

改进的多尺度熵算法及其情感脑电特征提取性能分析^①

李 昕^②* ** ** 谢佳利^③* ** 侯永捷**** 王金甲*****

(* 燕山大学电气工程学院生物医学工程研究所 秦皇岛 066004)

(** 河北省测试计量技术及仪器重点实验室 秦皇岛 066004)

(*** 北京工业大学生命科学与生物工程学院 北京 100124)

(**** 前景光电技术有限公司 秦皇岛 066004)

(***** 燕山大学信息科学与工程学院 秦皇岛 066004)

摘 要 进行了用多尺度熵提取情感脑电特征的研究,针对传统的基于多尺度熵的特征提取算法在粗粒化过程中存在重要信息丢失以及尺度选择过小造成特征不显著、尺度过大造成计算过度复杂的问题,提出了一种改进的多尺度熵算法。该改进算法通过自适应多尺度熵中本征模态函数的个数确定尺度,而且为突出脑电信号的微小变化,对脑电信号进行自适应二值化处理,充分挖掘特征并降低算法复杂性。利用 Deap 国际标准情感分析数据库并基于优化支持向量机分类器实现了情感脑电特征识别,进行了改进算法与传统多尺度熵算法的性能比较。结果表明,改进算法的分类准确率较传统多尺度熵算法提高了 12.33%,较自适应多尺度熵算法提高了 7.27%,表明改进算法是一种有效的脑电特征提取算法。

关键字 情感脑电,多尺度熵,自适应多尺度熵,改进的多尺度熵

0 引 言

1997 年,美国麻省理工学院的 Picard 教授在她的专著《Affective Computing》中首次提出了“情感计算”这一概念^[1]。情感识别是情感计算的关键问题之一。脑电信号能够反映大脑皮层神经元的综合活动,客观描述情感状态,基于脑电分析实现情感识别是一种可行有效的方法。在很多状态下,脑电时间序列有着显著的非线性特征,因此采用复杂度等非线性的动力学方法提取脑电的特征,能够有效描述脑电活动。Daniel 对比研究了阿尔茨海默症(Alzheimer's disease, AD)患者与健康对照组 19 个电极处的脑电近似熵,为了验证结果的可靠性同时进行了

功率谱分析。结果表明:AD 患者的近似熵在 P3、P4 电极处显著低于对照组,结果与功率谱分析的结果相关^[2]。Labate 等采用多尺度熵方法对比研究了正常对照组、轻度认知功能障碍(mild cognitive impairment, MCI)和 AD 静息状态下的脑电特征,也发现 AD 脑电复杂性显著减小,这与之前的非线性分析方法的结果一致^[3]。吴顺德等为克服传统多尺度熵由粗粒化造成的信息丢失以及多尺度熵在短时序计算中的不精确性,分别提出了改进算法——移动平均法和计算样本熵模板矢量时采用的时间延迟方法。多尺度熵方法和改进方法对白噪声的识别错误率在序列长度大于 2000 时基本相等,序列长度为 500 时识别错误率分别为 11.7% 和 5%^[4]。倪力等为了克服多尺度熵中尺度的选择问题,采用自适应

① 国家自然科学基金(nsfc61473339),河北省自然科学基金(F2014203204)和中国博士后科学基金(2014M550582)资助项目。

② 女,1970 年生,博士,教授;研究方向:医学信息处理,情感计算;E-mail: yddylixin@ ysu. edu. cn

③ 通讯作者, E-mail: 1045806092@qq. com

(收稿日期:2015-05-22)

方法选择尺度,并将该自适应多尺度熵方法成功应用于脑死亡诊断中^[5]。另外,在脑电麻醉深度的跟踪中,排序熵方法应用十分广泛^[6,7]。为了弥补排序熵的不足,学者将多尺度方法与排序熵方法结合,结果显示,多尺度排序熵能够更好地描述脑电特性,在麻醉深度检测中更加灵敏^[7]。

多尺度熵是基于熵的生理复杂性指数,用于评估信号多个时间尺度上的特征。脑电信号在不同尺度下的动力学特征可能会揭示出其在不同情感状态下的特异性特征,有利于情感脑电特征的识别。但是传统多尺度熵特征提取算法在粗粒化过程中会有重要信息丢失的问题^[4],同时还有尺度选择过小时容易造成特征不显著,尺度过大时造成计算复杂的问题。本文针对这种情况,提出了一种改进的多尺度熵特征提取算法,该算法为突出脑电信号的微小变化对脑电信号进行自适应二值化处理,以充分挖掘特征并降低算法复杂性。本研究采用 Deap 国际标准数据库并基于优化支持向量机 (support vector machine, SVM) 分类器实现了该方法与其他方法的情感脑电识别性能对比。

1 特征提取算法

1.1 样本熵

样本熵是计算时间序列复杂性的方法,源于近似熵,较近似熵精度更高。样本熵计算步骤如下:

(1) 假设有限长时间序列 $U = [u_1, u_2, \dots, u_N]$, 共 N 个点。

(2) 按顺序构造出一组 m 维矢量

$$U_i = [u_i, u_{i+1}, \dots, u_{i+m-1}], i = 1, 2, \dots, N - m + 1 \quad (1)$$

(3) 定义 U_i 与 U_j 间的距离 $d[U_i, U_j]$ 为两矢量中个元素之间的切比雪夫距离的最大值,即

$$d[U_i, U_j] = \max[|U_{i+k} - U_{j+k}|] \quad (2)$$

(4) 给定阈值 r , 对于每个 $i \leq N - m + 1$ 的值, 统计 $d[U_i, U_j]$ 小于 r 的数目 G 及 G 与距离总数 $N - m + 1$ 的比值, 记作 $B_i^m(r)$, 即

$$G = \{d[U_i, U_j] < r\}, B_i^m(r) = G / (N - m + 1) \quad (3)$$

(5) 先求 $B_i^m(r)$ 的对数, 再对其所有 i 值计算平均值, 记作 $B^m(r)$ 。即

$$B^m(r) = \frac{1}{N - m + 1} \sum_{i=1}^{N-m+1} \ln(B_i^m(r)) \quad (4)$$

(6) 将维数加 1, 对 $m + 1$ 重复步骤(2) - (5), 得 $B_i^{m+1}(r)$ 和 $B^{m+1}(r)$ 。

(7) 理论上来说样本熵值为

$$\text{SampEn}(m, r) = \lim_{N \rightarrow \infty} \{-\ln[B^{m+1}(r) / B^m(r)]\} \quad (5)$$

当 N 有限时, 上式表示为

$$\text{SampEn}(m, r, N) = -\ln[B^{m+1}(r) / B^m(r)] \quad (6)$$

1.2 多尺度熵

多尺度熵基于样本熵, 计算各尺度下时间序列样本熵。

(1) 离散时间序列的粗粒化

设有离散时间序列 $x_1, x_2, x_3, \dots, x_N$, 共 N 个数据点, 粗粒化后得到新的时间序列为

$$y_j^{(s)} = \frac{1}{s} \sum_{i=(j-1)s+1}^{js} x(i) \quad (7)$$

粗粒化后的时间序列长度为 N/s , 其中 s 为时间尺度。当 $s = 1$ 时, 粗粒化后的时间序列与原始时间序列相同。

(2) 计算各尺度下时间序列 $y^{(s)}$ 的样本熵

$$\text{SampEn}(m, r, N) = -\ln[B^{m+1}(r) / B^{(m)}(r)] \quad (8)$$

1.3 自适应多尺度熵

为了解决多尺度熵算法的尺度选择问题, 将经验模型分解 (empirical mode decomposition, EMD) 与多尺度熵结合, 通过 EMD 分解得到本征模态函数 (intrinsic mode function, IMF) 的个数自适应地确定多尺度熵中的尺度^[5]。采用“从精细到粗糙”的自适应多尺度熵算法对情感脑电特征进行提取:

(1) 通过 EMD 分解获得 IMF。

(2) 从原始数据中的第一个 IMF 开始, 连续移除高频的 IMF, 得到各尺度信号如下:

$$S_{2c}^k = \sum_{i=k}^N \text{IMF}_i, k \leq N \quad (9)$$

(3) 计算每个尺度上的样本熵值, 记作自适应多尺度熵:

$$AME_{J_{2c}}(k, m, r) = \text{SampEn}(S_{J_{2c}}^k, m, r) \quad (10)$$

1.4 改进多尺度熵

针对多尺度熵算法在对数据进行粗粒化过程中,不可避免地丢失了重要信息,以及尺度选择过小

造成的特征不显著或尺度过大造成计算复杂等问题,本文将自适应二值化方法、传统多尺度熵方法以及自适应多尺度熵方法相结合,提出一种改进的多尺度熵算法。自适应二值化算法流程如图 1 所示。

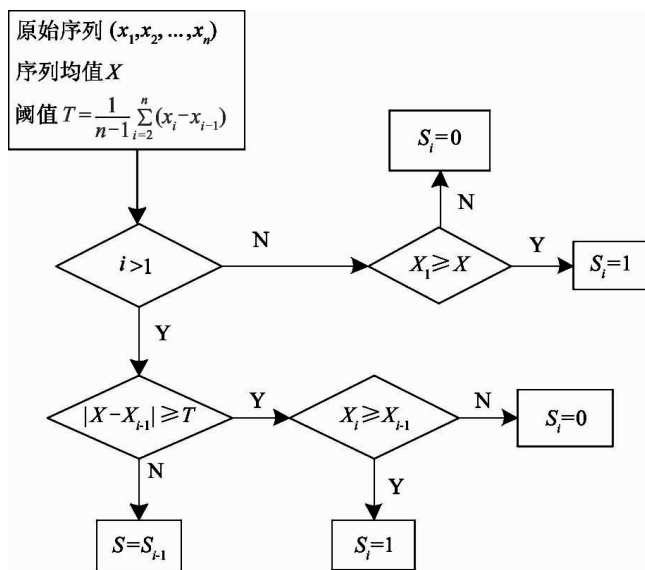


图 1 自适应二值化流程图

通过自适应多尺度熵中本征模态函数(IMF)的个数确定尺度,为突出脑电信号的微小变化对脑电信号进行自适应二值化^[8]处理后再求多尺度熵。设有原始序列 (x_1, x_2, \dots, x_n) , 均值为 X , 定义阈值 $T = \frac{1}{n-1} \sum_{i=2}^n (x_i - x_{i-1})$ 。如果第一个点 $x_1 > X$, 则二值化序列 $S_1 = 1$, 反之为 0。从序列第二个点 x_2 开始, $x_i (2 \leq i \leq n)$ 二值化值取决于与前一点的比较, 如果 $|x_i - x_{i-1}| < T$, $S_i = S_{i-1}$; 反之, 则根据与前一点的大小关系来确定二值化值。

2 情感脑电数据

本文采用文献[9]中的开放数据库, 该数据集记录了 32 位被试者观看 40 个时长一分钟的音乐视频时的脑电信号及外周生理信号。通过观看不同情感的音乐视频来引导不同情感, 每段音乐过后, 被试采用 1~9 打分制(正性 1~3.6; 中性 3.7~6.3; 负性 6.4~9), 评价音乐的效价。数据集已经进行了

预处理, 采用频率为 128Hz, 去除了眼电等噪声, 经过 4.0Hz~45Hz 的滤波, 可以直接用于分类研究。

根据多尺度熵算法特性和之前的研究^[8,10], 本文选用数据集中第 28s~38s 数据, 时长 10s, 共 1028 个采样点。为更好地对比和分析, 本文算法的参数设置均采用一般值, $m = 2, r = 0.15SD$ ^[5]。并且选用与文献[8]相同的 8 对电极, 包括: Fp1-Fp2、F7-F8、F3-F4、T7-T8、P7-P8、C3-C4、P3-P4、O1-O2。

3 结果与分析

本文通过上述三种特征提取算法, 得到了 8 位被试(男女各半, 其他条件均具有可比性)的多尺度熵分析结果。

通过对比多尺度熵算法与改进的多尺度熵算法在各尺度下的正性、中性、负性情感, 可以明显看出改进算法能够很好地区分不同极性的情感, 以 F3 电极为例, 对比图见图 2(a) 和图 2(b)。

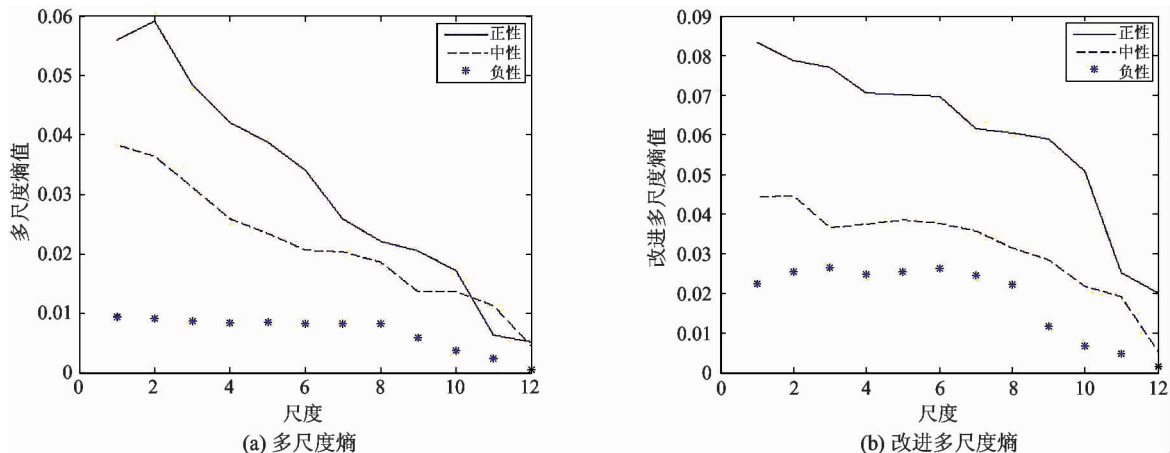


图2 F3电极正、中、负性情感脑电的多尺度熵值和改进多尺度熵值

基于支持向量机分类器,实现了情感特征提取算法效果比较。脑电特征提取算法分别为脑电多尺度熵算法、自适应多尺度熵算法和改进的多尺度熵算法。比较这三种方法的分类准确率,能够明显看出改进方法的结果得到了明显改善,以电极F3为例,分类的平均准确率如表1所示。

表1 不同方法分类准确率的对比

	训练集平均准确率 (%)	测试集平均准确率 (%)
多尺度熵	69.2	56.94
自适应多尺度熵	75.33	62
改进多尺度熵	82.29	69.27

从结果可以看出,改进的多尺度熵算法较多尺度熵算法以及自适应多尺度熵算法训练集和测试集

的分类准确率都有所提高,说明改进的多尺度熵算法在情感脑电识别上较多尺度熵算法和自适应多尺度熵算法的效果更佳。

同时,比较了不同采集位置处改进多尺度熵的分类正确率,如表2所示。总结表2中左右半脑对应电极对(P3与P4、O1与O2、Fp1与Fp2、F7与F8、F3与F4、T7与T8、P7与P8、C3与C4)之间的准确率,结果如表3所示。

从表2、3可以看出,右半脑分类准确率高的电极数较左半脑多,右半脑尤以P4、P8测试集分类正确率最高,可达70%,说明该试验中右脑顶区对情感最为敏感,与相关研究结果一致^[8,10]。从改进的多尺度熵算法与多尺度熵算法、自适应多尺度熵算法以及自适应LZC^[8]方法的分类准确率(P3:42.42%、P4:48.48%、O2:51.52%、F4:45.45%、

表2 不同电极改进算法平均分类准确率的比较

	训练集平均准确率 (%)	测试集平均准确率 (%)		训练集平均准确率 (%)	测试集平均准确率 (%)
P3	85	65	P4	90	70
O1	86.67	60	O2	90	55
Fp1	62.5	56.67	Fp2	59.1	59.1
F7	75	58.33	F8	58.33	58.33
F3	66.67	61.11	F4	70.83	54.17
T7	77.78	55.56	T8	94.72	65.56
P7	100	55	P8	70	70
C3	78.33	57.22	C4	83.33	53.75

表3 左右半球改进的多尺度熵算法分类准确率的比较

左半球	P3	O1	Fp1	F7	F3	T7	P7	C3
		★		★	★			★
右半球	P4	O2	Fp2	F8	F4	T8	P8	C4
	★		★	★		★	★	

注: ★代表分类准确率较高。

C4;54.55%)^[4]的分析结果可知,改进方法在分类准确率上有显著提高,但是对于左右脑分类结果差异不大,右半球对情感的分类稍高于左半球。由神经生理学知识我们知道,人的左右半球功能不同,左半球偏重于理性思维,长于推理,逻辑性较强,而右半球则偏重于感性思维,所以理论上右半球对情感的分类应较左半球更好,本文左右半球对情感的分类差异不是十分显著,归结其原因,可能是因为数据量较小的原因。

4 结 论

本文提出了一种多尺度熵改进算法,并将该算法用于情感脑电特征提取。比较了该多尺度熵改进算法、传统多尺度熵算法、自适应多尺度熵算法在情感脑电分析中的性能。结果表明:改进多尺度熵有效地解决了传统多尺度熵方法在粗粒化过程中成的信息丢失和尺度选择等问题,更能充分提取情感脑电特征,训练集与测试集分类正确率均显著提高,测试集分类正确率由 56.94% 提高到 69.27%。同时,基于以上脑电特征提取算法,分析比较了左右半球情感脑电的反映差异,结果表明:右半球对情感状态分析的分类正确率稍高于左半球,但由于数据量较小的原因,差异并不是十分显著。如何能更充分地提取脑电特征,特别是情感脑电特征,并进一步更好地分析人类情感状态及脑功能状态,是一项有意义的研究工作,也是一项需要长期深入开展的研究工作。

参考文献

- [1] Picard R W. *Affective Computing*. London: MIT Press, 1997
- [2] Daniel A, Roberto H, Pedro E, et al. Analysis of regularity in the EEG background activity of Alzheimer's disease patients with approximate entropy. *Clinical Neurophysiology*, 2005, 116:1826-1834
- [3] Labate D, Foresta F L, Morabito G, et al. Entropic measures of EEG complexity in alzheimer's disease through a multivariate multiscale approach. *IEEE Sensors Journal*, 2013, 13: 3284-3292
- [4] Wu S D, Wu C W, Lee K Y, et al. Modified multiscale entropy for short-term time series analysis. *Physical A*, 2013, 392: 5865-5873
- [5] 倪力,曹建庭,王如彬. 自适应多尺度熵在脑死亡诊断中的应用. *动力学与控制学报*, 2014,12(1):074-078
- [6] Li X L, Cui S Y, Voss L J. Using permutation entropy to measure the electroencephalographic effects of sevoflurane. *Anesthesiology*, 2008, 109(3):448-56
- [7] Li D, Li X L, Liang Z H, et al. Multiscale permutation entropy analysis of EEG recordings during sevoflurane anesthesia. *Neural Eng*, 2010, 7(4):046010
- [8] 张栋,陈东伟,游雅等. 基于自适应 Lempel-Ziv 复杂度的情感脑电信号特征分析. *计算机应用与软件*, 2014, 31(9):162-165
- [9] Koelstra S, Muhl C, Soleymani M, et al. Deap: A database for emotion analysis using physiological signals. *Affective Computing*, 2012, 3(1): 18-31
- [10] 李昕,李红红,李长吾. 基于复杂度熵特征融合的高压力人群情感状态评估. *中国生物医学工程学报*, 2013, 32(3):313-320

An improved multiscale entropy algorithm and its performance analysis in extraction of emotion EEG features

Li Xin^{* ** ***}, Xie Jiali^{**}, Hou Yongjie^{****}, Wang Jinjia^{*****}

(^{*} Institute of Biomedical Engineering, Yanshan University, Qinhuangdao 066004)

(^{**} Measurement Technology and Instrumentation Key Lab of Hebei Province, Qinhuangdao 066004)

(^{***} The College of Life Science and Bio-Engineering, Beijing University of Technology, Beijing 100124)

(^{****} Qinhuangdao Prospect Photoelectric Tech Co., Ltd, Qinhuangdao 066004)

(^{*****} Institute of Information Science and Engineering, Yanshan University, Qinhuangdao 066004)

Abstract

The study on using multiscale entropy to extract emotional EEG features was conducted, and considering that the traditional feature extraction algorithm using multi-scale entropy may result in loss of important information during the coarsening process and the scale selection problem: small-scale causes no significant feature while big-scale causes excessive computation, an improved extraction algorithm based on multi-scale entropy was put forward. The improved algorithm determines scales according to the number of intrinsic mode functions of the adaptive multiscale entropy, and uses the adaptive method to perform the binary-state processing of the EEG signal to highlight the EEG signal's small changes thus the characteristics of the EEG signal can be fully tapped, and the complexity of the algorithm can be reduced. Based on the optimized SVM (support vector machine) classifier, the emotional EEG recognition was achieved by using the international Deap database for emotion analysis, and the performance of the improved algorithm was compared with traditional algorithms. The results indicated that the classification accuracy of the improved algorithm was higher 12.33% compared with the traditional multiscale entropy algorithm, and higher 7.27% compared with the adaptive multiscale entropy algorithm, showing that the improved algorithm is effective for extracting EEG features.

Key words: emotional EEG, multiscale entropy, adaptive multiscale entropy, improved multiscale entropy