

基于变分模态分解的癫痫脑 电信号分类方法

张学军^{1,2}, 景 鹏¹, 何 涛^{1,2}, 孙知信^{3,4}

- (1. 南京邮电大学电子与光学工程学院, 江苏南京 210023;
2. 南京邮电大学射频集成与微组装技术国家地方联合工程实验室, 江苏南京 210023;
3. 南京邮电大学江苏省邮政大数据技术与应用工程研究中心, 江苏南京 210003;
4. 南京邮电大学国家邮政局邮政行业技术研发中心(物联网技术), 江苏南京 210003)

摘 要: 癫痫是一种常见的脑部疾病,通过脑电图能非侵入地定位人脑中的致病区域. 为了辨别病灶性和非病灶性癫痫脑电信号,文章提出一种基于变分模态分解的癫痫脑电信号自动检测方法,首先将原信号分割成多个子信号,并对各子信号进行变分模态分解,然后从分解后的不同变分模态函数中提取精细复合多尺度散布熵和精细复合多尺度模糊熵两个特征并利用支持向量机进行分类. 针对癫痫脑电的公共数据集,最终的实验结果表明,准确率、灵敏度和特异度三个性能指标分别达到 94.24%、95.58% 和 90.64%, ROC 曲线下面积达 0.978.

关键词: 癫痫脑电; 变分模态分解; 精细复合多尺度散布熵; 精细复合多尺度模糊熵; 支持向量机

中图分类号: R318 **文献标识码:** A **文章编号:** 0372-2112 (2020)12-2469-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.12.024

An Epileptic Electroencephalogram Signal Classification Method Based on Variational Mode Decomposition

ZHANG Xue-jun^{1,2}, JING Peng¹, HE Tao^{1,2}, SUN Zhi-xin^{3,4}

- (1. School of Electronic and Optical Engineering, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu 210023, China;
2. Nation-Local Joint Project Engineering Lab of RF Integration & Micropackage, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu 210023, China;
3. Post Big Data Technology and Application Engineering Research Center of Jiangsu Province, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu 210003, China;
4. Post Industry Technology Research and Development Center of the State Posts Bureau (Internet of Things Technology), Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu 210003, China)

Abstract: Epilepsy is a recurrent cerebral disease, and electroencephalogram (EEG) provides a non-invasive way to identify epileptogenic sites in the brain. In order to distinguish focal and non-focal epilepsy EEG signals, this paper proposes an automated epileptic EEG detection method based on variational mode decomposition. Firstly, the original signals are divided into several sub-signals, which are decomposed into intrinsic mode functions by using the variational mode decomposition (VMD). Furthermore, refined composite multiscale dispersion entropy (RCMDE) and refined composite multiscale fuzzy entropy (RCMFE) are extracted from each intrinsic mode function. Finally, the support vector machine (SVM) is used to classify characteristics. For an epilepsy EEG signals' public data set, the final experimental performance measures of accuracy, sensitivity, and specificity reach 94.24%, 95.58% and 90.64% respectively, and the area under the ROC curve is 0.978.

Key words: epileptic electroencephalogram; variational mode decomposition; refined composite multiscale dispersion entropy; refined composite multiscale fuzzy entropy; support vector machine

1 引言

癫痫是一种常见的脑部疾病,据世界卫生组织 2018 年统计当今世界上有超 6000 万人患有癫痫^[1],若能在患癫痫早期就检测出并进行药物治疗有助于康复.脑电图(ElectroEncephaloGraph, EEG)记录了人脑皮层上发出的轻微的电流信号,癫痫发作时人脑中枢神经系统会出现异常使得同步神经元突然放电,从而对应的脑电图就会呈现出异常波动,所以对脑电图的监测可以实现对癫痫的检测.但传统的监测是由医生通过临床经验对脑电图目视检查,由于癫痫发作时间的不确定性、脑电信号的伪迹与医生临床经验等原因,会出现监测时间长,检测效果差,效率低等问题^[2].因此,对脑电图进行自动监测以分辨病灶性和非病灶性癫痫脑电信号,进而实现癫痫自动检测,有助于确定脑内致痫区域,有助于癫痫患者的康复治疗和减轻医生的工作量,提高确诊的准确性.

目前脑电信号分析方法主要有时域分析法、频域分析法、时频分析法、非线性分析法、图论等^[3],其中又以时频分析法和非线性分析法这两种方法应用最多.时频域分析方法主要包括傅里叶变换^[4]、小波变换^[5]、经验模态分解^[6,7]等.经验模态分解作为一种自适应时频处理方法应用较广,但存在端点效应、模态混叠等缺陷^[8].由文献[8]提出的变分模态分解(Variational Mode Decomposition, VMD)是一种新的基于完全非递归思想的时频域信号分析方法,其在不需很高的计算量的情况下,有效改善了经验模态分解的缺陷^[8].非线性分析法主要有高阶矩^[9]、相关维度、概率密度函数参数^[10]、各类熵^[6,11~13]等.近年来, Azami 等人提出了两种新的复杂性度量特征即:精细复合多尺度散布熵(Refined Composite Multiscale Dispersion Entropy, RCMDE)^[14]和精细复合多尺度模糊熵(Refined Composite Multiscale Fuzzy Entropy, RCMFE)^[15],这两种特征作为非线性分析法在处理非线性不平稳生物信号时效果较好,因此在生理医学信号分析中的应用前景十分广阔.

本文将时频分析法与非线性分析法相结合,先将原始癫痫脑电信号进行分割,对分割后的子信号使用 VMD 进行分解,从分解后的变分模态分量中提取 RCMDE 和 RCMFE 两个特征,然后利用支持向量机(Support Vector Machine, SVM)对病灶性和非病灶性信号进行分类,从而实现癫痫脑电信号的自动检测.

2 相关算法

2.1 变分模态分解(VMD)

变分模态分解是一种完全非递归式的时频域信号分析与处理方法,其主要思想是将信号分解成若干个

围绕在各个中心频率附近的窄带变分模态分量,且中心频率不断变化,与经验模态分解通过不断循环筛分获取本征模态函数不同, VMD 通过寻找约束变分模型的最优解自适应获取变分模态函数(Variational Mode Function, VMF).详细求解过程可以参考文献[8],下面仅对 VMD 算法对于脑电信号的变分模型的构造与求解两部分进行简述.

首先,通过以下步骤建立约束变分模型:①通过希尔伯特变换求出每个模态函数的解析信号,进而可以获得脑电信号的单边频谱;②通过一个混合指数项将每个模态函数调制到对应中心频率的基频带上;③通过高斯平滑解调信号计算带宽,也就是求一个梯度二范数的平方根.建立的约束变分模型为:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad \text{s. t.} \quad \sum_k u_k(t) = x \quad (1)$$

其中, x 为脑电信号, $\{u_k\} = \{u_1, u_2, \dots, u_K\}$ 为所有模态的集合, $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_K\}$ 为对应中心频率的集合, $\sum_k = \sum_{k=1}^K$, $\delta(t)$ 为冲激函数, ∂t 为对 t 求偏导.

然后对约束变分模型求最优解.因为约束变分问题不易求最优解,所以先将拉格朗日乘法算子以及二次惩罚项加入到约束变分模型中,从而将约束变分模型转化为一个非约束变分模型,得到的增广拉格朗日函数为:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| x(t) - \sum_k u_k(t) \right\|_2^2 + [\lambda(t), x(t) - \sum_k u_k(t)] \quad (2)$$

其中 $\lambda(t)$ 为拉格朗日乘法算子, α 为惩罚因子, $\left\| x(t) - \sum_k u_k(t) \right\|_2^2$ 为二次惩罚项.

最后通过乘法算子交替方向法不断更新 u_k^{n+1} 、 ω_k^{n+1} 和 λ^{n+1} , 求解式(2)的最优解即极值,并通过傅立叶变化得到频域中模态函数和中心频率的更新表达式分别为:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{x}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (4)$$

其中, n 为迭代次数.

2.2 精细复合多尺度散布熵(RCMDE)

精细复合多尺度散布熵是文献[14]在散布熵的基

础上对信号进行多尺度量化得到的,避免了散布熵因单一尺度上处理信号会出现复杂性特征提取不完全等问题.求解 RCMDE 的步骤为:

步骤 1 假设脑电信号 x 经变分模态分解后得到的信号 u_k 是长度为 Ψ 的时间序列,则 u_k 的第 h 个粗粒度近似信号为:

$$a_{h,\gamma}^\tau = \frac{1}{\tau} \sum_{\chi=h+(\gamma-1)\tau}^{h+\gamma\tau-1} u_{k,\chi} \quad (5)$$

其中, $\gamma = \{1, 2, \dots, N\}$, $N = \frac{\Psi}{\tau}$, τ 为尺度因子.

步骤 2 使用正态累积分布函数将粗粒度近似信号 a 映射到 $b = \{b_1, b_2, \dots, b_N\}$ 上:

$$b_\gamma^\tau = \frac{1}{\sigma \sqrt{2\pi}} \int_{-\infty}^{a_\gamma^\tau} e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt \quad (6)$$

其中, μ 表示均值, σ 表示粗粒度近似 a 的标准差. b 的范围从 0 到 1.

步骤 3 将 b 以线性变换的形式映射到 $\{1, 2, \dots, c\}$ 中,记为 z ,即

$$z_\gamma^c = R(c \cdot b_\gamma + 0.5) \quad (7)$$

其中 $R(\cdot)$ 是取整运算, c 代表类别个数.

步骤 4 若嵌入维数标记为 m 和时间延迟标记为 d ,则时间序列 $z_i^{m,c}$ 定义为:

$$z_i^{m,c} = \{z_i^c, z_{i+d}^c, \dots, z_{i+(m-1)d}^c\} \quad (8)$$

其中 $i = \{1, 2, \dots, N - (m-1)d\}$.

步骤 5 设每一个时间序列 $z_i^{m,c}$ 对应一个散布模式 $\Theta_{v_0^c, \dots, v_{m-1}^c}$, 其 $z_i^c = v_0, z_{i+d}^c = v_1, z_{i+(m-1)d}^c = v_{m-1}$, 计算每个散布模式 $\Theta_{v_0^c, \dots, v_{m-1}^c}$ 的概率

$$p(\Theta_{v_0^c, \dots, v_{m-1}^c}) = \frac{\#(\Theta_{v_0^c, \dots, v_{m-1}^c})}{N - (m-1)d} \quad (9)$$

其中 $\#(\Theta_{v_0^c, \dots, v_{m-1}^c})$ 为 $z_i^{m,c}$ 对应散布模式的个数.

步骤 6 根据香农熵的定义,信号 u_k 的精细复合多尺度散布熵为:

$$\text{RCMDE}(u_k, m, c, d, \tau) = - \sum_{\Theta=1}^{c^m} \bar{p}(\Theta_{v_0^c, \dots, v_{m-1}^c}) \ln \bar{p}(\Theta_{v_0^c, \dots, v_{m-1}^c}) \quad (10)$$

其中, $\bar{p}(\Theta_{v_0^c, \dots, v_{m-1}^c}) = \frac{1}{\tau} \sum_{t=1}^{\tau} p_h^\tau$ 表示粗粒度近似信号 a 的散布模式 Θ 的平均值.

2.3 精细复合多尺度模糊熵 (RCMFE)

精细复合多尺度模糊熵是在模糊熵的基础上对信号进行多尺度量化得到的.文献[15]详细介绍了 RCMFE 的原理,这里仅简述其计算步骤:

步骤 1 假设脑电信号 x 经变分模态分解后得到的信号 u_k 是长度为 Ψ 的时间序列,则 u_k 的第 h 个粗粒度近似信号为:

$$a_{h,\gamma}^\tau = \sqrt{\frac{1}{\tau} \sum_{\chi=h+(\gamma-1)\tau}^{h+\gamma\tau-1} (u_{k,\chi} - \mu_h)^2} \quad (11)$$

其中, $\mu_h = (\sum_{\chi=h+(\gamma-1)\tau}^{h+\gamma\tau-1} u_{k,\chi}) / \tau$, $\gamma = \{1, 2, \dots, N\}$, $N = \frac{\Psi}{\tau}$, τ 为尺度因子.

步骤 2 与 RCMDE 一样,利用式(6)将其映射到 $b = \{b_1, b_2, \dots, b_N\}$ 上.

步骤 3 对于给定时刻 t ,定义一个新的复合延迟向量:

$$U_t^m = \{b_t, b_{t+1}, \dots, b_{t+m-1}\} - b0_t \quad (12)$$

其中, $b0_t = \sum_{\gamma=0}^{m-1} (b_{t+\gamma}/m)$, m 为嵌入维度.

步骤 4 复合延迟向量 $U_{t_1}^m$ 与 $U_{t_2}^m$ 之间的距离定义为:

$$d_{t_1, t_2} = d[U_{t_1}^m, U_{t_2}^m] = \max \{ |U_{t_1+h}^m - U_{t_2+h}^m| : 0 \leq h \leq m-1, t_1 \neq t_2 \} \quad (13)$$

步骤 5 假设给定模糊权值 n 以及相似容限 r ,则定义复合延迟向量 $U_{t_1}^m$ 与 $U_{t_2}^m$ 之间相似度为:

$$D_{t_1, t_2} = \mu(d_{t_1, t_2}, n, r) \quad (14)$$

其中, $\mu(d_{t_1, t_2}, n, r)$ 叫做模糊关系函数且 $\mu(d_{t_1, t_2}, n, r) = e^{-\frac{(d_{t_1, t_2})^n}{r}}$.

步骤 6 定义一个函数 ϕ^m ,表示在嵌入维数 m 中任意两个复合延迟向量相同的概率:

$$\phi^m(b, n, r) = \frac{1}{N-m} \sum_{t_1=1}^{N-m} \frac{1}{N-m-1} \sum_{t_2=1, t_1 \neq t_2}^{N-m} D_{t_1, t_2} \quad (15)$$

步骤 7 信号 u_k 的精细复合多尺度模糊熵定义为:

$$\text{RCMFE}(u_k, n, \tau, m, r) = - \ln \frac{\bar{\phi}^{m+1}}{\bar{\phi}^m} \quad (16)$$

其中, $\bar{\phi}^m = \frac{1}{\tau} \sum_{t=1}^{\tau} \phi_t^m$ 为 ϕ^m 在 t 下的平均值.

3 方法

本文提出的研究方法整体流程如图 1 所示,首先将经过 0.5 ~ 100Hz 带通滤波器预处理后的癫痫脑电数据集分割成 q 段不同的子数据集,然后将所有子数据集分别进行 K 重 VMD 分解,得到每个子数据集的 K 个变分模态函数 VMF,然后从每个 VMF 中获取 RCMDE 和 RCMFE 两个特征,并将其输入到支持向量机,从而完成对病灶性脑电信号和非病灶性脑电信号的区分.

3.1 数据集描述

本文所使用的癫痫脑电信号数据集是来自瑞士伯尔尼大学神经科提供的一个公共数据集^[16].该数据集数据采自 5 位患有颞叶病灶癫痫的病人,共包括 3750 对病灶性数据段和 3750 对非病灶性数据段,每个数据段包含两列数据,分别采自同一个区域相邻的两个通道.数据段的采样频率为 512Hz,时间为 20s.本文选用该数据集中 1000 对病灶性脑电数据段和 1000 对非病灶性脑电数据段作为实验数据.一方面,因为本方法计




图1 本文研究方法流程图

算量较大,为了减少计算量,节约计算成本;另一方面,在同类研究文献也多取部分样本数便可以得出结论,如文献[11]选取前 50 对病灶性脑电数据段和前 50 对非病灶性脑电数据段,文献[17]选择 750 对数据段,故本文选用该数据集中前 1000 对病灶性脑电数据段和 1000 对非病灶性脑电数据段作为实验数据,其余数据段用于模型检测。

3.2 EEG 数据段分割

首先将原始数据经过 0.5 ~ 100Hz 的带通滤波器进行预处理,从而去除部分伪迹与噪声。

然后将每对时长为 20s 的数据段分割为时长均为 1s 的子数据段,且相邻两个子数据段之间的时间重叠率为 50%,因此每个数据段共分割为 39 个子数据段,即 $q=39$ 。之所以需要将原始数据进行分割,第一是因为 VMD 算法在处理长时间非平稳非线性的脑电信号时具有一定的局限性,而将信号分割为短时间的子信号,可一定程度规避这种模式的谱带随时间剧烈变化造成分解效果差的局限性^[8]。第二是因为可以减小脑电数据中随机波动点的影响,比如假设某数据段中由于噪声等原因出现数个非预期的随机波动点,若对整个数据段进行分析显然这些点会影响最终分析结果,而对若干子数据段进行分析,这些点只会影响部分子数据段的分析结果,而对最终所求结果的影响将降低。

3.3 特征提取

3.3.1 VMD 分解

脑电信号各频段中,因为测试时间不同以及测试人的不同,其中心频率会随着神经活动而发生轻微的变化,简单的固定中心频率的带通滤波无法消除这种变化的影响,而 VMD 旨在将信号分解为围绕在中心频率附近的变分模态分量,即变分模态函数 VMF,且其中心频率是不断迭代变化的,故可以捕捉到这种变化。VMD 算法在对信号进行分解之前需要分别设定:分解模态的个数 K 以及惩罚因子 α 两个参数。对于惩罚因子 α ,其值过大会引起模态重叠,较小会引入噪声^[17],所以根据文献[17]的建议本文将其设定为 2000。对于分解模态数 K ,若 K 值过大会造成过分解,产生无用分量,也会增加计算复杂度,若 K 值过小会造成欠分解,使部分带限信号分解不出来造成原信号信息的丢失,进而影响分析结果。为寻求合适的 K 值,本文先随机选择一对病灶性脑电数据段,并分别进行三重、四重、五重变分模态分解,即将 K 值分别设为 3、4、5。

图 2 所示为不同 K 值下,各个变分模态函数分量其中心频率 ω 随迭代次数的变化曲线。从图中可以看出,当 K 为 3 时,变分模态函数 VMF1 ~ VMF3 的中心频率均在 40Hz 以下。当 K 为 4 时,变分模态函数 VMF1 ~ VMF3 的中心频率仍在 40Hz 以下,VMF4 虽然在迭代次数较少时有部分超过 50Hz,但随着迭代次数的增加其中心频率仍稳定在 50Hz 以下。当 K 为 5 时,可以看到 VMF5 的中心频率超过了 50Hz。一方面由于脑电活动的信息大都包含在低频带(频率 < 50Hz),另一方面为了防止过分解或欠分解,故本文选取 K 值为 4。

3.3.2 提取特征 RCMDE 和 RCMFE

由式(9)可以看出,计算 RCMDE 需要分别设置:类别个数 c ,嵌入维度 m ,时间延迟 d 以及尺度因子 τ 等四个参数。类别个数 c 若过大会导致具有较大差异的两个量被归为同一类,过小则导致具有较小差异的两个量被归为不同类,根据文献[14]的建议,此处将 c 值设为 6。对于嵌入维度 m ,为了保证统计可靠性,文献[14]中建议 $c^m < \Psi$,其中 Ψ 为数据长度,本文将原来采样率是 512Hz,采样时间是 20s 的数据段分割为时长为 1s 的子数据段,因此 $\Psi=512$,而 $6^4=1296 > \Psi$,故将 m 值设为 3。时间延迟 d 一般取 1,本文尺度因子 τ 设为 3,即每个数据段提取三个尺度上的 RCMDE 值。

同样,由式(14)可以看出计算 RCMFE 需要设置:嵌入维度 m ,相似容限 r ,模糊权值 n 和尺度因子 τ 等四个参数。嵌入维度 m 和尺度因子 τ ,与 RCMDE 一样,本文设置为 3。相似容限 r 决定匹配的相似性,其值越大将会丢失越多数据信息,越小则对噪声越敏感,因此文献[15]建议 r 一般为 SD(原数据的标准差)的 0.1 ~





图2 不同K值下中心频率随迭代次数的变化

0.25 倍,本文设置 $r = 0.15SD$. 对于模糊权重 n ,其影响相似容限边界的梯度,本文设置为 2.


图 3 是一对病灶和非病灶脑电数据经过变分模态分解后四个 VMF 下的 RCMDE 与 RCMFE 特征箱型图,其中 F 表示病灶性脑电,NF 表示非病灶性脑电,D1、D2、D3 表示 RCMDE 在尺度因子为 3 的情况下的三重特征,F1、F2、F3 表示 RCMFE 在尺度因子为 3 的情况下的三重特征.从箱型图中,可以看出对于病灶性脑电数据和非病灶性脑电数据,在不同的 VMF 和不同的尺度因子下,两个特征 RCMDE 与 RCMFE 的中位数以及分布区间都是不同的.因此,RCMDE 与 RCMFE 可以作为区别病灶性和非病灶性癫痫脑电数据的分类特征.

4 实验结果与分析

选用 1000 对病灶性癫痫脑电数据段和 1000 对非病灶性癫痫脑电数据段,按上述方法进行处理,并将得到的每段脑电数据的 RCMDE 与 RCMFE 特征送入 SVM 进行特征分类,SVM 的选用线性核函数,通过网格搜索法将惩罚参数设定为 0.48,并重复进行 10 次 5 折交叉验证实验,结果取 10 次实验的平均值.采用准确度、灵敏度和特异度这三个指标对最终分类结果进行度量,



(a)精细复合多尺度散布熵特征箱型图



(b)精细复合多尺度模糊熵特征箱型图

图3 一对病灶和非病灶脑电数据各VMF提取RCMDE和 RCMFE特征箱型图

其结果如表 1 所示.

表 1 不同特征下的分类结果

特征	灵敏度/%	特异度/%	准确率/%
RCMDE	89.49	87.56	88.12
RCMFE	82.63	87.25	84.94
RCMDE + RCMFE	95.58	90.64	94.24

从表 1 可以看出单一特征时,RCMDE 相比 RCMFE 而言,拥有更好的分类效果.两个特征共同作为分类特征时,分类准确率达到 94.24%.图 4 所示为两个特征分类的受试者工作 (Receiver Operating Characteristic, ROC) 曲线,其曲线下面积 (Area Under Curve, AUC) 为 0.978.

此外,为了验证本文方法的有效性,将数据集中剩余的 2750 对数据段重复进行实验,结果显示准确率、灵敏度和特异度分别为 94.12%、95.34% 和 91.06%,ROC 曲线下面积为 0.972.可见,与选择 1000 对数据段时结果基本吻合,证明了本文方法是有效的.

对相同的癫痫脑电信号数据集,将本文方法得到的结果与其他文献的结果相比较,比较结果如表 2 所

示,可以看出本文所提方法的特异度为 90.64% 略低于 94.24%,较其他文献有显著的提高,故本方法性能优于文献[18]和文献[19],但灵敏度为 95.58%、准确度为 其他方法。

表 2 本文方法分类效果与其他方法比较

	提取方法	特征	分类器	灵敏度、特异度、准确度(%)
Sharma ^[6] (2015)	经验模态分解	平均香农熵、样本熵等	LSSVM	90、84、87
Abhijit ^[11] (2017)	TQWT	模糊熵	LSSVM	83.86、85.46、84.67
Chatterjee ^[18] (2017)	MF DFA	多重分形	SVM	92.5、92.7、92.2
Bhattacharyya ^[19] (2018)	EWT	RPS、CTM	LSSVM	88、92、90
本文	VMD	RCMDE、RCMFE	SVM	95.58、90.64、94.24




图4 ROC曲线

5 结论

本文提出一种基于变分模态分解,从分解后的VMF中提取RCMDE和RCMFE两个特征,并利用支持向量机对其进行分类的癫痫脑电信号自动检测方法.应用本文提出的方法对公共癫痫脑电数据集进行处理,得到最终准确率为94.24%,灵敏度95.58%,特异度90.64%,ROC曲线下面积0.978,并与针对同一公共数据集的其他处理方法进行比较,证明了该方法的有效性.

本文利用数据分割思想解决了变分模态分解处理长时间不规则非平稳脑电信号的局限性,利用各个VMF中心频率随迭代次数的变化确定了变分模态分解的分解层数 K ,从而避免了过分解与欠分解现象,降低了计算量,此外,利用特征的箱型图说明了RCMDE与RCMFE这两个特征在癫痫脑电信号分类中的适用性.

参考文献

[1] World Health Organization. Epilepsy[EB/OL]. <http://www.who.int/news-room/fact-sheets/detail/Epilepsy>. 2018-08-02.

[2] Verhellen E, Boon P. EEG source localization of the epileptogenic focus in patients with refractory temporal lobe epilepsy, dipole modelling revisited[J]. Acta Neurologica Bel-

gica, 2007, 107(3): 71–77.

- [3] 张瑞, 宋江玲, 胡文凤. 癫痫脑电的特征提取方法综述[J]. 西北大学学报(自然科学版), 2016, 46(06): 781–788.
- ZHANG Rui, SONG Jiang-ling, HU Wei-fang. A review of feature extraction methods for epileptic EEG[J]. Journal of Northwest University (Natural Science Edition), 2016, 46(06): 781–788. (in Chinese)
- [4] Kiymi M, Guler Inan, Dizibuyuk, et al. Comparison of STFT and wavelet transform methods in determining epileptic seizure activity in EEG signals for realtime application[J]. Computers in Biology and Medicine, 2005, 35(7): 603–616.
- [5] Rajeev S, Ram P, Acharya U. An integrated index for the identification of focal electroencephalogram signals using discrete wavelet transform and entropy measures[J]. Entropy, 2015, 17(12): 5218–5240.
- [6] Sharma R, Pachori R, Acharya U. Application of entropy measures on intrinsic mode functions for the automated identification of focal electroencephalogram signals[J]. Entropy, 2015, 17(2): 669–691.
- [7] Das A, Bhuiyan M. Discrimination and classification of focal and nonfocal EEG signals using entropy based features in the EMD-DWT domain[J]. Biomedical Signal Processing and Control, 2016, 29: 11–21.
- [8] Dragomiretskiy K, Zosso P. Variational mode decomposition[J]. IEEE Trans Signal Process, 2014, 62(3): 531–544.
- [9] Alam S, Bhuiyan M. Detection of seizure and epilepsy using higher order statistics in the EMD domain[J]. IEEE Journal of Biomedical and Health Informatics, 2013, 17(2): 312–318.
- [10] Das A, Bhuiyan M. Classification of EEG signal using normal inverse Gaussian parameters in the dualtree complex wavelet transform domain for seizure detection[J]. Signal, Image and Video Processing, 2016, 10(2): 259–266.
- [11] Abhijit B, Ram P. Tunable-Q wavelet transform based multivariate sub-band fuzz entropy with application to focal EEG signal analysis[J]. Entropy, 2017, 19(3): 1–14.

- [12] 高军峰, 司慧芳, 余彬. 基于脑电样本熵的测谎分析[J]. 电子学报, 2017, 45(08): 1836 – 1841.
GAO Jun-feng, SI Hui-fang, YU Bin. Lie detection analysis based on the sample entropy of EEG[J]. Acta Electronica Sinica, 2017, 45(08): 1836 – 1841. (in Chinese)
- [13] 席旭刚, 左静, 罗志增. 肌电模糊熵特征的加权核 FDA 跌倒识别[J]. 电子学报, 2016, 44(06): 1376 – 1382.
XI Xu-gang, ZUO Jing, LUO Zhi-zeng. Weighted kernel FDA fall recognition of EMG fuzzy entropy[J]. Acta Electronica Sinica, 2016, 44(06): 1376 – 1382. (in Chinese)
- [14] Azami H, Rostaghi M, Abasolo D, et al. Refined composite multiscale dispersion entropy and its application to biomedical signals[J]. IEEE Transactions on Biomedical Engineering, 2017, 64(12): 2872 – 2879.
- [15] Azami H, Fernandez A, Escudero J. Refined multiscale fuzzy entropy based on standard deviation for biomedical signal analysis[J]. Medical & Bioengineering & Computing, 2016, 55(11): 2037 – 2052.
- [16] Andrzejak R G, Schindler K, Rummel C. Nonrandomness, nonlinear dependence, and nonstationarity of electroencephalographic recordings from epilepsy patients[J]. Physical Review E, 2012, 86(4): 046206.
- [17] Taran S, Bajaj V. Clustering variational mode decomposition for identification of focal EEG Signals[J]. IEEE Sensors Letters, 2018, 2(4): 1 – 4.
- [18] Chatterjee S, Pratiher S, Bose R. Multifractal detrended fluctuation analysis based novel feature extraction technique for automated detection of focal and non-focal EEG signals[J]. IET Science Measurement & Technology, 2017, 11(8): 1014 – 1021.
- [19] Bhattacharyya A, Sharma M, Pachori R, et al. A novel approach for automated detection of focal EEG signals using empirical wavelet transform[J]. Neural Computing and Applications, 2018, 29(8): 47 – 57.

作者简介



张学军 男, 1969 年生于江苏南通. 工学博士. 现为南京邮电大学教授, 硕士生导师. 研究方向为智能信息处理、认知网络频谱感知、深度学习等.

E-mail: zhxj@njupt.edu.cn



景 鹏 男, 1995 年生于江苏泰州. 硕士研究生. 研究方向为智能信息处理、脑机接口技术.

E-mail: japee@foxmail.com