1360/N972018-01066

PAF)对神经网络的发育变化非常敏感^[6],其随着认知需求和任务参与而增加.由于 α 频率存在显著的个体差异,因此使用个体化 α 峰值频率来估计受试者 α 频率能够更加的准确^[8].最近的研究表明,孤独症儿童的 α 峰值频率与正常儿童相比较低^[11].因此如何准确提取 α 节律进行分析成为核心问题.

有许多方法用于从受干扰的信号中提取节律,傅里叶变换(Fourier transformation, FT)能够在分析信号时获得所需的频率分量,是最常用的计算方法,但其仅适用于平稳信号,不能反映信号瞬时频率随时间的变化情况.经验模式分解(empirical mode decomposition, EMD)也是一种广泛使用的信号处理方法,利用固有模式功能允许单独处理信号中包含的振荡分量^[12],但固有模式功能选择缺乏清晰的频率差异^[13],因此可能导致周期信号失真.小波变换也可以用于去除伪迹来分解频率成分,但计算时间相对较长、效率较低,也无法分离出在时频空间中重叠分量^[14].本文采用的奇异谱分析(singular spectrum analysis, SSA)方法是一种广泛的研究非线性时间序列的方法,其优点是可以从脑电信号中提取并消除噪声分量^[15],能够有效的提取期望节律,已经应用于心音中的杂音检测^[16],睁眼和闭眼状态分类^[17],清醒和睡眠状态分类^[18]等信号处理领域.

本文将SSA方法应用于孤独症儿童和正常儿童脑电序列分析中,可以有效消除脑电信号中的高频噪声分量,从而准确提取出 α 节律.通过对正常儿童和孤独症儿童 α 节律的探讨分析,寻找能够区分正常儿童和孤独症儿童的脑电特异性指标,利用SVM进行分类,提高分类的准确度,希望能够为孤独症诊断提供科学可靠的依据.

1 材料与方法

1.1 材料

(i) 被试. 本研究共招收被试59名.其中ASD儿童30名(3~6周岁,平均年龄为 4.2 ± 1.6 周岁),正常发育儿童29名(3~6周岁,平均年龄为 4.3 ± 1.5 周岁).其中ASD患者均经由专业的儿童精神科医生根据《精神障碍诊断与统计手册》和《儿童孤独症评定量表》进行诊断确定为低功能孤独症.两组被试之间年龄无显著性差异(年龄: $t=0.509$, $P=0.615$).本研究经过北京师范大学伦理委员会批准,在完整描述实验步骤

后,被试监护人签署书面知情同意书,均自愿参加此项研究.

(ii) 脑电采集. 本项研究采用八通道脑电采集系统采集EEG脑电信号,其中Cz为参考电极,采样频率为1000 Hz,电极的阻抗被控制在50 k Ω 以下.实验在安静的环境下进行,要求被试坐在舒适座位上处于放松状态,睁眼保持5 min. 本实验选取与 α 节律密切相关的枕叶区域的两个通道(以下称为通道O1,通道O2)来进行分析.

(iii) 数据预处理. 使用MATLAB中的EEGLAB工具箱将采集到的数据进行预处理.挑除部分干扰信号,如肌电、眼电、工频、呼吸等,并将数据采样率降至200 Hz.

1.2 数据处理

1.2.1 基于SSA方法数据预处理

SSA方法能够从受干扰的信号中提取脑电时间序列中的周期信号,提取期望节律并消除噪声分量,因此利用该方法可以有效地从脑电信号中提取 α 节律. SSA方法包括两部分: 分解和重构.

分解阶段包含时间延迟嵌入和奇异值分解(singular value decomposition, SVD)两部分.

(i) 时间延迟嵌入. 将一维脑电时间序列 $S = (S_1, S_2, \dots, S_N)$ 映射到多维轨迹矩阵上:

$$X = \begin{pmatrix} S_1 & S_2 & \cdots & S_K \\ S_2 & S_3 & \cdots & S_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ S_L & S_{L+1} & \cdots & S_N \end{pmatrix}, \quad (1)$$

其中 L 表示窗口长度,取值范围在 $1 < L < M$ 之间, $K = N - L + 1$, X 是Hankel矩阵,沿对角线元素相同^[17,19].

(ii) 奇异值分解. 使用SVD分解将轨迹矩阵分解为其特征子空间,可重写为

$$X = X_1 + X_2 + \cdots + X_r. \quad (2)$$

计算协方差矩阵 $X^T X$ 从而得到 L 个特征值 $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_L \geq 0$, 其中, $X_i = \sqrt{\lambda_i} u_i v_i^T$, 表示第 i 个SVD分量, u_i (左奇异向量)是协方差矩阵 XX^T 的特征向量, v_i (右奇异向量)是协方差矩阵 $X^T X$ 的特征向量, 由此, 每个主成分子空间包含脑电信号的不同特征, 每个特征值代表对应的SVD分量对原信号的贡献度^[17,18,20].

重构阶段包含分组和重建(对角线平均)两部分. 在分组步骤中, 首先将基本矩阵 X_i 分成若干组, 以表示不同的脑电节律、噪声等. 分组规则取决于问题的要求以及贡献信号和噪声类型^[17]. 由对角线平均步骤从相应的基本矩阵中重建时间序列, 并称之为重建分量(reconstructed components, RC), 最后, 根据所提出的自适应分组规则, 将RC分组用于伪迹去除和节律提取.

在分解阶段中可得奇异值 $\sigma = \sqrt{\lambda}$, 每个奇异值都是按从大到小的顺序排列, 且急速衰减. 因此前几个RCs主导着脑电时间序列趋势, 具有高能量的信号相关特征值位于较低子空间中, 而较弱信号在较高子空间中出现, 其中噪声分量通常出现在较高子空间中且幅值较高, 因此, 需要较低子空间与噪声分量分开. 在本研究中, 当脑电幅值较高时, 去除1/3高频成分, 否则去除1/4高频成分.

在去除伪影之后, 从脑电时间序列中提取 α 节律, 节律是脑电时间序列的振荡分量, 包括但不限于周期分量, 为了提取脑电节律, 将RC分为两组, 周期性和非周期性, 首先, 提取周期性分量. 使用SSA将周期时间序列分解为具有相似幅度的特征值对, 具有相似特征值的RC属于相同的周期分量(periodic components, PC)^[21], 其中周期分量特征值相似性由以下标准确定:

$$\left| 1 - \frac{\lambda_j}{\lambda_i} \right| = K, \quad (3)$$

其中 K 值可以根据波形幅度进行更改, 因为 α 包含更高的振幅, 因此选择 $K=0.05$ ^[18], 根据傅里叶变换中峰值频率表示PC和RC的频率范围:

$$f_{\max} = \arg \max_f \{ \text{abs}[FFT(RC)] \}, \quad (4)$$

其中 $f_{\max}$ 是峰值频率, $FFT(RC)$ 是RC或PC的快速傅里叶变换. 具有相同节律带峰值频率的RC和PC成为一个组, 构成了脑节律.

嵌入窗口的大小能够捕获至少一个周期的周期

信号, 由经验可知 L 取值范围在20~100之间, 在本研究中, 当窗口长度为 $L=60$ 时, 得到较好的结果. 自适应SSA方法的流程如图1所示.

1.2.2 节律相对能量

(i) 频域方法. 对于脑电信号 S 及 α 节律信号分别计算功率谱 P_s 与 P_α , 若 α 节律频段边界为 a 与 b , 则该节律的频域相对能量计算方法为

$$re_\alpha = \frac{\sum_{i=a}^b p_i^a}{\sum_{i=a}^b p_i^1}. \quad (5)$$

(ii) 时域方法. 给定单通道脑电信号 $S=(S_1, S_2, \dots, S_N)$, 采用SSA方法提取 α 节律时域信号 $x=(x_1, x_2, x_3, \dots, x_n)$, 则该节律时域相对能量为

$$re_\alpha^{\text{TD/ASD}} = \frac{\sum_{i=1}^n x_i^2}{\sum_{i=1}^n s_i^2}. \quad (6)$$

(iii) α 峰值频率. 对于脑电信号 S 计算功率谱 P_s , 使用加权重心点求 α 峰值频率:

$$CoG = \frac{\sum_{i=n}^m p_i f_i}{\sum_{i=n}^m p_i}, \quad (7)$$

其中 n 为低频阈值, m 为高频阈值, f_i 为频率, p_i 为其能量, 从而求得峰值, 进而将 α 节律范围确定为 $0.8 \cdot CoG \sim 1.2 \cdot CoG$, 在本研究中, 选择 $n=7$ Hz, $m=14$ Hz. 个体化 α 峰值频率AFi被确定为7~14 Hz频段内的重心频率, 能够提供更准确的频谱估计, 特别是在可识别多个峰值的情况下^[22].

(iv) 分类. 在本研究中, 使用SVM(support vector machines, 支持向量机)分类器、AUC(area under the curve)值(ROC曲线下面积)指标来进行分类模型评估. SVM原理是在特征空间中确定一个最优超平面, 使类别间距离最大, 分类超平面的

图1 SSA方法预处理流程

Figure 1 The preprocessing process of SSA

确定取决于最接近的数据点, 这些数据点被称为支持向量(support vector)^[23]. 其中包含多种SVM分类器, 在本研究中选用线性SVM分类器. 为评估分类模型, 需要对数据进行交叉验证. K 折交叉验证(K -folded cross validation)是将样本随机划分为 K 个大小相等的子样本, 并将其中的一个子样本作为测试集, 剩下的 $K-1$ 个子样本用于训练, 将 K 个子样本轮流作为测试集, 得到 K 个分类准确率求平均得到分类精度. 在本研究中使用常用的10折交叉验证.

ROC曲线(receiver operating characteristic curve), 在1982年应用于评判模型诊断效果, 经大量学者研究实践, 目前ROC分析已广泛应用于描述诊断试验准确性. ROC结合了灵敏度和特异性^[24], 并根据曲线的面积对模型进行评估. ROC曲线纵坐标为真阳性率, 指在实际为阳性的样本中, 被正确判断为阳性的比率; 横坐标为假阳性率, 指在实际为阴性的样本中, 被错误判断为阳性的比率. ROC曲线下面积AUC表示若随机抽取一个阳性和一个阴性样本, 分类器正确判断阳性样本的值高于阴性样本的几率^[25]. AUC的值在0~1之间, 且AUC值越大的分类器正确率越高. 本文使用AUC的值作为模型优劣的指标. 本研究的总体流程如图2所示.

2 结果与讨论

2.1 结果

(i) SSA方法能够有效去除高频噪声对信号的影响. 在实验环境中, 采集的脑电信号会受到伪迹的干扰, 采集到的脑电信号如图3(a)所示, 经过SSA方法预处理后的脑电数据如图3(b)所示, 经

SSA方法预处理后的脑电数据去除了高频噪声, 表明SSA方法能够有效地对受到干扰的脑电信号进行滤波和去噪. 当SSA方法中预处理参数 $L=60$, $C=16$ 时, 每个RC分量的频谱图如图3(c)所示, 可从重构的分量中有效提取期望 α 节律.

统一的 α 节律AFu为8~13 Hz, 根据公式(4)提取出 α 节律, 结果如图4所示, 将SSA处理前后两个通道通过公式(6)计算的 α 节律频域相对能量作为特征输入分类器中进行分类对比, 分类对比结果如图5(a), (b)所示, 结果显示, SSA算法对脑电信号去除高频噪声后, 分类准确率为91.53%, AUC值为0.9483, 高于噪声去除前的81.36%分类准确度和0.9023的AUC值.

(ii) 采用时域方法计算 α 节律相对能量能够有效提高分类准确度. SSA算法能够有效地去除脑电信号高频部分的噪声, 计算 α 节律相对能量的方法有频域和时域两种, 前面介绍了 α 节律的频域相对能量. 根据公式(5)计算 α 节律的时域相对能量, 将两个通道 α 节律的频域相对能量和时域相对能量作为特征输入分类器中进行对比, 分类对比结果如图5(b), (c)所示, 结果显示, SSA方法中采用时域方法计算的 α 节律相对能量, 分类准确率为91.53%, AUC值为0.9483, AUC值低于采用频域方法计算 α 节律相对能量的0.9529, 分类准确度高于频域方法的89.83%. 因此在SSA方法中, 采用时域方法计算得到的 α 节律相对能量能够有效地区分两组儿童.

(iii) 孤独症儿童 α 节律异常同时表现为相对能量和频段范围的异常, 二者结合的分类准确率可以达到94.92%. 本文SSA方法能够有效地去除脑电信号的高频噪声, 提取期望的 α 节律. 引言部分提到当前在脑电节律的研究中发现孤独症儿童的 α 峰值频

图2 算法流程图

Figure 2 The flow chart of algorithm

图3 基于SSA方法处理前后的脑电数据. (a) 未经SSA方法预处理的脑电信号; (b) 经过SSA方法预处理的脑电信号; (c) 重构的前16个分量
Figure 3 EEG data before and after processing based on SSA method. (a) The EEG before SSA preprocess; (b) the EEG after SSA preprocess; (c) the 16 components before reconstruction

率存在异常情况, 根据AFu计算的两组儿童的 α 节律相对能量的结果可靠性不强. 为了矫正提取的 α 节律, 本研究使用公式(7)计算孤独症儿童与正常儿童两个通道的个体化 α 峰值频率, 比较两组儿童的 α 峰值频率差异, 计算得出正常儿童通道O1和通道O2的个体化 α 峰值频率的测量值($Mo_1=7.84$, $SDo_1=0.25$; $Mo_2=7.83$, $SDo_2=0.26$)与孤独症儿童通道O1和通道

O2的 α 峰值频率的测量值($Mo_1=7.43$, $SDo_1=0.29$; $Mo_2=7.42$, $SDo_2=0.27$)具有显著性差异($to_1=-5.735$, $po_1<0.001$; $to_2=-5.844$, $po_2<0.001$). 利用SSA方法根据 α 峰值频率提取两组儿童个体化的 α 节律AFi, 通过时域方法计算两个通道AFi的相对能量, 将其作为特征输入分类器中进行分类. 分类结果如图6(a)所示, 结果显示两组儿童个体化 α 节律相对能量的分类准

图4 正常组和孤独症组的 α 节律. (a) 提取通道O1的 α 节律; (b) 提取通道O2的 α 节律

Figure 4 Alpha Rhythm in the normal group and autism group. (a) Alpha Rhythm from channel O1; (b) alpha Rhythm from channel O2

图5 基于SSA算法的正常组与孤独症组的分类结果. (a) SSA预处理前的脑电信号提取AFu, 计算其频域相对能量, 作为特征进行分类; (b) 经SSA处理后的脑电信号提取AFu, 计算其频域相对能量, 作为特征进行分类; (c) 经SSA处理后的脑电信号提取AFu, 计算其时域相对能量, 作为特征进行分类

Figure 5 Classification of normal group and autism group based on SSA algorithms. (a) Extracting AFu from EEG before SSA preprocessing and calculating relative energy in frequency domain as a feature for classification; (b) extracting AFu from EEG after SSA preprocessing and calculating relative energy in frequency domain as a feature for classification; (c) extracting AFu from EEG after SSA preprocessing and calculating relative energy in time domain as a feature for classification

图6 基于不同特征的正常组和孤独症组的分类结果. (a) 经过SSA方法提取的AFi相对能量分类结果; (b) 孤独症儿童和正常儿童的PAF分类结果; (c) 孤独症儿童和正常儿童的PAF和AFi时域相对能量作为共同特征的分类结果

Figure 6 Classification based on different characteristics of the normal group and autism group. (a) Classification results from AFi by SSA; (b) classification results from PAF; (c) classification results from AFi and PAF

确度下降到81.36%, AUC的值也降低到0.9161, 分类模型性能降低, 表明之前根据AFu选取的 α 频段得到的分类结果不可靠, 孤独症儿童的 α 节律异常不仅体现在时域相对能量上, 还体现在个体化 α 峰值频率上。

本研究的 t 检验结果发现孤独症儿童和正常儿童的 α 峰值频率存在显著性差异, 将两组儿童的个体化 α 峰值频率作为特征输入到分类器中得到的分类结果如图6(b)所示, 结果显示, 利用CoG计算的两组儿童的 α 峰值频率分类准确度只有71.19%, 表明孤独症儿童和正常儿童的 α 峰值频率虽有显著性差异, 但不足以单独将 α 峰值频率作为区分两组儿童的特异性指标。由此, 本研究将求得的AFi时域相对能量和 α 峰值频率共同作为特征进行分类, 结果如图6(c)所示。分类结果显示将计算的个体化 α 节律时域相对能量和 α 峰值频率共同作为特征时分类准确率最优, 达到94.92%, AUC值达到0.9931, 分类模型最佳。表明对区分正常儿童和孤独症儿童而言, 其个体化AFi时域相对能量和峰值频率都是重要因素。

2.2 讨论

以往研究发现SSA方法在分解和重构阶段可以从信号中提取并消除噪声分量, 能够提取脑电时间序列中的周期信号, 提取期望的节律, 如提取睁眼、闭眼状态下的 α 节律^[16]。本研究进一步证明了SSA方法作为预处理和节律提取方法的有效性, 可作为提取 α 节律的有效工具。

在研究中, 孤独症儿童 α 节律相对能量显示异

常, 即枕叶区域通道O1, O2的AFi的相对能量显著降低, 与之前的研究一致^[9,10], 进一步证明了孤独症儿童 α 节律相对能量的异常。 α 节律相对能量降低与缺乏 α 抑制和低效神经功能有关, 影响儿童认知学习能力^[26], 可作为诊断孤独症儿童的指标。

在进一步探讨孤独症儿童 α 峰值频率特异性时发现孤独症儿童的PAF较正常儿童显著性偏低。这与Dickinson等人^[11]的发现一致, PAF能够反映大脑神经网络的完整性, 而神经网络的偏差与孤独症儿童认知功能有关, 在孤独症儿童中, PAF也与非语言认知功能强烈相关。本研究结果表明PAF的差异可作为诊断孤独症儿童的指标。

最后, 本研究融合了孤独症儿童脑电的AFi相对能量和PAF共同作为特征指标进行分类, 与之前用单一指标分类结果相比较, 显示出了更高的分类精度。

3 结论

本研究致力于寻找一种能够区分孤独症儿童和正常儿童的生物标记物。本文结果发现孤独症儿童与正常儿童相比, 枕叶区域AFi相对能量较低, 孤独症儿童的PAF较正常儿童显著偏低, 表明儿童 α 节律相对能量较低和 α 峰值频率偏低与临床认知功能下降一致, 反映了孤独症儿童脑发育较迟缓。本文将两种指标结合, 得到94.92%的分类准确率, 较之前的分类精度有大幅提升, 因此能够为孤独症儿童的辅助诊断提供科学客观的依据。

参考文献

- 1 Chez M G, Chang M, Krasne V, et al. Frequency of epileptiform EEG abnormalities in a sequential screening of autistic patients with no known clinical epilepsy from 1996 to 2005. *Epilepsy Behav*, 2006, 8: 267–271
- 2 Blumberg S J, Bramlett M D, Kogan M D, et al. Changes in prevalence of parent-reported autism spectrum disorder in school-aged U.S. children: 2007 to 2011–2012. *Natl Health Stat Report*, 2013, 1–11
- 3 Ingber L, Nunez P L. Neocortical dynamics at multiple scales: EEG standing waves, statistical mechanics, and physical analogs. *Math Biosci*, 2011, 229: 160–173
- 4 Akin M. Comparison of wavelet transform and FFT methods in the analysis of EEG signals. *J Med Syst*, 2002, 26: 241–247
- 5 Berger H. Über das Elektroencephalogramm des Menschen. *Archiv Psychiatr Nervenkrankh*, 1929, 87: 527–570
- 6 Mierau A, Klimesch W, Lefebvre J. State-dependent alpha peak frequency shifts: Experimental evidence, potential mechanisms and functional implications. *Neuroscience*, 2017, 360: 146–154
- 7 Klimesch W, Sauseng P, Hanslmayr S. EEG alpha oscillations: The inhibition-timing hypothesis. *Brain Res Rev*, 2007, 53: 63–88
- 8 Haegens S, Cousijn H, Wallis G, et al. Inter- and intra-individual variability in alpha peak frequency. *Neuroimage*, 2014, 92: 46–55
- 9 Shephard E, Tye C, Ashwood K L, et al. Resting-state neurophysiological activity patterns in young people with ASD, ADHD, and ASD+ADHD. *J Autism Dev Disord*, 2018, 48: 110–122

- 10 Wang J, Barstein J, Ethridge L E, et al. Resting state EEG abnormalities in autism spectrum disorders. *J Neurodevel Disorders*, 2013, 5: 24
- 11 Dickinson A, DiStefano C, Senturk D, et al. Peak alpha frequency is a neural marker of cognitive function across the autism spectrum. *Eur J Neurosci*, 2018, 47: 643–651
- 12 Liang Z, Wang Y, Sun X, et al. EEG entropy measures in anesthesia. *Front Comput Neurosci*, 2015, 9: 16
- 13 Güven A, Batbat T. Evaluation of filters over different stimulation models in evoked potentials. *Biocybernetics Biomed Eng*, 2018, <https://doi.org/10.1016/j.bbe.2018.08.007>
- 14 Azami H, Sanei S. Automatic signal segmentation based on singular spectrum analysis and imperialist competitive algorithm. 2012 2nd International Conference on Computer and Knowledge Engineering (ICCKE), 2012, 50–55
- 15 Mohammadi S M, Enshaeifar S, Ghavami M, et al. Classification of awake, REM, and NREM from EEG via singular spectrum analysis. *Conf Proc IEEE Eng Med Biol Soc*, 2015, 2015: 4769–4772
- 16 Sanei S, Ghodsi M, Hassani H. An adaptive singular spectrum analysis approach to murmur detection from heart sounds. *Med Eng Phys*, 2011, 33: 362–367
- 17 Hu H, Guo S, Liu R, et al. An adaptive singular spectrum analysis method for extracting brain rhythms of electroencephalography. *PeerJ*, 2017, 5: e3474
- 18 Mohammadi S M, Kouchaki S, Ghavami M, et al. Improving time-frequency domain sleep EEG classification via singular spectrum analysis. *J Neurosci Methods*, 2016, 273: 96–106
- 19 Mees A I, Rapp P E, Jennings L S. Singular-value decomposition and embedding dimension. *Phys Rev A*, 1987, 36: 340–346
- 20 Xu S, Hu H, Ji L, et al. Embedding dimension selection for adaptive singular spectrum analysis of EEG signal. *Sensors (Basel)*, 2018, 18: 697
- 21 Vautard R, Yiou P, Ghil M. Singular-spectrum analysis—A toolkit for short, noisy chaotic signals. *Physica D*, 1992, 58: 95–126
- 22 Christie S, di Fronso S, Bertollo M, et al. Individual alpha peak frequency in ice hockey shooting performance. *Front Psychol*, 2017, 8: 762
- 23 Mueller A, Candrian G, Kropotov J D, et al. Classification of ADHD patients on the basis of independent ERP components using a machine learning system. *Nonlinear Biomed Phys*, 2010, 4(Suppl 1): S1
- 24 Hanley J A, Mcneil B J. The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*, 1982, 143: 29–36
- 25 Fawcett T. An introduction to roc analysis. *Pattern Recongn Lett*, 2006, 27: 861–874
- 26 Mathewson K J, Jetha M K, Drmic I E, et al. Regional EEG alpha power, coherence, and behavioral symptomatology in autism spectrum disorder. *Clin Neurophysiol*, 2012, 123: 1798–1809

Summary for “基于奇异谱分析方法的孤独症儿童脑电信号特征提取及分类”

Feature extraction and classification of EEG signals in autistic children based on singular spectrum analysis

Jie Zhao¹, Jiajia Song¹, He Chen², Xiaoli Li² & Jiannan Kang^{1*}

¹ Institute of Electronic Information Engineering, Hebei University, Baoding 071000, China;

² State Key Laboratory of Cognitive Neuroscience and Learning, Beijing Normal University, Beijing 100875, China

* Corresponding author, E-mail: kangjiannan81@163.com

Autism spectrum disorder is a heterogeneous neurodevelopmental disorder involving social, emotional, cognitive, and behavioral disorders. In recent years, with the increasing number of patients with autism, the autistic population has received more and more attention abroad, but the pathogenesis is still unclear. The clinical diagnosis depends on the behavior observation and scale evaluation. Therefore, objective indicators are of great significance for the diagnosis of autism. Electroencephalogram (EEG) is a commonly used neuroimaging technique for its high temporal resolution. This study mainly focus on the feature extraction of EEG and classification of children with autism based on the analyses of EEG, including the individualized α peak frequency (PAF) and the relative energy of AFi.

In this study, we enrolled 30 children with autism (3–6 years old) and 29 age-matched normal children. Resting-state EEG was obtained from each subject with eyes open in a quiet environment. Singular spectrum analysis (SSA) method is proposed to remove artifacts and extract rhythm from EEG signals. The unified α rhythm AFu, was extracted from the EEG signals of normal and autistic children and the classification results were compared by support vector machine (SVM) method. Furthermore, the weighted centroid point was used to explore the individualized α peak frequency (PAF) and rhythmic AFi. The AFi was extracted by SSA method and then repeated and compared.

The results showed that the relative energy of AFu was extracted from the EEG data without preprocessing by SSA; the classification accuracy was 81.36%. After preprocessing by SSA, the classification accuracy was increased to 89.83%, which verified the validity of SSA for artifact removing. Using individual the relative energy of α rhythm AFi as the feature, the classification accuracy is reduced to 81.36%, but the classification accuracy rate of 94.92% could be obtained by using individual the relative energy of α rhythm AFi and α peak frequency as common features. The results showed that the abnormal EEG rhythm in autistic children is reflected in two aspects: frequency distribution and power modulation; the α rhythm of autistic children has a low frequency offset and a decrease in relative energy. This study provides a powerful technical means and scientific basis for the auxiliary diagnosis of autistic children from the point of method verification and pathological revealing.

autism, electroencephalogram, singularity spectrum analysis, α peak frequency

doi: 10.1360/N972018-01066