

EEG信号识别中可调优化 Q 因子小波变换的多特征融合算法

刘 聲, 朱炳宇, 张景祥[†]

(江南大学 理学院, 江苏 无锡 214122)

摘要: EEG信号对脑部疾病诊断具有重要意义, 但其特征选择对信号识别准确率影响较大。针对这个问题, 本文基于 Q 因子小波变换, 提出一种可调优化 Q 因子小波变换融合多维特征的脑电信号识别(Ad-TQWT MF)算法。该算法首先根据小波分解后的子带信号定义能量香农熵比, 用其作为可调 Q 因子小波的优化评价标准; 再融合变换后信号的时域、频域和非线性特征, 通过自适应特征选择方法构建特征子空间; 最后在该特征子空间下对脑电信号进行识别。在BCI脑电竞赛数据集Dataset_III, O3VR, X11b和S4b进行了实验, 实验结果表明: Ad-TQWT MF算法在LDA分类器中精度为89.2%, 81.2%, 83.2%和85.6%, 相比于原 Q 因子小波变换, 冗余特征减少10%~30%, 相较于Haar和Db_4小波精度提高3%~5%, 证明了Ad-TQWT MF算法的有效性。

关键词: EEG信号; 可调 Q 因子小波变换; 能量香农熵比; 特征选择

引用格式: 刘声, 朱炳宇, 张景祥. EEG信号识别中可调优化 Q 因子小波变换的多特征融合算法. 控制理论与应用, 2022, 39(12): 2302–2312

DOI: 10.7641/CTA.2022.10725

Multi-feature fusion algorithm for adaptive-tunable Q -factor wavelet transform in EEG signal recognition

LIU Zhen, ZHU Bing-yu, ZHANG Jing-xiang[†]

(School of Science, Jiangnan University, Wuxi Jiangsu 214122, China)

Abstract: EEG signals are of great significance for the diagnosis of brain diseases. However, the recognition accuracy is greatly affected by the feature selection and redundant features. To solve this problem, an adaptive-tunable Q -factor wavelet transform multi-feature algorithm (Ad-TQWT MF) is proposed based on the Q -factor wavelet transform in this paper. First, the energy Shannon entropy ratio based on the decomposed subbands is defined, and it is set to the optimization evaluation standard of the adjustable Q factor wavelet. Then, the time domain, frequency domain and nonlinear features of the transformed EEG are fused to construct a useful characteristic subspace through the adaptive feature selection. Finally, the characteristic subspace of EEG is identified by the Ad-TQWT MF. Some experiments are carried out on the EEG datasets of first and second BCI competitions including Dataset_III, O3VR, X11b and S4b. The experimental results show that the accuracy of the proposed algorithm in the linear discriminant analysis classifier are 89.2%, 81.2%, 83.2% and 85.6%. Compared to Haar and Db_4, the feature redundancy rate of proposed algorithm drops by 10%~30% and the recognition accuracy of EEG increases 3%~5%. The experimental results strongly prove the effectiveness of the Ad-TQWT algorithm.

Key words: electroencephalogram; tunable Q -factor wavelet transform; energy Shannon entropy ratio; feature subset selection

Citation: LIU Zhen, ZHU Bingyu, ZHANG Jingxiang. Multi-feature fusion algorithm for adaptive-tunable Q -factor wavelet transform in EEG signal recognition. *Control Theory & Applications*, 2022, 39(12): 2302–2312

1 引言

在脑部疾病诊断中, 脑-机接口(brain-computer interface, BCI)利用外部设备采集脑电信号(electroencephalogram, EEG), 实现了脑电信号与外界的交互^[1]。运动想象脑电信号是大脑受到外界运动想象刺激生

成, 当大脑受到单侧肢体的运动想象的刺激时, 其对侧运动感知区则处于激活状态, 与其对应节律的幅值会降低, 这种现象称为事件相关去同步(event-related desynchronization, ERD)。大脑同侧的感知区则处于抑制状态, 对应节律的幅值则会升高, 这种现象称为

收稿日期: 2021-08-09; 录用日期: 2022-05-26。

[†]通信作者. E-mail: zhangjingxiang@jiangnan.edu.cn; Tel.: +86 13921538669.

本文责任编辑: 潘泉。

国家自然科学基金项目(61772013)资助。

Supported by the National Natural Science Foundation of China (61772013).

事件相关同步(event-related synchronization, ERS). 利用运动想象特定频段中存在的ERD/ERS现象, 可以实现对运动想象脑电信号的有效识别^[2]. 考虑到ERD/ERS的特定频域特征空间下的信息可能有助于运动想象信号识别, 本文对ERD/ERS对应的频域区间信号提取特征.

EEG信号随时间变化具有非线性、非平稳特征, 且不具备各态历经性^[2]. 现有的EEG信号识别方法大致分为3类: 时域分析法、频域分析法和时频分析法. 时域分析方法是将EEG信号作为时序数据, 分析信号内部的时域特征. 时域分析方法代表性的工作有: Ghosh-Dastidar等人^[3]利用主成分分析(principle component analysis, PCA)提取EEG信号的时域特征, 度量不同EEG信号类别之间的时域差异性. Ozcan等^[4]对EEG信号提取谱宽度, 统计矩以及Hjorth等统计特征, 结合深度学习实现癫痫EEG信号的自动诊断. 频域分析方法则将信号映射到频域中, 分析不同频率子空间上信号存在的差异. 频域分析方法代表性的工作有: Zhang等人^[5]利用稀疏化贝叶斯学习算法, 分析EEG的不同频率区间, 结合稀疏化贝叶斯学习选择重要的特征, 完成运动想象信号的识别. Mehla等人^[6]使用了傅里叶分解的方法, 将EEG信号分解成傅里叶本征带函数进行特征提取, 提高了癫痫信号的识别率. 时频分析方法结合时域和频域对EEG信号处理. 时频分析方法代表性的工作有: 王洪涛等^[7]选择不同的时间窗和频带, 通过多个共空滤波器提取时频特征, 结合相关向量机实现运动想象信号识别. Acharya等人^[8]利用样本熵, 相位熵和近似熵分别对EEG信号进行处理, 多尺度的分析了信号的时频信息, 对信号中的癫痫特征进行检测. Fu等人^[9]提出稀疏化共空间模式的正则判别分析算法, 对运动想象EEG信号进行识别. 孟明等^[10]将通道间的差异性与共空间模式结合, 根据时频信息的Fisher比划分块的分类能力, 提出块选择共空间模式识别运动想象信号. 陈万忠等^[11]针对运动想象EEG信号模式精度以及互信息不高的问题, 结合多尺度特征提出基于可调Q因子小波变换的EEG信号识别算法. Al Ghayab等^[12]将运动想象EEG信号进行TQWT分解, 分别提取不同小波子带的统计学特征, 结合机器学习算法完成识别.

上述方法在运动想象EEG信号识别上虽然取得一定的效果, 但仍存在一些不足之处:

1) 时域和频域的方法仅分析了信号在各自域的特征, 其他维度信息缺失, 导致识别精度较差;

2) 时频分析中, 在可调Q因子小波变换方法的应用中, 存在小波变换参数难以确定的问题, 且特征存在冗余.

针对上述问题, 本文基于可调Q因子小波变换(tu-

nable Q-factor wavelet transform, TQWT)以及特征选择的理论, 提出一种基于可调优化Q因子小波变换的多特征融合的EEG信号识别算法(adaptive-tunable Q-factor wavelet transform multi-feature, Ad-TQWT MF). Ad-TQWT MF算法利用能量香农熵比的指标, 确定TQWT中最优的Q因子, 并结合EEG信号的时域, 频域和非线性多维特征, 自适应特征选择, 对特征提取后的数据进行稀疏化处理, 减少冗余特征, 降低数据维度以及计算复杂度, 减少模型训练的时间. 本文将能量香农熵比(energy-shannon entropy ratio, ESE-R)作为TQWT中Q因子的优化评价标准, 选择合适的Q因子, 提高TQWT对EEG中运动想象的识别能力, 并结合样本熵, LP系数, 小波能量以及分形维数, 多维度提取EEG中运动想象信息, 最后自适应特征选择确定最优特征子空间进行EEG信号识别. 本文方法的特色之处在于:

1) 对不同Q因子下TQWT分解后得到的子带, 分别计算其子带能量和香农熵, 能量与香农熵的比值作为评价该小波分解的优劣指标, 使小波匹配EEG运动想象的震荡特性;

2) 在小波子带的特征提取中, 嵌入样本熵, LP系数等时域特征, 以及小波能量, 分形维数等频域非线性特征, 充分提取了EEG不同维度下的信息;

3) 针对多维特征存在的冗余问题, 利用自适应特征选择确定最优特征子空间, 降低了模型复杂度, 提高了EEG信号识别精度.

2 可调优化Q因子小波的多特征融合(Ad-TQWT MF)

由于EEG信号的非线性和非平稳性存在难以识别的波段, 合适的小波可提取EEG的特殊频段^[2]. 利用小波基函数将信号分解为不同频率的子带, 传统的小波基有Haar, Db_4等. 但这些小波均为恒定Q因子小波, 无法与EEG信号中震荡成分相匹配. TQWT可调节不同的Q因子, 适应信号非平稳的特性, 充分地保留原信号震荡信息. 但TQWT在Q因子的选择上依赖数据先验信息或特定实验, 在理论上缺乏评判指标^[10-11]. 针对这个问题, 本文根据信号分解的最大化能量以及最小化香农熵准则, 提出了Ad-TQWT MF算法. 能量香农熵比优化TQWT的Q因子, 使小波更准确提取信号中存在的ERD/ERS特征, 并融合多维度特征, 选择最佳特征子空间, 通过分类器完成对EEG信号的识别. Ad-TQWT MF算法的总体流程如图1所示.

2.1 可调Q因子小波变换(TQWT)

TQWT与普通小波变换处理信号的过程类似^[13], 该分解中小波的Q因子影响其对信号信息的提取能力, 不同Q因子的小波能分解出对应频率成分, TQWT通过调节Q因子使得小波与原信号中震荡成分相匹

配, 提取信号中的震荡信息.

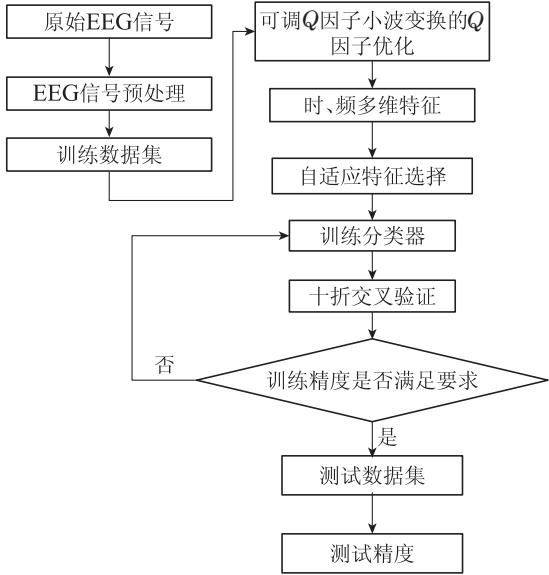


图 1 Ad-TQWT MF 算法流程图

Fig. 1 Flow chart of Ad-TQWT MF

信号 $X(n)$ 的 TQWT 分解中, 利用两个滤波器组 $H_0(\omega)$ 和 $H_1(\omega)$ 进行滤波后, 再进行尺度缩放, 实现低频与高频信号的分离. $H_0(\omega)$ 和 $H_1(\omega)$ 称为低通和高通滤波器, 其具体形式如式(1)–(2):

$$H_0(\omega) = \begin{cases} 1, & |\omega| \in [0, \pi - \beta\pi], \\ \theta\left(\frac{\omega + \beta\pi - \pi}{\alpha + \beta - 1}\right), & |\omega| \in [\pi - \beta\pi, \alpha\pi], \\ 0, & |\omega| \in [\alpha\pi, \pi], \end{cases} \quad (1)$$

$$H_1(\omega) = \begin{cases} 0, & |\omega| \in [0, \pi - \beta\pi], \\ \theta\left(\frac{\alpha\pi - \omega}{\alpha + \beta - 1}\right), & |\omega| \in [\pi - \beta\pi, \alpha\pi], \\ 1, & |\omega| \in [\alpha\pi, \pi], \end{cases} \quad (2)$$

其中 α, β 分别为低通和高通缩放尺度参数, 它们的大 小决定了滤波器组 $H_0(\omega)$ 和 $H_1(\omega)$ 保留信号 $X(n)$ 的区间大小, 影响 TQWT 对信号波动的分解提取能力. 根据文献[13]中指出小波变换应满足对信号分解重构的条件, 因此 α, β 需满足式(3)的约束条件

$$\alpha + \beta \leq 1, 0 \leq \alpha \leq 1, 0 \leq \beta \leq 1. \quad (3)$$

式(1)–(2)中 $H_0(\omega)$ 与 $H_1(\omega)$ 相交的区间称为过渡带, 即 $\omega \in [-\alpha\pi, -(1-\beta)\pi] \cup [(1-\beta)\pi, \alpha\pi]$. 对于过渡带的信号, 滤波函数采用具有二阶消失矩的 Daubechies 频率响应 $\theta(\omega)$, 函数的具体形式以及性质如式(4):

$$\begin{cases} \theta(\omega) = \frac{1}{2}(1 + \cos \omega)\sqrt{2 - \cos \omega}, \\ \theta^2(\omega) + \theta^2(\pi - \omega) = 1. \end{cases} \quad (4)$$

结合式(1)–(2)(4), 可知过渡带上滤波函数满足式(5),

$$H_0^2(\omega) + H_1^2(\omega) = 1, \quad (5)$$

结合式(3)尺度参数 α, β 的约束条件以及式(5) $H_0(\omega)$ 和 $H_1(\omega)$ 性质, TQWT 符合小波重构的原理, 可以实现信号分解以及重构.

TQWT 信号分解中存在两个重要的参数 Q 因子以及冗余率 r . 其中, Q 因子是衡量小波提取 $X(n)$ 震荡特性的一个重要指标, 它定义为小波中心频率 ω_c 与带宽 BW 的比值, 与尺度参数 β 相关, 具体定义如式(6):

$$Q = \frac{\omega_c}{BW} = \frac{2 - \beta}{\beta}, \quad (6)$$

冗余率 r 由尺度参数 α, β 定义, 具体形式如式(7):

$$r = \frac{\beta}{1 - \alpha}, \quad (7)$$

上述式(6)–(7)中, Q 因子, 冗余率 r 均与 TQWT 中 α, β 相关, 由于实际采集的均为有限长度信号, 故实际信号的 TQWT 分解存在上限. 文献[13]给出了有限时长的信号最大分解层数 J_{\max} , 定义如式(8)所示:

$$J_{\max} = \lfloor \frac{\log \frac{N\beta}{8}}{\log \frac{1}{\alpha}} \rfloor = \lfloor \frac{\log \frac{N}{4(Q+1)}}{\log \frac{Q+1}{Q+1-2/r}} \rfloor, \quad (8)$$

其中 $\lfloor \cdot \rfloor$ 为向下取整函数. 从式(8)最大分解层数 J_{\max} 的定义可知, 调整尺度参数 (α, β) 的大小, 其 TQWT 对信号的分解层数会随之变化. 式(6)–(7)揭示了 (Q, r) 的大小与尺度参数 (α, β) 之间的联系. EEG 信号经过 TQWT 分解后得到各个子带系数, 其中第 i 层低频系数 $l_i(\omega)$ 如式(9)所示:

$$l_i(\omega) = \begin{cases} \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} f(x, \omega), & |\omega| \in [0, \frac{1-\beta}{\alpha}\pi], \\ \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} \theta_0(\alpha^i \omega) f(x, \omega), & |\omega| \in [\frac{1-\beta}{\alpha}\pi, \pi], \end{cases} \quad (9)$$

其中 $f(x, \omega) = x(n)e^{-j\pi n \alpha^i \omega}$. 同理, 可得第 i 层的高频系数 $h_i(\omega)$ 如式(10)所示:

$$h_i(\omega) = \begin{cases} \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} f_1(x, \omega_1), & \omega \in [-\pi, -s_1], \\ \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} f_1(x, \omega_1) \theta_1\left(\frac{\omega_1}{\alpha^{i-1}}\right), & \omega \in [-s_1, -s_2], \\ \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} f_2(x, \omega_1) \theta_1(\omega_1), & \omega \in [-s_2, 0], \\ \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} f_2(x, \omega_2) \theta_1(\omega_2), & \omega \in [0, s_2], \\ \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} f_1(x, \omega_2) \theta_1\left(\frac{\omega_2}{\alpha^{i-1}}\right), & \omega \in [s_2, s_1], \\ \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} f_1(x, \omega_2), & \omega \in [s_1, \pi]. \end{cases} \quad (10)$$

其中: $\theta_0(\omega), \theta_1(\omega)$ 满足式(4)的滤波函数的条件, 即

$$\begin{aligned}\theta_0^2(\omega) + \theta_1^2(\omega) &= 1, \\ f_1(x, \omega) &= \theta(\omega)x(n)e^{-jn\omega}, \\ f_2(x, \omega) &= \theta_1(\omega)x(n)e^{-jn\omega}, \\ \omega_1(\omega) &= \alpha^{i-1}[\beta\omega - (1-\beta)\pi], \\ \omega_2(\omega) &= \alpha^{i-1}[\beta\omega + (1-\beta)\pi].\end{aligned}$$

区间范围内

$$s_1 = \frac{\alpha + \beta - 1}{\beta}\pi, s_2 = \frac{(1-\alpha)(1-\beta)}{\alpha\beta}\pi.$$

2.2 可调优化Q因子小波(Ad-TQWT)

从上述信号TQWT分解中, Q 因子影响式(1)–(2)的 $H_0(\omega)$ 和 $H_1(\omega)$ 滤波范围以及分解层数, 因此合适

的 Q 因子是提取 EEG 运动想象相关信息的关键。现有 Q 因子的选择过分依赖实验结果以及先验信息, 但这些信息获取难度较大, 不利于 Q 因子的选择。本文提出使用能量香农熵比(E-SER)^[14]评价不同 Q 因子下 TQWT 对 EEG 信号的分解效果, 最大化 TQWT 分解 EEG 信号后子带保留的特征信息。

EEG 信号的 J 层分解与 Q 因子寻优过程示意图如图 2 所示, 图 2 的 TQWT 信号分解过程中, $X(n)$ 为输入信号, $l_i(n), h_i(n)$ 分别为第 i 层的低通, 高通成分, J 为分解层数。在对 $X(n)$ 每层的 TQWT 分解中, 仅对上一层的 $l_i(n)$ 进行分解, 保留 $h_i(n)$, 并对每层分解的 $h_i(n)$ 计算其子带能量 E_h^i 和香农熵 S_h^i 得到其比值 R_h^i , 将 R_h^i 的均值 \bar{R} 作为该 Q 因子小波变换的评价指标, 通过最大化该指标对 Q 因子进行调整。

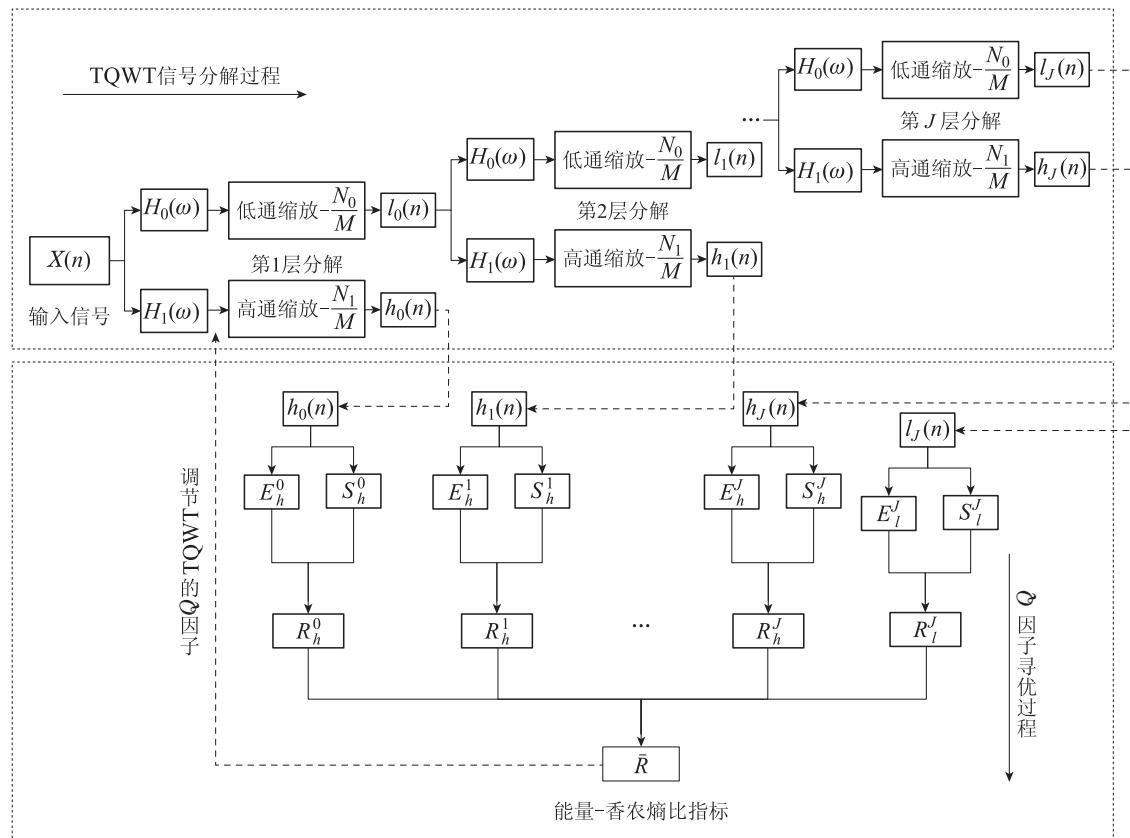


图 2 Ad-TQWT 的 J 层分解与 Q 因子优化

Fig. 2 Decomposition- J and Q -factor optimization of Ad-TQWT

TQWT 分解得到的各子带可分别计算其 E-SER 指标, 该指标主要通过信号的能量和香农熵进行定义。对于分解得到的第 i 个低频子带 $l_i(n)$, 利用式(11)可计算其能量 E_0^i , 即

$$\begin{aligned}E_0^i &= \frac{1}{N} \left(\sum_{k=0}^{n_1} \sum_{n=0}^{N-1} x^2(n) e^{-2jna^{i-1}\omega_{1k}} + \right. \\ &\quad \left. \sum_{k=0}^{n_2} \sum_{n=0}^{N-1} \theta_0^2(\alpha^i \omega_{2k}) x^2(n) e^{-2jna^{i-1}\omega_{2k}} + \right. \\ &\quad \left. \sum_{k=0}^{n_3} \sum_{n=0}^{N-1} \theta_0^2(\alpha^i \omega_{3k}) x^2(n) e^{-2jna^{i-1}\omega_{3k}} \right), \quad (11)\end{aligned}$$

其中: N_0^i 为低频子带信号 $l_i(n)$ 的长度, $l_i(\omega_k)$ 为子带系数, $\{\omega_{ik}, i = 1, 2, 3\}$ 定义如下:

$$\begin{cases} \omega_{1k} = \frac{\beta-1}{\alpha}\pi + \frac{k_1}{n_1} \cdot \frac{1-\beta}{\alpha} \cdot 2\pi, \\ \omega_{2k} = \frac{1-\beta}{\alpha}\pi + \frac{k_2}{n_2} \cdot \frac{\alpha+\beta-1}{\alpha} \cdot \pi, \\ \omega_{3k} = -\pi + \frac{k_3}{n_3} \cdot \frac{\alpha+\beta-1}{\alpha} \cdot \pi. \end{cases} \quad (12)$$

式(11)–(12)中各区间离散点满足 $n_1 + n_2 + n_3 = N_0^i$,

其中: $n_1 = \frac{1-\beta}{\alpha} N_0^i$, $n_2 = n_3 = \frac{\alpha+\beta-1}{2\alpha} N_0^i$. 同理, 第*i*个高频频子带 $h_i(\omega)$ 能量 E_1^i 如式(13):

$$\begin{aligned} E_1^i &= \frac{1}{N} \left(\sum_{k=0}^{n_1} \sum_{n=0}^{N-1} \theta_0^2(\alpha^{i-1} B_1) f(x, B_1) + \right. \\ &\quad \sum_{k=0}^{n_2} \sum_{n=0}^{N-1} \theta_0^2(\alpha^{i-1} B_2) f(x, B_2) \theta_1^2(B_2) + \\ &\quad \sum_{k=0}^{n_3} \sum_{n=0}^{N-1} f(x, B_3) \theta_1^2(B_3) + \\ &\quad \sum_{k=0}^{n_3} \sum_{n=0}^{N-1} f(x, B_4) \theta_1^2(B_4) + \\ &\quad \sum_{k=0}^{n_2} \sum_{n=0}^{N-1} \theta_0^2(\alpha^{i-1} B_5) f(x, B_5) \theta_1^2(B_5) + \\ &\quad \left. \sum_{k=0}^{n_1} \sum_{n=0}^{N-1} \theta_0^2(\alpha^{i-1} B_6) f(x, B_6) \right), \quad (13) \end{aligned}$$

其中: $f(x, B_i) = x^2(n) e^{-2j n \alpha^{i-1} B_i}$, N_1^i 为 $h_i(\omega)$ 的长度. $[-\pi, \pi]$ 被分成 6 个区间, B_i 分别为 $\{B_i = \beta \omega_{ik} - (1-\beta)\pi, i = 1, 2, 3\}$, $\{B_i = \beta \omega_{ik} + (1-\beta)\pi, i = 4, 5, 6\}$. $\{\omega_{ik}, k = 1, 2, 3, 4, 5, 6\}$ 按式(14)定义, 即

$$\left\{ \begin{array}{l} \omega_{1k} = -\pi + \frac{k_1}{n_1} \cdot \frac{1-\alpha}{\beta} \pi, \\ \omega_{2k} = \frac{1-\alpha-\beta}{\beta} \pi + \frac{k_2}{n_2} \cdot \frac{\alpha^2+\beta-1}{\alpha\beta} \pi, \\ \omega_{3k} = \frac{(1-\alpha)(\beta-1)}{\alpha\beta} \pi + \frac{k_3}{n_3} \cdot \frac{(1-\alpha)(1-\beta)}{\alpha\beta} \pi, \\ \omega_{4k} = \frac{k_3}{n_3} \cdot \frac{(1-\alpha)(1-\beta)}{\alpha\beta} \pi, \\ \omega_{5k} = \frac{(1-\alpha)(1-\beta)}{\alpha\beta} \pi + \frac{k_2}{n_2} \cdot \frac{\alpha^2+\beta-1}{\alpha\beta} \pi, \\ \omega_{6k} = \frac{\alpha+\beta-1}{\beta} \pi + \frac{k_1}{n_1} \cdot \frac{1-\alpha}{\beta} \pi. \end{array} \right. \quad (14)$$

式(13)–(14)中, 各区间离散化后离散点总数满足条件

$$\begin{aligned} 2(n_1 + n_2 + n_3) &= N_1^i, \\ n_1 &= \frac{1-\alpha}{2\beta} N_1^i, \\ n_2 &= \frac{\alpha^2+\beta-1}{2\alpha\beta} N_1^i, \\ n_3 &= \frac{(1-\alpha)(1-\beta)}{2\alpha\beta} N_1^i. \end{aligned}$$

由式(6)–(7)可得 (α, β) 与 (Q, r) 的关系如式(15):

$$\left\{ \begin{array}{l} \alpha = 1 - \frac{2}{r(1+Q)}, \\ \beta = \frac{2}{1+Q}. \end{array} \right. \quad (15)$$

由式(15)知, $n_1 = \frac{1}{r} N_1^i$, $n_3 = \frac{1}{r} (1 - \frac{2}{1+Q}) N_1^i$. 故当 Q 因子增大时, n_1 保持不变, n_3 随之变大, 再结合条件 $n_1 + n_2 + n_3 = N_1^i$, 可知 n_2 会随之减小. n_3 增大和 n_2 减小, 导致式(13)中 n_3 对应的频率区间变宽, 其项数

增多. n_2 对应的频率区间将会变窄, 其项数减少. 由此, Q 因子的增大会引起高频频子带中的过渡频率变高, 低频段区间变窄, 分解后的能量也会发生相应的变化, 因此可以得到信号分解的最大能量准则.

最大能量准则^[14]: 小波分解后子带的能量越大, 小波与原信号的匹配度越高, 小波分解后保留的信息越充分.

由式(11)(13)定义的子带能量, 可定义相应子带的香农熵. 第*i*个低频频子带的香农熵 S_l^i 定义式(16), 即

$$\left\{ \begin{array}{l} S_l^i = - \sum_{k=1}^{k=1} p_k^{l_i} \log(p_k^{l_i}), \\ \sum_{k=1}^{N_0^i} p_k^{l_i} = \sum_{k=1}^{N_0^i} \frac{|h_i(\omega_k)|^2}{E_0^i} = 1, \end{array} \right. \quad (16)$$

式中的 $p_k^{l_i}$ 为第*i*个低频频子带 E_0^i 的概率分布, 满足概率的正则性. 根据式(13)的第*i*个高频频子带能量 E_1^i , 可通过式(17)定义其香农熵 S_h^i , 即

$$\left\{ \begin{array}{l} S_h^i = - \sum_{k=1}^{k=1} p_k^{h_i} \log(p_k^{h_i}), \\ \sum_{k=1}^{N_1^i} p_k^{h_i} = \sum_{k=1}^{N_1^i} \frac{|h_i(\omega_k)|^2}{E_1^i} = 1, \end{array} \right. \quad (17)$$

式中的 $p_k^{h_i}$ 为第*i*个高频频子带 E_1^i 的概率分布, 满足正则性. 通过式(16)–(17)计算低、高频频子带香农熵. Q 因子影响分解EEG信号中特定频率上的分量系数, 决定着香农熵的大小, 因此可以得到最小香农熵准则.

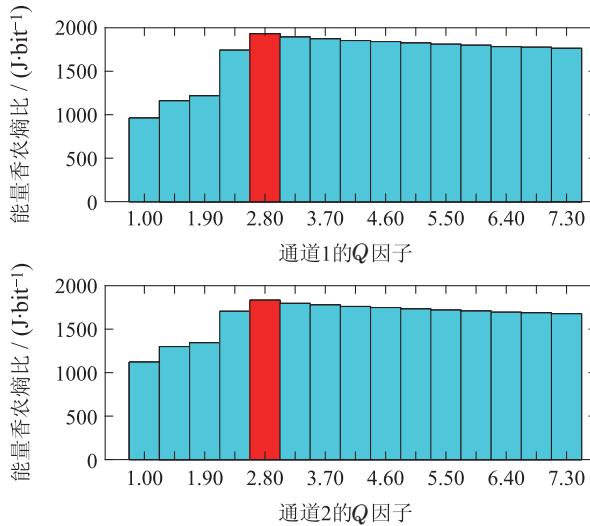
最小香农熵准则^[14]: 香农熵的大小反映出其系数的分布情况. 香农熵越低, 说明该系数分布的不确定性越低, 小波分解后得到的信息就越多.

结合最大能量和最小香农熵准则, 能量与香农熵的比值就越大, 其子带的能量越大, 香农熵越小, 信号的小波分解越充分. 根据式(11)(13)所定义的低, 高频频子带能量 E_0^i 和 E_1^i , 以及式(16)–(17)对应的子带香农熵 S_l^i 和 S_h^i , 相应子带的能量香农熵比定义如式(18):

$$R_l^i = \frac{E_0^i}{S_l^i}, R_h^i = \frac{E_1^i}{S_h^i}. \quad (18)$$

计算所有子带的能量香农熵比 (R_l^i, R_h^i) 并取均值得 \bar{R} , 将其作为对应 Q 因子的E-SER. 依据该指标, 则最优TQWT分解得到子带能量应越大, 且香农熵越小, 因此E-SER指标 \bar{R} 可以对TQWT分解EEG信号中相关震荡频率成分的有效性进行度量.

根据文献[12]以及分解后的信号特征, 确定TQWT的 Q 因子取值范围 $[Q_{\min}, Q_{\max}]$. 对该区间以步长 $\Delta Q = \frac{Q_{\max} - Q_{\min}}{n}$ 遍历, 分别计算对应的E-SER, 选取其中最大的 \bar{R}_{\max} 对应的 Q 因子, 作为TQWT分解该EEG数据集最优的 Q 因子. 以数据集S4b为例, 图3给出了该数据集的两个通道在不同 Q 因子下E-SER值的变化情况.

图 3 S4b 数据集不同 Q 因子的 \bar{R} Fig. 3 \bar{R} of different Q -factor in S4b

从图3中可以看出,最大E-SER指标 \bar{R} 对应红色柱形。通道1,2的 Q 因子为2.8时,其能量香农熵比值 \bar{R} 达到最大,说明对通道1,2的TQWT中, Q 因子为2.8时TQWT分解后子带能量更大,同时香农熵相对较小,震荡信息提取的更完善。

2.3 EEG信号多维度特征融合

为进一步提取EEG信号的信息,需对原始EEG信号和分解得到的子带进行特征提取。文献[11]中主要提取多维度特征,但忽略了信号自身波动之间的差异性,这在检测运动想象中尤为重要。因此,本文此基础上嵌入样本熵特征,挖掘EEG信号自身波动信息。

2.3.1 EEG信号的时域特征

样本熵^[15](sample entropy, SampEn)计算序列中相同波动的概率,度量序列的复杂程度,反映EEG信号随时间推移产生的差异性。样本熵越大,序列复杂度越高,EEG信号存在不同波动的可能性越大。反之样本熵越小,其复杂度越低^[16]。

对于EEG序列 $X=\{x_1, x_2, \dots, x_N\}$,定义 m 维向量序列 $X_m(i)=\{x_{i+1}, x_{i+2}, \dots, x_{i+m-1}\}$,原序列 X 的样本熵通过计算不同时段数据的差异,利用其比值度量波动大小,样本熵具体定义如下式(19):

$$\text{SampEn}(m, r, N) = -\ln\left(\frac{A^m(r)}{B^m(r)}\right), \quad (19)$$

其中 $A^m(r)$ 和 $B^m(r)$ 的定义如下:

$$\begin{cases} A^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \frac{1}{N-m-1} A_i, \\ B^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \frac{1}{N-m-1} B_i, \end{cases} \quad (20)$$

式中: N 为EEG信号序列总长度, m 为时间间隔,一般取为2, t 为判断距离的阈值,取值范围为 $[0.1\text{Std}(X), 0.35\text{Std}(X)]$, $\text{Std}(X)$ 是原始序列 X 的标准差。式(20)中的 A_i 和 B_i 按式(21)定义,

$$\begin{cases} A_i = \text{card}\{d(X_{m+1}(i), X_{m+1}(j)) \leq t | j \neq i\}, \\ B_i = \text{card}\{d(X_m(i), X_m(j)) \leq t | j \neq i\}, \end{cases} \quad (21)$$

其中: $j \in [1, N-m]$, $\text{card}(\cdot)$ 函数是统计集合元素个数, A_i 和 B_i 分别表示序列长度为 m 和 $m+1$ 时存在差异的元素个数。序列 $X_m(i)$ 与 $X_m(j)$ 的差异大小可通过切比雪夫距离定义序列距离,即二者对应向量元素差的无穷范数。具体定义如式(22):

$$d(X_m(i), X_m(j)) = \|(X_m(i), X_m(j))\|_\infty, \quad (22)$$

其中 $\|\cdot\|_\infty$ 为向量的无穷范数。式(22)利用切比雪夫距离衡量序列 $X_m(i)$, $X_m(j)$ 之间距离,通过两个序列对应的最大差值,可以有效地反映出两者之间存在差异的上界,提高SampEn特征的可区分性。

以S4b数据集为例,对该数据集的训练集的两个通道数据计算相应左右手样本熵的值,如图4所示。

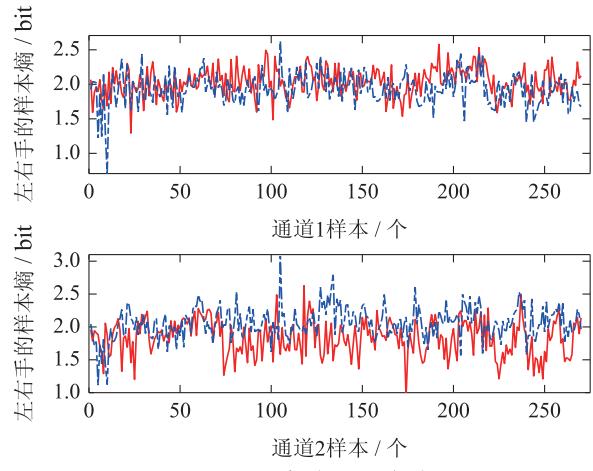


图 4 S4b 数据集左右手样本熵

Fig. 4 SampEn of left-right sample in S4b

图4中,实线代表左手样本的样本熵,虚线代表右手样本的样本熵。从通道1的图中可以看出,左手的样本熵略大于右手,通道2中左手样本熵均位于右手的下方,说明该通道左手与右手运动想象EEG的样本熵存在明显差异。样本熵的差异有效佐证了该特征在分类左右手EEG信号的有效性。

线性预测(linear predication, LP)^[17]是分析时序数据的一种模型,模型系数刻画了 t 时刻信号强度与 $t-i$ 时刻之间的关系,具体定义如下:

$$x(t) = \sum_{i=1}^{l-1} a_i x(t-i), \quad (23)$$

其中: $x(t)$, $x(t-i)$ 分别为 t 和 $t-i$ 时刻EEG信号强度, l 为与 t 时刻相关的时刻点数, a_i 为模型的LP系数。 a_i 越大,说明 t 与 $t-i$ 时刻的相关性越大。反之, $t-i$ 对 t 时刻的影响越小。利用式(19)(23)定义的样本熵和LP模型,分别计算EEG信号的样本熵和LP系数,将其作为EEG信号的时域特征。

2.3.2 EEG信号的频域和非线性特征

TQWT对EEG信号进行 J 层分解后,信号被分解成 $J+1$ 个不同频率的子带,对应各频率的分量。因此子带能量分布反映各个频率区间上EEG的能量分布情况^[18],经TQWT分解后的能量 E 是式(11)(13)定义的所有低、高频子带能量(E_0^i, E_1^i)的集合,即

$$E = \{E_1^i, E_0^j | 1 \leq i \leq J\}. \quad (24)$$

分形维数是通过定义分形,度量EEG信号中局部与整体的相似性,具有自相关性与标度不变性^[19]。其中计盒维数的分形 $d(s)$ 具体定义如下:

$$d(s) = \lim_{n \rightarrow 0} \frac{\log(N_n(s))}{\log(\frac{1}{G})}, \quad (25)$$

其中: G 为每一个网格的长度; $N_n(s)$ 表示在长度为 G 的网格中覆盖分形 s 所需的最小网格数; $d(s)$ 是一种非线性特征, $d(s)$ 越大,序列的复杂度越高^[20]。根据式(24)–(25)定义的小波能量以及分形维数,分别计算EEG信号的分形维数和小波能量,作为其频域和非线性特征。

2.3.3 EEG信号特征融合和选择

对时,频和非线性特征提取时,特征空间之间可能存在重叠,出现特征冗余。特征选择(feature selection, FS)在确保不丢失重要特征的前提下,根据实际任务目标对评估特征,去掉冗余特征^[21],本文在过滤式特征选择的基础上提出自适应特征选择算法,将分类精度融入特征评价中,加强特征与分类器之间的联系,自适应地完成特征选择。算法1给出了EEG信号的Ad-TQWT MF算法的具体流程。

3 实验分析

为了验证Ad-TQWT MF算法的可行性、有效性以及鲁棒性,本节利用该算法对BCI竞赛数据集进行实验。选用第二、三届BCI竞赛的EEG左右手数据集,其中Dataset_III以128 Hz对C3, Cz和C4三个通道进行采样,每次采集9 s时长的信号,O3VR, X11b和S4b均以125 Hz对C3和C4两个通道进行采样,每个实验时长为8 s,4个数据集的信号均经过Notch滤波器处理后,频率在ERD/ERS可能存在的0.5 Hz和30 Hz区间内。实验前去除数据中异常样本,在进行特征提取之前,为满足数据平稳性的要求还需对数据进行窗口化处理^[22]。数据集中样本的具体信息如表1所示。

表1中, Dataset_III采用时长为3 s的滑动窗口,从 $t=6$ s开始并以 $\Delta t=0.125$ s滑动,其余3个数据集均采用时长为4 s的滑动窗口,从 $t=4$ s开始并以 $\Delta t=0.04$ s滑动,表1中最后一列为窗口化后数据集的样本数。

算法1 EEG信号的Ad-TQWT MF算法

输入: 原始EEG信号数据集和标签 $X=\{X_1, X_2, \dots, X_n\}$,

$$Y = \{y_1, y_2, \dots, y_n\}.$$

输出: 特征集合 $F' = \{F'_1, F'_2, \dots, F'_n\}$.

特征提取:

步骤1 去除数据集 X 中的异常数据,并进行窗口化处理,得到 $\{X'_1, X'_2, \dots, X'_n\}$ 。

步骤2 对 $\{X'_1, X'_2, \dots, X'_n\}$ 中的每个 X'_i 进行不同 Q 因子的TQWT分解,利用 \bar{R} 进行评价,选出 \bar{R} 最大的 Q 因子。

步骤3 对该 Q 下的 $\{X'_1, X'_2, \dots, X'_n\}$ 中的 X'_i 进行 J 层分解,得 $J+1$ 个子带 $\{l_j(n), h_i(n) | 1 \leq i \leq J\}$ 。

步骤4 对 $\{l_i(n), h_i(n)\}$ 和 $\{X'_1, X'_2, \dots, X'_n\}$ 用式(11)(13)(20)(23)得到特征集 $F = \{F_1, F_2, \dots, F_n\}_{n \times m}$ 。

特征选择:

步骤5 根据标签 Y 和各样本的特征集合 F ,在该维度为 m 的总特征空间 F 中,依次选择每个样本的第 i 个维度的特征 $f_i = \{F_i^1, F_i^2, \dots, F_i^n\}_{n \times m}$ 加入待训练的特征子空间中,组成新的特征子空间 $F' = \{F', f_i\}$ 。

步骤6 将第 i 次得到的 $F' = \{F', f_i\}$ 放入分类器中进行训练得到精度 Acc_i ,按 $Acc_i > Acc_{i-1}$ 或 $Acc_i + \delta > Acc_{i-1}$ 与第 $i-1$ 次进行比较,如果满足条件则转至Step5, δ 为设置的精度变化阈值。否则,舍弃第 i 维度的特征 f_i 。

步骤7 当 F' 的特征维度为 m 时结束循环,将特征子空间 $F' = \{f_i, f_{i+1}, \dots, f_k\}$ 作为最终的特征训练集合。

表1 实验数据集

Table 1 Experiment Dataset

数据集	通道数	类别数	样本数	窗口化样本数
Dataset_III	3	2	280	3360
O3VR	2	2	400	32320
X11b	2	2	1080	14040
S4b	2	2	1080	14040

3.1 特征提取

根据TQWT的分解重构原理以及采样频率,结合ERD/ERS现象存在的频率区间和文献[23]的先验信息,可以确定Dataset_III的 Q 因子取值范围为[1, 12],其余3个数据集的 Q 因子取值范围为[1, 10]。对于上述4个数据集,分别对各区间寻优后确定适合其数据集的 Q 因子,各数据集优化前后各参数见表2。

表2 数据集TQWT分解参数

Table 2 Parameters of TQWT in different datasets

数据集	文献[10]的参数			优化的参数		
	Q	r	J	Q	r	J
Dataset_III	1	3	2	3.40	5	8
O3VR	2	3	7	2.35	5	8
X11b	1	3	2	5.30	3	7
S4b	2	3	3	2.80	3	7

根据表2中优化后的Q因子,冗余率 r 和分解层数 J 分别对各数据集进行TQWT分解。根据式(9)–(10)计算各子带系数,按式(11)–(13)小波能量特征。利用式(25)计算分形维数,分形网格的分割上限取为2048,将这两个维度作为频域特征。除频域特征外,还需提取样本熵和LP系数等时域特征,按式(19)计算各数据集样本熵,最后通过式(23)建立LP模型,数据集1和4的LP系数 l 为8,数据集2和3的LP系数 l 为8。

3.2 特征选择

通过样本熵,LP系数,小波能量以及分形维数对各数据集进行特征提取,得到样本的特征维数见表3。利用Ad-TQWT MF的自适应特征选择算法提取特征子空间,得到去除的样本特征维度序号如表4所示。其中X11b数据集减少了28%的特征,其他3个数据集删除的特征比例范围在10%~18%之间。经过自适应特征选择对特征进行筛选后,去除了原数据集中冗余特征,降低了训练数据的规模和模型复杂度。

表3 样本的特征维度

Table 3 Feature dimensions of the sample

数据集	小波能量	LP系数	样本熵	分形维数	通道数	总计
Dataset_III	9	8	1	1	3	57
O3VR	9	8	1	1	2	34
X11b	8	6	1	1	2	32
S4b	8	8	1	1	2	36

表4 特征选择去除的特征维度

Table 4 Feature dimensions removed by feature selection

数据集	去除特征维度的序号	剩余特征数	删除比例
Dataset_III	[1,19,28,29,40,41]	51	10.5%
O3VR	[1,3,4,5,7,18]	28	17.6%
X11b	[1,2,3,6,15,16,17,19,22]	23	28.1%
S4b	[18,27,33,34]	32	11.1%

3.3 分类性能比较

经过特征提取以及特征选择后,将最终得到的特征集依次放入线性判别分类器(linear discriminant analysis, LDA),支持向量机(support vector machine, SVM)以及高斯核支持向量机(高斯SVM)中进行训练。为说明Ad-TQWT MF算法的可行性和有效性,还将Haar以及Db_4小波函数处理得到的数据集作为对照组。对上述数据集进行特征提取和分类时采用了十折交叉验证,将测试集准确率的均值作为最终算法的分类准确率。以X11b数据集为例,分别利用5种不同特征提取方法(Haar, Db_4, TQWT, Ad-TQWT, Ad-TQWT MF)进行特征提取,分别放入LDA, SVM以及高斯SVM进行训练,得到各方法的ROC曲线。其中,Haar小波结合3个分类器的ROC曲线如图5所示,从图5中看出Haar小波在3个分类器的AUC均为88%,模型的测试准确率分别为81%, 81% 和78%。Haar小波是最常见的二进制小波,其小波具有离散不连续性,导致其不能充分提取左右手波动特征,因此信号分类的精度较低。

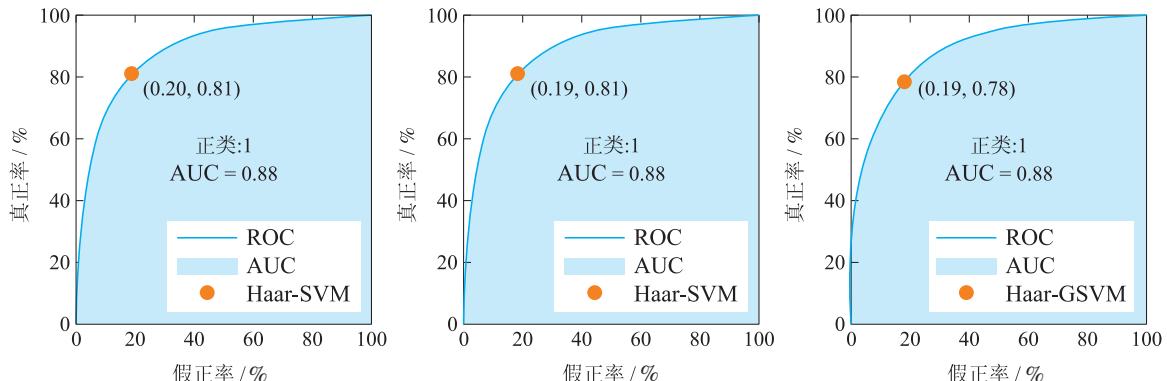


图5 Haar的ROC曲线(X11b-LDA, SVM, 高斯SVM)

Fig. 5 ROC of Haar(LDA, SVM and GSVM in X11b)

Db_4小波作为一种连续小波,解决了Haar小波不连续的问题。图6给出了该小波提取特征后3个分类器的ROC曲线,从图6中,可以看出Db_4小波提取的特征集合,经过3个分类器分类的AUC均为88%,模型的测试准确率分别为81%, 82%和79%。较于Haar小波,Db_4小波函数具备连续性,提取EEG左右手特征的能力上有所提高,但由于其Q因子固定不变,该小波不

能适应EEG信号非平稳的波动特性。

TQWT与Haar, Db_4小波不同,其Q因子可调节,图7是TQWT提取特征训练后的ROC曲线。图7中,可以看出TQWT提取的特征集合经过3个分类器的AUC分别为88%, 88%和89%,模型的测试准确率分别为80%, 82%和79%。较于Haar和Db_4小波,TQWT其Q因子可根据信号的特性进行调节,可以适应EEG信

号中复杂震荡的情况,但在实际的Q因子选择中,需大量的实验缺乏理论方法.

针对Q因子选择缺乏理论的问题,利用E-SER评价Q因子,Ad-TQWT分解信号得到的ROC曲线如图

8, Ad-TQWT在3个分类器AUC均为90%,模型的准确率分别为84%,84%和82%.较于原TQWT,Ad-TQWT其Q因子优化后,小波更准确匹配EEG信号中特定震荡,使信号提取的特征信息更加充分.

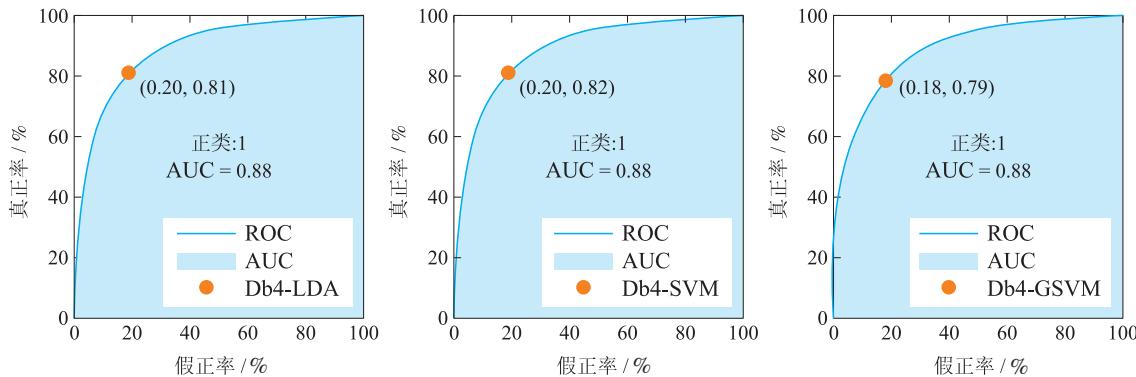


图6 Db_4的ROC曲线(X11b-LDA, SVM, 高斯SVM)

Fig. 6 ROC of Db_4(LDA, SVM and GSVM in X11b)

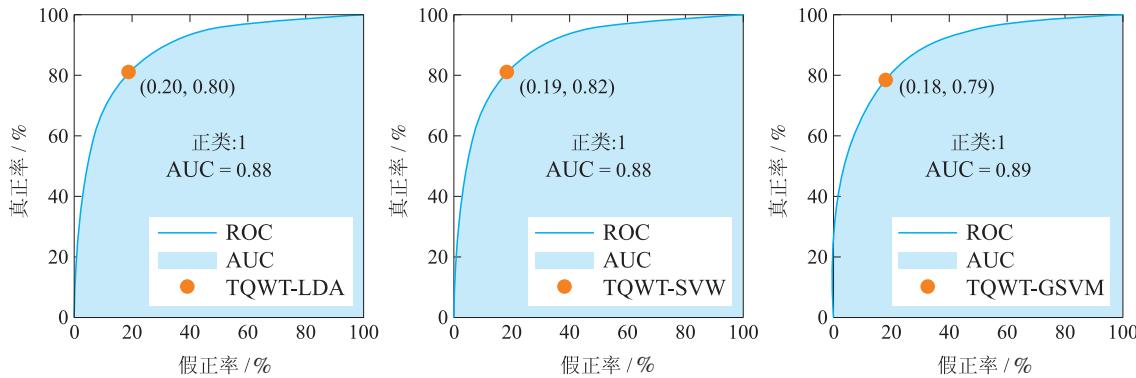


图7 TQWT的ROC曲线(X11b-LDA, SVM, 高斯SVM)

Fig. 7 ROC of TQWT(LDA, SVM and GSVM in X11b)

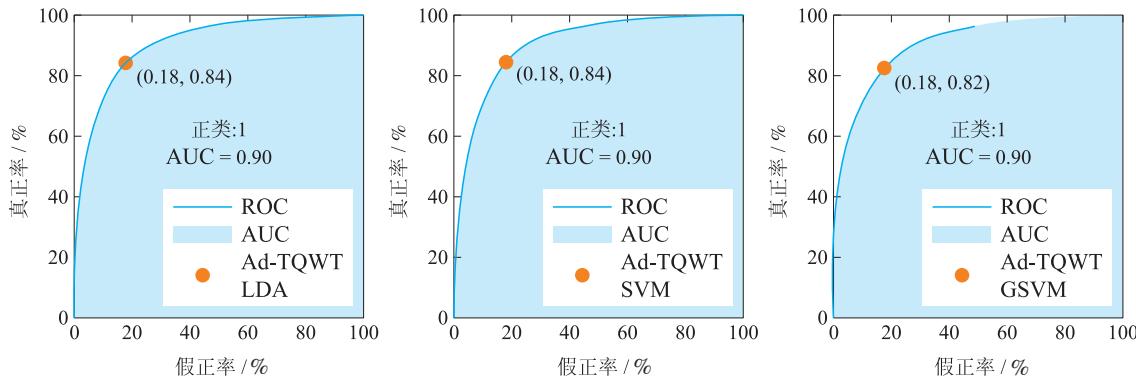


图8 Ad-TQWT的ROC曲线(X11b-LDA, SVM, 高斯SVM)

Fig. 8 ROC of Ad-TQWT(LDA, SVM and GSVM in X11b)

Ad-TQWT虽然提取了多维度特征,但忽略了特征之间的相关性,可能出现特征冗余,因此利用特征选择合适的特征子空间,提出Ad-TQWT MF算法.其分类的ROC曲线如图9.

图9中3个分类器的AUC均为90%,其测试的准确率分别为85%,84%和82%.较于前面4种方法,本文

提出的Ad-TQWT MF算法,充分提取EEG信息,利用自适应特征选择合适的特征子空间,降低了模型复杂度,提高了模型的准确率,佐证算法的可行性以及有效性.

表5给出了所有训练数据集在3个分类器下具体的测试准确率以及AUC,从表5的实验结果分析,可以得

到如下的结论:

1) Ad-TQWT 与 Haar, Db_4 小波和 TQWT 相比, 对 O3VR 和 S4b 的识别中测试准确率提高了 1%~3%, 在 Dataset_III 和 X11b 中提高了 2%~4%;

2) 在 TQWT 与 Ad-TQWT MF 算法识别 EEG 信号中, 后者利用能量香农熵比作为 Q 因子评价指标, 融合时域、频域和非线性特征, 通过自适应特征选择构建特征子空间, 去除了 10%~30% 冗余特征, 提高了

2%~5% 准确率;

3) 在 LDA, SVM 以及高斯 SVM 3 种分类器中, Dataset_III 和 X11b 在 LDA 下测试准确率比 SVM 与高斯 SVM 高 1%~4%。O3VR 在高斯 SVM 的测试准确率高出 LDA 和 SVM 2%~3%。S4b 在 SVM 下测试准确率最高达 85.6%。Ad-TQWT MF 算法在不同分类器上识别的测试准确率均为最高。针对不同的数据集, Ad-TQWT MF 均可进一步提高识别 EEG 信号的精度。

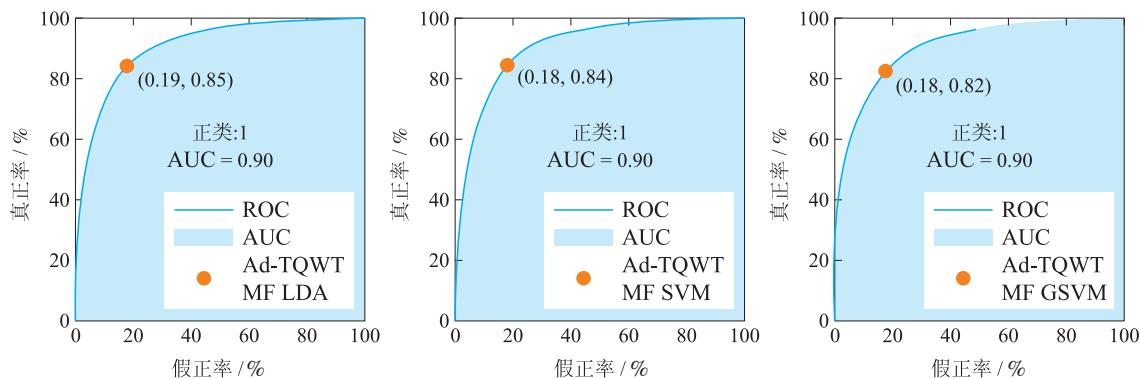


图 9 Ad-TQWT MF 的 ROC 曲线(X11b-LDA, SVM, 高斯 SVM)

Fig. 9 ROC of Ad-TQWT MF(LDA, SVM and GSVM in X11b)

表 5 各数据集的测试准确率

Table 5 Test accuracy of each dataset

数据集/特征提取		LDA	SVM	高斯 SVM
		测试准确率	测试准确率	测试准确率
Dataset_III	Harr	85.8%	85.5%	83.3%
	Db_4	86.2%	84.7%	83.0%
	TQWT	85.7%	84.3%	82.4%
	Ad_TQWT	88.6%	85.6%	84.4%
O3VR	Ad_TQWT MF	89.2%	85.5%	85.4%
	Harr	76.7%	75.1%	78.1%
	Db_4	76.5%	74.8%	78.2%
	TQWT	78.8%	77.6%	81.4%
S4b	Ad_TQWT	78.9%	77.8%	80.9%
	Ad_TQWT MF	79.2%	78.1%	81.2%
	Harr	82.6%	82.4%	82.1%
	Db_4	82.4%	82.3%	82.7%
X11b	TQWT	83.0%	84.5%	83.7%
	Ad_TQWT	84.1%	85.5%	84.8%
	Ad_TQWT MF	84.6%	85.6%	84.8%
	Harr	80.3%	81.0%	79.8%
	Db_4	80.2%	81.0%	80.5%
	TQWT	80.3%	80.9%	80.9%
	Ad_TQWT	82.2%	82.9%	82.2%
	Ad_TQWT MF	83.2%	82.9%	82.4%

4 展望

本文针对 EEG 信号识别中 TQWT 参数 Q 因子无优化评价标准, 特征存在冗余的问题, 提出 Ad-TQWT MF 算法。通过能量香农熵比作为 TQWT 的 Q 因子优化评价标准, 选择最优 Q 因子小波变换, 将时、频域和非线性特征融合, 自适应的特征选择获取特征子空间, 提高了 EEG 信号的识别精度。后续工作将在 EEG 信号的异常特征提取方面进一步开展相关研究。

参考文献:

- [1] ALARCAO S M, FONSECA M J. Emotions recognition using EEG signals: A survey. *IEEE Transactions on Affective Computing*, 2019, 10(3): 374 – 393.
- [2] BALCONI M, MAZZA G. Brain oscillations and BIS/BAS (behavioral inhibition/activation system) effects on processing masked emotional cues. ERS/ERD and coherence measures of alpha band. *International Journal of Psychophysiology*, 2009, 74(2): 158 – 165.
- [3] GHOSH-DASTIDAR S, ADELI H, DADMEHR N. Principal component analysis-enhanced cosine radial basis function neural network for robust epilepsy and seizure detection. *IEEE Transactions on Biomedical Engineering*, 2008, 55(2): 512 – 518.
- [4] OZCAN A R, ERTURK S. Seizure prediction in scalp EEG using 3D convolutional neural networks with an image-based approach. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27(11): 2284 – 2293.
- [5] ZHANG Y, WANG Y, JIN J, et al. Sparse bayesian learning for obtaining sparsity of EEG frequency bands based feature vectors in motor imagery classification. *International Journal of Neural Systems*, 2017, 27(2): 1650032.
- [6] MEHLA V K, SINGHAL A, SINGH P, et al. An efficient method for identification of epileptic seizures from EEG signals using Fouri-

- er analysis. *Physical and Engineering Sciences in Medicine*, 2021, 44(2): 443 – 456.
- [7] WANG Hongtao, LI Ting, HUANG Hui, et al. A motor imagery analysis algorithm based on spatio-temporal-frequency joint selection and relevance vector machine. *Control Theory & Applications*, 2017, 34(10): 1403 – 1408.
(王洪涛, 李霆, 黄辉, 等. 一种基于时-空-频联合选择与相关向量机的运动想象脑电信号分析算法. 控制理论与应用, 2017, 34(10): 1403 – 1408.)
- [8] ACHARYA U R, MOLINARI F, SREE S V, et al. Automated diagnosis of epileptic EEG using entropies. *Biomedical Signal Processing & Control*, 2012, 7(4): 401 – 408.
- [9] FU R, HAN M, TIAN Y, et al. Improvement motor imagery EEG classification based on sparse common spatial pattern and regularized discriminant analysis. *Journal of Neuroscience Methods*, 2020, 343: 108833.
- [10] MENG Ming, YIN Xu, GAO Yunyuan, et al. Block-selection based common space pattern feature extraction of motor imagery EEG. *Control Theory & Applications*, 2021, 38(3): 301 – 308.
(孟明, 尹旭, 高云园, 等. 运动想象脑电的块选择共空间模式特征提取. 控制理论与应用, 2021, 38(3): 301 – 308.)
- [11] CHEN Wanzhong, WANG Xiaoxu, ZHANG Tao. Research of discrimination between left and right hand motor imagery EEG patterns based on tunable Q -factor wavelet transform. *Journal of Electronics & Information Technology*, 2019, 41(3): 27 – 33.
(陈万忠, 王晓旭, 张涛. 基于可调 Q 因子小波变换的识别左右手运动想象脑电模式研究. 电子与信息学报, 2019, 41(3): 27 – 33.)
- [12] AL GHAYAB H R, LI Y, SIULY S, et al. A feature extraction technique based on tunable Q -factor wavelet transform for brain signal classification. *Journal of Neuroscience Methods*, 2019, 312: 43 – 52.
- [13] SELESNICK I W. Wavelet transform with tunable Q -factor. *IEEE Transactions on Signal Processing*, 2011, 59(8): 3560 – 3575.
- [14] GAO R X, YAN R. *Wavelets: Theory and Applications for Manufacturing*. Berlin: Springer, 2010: 130 – 137.
- [15] SHARMA R, PACHORI R B, ACHARYA U R. Application of entropy measures on intrinsic mode functions for the automated identification of focal electroencephalogram signals. *Entropy*, 2015, 17(2): 669 – 691.
- [16] ZHAO L, ZHU X. Feature extraction and classification of electroencephalogram signals based on local mean decomposition and sample entropy. *Computer Engineering*, 2017, 43(2): 299 – 303.
- [17] AWHERN V, HAIRSTON W D, McDOWELL K, et al. Detection and classification of subject-generated artifacts in EEG signals using autoregressive models. *Journal of Neuroscience Methods*, 2012, 208(2): 181 – 189.
- [18] AMIN H U, MALIK A S, AHMAD R F, et al. Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques. *Australasian Physical & Engineering Sciences in Medicine*, 2015, 38(1): 139 – 149.
- [19] CHEN Zhe, WANG Rong, ZHOU Wenying, et al. Review on measurement parametrics and methods for nonstationary signal. *Journal of Data Acquisition and Processing*, 2017, 32(4): 667 – 683.
(陈喆, 王荣, 周文颖, 等. 非平稳信号度量方法综述. 数据采集与处理, 2017, 32(4): 667 – 683.)
- [20] ZHANG Y L. *Research on fractal analysis of epileptic EEG and automatic seizure detection methods*. Shandong: Shandong University, 2016.
- [21] ZHOU Z H. *The Main Algorithm Research on Financial Time Series Data Mining*. Beijing: Tsinghua University Press, 2016: 247 – 254.
- [22] SUPRIYA S, SIULY S, WANG H, et al. Automated epilepsy detection techniques from electroencephalogram signals: A review study. *Health Information Science and Systems*, 2020, 8(1): 33.
- [23] GEORGE S T, SUBATHRA M S P, SAIRAMYA N J, et al. Classification of epileptic EEG signals using PSO based artificial neural network and tunable- Q wavelet transform. *Biocybernetics and Biomedical Engineering*, 2020, 40(2): 709 – 728.

作者简介:

刘朕 硕士研究生, 目前研究方向为人工智能和模式识别、智能计算及应用, E-mail: 6201204018@stu.jiangnan.edu.cn;

朱炳宇 硕士研究生, 目前研究方向为人工智能和模式识别、智能计算及应用, E-mail: 6191204022@stu.jiangnan.edu.cn;

张景祥 副教授, 硕士生导师, 目前研究方向为人工智能和模式识别、智能计算及应用, E-mail: zhangjingxiang@jiangnan.edu.cn.