

基于 DD-DWT 和 Log-Logistic 参数回归的 癫痫脑电自动识别方法^{*}

李明阳, 陈万忠, 张 涛

(吉林大学通信工程学院 长春 130012)

摘 要:针对现有癫痫脑电(EEG)识别算法分类模式单一、普适性不强的问题,提出了一种新的基于双密度离散小波变换(DD-DWT)和 Log-Logistic 参数回归(LLPR)的脑电信号自动识别方法。不仅利用了 DD-DWT 算法的分解特性,还建立了脑电信号的 LLPR 模型,并将二者有机的结合,从而更好的发挥算法的优势。滤波后脑电信号由 DD-DWT 进行 6 层分解,提取各子频带系数的小波域能量波形,并结合 LLPR 模型计算尺度参数 α 和形状参数 β 以表征信号,将构成的特征向量送入遗传算法(GA)优化的支持向量机(SVM)得出识别结果,从而实现脑电信号的自动识别。所提方法在处理 A\D\E 与 AB\CD\E 两种多模式脑电分类问题时,识别率分别为 98.90% 和 97.75%。实验结果表明,所提算法更符合实际应用需求,可以较好地解决多类脑电信号识别问题,具有良好的普适能力和分类性能。

关键词: 癫痫;脑电;双密度离散小波变换;Log-Logistic 参数回归模型

中图分类号: TH79 文献标识码: A 国家标准学科分类代码: 510.40

Automatic epilepsy EEG recognition method based on DD-DWT and Log-Logistic parameter regression

Li Mingyang, Chen Wanzhong, Zhang Tao

(Department of Communication Engineering, Jilin University, Changchun 130012, China)

Abstract: Aiming at the problems of single classification mode and poor universality of existing epilepsy EEG recognition algorithms, a novel EEG signal automatic recognition method is proposed based on Double-Density Discrete Wavelet Transform (DD-DWT) and Log-Logistics parameter regression (LLPR). This method not only utilizes the decomposition capacity of DD-DWT algorithm, but also constructs the LLPR model for EEG signal, integrates the two algorithms organically, and fully exploits the advantages of the two algorithms. In this study, the filtered EEG signals are decomposed into six levels with DD-DWT, and the wavelet coefficients of various sub-bands are transformed to the energy waveforms in wavelet domain to acquire the feature parameters using the LLPR model. The scale parameter α and shape parameter β are calculated to characterize the EEG signal. The feature parameters extracted from all the sub-bands are composed as the eigenvalues, which are fed to support vector machine (SVM) optimized with genetic algorithm (GA) to obtain the final classification results, thus the EEG signal automatic recognition is achieved. When the proposed method was used to deal with two multi-mode EEG classification problems of A\D\E and AB\CD\E, the satisfied accuracies of 98.9% and 97.75% were obtained respectively. Experiment results indicate that the proposed method can meet the actual application requirement, is more appropriate for solving the recognition problems of multi-class EEG signals, has good universality and classification performance, and has great value in practical applications dealing with epileptics.

Keywords: epilepsy; electroencephalogram (EEG); double-density discrete wavelet transform (DD-DWT); Log-Logistic parameter regression (LLPR) model

1 引言

癫痫病是由脑部突然异常放电所引起的脑功能失常,是神经系统疾病中仅次于脑血管疾病的第二大顽症,常会反复、突发性发作^[1-2]。据统计,全球大约有 5 000 万人被诊断为癫痫症,而我国现有癫痫患者近 600 万,并以每年 27 万的速率增长。癫痫发病具有突然性和反复性,不仅对大脑损伤极大,严重时甚至危及生命。脑电 (electroencephalogram, EEG) 信号是脑神经细胞群电生理活动在大脑皮层或头皮表面的总体反映,蕴涵着丰富的生理、心理及病理信息,是临床上诊断癫痫病的有效手段^[3]。传统的癫痫检测主要依靠临床病史和视觉检测脑电图的人工方法,该方法检测时间长、效率低,并且根据医生的临床经验判断容易出现不一致的判断情况^[4]。因此,寻求一种高效、可靠的自动检测方法不仅可以减轻医生的工作量,还可以使患者得到及时、有效的治疗^[5]。

近年来,癫痫 EEG 信号自动检测技术受到了广泛关注,很多专家在这一领域做了大量研究。目前,常用的 EEG 信号分析方法主要有时域分析法、频域分析法、时频域分析法和非线性动力学分析法。由于脑电信号具有非线性、非平稳且随机性强的特点^[6],时频分析结合非线性分析的方法成为当前的脑电研究热点。文献[7]将小波变换和近似熵结合,利用神经网络分类正常和癫痫发作期两类 EEG 信号,识别率可达 99.8%;类似地,文献[8]提出一种基于小波变换和模糊熵的分析法,并将该方法用于分类癫痫发作间歇和发作期脑电信号,取得了 95.85% 分类正确率;文献[9]进一步应用小波包变换并结合多种非线性特征分析正常、发作间歇、癫痫发作期 EEG 信号,识别率为 98%。随着研究的深入,人们对算法的要求也不再仅集中于识别率方面,还包括分类效率和分类多样性。因此,多数现有算法并不能满足实际的应用需求。

本文提出一种基于双密度离散小波变换 (double-density discrete wavelet transform, DD-DWT) 和 Log-Logistic 参数回归 (Log-Logistic parameter regression, LLPR) 的癫痫 EEG 信号自动识别方法。作为小波变换的一种改进算法,DD-DWT 克服了传统离散小波变换 (discrete wavelet transform, DWT) 对输入数据敏感、抗混叠性差的缺点,具有近似的平移不变性和冗余量小等优点,能够更加精准地捕捉信号的细节特征,已成功用于图像处理^[10]和信号去噪^[11]等领域。LLPR 属于概率型非线性回归模型,是分析反应变量为独立分类资料的常用统计分析方法,在数据分析方面有着非常广泛的应用。然而,在癫痫脑电信号检测方面,DD-DWT 和 LLPR 均未见具体应用。

利用 DD-DWT 对信号进行时频分解后,采用 LLPR

模型提取特征,并由支持向量机 (support vector machine, SVM) 分类器识别结果。本研究旨在提出一种分类性能高、普适性好的癫痫 EEG 信号检测算法,同时探索脑电信号 LLPR 模型的搭建。实验结果表明,所提算法可以较好地处理多分类脑电问题且具有很好的分类多样性,具有较高的临床应用价值。

2 基本原理

2.1 双密度离散小波变换

DD-DWT 是 Selesnick I. V.^[12] 在 2001 年提出的一种新的离散小波分析方法。DD-DWT 突破了传统的离散小波变换在信号描述方面的限制,有着有近似的平移不变性、良好的抗混叠和冗余量小等特性,能够更加准确地捕捉信号的细节特征。

与传统小波变换的单一小波函数组成形式不同,DD-DWT 采用彼此间偏移量为 0.5 个单位的双小波函数构成方式,缩小了同一个尺度内两小波间的频带间隔,这就大大降低其对平移的敏感性^[11]。DD-DWT 的尺度函数 $\varphi(t)$ 和两个小波函数 $\psi_1(t)$ 和 $\psi_2(t)$ 之间关系为:

$$\varphi(t) = \sqrt{2} \sum_n h_0(n) \varphi(2t - n) \tag{1}$$

$$\psi_i(t) = \sqrt{2} \sum_n h_i(n) \varphi(2t - n) \quad i = 1, 2 \tag{2}$$

式中: h_0 是低通滤波器, h_1 和 h_2 是高通滤波器。令:

$$\phi_k = \varphi(t - k) \tag{3}$$

$$\psi_{1,j,k}(t) = \psi_1(2^j t - k) \tag{4}$$

$$\psi_{2,j,k}(t) = \psi_2(2^j t - k) \tag{5}$$

式中: k 和 j 均为整数,则任意平方可积信号 $f(t)$ 可以表述为:

$$f(t) = \sum_{k=-\infty}^{\infty} c(k) \phi_k(t) + \sum_{i=1}^2 \sum_{j=0}^{\infty} \sum_{k=-\infty}^{\infty} d_i(j, k) \psi_{i,j,k}(t) \tag{6}$$

根据式(6),低频系数 c 和高频系数 d 可以扩展表示为:

$$c(k) = \int f(t) \phi_k(t) dt \tag{7}$$

$$d_i(j, k) = \int f(t) \psi_{i,j,k}(t) dt \quad i = 1, 2 \tag{8}$$

图 1 所示为 3 层 DD-DWT 分解示意图。从图 1 中可知,由于 DD-DWT 的双小波函数结构,信号经过 3 通道的滤波器系统 h_0, h_1 和 h_2 分解后,每一层都会得到 2 个高频系数和 1 个低频系数,而低频系数会进一步分解以完成确定层数的分解。利用 DD-DWT 精确的分解能力将 EEG 信号分为若干细节分量,为接下来的特征提取奠定良好的基础。

2.2 LLPR 模型

Log-Logistic 回归是一种概率型非线性回归模型,可




图 1 三层 DD-DWT 分解流程

Fig. 1 Procedure of a 3-level DD-DWT decomposition

同时分析包含连续变量和离散变量的多个自变量,并能有效地分析自变量之间的相互作用,多被用于经济学^[13]和心理学领域^[14]。Log-Logistic 回归模型对非线性和离散数据具有很好的定量描述能力,且计算复杂度低、耗时少。因此,该方法可以被拓展用于 EEG 信号的分析中。本文尝试搭建 EEG 信号的 LLPR 模型,并将其用于癫痫 EEG 自动检测。

对连续非负随机变量 x ,其 Log-Logistic 分布的累积分布函数 $F(x)$ 和概率密度函数 $f(x)$ 定义为:

$$F(x;\alpha,\beta) = \frac{1}{1 + (x/\alpha)^{-\beta}} \tag{9}$$

$$f(x;\alpha,\beta) = \frac{(\beta/\alpha)(x/\alpha)^{\beta-1}}{(1 + (x/\alpha)^{\beta})^2} \tag{10}$$

式中: α 是尺度参数, β 是形状参数,且 α 和 β 均为正数。

最大似然估计因其优越的统计特性而成为主流的参数估计方法。据此,应用最大似然估计法建立 EEG 信号的 LLPR 模型,则 Log-Logistic 回归模型的对数似然函数可写作:

$$L(\alpha,\beta | x_1, \dots, x_n) = n\log\beta - n\log\alpha + (\beta - 1) \sum_{i=1}^n (\log x_i - \log\alpha) - 2 \sum_{i=1}^n \ln\left(1 + \left(\frac{x_i}{\alpha}\right)^{\beta}\right) \tag{11}$$

式(11)的求解可化为求解得分方程:

$$\frac{\partial L(\alpha,\beta)}{\partial \alpha} = 0 \tag{12}$$

$$\frac{\partial L(\alpha,\beta)}{\partial \beta} = 0 \tag{13}$$

整理上述两个得分方程,则参数 α 和 β 可以通过下式得出:

$$2 \sum_{i=1}^n \frac{(x_i/\alpha)^{\beta}}{1 + (x_i/\alpha)^{\beta}} = n \tag{14}$$

$$2\beta \sum_{i=1}^n \frac{(x_i/\alpha)^{\beta} \ln(x_i/\alpha)}{1 + (x_i/\alpha)^{\beta}} - \beta \sum_{i=1}^n \ln(x_i/\alpha) = n \tag{15}$$

利用牛顿-拉普森方法求解上面方程,得出参数 α 和 β 的估计值。图 2 和 3 分别为不同 α 和 β 的数值组合下 Log-Logistic 累积分布函数和概率密度函数示意图。从图中可以看出, α 和 β 是影响 Log-Logistic 分布的两个重要参数,决定了 Log-Logistic 的分布形态。反过来,若假设

某一 EEG 序列服从标准 Log-Logistic 分布,那么存在一组特定的 α 和 β 的组合使该 EEG 序列近似的呈现出 Log-Logistic 分布形态。这样, α 和 β 就可以看作该 EEG 序列的特征参数,表征了 EEG 信号在 Log-Logistic 分布下形态信息和统计信息。因此,提出了基于 LLPR 模型的特征提取算法,探索统计分布模型在 EEG 信号识别领域的应用和搭建。




图 2 Log-Logistic 累积分布函数示意图

Fig. 2 Schematic diagram of the cumulative distribution function of Log-Logistic




图 3 Log-Logistic 概率密度函数示意图

Fig. 3 Schematic diagram of the probability density function of Log - Logistic

2.3 SVM 分类器

SVM 是由 Vapnik 等人在统计学习理论上发展起来的算法^[15],是目前应用最为广泛的分类器之一。其基本思想是将待分类的点映射到“高维空间”,并在空间中寻找一个最优超平面,使距离该平面最近的不同类样本集之间的间隔最大。在 SVM 算法中,核函数是实现输入空间中线性不可分向量转换为输出空间中线性可分向量的关键。

常用的核函数主要有 3 种:多项式函数、径向基函数、Sigmoid 函数。其中径向基函数具有较宽的收敛域,并有研究表明,基于径向基函数的 SVM 更适用于

EEG 信号的分类研究^[9]。因此采用径向基函数作为核函数,则其表达式为:

$$K(\mathbf{x}, \mathbf{x}_i) = \exp\left\{-\frac{|\mathbf{x} - \mathbf{x}_i|^2}{\sigma^2}\right\}$$

(16)

式中: $\mathbf{x}$ 为输入向量, $\mathbf{x}_i$ 为训练向量, σ 为径向基核函数参数。

在 SVM 的应用过程中,核函数参数 σ 和惩罚因子 C 设置过大或过小均会对系统的计算精度产生一定的影响。因此,本文采用遗传算法 (genetic algorithm, GA) 对 SVM 参数进行优化,获取推广能力良好的 SVM 模型,避免人工选取参数的主观性影响。GA 是一种模拟自然选择和遗传机制的寻优方法,可以在全局范围内搜索最优参数。基于遗传算法优化的 SVM 分类器实施流程如图 4 所示。




图4 基于遗传算法优化的 SVM 实施流程
Fig. 4 Implementation procedure of the genetic algorithm optimized SVM

综上,所提出的癫痫 EEG 信号自动识别方法流程可总结如图 5 所示。首先,EEG 信号经滤波后由 DD-DWT 进行 6 层分解,并取各层分解系数的小波域能量;其次,利用已搭建的 LLPR 模型估计各子频带能量波形的尺度参数 α 和形状参数 β ;最后,由优化的 SVM 分类器判别信号模式并输出识别结果。整个算法不需人工干预,完全由计算机自动操控,提高工作效率的同时还避免了人工判别的主观性影响。




图5 本文算法的流程
Fig. 5 Process of the proposed method

3 实验结果与分析

3.1 数据说明

为了更好地反映实验的客观性,数据取自德国波恩癫痫研究室的癫痫数据库^[16],该数据集具有很高的公信力并被广泛用于癫痫识别领域。EEG 信号数据集由 Set A-E 五组数据构成,采样频率为 173.6 Hz,每组数据包含 100 个 23.6 s 的单通道数据。根据介绍,数据采集于 5 名健康志愿者和 5 名癫痫患者:其中 Set A 和 Set B 属于正常人脑电;Set C 和 Set D 属于癫痫发作间歇期脑电;Set E 属于癫痫发作期脑电。当前,基于正常、癫痫发作间歇和癫痫发作期的 3 分类脑电问题是领域内研究难点,同时也更符合实际需求。为了验证算法的优越性和普适性,将针对两种三模式分类问题展开实验,分别为方案 1(A\N\E)、方案 2(AB\CD\E)。图 6 所示为不同数据集的 EEG 波形图。




图6 不同数据集的脑电波形图
Fig. 6 Sample EEG waveforms of different data sets

3.2 评价参数

在算法性能评估方面,除分类正确率(ACC)外,还引入敏感性(SEN)、特异性(SPE)、阳性预测值(positive predictive value, PPV)和马修斯相关系数(Matthews correlation coefficient, MCC)作为算法性能评价指标。采用十折交叉检验对分类器进行训练和测试,以获取更稳定和可信的实验结果。相关评价参数公式定义为^[17]:

$$SEN = \frac{TP}{TP + FN} \times 100\% \tag{17}$$

$$SPE = \frac{TN}{TN + FP} \times 100\% \tag{18}$$


$$PPV = \frac{TP}{TP + FP} \times 100\% \tag{19}$$

$$MCC = \frac{TP \cdot TN - FN \cdot FP}{\sqrt{(TP + FN)(TP + FP)(TN + FN)(TN + FP)}} \tag{20}$$

式中:TP为被阳性数据预测正确个数,TN为阴性数据预测正确个数,FP为阴性数据预测错误个数,FN为阳性数据预测错误个数。将正常EEG作为阴性数据,癫痫间期和癫痫发作期EEG作为阳性数据。

3.3 特征值提取

根据人体生理特征,频率超过60 Hz的EEG可视为噪声^[2]。因此,采用60 Hz巴特沃兹低通滤波器对信号进行预处理。与传统DWT相似,滤波器的选择和分解层数的设置对DD-DWT性能有很大的影响。选用可以满足精确分解条件的迭代滤波器,并通过多次实验将分解层数确定为6层(详见3.4节)。脑电经6层DD-DWT分解后,被细致的分为13个系数频带,其中12个高频系数,1个低频系数。图7所示为样本信号6层DD-DWT分解的频带波形。






图 7 五类数据集中样本数据 6 层 DD-DWT 分解的频带波形

Fig. 7 The frequency band waveforms of the sample EEG signals from the five data sets after 6-level DD-DWT decomposition

利用 LLPR 提取子频带信号特征。由 LLPR 模型原理可知,待分析数据不能为负数,因此取各子频带系数的绝对值,将系数波形转换为小波域能量波形后,再进一步对能量波形进行参数估计,从而得到各子频带的统计分布特征。由于篇幅限制,本文仅示意各数据集中样本数据的特征数值,如表 1 所示。

表 1 各数据集中样本脑电数据特征数值

Table 1 Feature values of sample EEG in each data sets

频带	Set A		Set B		Set C		Set D		Set E	
	β	α	β	α	β	α	β	α	β	α
d 11	1.673 3	0.578 5	1.543 5	0.582 5	0.599 7	0.603 2	0.690 6	0.601 4	3.268 0	0.881 7
d 12	0.508 3	0.588 4	0.387 6	0.598 0	0.309 4	0.561 2	0.469 4	0.573 9	1.609 7	0.872 4
d 21	2.819 7	0.585 8	2.640 5	0.569 1	1.594 3	0.582 0	1.978 6	0.565 9	4.728 3	0.858 2
d 22	2.145 4	0.581 7	2.097 6	0.596 7	1.137 3	0.574 8	1.132 9	0.622 5	3.788 8	0.916 1
d 31	3.505 2	0.604 7	3.351 2	0.567 9	2.402 4	0.552 9	3.025 5	0.596 1	5.496 8	0.696 6
d 32	3.422 4	0.552 3	3.126 4	0.605 2	1.925 0	0.647 8	2.414 6	0.580 5	5.352 7	0.821 2
d 41	3.364 3	0.580 6	3.426 7	0.534 3	3.022 2	0.619 0	3.802 7	0.543 5	6.131 2	0.595 7
d 42	3.564 3	0.599 7	3.555 1	0.599 3	2.747 8	0.568 0	3.476 5	0.668 0	5.704 0	0.613 4
d 51	3.763 6	0.644 1	3.455 2	0.521 5	3.627 1	0.613 7	4.200 9	0.558 6	6.189 1	0.535 7
d 52	3.552 4	0.677 1	3.757 4	0.520 9	3.249 3	0.611 9	4.260 1	0.555 6	6.601 5	0.479 4
d 61	4.107 2	0.622 7	4.127 7	0.510 5	3.733 2	0.627 3	4.161 3	0.489 4	5.543 5	0.674 7
d 62	4.258 1	0.558 3	3.823 2	0.559 9	3.916 4	0.537 7	4.427 7	0.562 3	6.343 3	0.498 4
$\alpha 6$	4.365 2	0.711 9	4.675 6	0.529 6	5.339 7	0.346 5	4.883 8	0.474 8	5.962 2	0.565 5

3.4 分类结果

将提取回归参数整合为 26 维的特征向量,送入 GA-SVM 分类器中进行分类。为进一步分析小波分解层数对实验结果的影响,分别将层数设置为 1~9,并计算相应的分类正确率和单个样本运算时间。图 8 所示为两种分类方案在不同分解层数下的分类性能和运算

时间。图 8 所示的结果表明,分解层数设置过大会导致运算时间增加,设置过小会导致信号表征不具体降低分类正确率;当分类层数选为 6 时,方案 1 和方案 2 同时获得最高的分类正确率,分别为 98.90% 和 97.75%,对应的单个样本运算时间也较为合理,分别为 0.34 s 和 0.36 s。




图 8 不同分解层数时分类正确率和运算时间

Fig. 8 Classification accuracy and computing time for different number of decomposition levels

本文还分析了特征参数 α 和 β 的表征能力,将两个参数分别作为分类器的输入并计算相关评价指标。图 9 所示为两种分类方案在选用不同参数组合时的分类性能(为了计量统一,将 MCC 作百分化处理)。从图 9 分析可知,形状参数 β 明显比尺度参数 α 具有更强信号表征能

力。两个特征组合时,识别结果比仅使用 β 提高 2% 左右,因此参数 α 和 β 是可以正向补充的特征组合,二者互相补充,使特征分辨能力增强。

表 2 为基于 DD-DWT 分解的算法与无分解算法的分类结果比较。从 ACC 这一重要评价指标可以看出,直接




图9 两种分类方案在选用不同特征参数组合时的分类性能

Fig.9 Classification performance for two classification schemes using different feature parameter combinations

提取原始 EEG 信号的 LLPR 所取得结果并不能满足实际需求,方案 1 和方案 2 的平均分类正确率仅为 69.33% 和 57.60%。不仅如此,在不采用任何分解算法的情况下,方案 2 的 MCC 仅为 0.037,说明阳性数据和阴性数据的混淆程度极高。此实验结果也进一步验证了,子频带特征比原始信号特征更具有表征能力,且特异性更强。

表2 不同分解方法下的分类性能比较

Table 2 Classification performance comparison for different decomposition methods						
方案	分解算法	SEN/%	SPE/%	PPV/%	MCC	ACC/%
方案 1	无分解	85.71	53.62	70.91	0.423 5	69.33
	DD-DWT	99.44	98.24	99.11	0.978 4	98.80
方案 2	无分解	60.89	43.75	82.0	0.037 3	57.60
	DD-DWT	99.58	96.71	97.75	0.967 1	97.75

3.5 算法比较

为了验证本文算法的优越性,本文对比分析了多种算法组合的性能。将 DD-DWT 与传统的 DWT 算法相比较,不仅如此,还考虑了多种非线性特征,包括 Hurst 指数、排列熵、样本熵等。实验中采用 db4 作为 DWT 的小波基函数,同样选取最佳分解层数下的结果以确保结论的客观、有效。分别在 DD-DWT 和 DWT 的子频带上提

取上述特征,由优化的 SVM 输出结果,如表 3 和 4 所示。从表中分析得知,对任一分类方案,若提取的特征相同,基于 DD-DWT 的算法组合得到的分类结果要明显高于基于传统 DWT 的算法组合,这就证明了 DD-DWT 可以更好地捕捉 EEG 信号的细节信息;若采用同样的变换方法,LLPR 的特异性更强,分类结果更好。因此,DD-DWT 和 LLPR 相结合的算法更适用于 EEG 信号的多类别检测,且算法复杂度低,易于实现。

表3 分类方案 1 时不同算法组合的分类性能

Table 3 Classification performance of different algorithm combinations for classification scheme 1					
算法组合	SEN/%	SPE/%	PPV/%	MCC	ACC/%
DWT + Hurst 指数	85.40	89.60	94.25	0.7240	84.13
DWT + 排列熵	83.74	93.89	96.60	0.7610	82.0
DWT + 样本熵	96.68	78.99	87.50	0.7853	87.66
DWT + Log-Logistic	99.79	93.28	96.40	0.9452	96.80
DD-DWT + Hurst 指数	96.98	89.78	94.91	0.8775	92.0
DD-DWT + 排列熵	85.40	94.36	98.0	0.7165	84.13
DD-DWT + 样本熵	98.46	87.98	93.57	0.8842	93.66
DD-DWT + Log-Logistic	99.44	98.24	99.11	0.9784	98.80

表4 分类方案 2 时不同算法组合的分类性能

Table 4 Classification performance of different algorithm combinations for classification scheme 2					
算法组合	SEN/%	SPE/%	PPV/%	MCC	ACC/%
DWT + Hurst 指数	88.35	82.75	88.53	0.7102	82.8
DWT + 排列熵	76.25	70.53	82.76	0.4545	72.8
DWT + 样本熵	85.85	70.97	78.0	0.5765	74.0
DWT + Log-Logistic	98.80	94.72	96.30	0.9402	96.56
DD-DWT + Hurst 指数	96.85	90.32	93.24	0.8788	89.36
DD-DWT + 排列熵	88.76	88.04	92.53	0.7586	85.84
DD-DWT + 样本熵	98.63	94.17	96.0	0.9339	94.60
DD-DWT + Log-Logistic	99.58	96.71	97.75	0.9671	97.75

表 5 为本文算法与现有算法之间的比较。分析表中数据可知,多数算法仅基于单一分类方案设计,未考虑算法对其他分类方案的适用性,且分类方案 A\D\E 的识别率提升空间有限,已达到 98% 以上,但现有算法对分类方案 AB\CD\E 的识别率并不高。少数研究考虑到了多个分类问题^[22-23],但所得识别率却不如针对单一方案的算法高,难以兼顾算法的普适性与分类性能。本文所提出的方法在 A\D\E 和 AB\CD\E 方案下取得的分类正确

率高于表 5 中方法,普适性和分类性能优异,可以很好的适应不同分类方案之间的差异,为癫痫脑电信号的识别提供了新的思路。

表 5 本文算法与现有算法之间的比较

Table 5 Comparison between the proposed algorithm and existing algorithms		
采用方法	分类方案	ACC/%
小波包变换 + 非线性特征 + SVM [9]	A\D\E	98.0
小波变换 + 高阶谱和纹理特征 + SVM [18]	A\D\E	96.0
熵 + 模糊分类器 [6]	A\D\E	98.10
局部二值模式 + 贝叶斯分类器 [23]	A\D\E	95.67
小波变换 + 熵 + 神经网络 [19]	AB\CD\E	97.13
小波变换 + 混合特征 + 神经网络 [20]	AB\CD\E	96.70
K 平均算法 + 神经网络 [22]	AB\CD\E	95.60
	A\D\E	96.67
经验模态分解 + 谱特征 + SVM [21]	AB\CD\E	83.60
	A\D\E	84.50
本文	A\D\E	98.90
	AB\CD\E	97.75

4 结 论

随着医疗行业的发展,异常 EEG 自动检测方法将成为临床辅助诊断的重要技术。针对现有方法分类模式单一、分类效率不高的问题,提出了一种新的癫痫 EEG 信号自动识别方法。首次尝试将 DD-DWT 和 LLPR 模型有机的结合,并应用于 EEG 信号识别领域。该方法可以减少频带混叠的影响,从而获得表征性更强的特征。不仅全面考虑了多种影响因素,还做了不同分解算法和特征组合之间的对比实验。结果表明,本文算法更适用于多类 EEG 信号检测,兼顾算法的普适性和分类性能,具有较强的实际应用价值。

参考文献

[1] FU K, QU J, ChAI Y, et al. Hilbert marginal spectrum analysis for automatic seizure detection in EEG signals [J]. Biomedical Signal Processing and Control, 2015, 18(4):179-185.

[2] 张鹏博,王雪,张蔚航,等. 癫痫发作瞬态带宽特征自适应检测方法[J]. 仪器仪表学报, 2016, 37(6): 1390-1397.

ZHANG P B, WANG X, ZHANG W H, et al. Adaptive detection method based on instantaneous bandwidth feature for seizure onset [J]. Chinese Journal of Scientific Instrument, 2016, 37(6):1390-1397.

[3] 袁琦,周卫东,李淑芳,等. 基于 ELM 和近似熵的脑电信号检测方法[J]. 仪器仪表学报, 2012, 33(3):

514-519.

YUAN Q, ZHOU W D, LI SH F. Approach of EEG detection based on ELM and approximate entropy [J]. Chinese Journal of Scientific Instrument, 2012, 33(3): 514-519.

[4] 张涛,陈万忠,李明阳. 基于 AdaBoost 算法的癫痫脑电信号识别[J]. 物理学报, 2015, 64(12):419-425.

ZHANG T, CHEN W ZH, LI M Y. Recognition of epilepsy electroencephalography based on AdaBoost algorithm[J]. Acta Physica Sinica, 2015, 64(12): 419-425.

[5] 韩凌,王宏. 基于空频域特征分析方法的癫痫发作预测[J]. 仪器仪表学报, 2014, 35(11):2501-2507.

HAN L, WANG H. Epileptic seizure prediction based on spatial-frequency domain feature analysis[J]. Chinese Journal of Scientific Instrument, 2014, 35(11): 2501-2507.

[6] ACHARYA U R, MOLINARI F, SREE S V, et al. Automated diagnosis of epileptic EEG using entropies[J]. Biomedical Signal Processing AND Control, 2012, 7(4):401-408.

[7] GUO L, RIVERO D, PAZOS A. Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks [J]. Journal of Neuroscience Methods, 2010, 193(1):156-63.

[8] KUMAR Y, DEWAL M L, ANAND R S. Epileptic seizure detection using DWT based fuzzy approximate entropy and support vector machine [J]. Neurocomputing, 2014, 133(8):271-279.

[9] MARTIS R J, TAN J H, CHUA C K, et al. Epileptic EEG classification using nonlinear parameters on different frequency bands[J]. Journal of Mechanics in Medicine and Biology, 2015, 15(3):1550040.

[10] 尚赵伟,张明新,沈钧毅,等. 基于双密度小波变换的纹理图像检索[J]. 西安交通大学学报, 2005, 39(10):1081-1084.

SHANG ZH W, ZHANG M X, SHEN J Y, et al. Texture image retrieval based on double density wavelet transform [J]. Journal of Xi'an Jiaotong University, 2005, 39(10):1081-1084.

[11] 曹世超,张国勋. 双密度小波变换的自适应电能质量信号去噪[J]. 计算机工程与应用, 2012, 48(13): 244-248.

CAO SH CH, ZHANG G X. Computer engineering and application[J]. Computer Engineering and Applications, 2012, 48(13):244-248.

[12] SELESNICK I W. The double density DWT [M]. Boston: Kluwer, 2001:1-25.

- [13] ARIK I, KANTAR Y M. Estimator based on percentiles for log-logistic distribution[C]. International Conference on Statistics in Science, Business and Engineering, 2012:10-12.
- [14] HIDALGO M D, GOMEZ-BENITO J, ZUMBO B D. Binary logistic regression analysis for detecting differential item functioning: Effectiveness of R [superscript 2] and Delta Log Odds Ratio Effect Size Measures [J]. Educational and Psychological Measurement, 2015, 74(6):927-949.
- [15] 焦卫东, 林树森. 整体改进的基于支持向量机的故障诊断方法[J]. 仪器仪表学报, 2015, 36(8):1861-1870.
JIAO W D, LIN SH S. Overall improved fault diagnosis approach based on support vector machine[J]. Chinese Journal of Scientific Instrument, 2015, 36(8):1861-1870.
- [16] ANDRZEJAK R G, LEHNERTZ K, MORMANN F, et al. Indications of nonlinear deterministic and finite - dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state[J]. Physical Review E, 2002, 64(6 Pt 1):116-126.
- [17] SHARMA R, PACHORI R B. Classification of epileptic seizures in EEG signals based on phase space representation of intrinsic mode functions [J]. Expert Systems with Applications, 2015, 42(3):1106-1117.
- [18] ACHARYA U R, YANTI R, ZHENG J W, et al. Automated diagnosis of epilepsy using CWT, HOS and texture parameters [J]. International Journal of Neural Systems, 2013, 23(3):1001-1007.
- [19] WANG D, MIAO D, XIE C. Best basis-based wavelet packet entropy feature extraction and hierarchical EEG classification for epileptic detection[J]. Expert Systems with Applications, 2011, 38(11):14314-14320.
- [20] GHOSH-DASTIDAR S, ADELI H, DADMEHR N. Mixed-band wavelet-chaos-neural network methodology for epilepsy and epileptic seizure detection [J]. IEEE

Transactions on Biomedical Engineering, 2007, 54(9): 1545-1551.

- [21] RIAZ F, HASSAN A, REHMAN S, et al. EMD-Based temporal and spectral features for the classification of EEG signals using supervised learning [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2016, 24(1):28-35.
- [22] ORHAN U, HEKIM M, OZER M. EEG signals classification using the K -means clustering and a multilayer perceptron neural network model[J]. Expert Systems with Applications, 2011, 38(10):13475-13481.
- [23] KAYA Y, UYAR M, TEKIN R, et al. 1D-local binary pattern based feature extraction for classification of epileptic EEG signals [J]. Applied Mathematics and Computation, 2014, 243(9):209-219.

作者简介



李明阳, 2013 年于上海理工大学获得学士学位, 现为吉林大学博士研究生, 主要研究方向为模式识别与智能系统。

E-mail: mingyang15@mails.jlu.edu.cn

Li Mingyang received her B. Sc. degree in 2013 from University of Shanghai for Science and Technology; now, she is pursuing her Ph. D. degree in Jilin University. Her main research interest includes pattern recognition and intelligent system.



陈万忠 (通讯作者), 分别在 1994 年和 2001 年于吉林工业大学获得硕士学位和博士学位, 现为吉林大学教授, 主要研究方向为脑机接口与智能控制。

E-mail: chenwz@jlu.edu.cn

Chen Wanzhong (Corresponding author) received his M. Sc. degree in 1994 from Jilin University of Technology, received his Ph. D. degree in 2001 from Jilin University; now, he is a professor in Jilin University. His main research interest includes brain-computer interface technology and intelligent control.