

基于 HHT 和 CSSD 的多域融合自适应脑电特征提取方法

李明爱¹, 崔 燕¹, 杨金福¹, 郝冬梅²

(1. 北京工业大学电子信息与控制工程学院, 北京 100124; 2. 北京工业大学生命科学与生物工程学院, 北京 100124)

摘 要: 为改善运动想象脑电信号特征提取的自适应性和实时性, 提出一种基于希尔伯特-黄变换(HHT)与共空域子空间分解算法(CSSD)的特征提取方法(HCSSD). 在对脑电信号进行预处理的基础上, 定义一种相对距离准则优选脑电极组合; 计算脑电的 Hilbert 瞬时能量谱和边际能量谱, 以获取脑电的时-频特征, 并基于 CSSD 提取其空域特征, 采用串行特征融合策略得到脑电的时-频-空特征; 设计学习矢量量化神经网络分类器, 实现脑电数据分类. 在训练集与测试集间隔一周且减少导联数量的情况下, 基于 HCSSD 对左手小指和舌头的运动想象 ECoG 脑电数据的平均识别率为 92%. 实验结果表明: HCSSD 在增强特征提取方法的自适应性、改善实时性的同时, 提高了脑电信号识别率, 为便携式 BCI 系统在康复领域的应用创造了条件.

关键词: 脑机接口; 运动想象; 希尔伯特-黄变换; 共空域子空间分解; 特征融合; 自适应

中图分类号: R318 **文献标识码:** A **文章编号:** 0372-2112 (2013) 12-2479-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2013.12.025

An Adaptive Multi-Domain Fusion Feature Extraction with Method HHT and CSSD

LI Ming-ai¹, CUI Yan¹, YANG Jin-fu¹, HAO Dong-mei²

(1. College of Electronic Information & Control Engineering, Beijing University of Technology, Beijing 100124, China;

2. College of Life Science & Biological Engineering, Beijing University of Technology, Beijing 100124, China)

Abstract: The adaptivity and real-time performance of feature extraction method are crucial in brain-computer interface. Based on Hilbert-Huang transform (HHT) and common spatial subspace decomposition (CSSD) algorithm, a novel feature extraction method, denoted as HCSSD, was proposed. Firstly, the motor imagery electroencephalography (EEG)/ electrocorticography (ECoG) was preprocessed, and a relative distance criterion was defined to select the optimal combination of channels. Secondly, Hilbert instantaneous energy spectrum and marginal energy spectrum of EEG/ECoG were calculated to extract time feature and frequency feature respectively. Then CSSD was applied to extract spatial feature. Furthermore, serial feature fusion strategy was adopted to obtain time-frequency-spatial feature. Finally, learning vector quantization neural network was designed to classify the EEG/ECoG data. The average recognition accuracy was 92% for the left small finger and tongue motor imagery ECoG tasks. Experiment results show that HCSSD can enhance the adaptivity and real-time performance of feature extraction, with the recognition accuracy improved. This method provides a new idea for the application of portable BCI system in rehabilitation field.

Key words: brain-computer interface (BCI); motor imagery (MI); hilbert-huang transform (HHT); common spatial subspace decomposition (CSSD); feature fusion; adaptivity

1 引言

目前, 在老龄人群中有大量的脑血管疾病或脊髓损伤患者, 其多数伴有中风及偏瘫症状. 医学理论和实践证明, 科学的康复训练可使大脑中残存的神经细胞功能得到增强和恢复, 从而促进肢体运动功能的康复. 但由于偏瘫患者的自主运动能力将部分或全部丧失, 致使其训练方法受到限制. 基于运动想象 (Motor Imagery, MI) 的

脑机接口 (Brain-Computer Interface, BCI) 技术为运动功能障碍患者提供了一种全新的主动式康复手段. 该方法可在不增加康复训练强度的情况下提高患者运动功能恢复程度, 具有明显优势^[1].

基于 MI-BCI 的运动功能康复研究已取得了令人鼓舞的进展, 实验研究及临床验证都显示其有效性^[2]. 但该项研究仍无法应用于实际康复中, 主要原因在于: 随着时间的推移和康复训练的进行, 患者大脑状态会发生

改变,难以自适应地识别运动想象脑电信号,使识别率达到并稳定在较高水平;同时,BCI系统电极数量庞大,限制了系统的实时性.这正是当前普遍关注而尚未很好解决的问题.

头皮脑电(Electroencephalography, EEG)/皮层脑电(Electrocorticography, ECoG)是MI-BCI系统的信号源,信号微弱且具有非线性、非平稳及时变敏感等特点,有效的特征提取方法是提高其识别准确率的关键技术之一.时频分析法是目前倍受关注的一种智能信号处理方法,已应用于脑电特征研究中,主要包括短时傅里叶变换、小波变换及Wigner-Ville分布等方法.这些方法的本质是傅里叶变换,受Heisenberg测不准原理的束缚,无法在时域和频域同时具有较高的分辨率.希尔伯特-黄变换(Hilbert-Huang Transform, HHT)^[3,4]是一种适合于非线性非平稳信号的有效时频分析方法.该方法通过经验模态分解(Empirical Mode Decomposition, EMD)将非平稳信号自适应分解成一系列具有物理意义的窄带信号,即固有模态函数(Intrinsic Mode Function, IMF),并对各层IMF做Hilbert变换.该方法不受测不准原理的束缚,在时域、频域同时具有很高的分辨率,已用于雷达检测、地震信号及生物医学信号等信息处理.

脑电信号的时频特征会随着大脑状态的变化而改变,这要求其特征提取算法应具有更好的自适应性及稳健性,一些研究者试图综合考虑脑电的时间-频率-空间信息进行特征提取.如文献[3]对28导脑电信号在时-频平面进行网格划分,并以每个网格内的Hilbert能量谱作为脑电特征.实验结果表明,该方法提取的特征虽然在一定程度上能够体现脑电信号的时-频-空信息,但自适应能力不强,网格大小对识别率影响很大.同时,由于HHT速度较慢,对各导电极均进行特征提取耗时很长,难以实现在线应用;文献[5]最早利用共空域子空间分解(Common Spatial Subspace Decomposition, CSSD)算法提取脑电的空域特征.该方法是一种针对多通道EEG/ECoG数据的空域滤波算法,每个空域模式描述了特定的源信号在脑部不同区域空间的分布模式,其对多脑区协同工作机制有很大的研究价值.CSSD已在BCI研究,特别是运动想象脑电的特征提取中被广泛采用^[6].但CSSD需要大量电极的脑电数据,导联数目的减少会导致脑电识别率显著降低.因此,如何在减少电极数量的同时,有效增强特征提取算法的自适应能力和泛化能力,并获得较高的识别准确率有待深入研究.

本文基于HHT和CSSD提出一种融合时域、频域和空域特征的特征提取方法(HCSSD),即采用HHT提取运动想象脑电的时域与频域特征,基于CSSD提取脑电的空域特征,进而将三者融合获取脑电的全部特征信息,并设计学习矢量量化(Learning Vector Quantization,

LVQ)神经网络分类器进行分类.实验结果表明,HCSSD不仅增强了特征提取方法的自适应性和稳健性,而且在使用较少导联的情况下提高了脑电信号的识别率,为便携式BCI系统在康复领域的应用创造了条件.

2 实验数据

本文采用的运动想象脑电数据集来源于“BCI Competition III”(Data set I < motor imagery in ECoG recordings, session-to-session transfer >),由德国Tübingen大学等三个单位联合提供^[7].实验执行想象左手小指与想象舌头运动两种思维任务,其数据由植入大脑右侧运动皮层的一个 8×8 (64导)的电极阵列记录,如图1所示.信号的采样频率为1000Hz,经过0.016-300Hz的带通滤波.

实验时序如图2(a),每次实验持续7s,每两次实验中间均有几分钟的间隔. $t=0$ 时,屏幕中央出现一个十字光标; $t=1 \sim 5$ s时,屏幕上出现一幅图片以提示受试者想象左手手指或舌头运动,具体见图2(b),两种想象任务出现的次序随机; $t=5 \sim 7$ s,显示器处于白屏状态,受试者此时可以休息.随后下一次实验开始.为避免视觉诱发电位对数据的影响,竞赛数据集Data set I中截取1.5~4.5s的数据段用于离线分析.





图1 运动感知区放置微电极板



(a) 实验时序示意图



(b) 提示图片

图2 基于ECoG的运动想象BCI实验范例

整个数据集包括两部分:给定标签的278次实验组成的训练集(两种运动想象实验数据各139次)和未知

标签的 100 次实验组成的测试集(两种运动想象数据各 50 次).训练数据和测试数据记录时间相隔一周,因此,该数据集更有利于检验识别方法的自适应性和稳健性.

3 基于 HCSSD 的特征提取方法

近年来,数据融合在模式识别领域得到迅速发展,主要分为数据级融合、特征级融合和决策级融合三个层次.特征级融合具有保留参与融合的多种特征有效分类信息的优点,备受瞩目.针对脑机接口研究中,患者运动想象脑电信号随着时间的推移而改变、识别率较低、电极数量庞大等问题,本文提出了一种基于多域融合的特征提取方法,即 HCSSD 法.该方法采用 Hilbert-Huang 变换提取运动想象脑电的时域与频域特征,并基于 CSSD 提取其空域特征,在特征级进行多域特征融合以保证脑电特征信息的完整性,获得鲁棒性更强的联合特征.

3.1 基于 HHT 变换的时-频域特征提取

1998 年, N E Huang 等人首次提出 Hilbert-Huang 变换(即 HHT).它是一种针对非平稳非线性信号的时频分析方法,在时域、频域同时具有很高的分辨率,能够有效提取脑电的时-频特征.其主要包括经验模态分解和 Hilbert 变换两个过程.

3.1.1 经验模态分解

经验模态分解是一种纯数据驱动的自适应分析方法,其本质是通过信号特征时间尺度判别内蕴振荡模式,然后以此为依据将信号分解成一系列具有物理意义的固有模态函数 IMF.因此,EMD 的分解基完全由信号本身决定,具有自适应性,从而使信号得到精确的表达式^[4].

对任意实信号 $x(t)$, EMD 算法^[8]步骤如下:

步骤 1 确定 $x(t)$ 所有的极值点,用三次样条曲线分别对极小值点和极大值点进行拟合,得到上包络曲线 $e_{\max}(t)$ 和下包络曲线 $e_{\min}(t)$.

步骤 2 依式(1)计算上、下包络线的平均值:

$$m(t) = \frac{e_{\min}(t) + e_{\max}(t)}{2} \quad (1)$$

步骤 3 依式(2)计算新的信号 $c(t)$:

$$c(t) = x(t) - m(t) \quad (2)$$

若 $c(t)$ 不满足 IMF 定义,则将 $c(t)$ 取代 $x(t)$ 重复步骤 1 ~ 步骤 3;否则, $c(t)$ 为分离出的一个 IMF,并计算剩余信号 $r(t)$:

$$r(t) = x(t) - c(t) \quad (3)$$

步骤 4 将 $r(t)$ 作为原始信号对 $r(t)$ 重复步骤 1 ~ 步骤 3 的筛选过程,直到 $r(t)$ 满足筛选停止条件为止.

在 EMD 过程结束时,假设原信号 $x(t)$ 被分解成 n 个 IMF 和一个残差分量 $r_n(t)$,则 $x(t)$ 可表示为

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (4)$$

其中, $c_i(t)$ 表示第 i 次筛选得到的 IMF 分量, $r_n(t)$ 为最终的剩余信号.

3.1.2 Hilbert 变换与 Hilbert 能量谱

依式(5)对每个 IMF 分量 $c_i(t)$ ($i = 1, 2, \dots, n$) 进行 Hilbert 变换:

$$y_i(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{c_i(\tau)}{t - \tau} d\tau \quad (5)$$

构造解析信号 $z_i(t)$:

$$z_i(t) = c_i(t) + jy_i(t) = a_i(t) e^{j\theta_i(t)} \quad (6)$$

其中, $a_i(t)$ 和 $\theta_i(t)$ 分别表示第 i 个 IMF 分量的瞬时幅值和瞬时相位,由下式计算:

$$a_i(t) = \sqrt{y_i(t)^2 + c_i(t)^2} \quad (7)$$

$$\theta_i(t) = \arctan \frac{y_i(t)}{c_i(t)} \quad (8)$$

由 $a_i(t)$ 与 $\theta_i(t)$ 进一步求得瞬时频率 $\omega_i(t)$, 即

$$\omega_i(t) = \frac{d\theta_i(t)}{dt} \quad (9)$$

则

$$x(t) = \operatorname{Re} \left\{ \sum_{i=1}^n a_i(t) e^{j\theta_i(t)} \right\} = \operatorname{Re} \left\{ \sum_{i=1}^n a_i(t) e^{j \int \omega_i(t) dt} \right\} \quad (10)$$

式中, $\operatorname{Re}\{\cdot\}$ 表示取实部.这里忽略了 EMD 分解后信号 $x(t)$ 的残差 $r_n(t)$.式(10)描述了信号幅度在整个频率段上随时间和瞬时频率的变化规律,幅度的这种时频分布表示称为 Hilbert 谱,记为 $H(\omega, t) =$

$$\operatorname{Re} \left\{ \sum_{i=1}^n a_i(t) e^{j \int \omega_i(t) dt} \right\}.$$

进一步由下式求取 Hilbert 能量谱:

$$H^2(\omega, t) = \left\{ \operatorname{Re} \left\{ \sum_{i=1}^n a_i(t) e^{j \int \omega_i(t) dt} \right\} \right\}^2 \quad (11)$$

Hilbert 能量谱反映了信号的能量在时间和频率平面上的分布情况,真实地体现了非线性非平稳信号的本质特性.

3.1.3 特征向量定义

依式(12)计算 Hilbert 瞬时能量谱(Instantaneous Energy Spectrum, IES):

$$\text{IES}(t) = \int_{\omega_1}^{\omega_2} H^2(\omega, t) d\omega \quad (12)$$

式中, $[\omega_1, \omega_2]$ 为定义的信号频率范围.

Hilbert 瞬时能量谱反映了信号能量随时间的变化规律,即体现了信号的时域能量特征,本文将其定义为脑电信号的时域特征 $f_1 \in \mathbf{R}^{M_1 \times 1}$, 其中 M_1 为时间点数.

同时,由 Hilbert 能量谱进一步计算 Hilbert 边际能量谱(Marginal Energy Spectrum, MES):

$$\text{MES}(\omega) = \int_{t_1}^{t_2} H^2(\omega, t) dt \quad (13)$$

式中, $[t_1, t_2]$ 为定义的信号时间范围.

Hilbert 边际能量谱表示信号中不同频率成分的能量分布情况,即体现了信号的频域能量特征,本文将其定义为脑电信号的频域特征 $f_2 \in \mathbf{R}^{M_2 \times 1}$,其中 M_2 为频率点数.

3.2 基于 CSSD 的空域特征提取

CSSD 是一种针对多通道 EEG/ECoG 数据的空域滤波算法,该方法基于空间-时间源建模和两个实对称矩阵(协方差矩阵)的同时对角化,将原始信号分解为多个空域模式,每个空域模式描述了特定的源信号在脑部不同区域空间的分布模式^[5].

假设 $X_A \in \mathbf{R}^{N \times M}$ 和 $X_B \in \mathbf{R}^{N \times M}$ 分别为想象任务 A 与 B 时记录的脑电信号,其中, N 表示导联数, M 为信号采样点数,则基于 CSSD 进行特征提取的主要步骤如下.

步骤 1 求信号 X_A 和 X_B 的协方差矩阵 R_A 和 R_B .

$$R_A = \frac{X_A X_A^T}{\text{trace}(X_A X_A^T)}, R_B = \frac{X_B X_B^T}{\text{trace}(X_B X_B^T)} \quad (14)$$

其中, T 表示转置, $\text{trace}(\cdot)$ 表示矩阵的迹.

步骤 2 分解协方差矩阵.

记 A、B 两类任务多次实验的平均协方差矩阵分别为 $\bar{R}_A \in \mathbf{R}^{N \times N}$ 与 $\bar{R}_B \in \mathbf{R}^{N \times N}$, 对平均协方差矩阵之和进行特征分解:

$$\bar{R} = \bar{R}_A + \bar{R}_B = U_0 \Sigma U_0^T \quad (15)$$

式中, $\Sigma \in \mathbf{R}^{N \times N}$ 为特征值矩阵, $U_0 \in \mathbf{R}^{N \times N}$ 为与其对应的特征向量矩阵.

步骤 3 构造白化值转换矩阵 $P \in \mathbf{R}^{N \times N}$, 并对平均协方差矩阵 \bar{R}_A 和 \bar{R}_B 进行形式转换与特征值分解.

$$P = \Sigma^{-1/2} U_0^T \quad (16)$$

则平均协方差矩阵 \bar{R}_A 和 \bar{R}_B 可转换为如下形式:

$$S_A = P \bar{R}_A P^T, S_B = P \bar{R}_B P^T \quad (17)$$

再依下式对 S_A 和 S_B 进行特征值分解:

$$S_A = U_A \Sigma_A U_A^T, S_B = U_B \Sigma_B U_B^T \quad (18)$$

其中, $\Sigma_A \in \mathbf{R}^{N \times N}$ 和 $\Sigma_B \in \mathbf{R}^{N \times N}$ 为特征值矩阵, $U_A \in \mathbf{R}^{N \times N}$ 和 $U_B \in \mathbf{R}^{N \times N}$ 为相应的特征向量矩阵.

可以证明, S_A 和 S_B 具有相同的特征向量矩阵,即 $U_A = U_B$, 且特征值矩阵满足 $\Sigma_A + \Sigma_B = I$. 因此,对于同一特征向量,如果 S_A 具有较大的特征值,则 S_B 相应的特征值较小,反之亦然.

步骤 4 构造空间滤波器 W .

应用主成分分析法可知, Σ_A 的前 m_a 个特征值和 Σ_B 的后 m_b 个特征值所对应的特征向量能够表征 A、B 两类的空域特征.为了区分两类信号,从 U_A (或 U_B) 中同时提取前 m 列与后 m 列特征向量,并将其组合成矩阵 $U \in \mathbf{R}^{N \times 2m}$, 进而依下式构造空域滤波器 $W \in \mathbf{R}^{2m \times N}$:

$$W = U^T P \quad (19)$$

其中, m 为从特征向量矩阵中选取的对应于某一任务的特征向量的个数, m 为整数且 $1 \leq m \leq \text{int}(\frac{N}{2})$, $\text{int}(\cdot)$ 表示取整运算.

步骤 5 对运动想象脑电进行滤波,提取空域特征 f_3 .

设某实验记录的脑电信号数据为 $X \in \mathbf{R}^{N \times M}$, 则通过 CSSD 空域滤波器产生新的时间序列为 $Z \in \mathbf{R}^{2m \times M}$:

$$Z = WX \quad (20)$$

将 Z 的第 p 行记为 Z_p ($p = 1, 2, \dots, 2m$), 并定义其方差 v_p 如下:

$$v_p = \log \left[\frac{\text{var}(Z_p)}{\sum_{i=1}^{2m} \text{var}(Z_i)} \right] \quad (21)$$

其中, $\text{var}(\cdot)$ 表示时间序列的方差.

不同类别的信号经过空域滤波器 W , 相当于将原始信号沿着 w_i 方向进行投影 (w_i 为 W 的第 i 个行向量, $i \in [1, 2m]$), 在这些方向某一类信号的方差最大,另一类的方差则最小.为区分两类想象脑电信号,本文依式(22)定义方差向量作为其空域特征 $f_3 \in \mathbf{R}^{2m \times 1}$:

$$f_3 = [v_1, v_2, \dots, v_{2m}]^T \quad (22)$$

3.3 特征融合

特征级融合方法主要包括串行特征融合与并行特征融合策略两种.其中,串行特征融合是将表征样本的多种特征分别归一化后进行串接,不仅计算简单、且能够有效保留各种特征的分类信息;而并行特征融合方法则利用复向量将样本空间上的特征集组合起来,构成复特征向量空间,其计算较为复杂,并对分类器的设计提出更高要求.为尽可能减少计算复杂度,本文选用串行特征融合策略获取脑电特征.

假设基于串行特征融合法和 HCSSD 法获得的脑电信号特征向量为 $F \in \mathbf{R}^{(KM_1 + KM_2 + 2m) \times 1}$, 则

$$\begin{cases} F = [F_1, F_2, F_3]^T \\ F_1 = \left[\frac{f_{11}^T}{\|f_{11}\|}, \frac{f_{12}^T}{\|f_{12}\|}, \dots, \frac{f_{1K}^T}{\|f_{1K}\|} \right] \in \mathbf{R}^{1 \times KM_1} \\ F_2 = \left[\frac{f_{21}^T}{\|f_{21}\|}, \frac{f_{22}^T}{\|f_{22}\|}, \dots, \frac{f_{2K}^T}{\|f_{2K}\|} \right] \in \mathbf{R}^{1 \times KM_2} \\ F_3 = \frac{f_3^T}{\|f_3\|} \in \mathbf{R}^{1 \times 2m} \end{cases} \quad (23)$$

式中, F_1, F_2 分别为基于 HHT 对 K 导脑电信号提取的时域特征与频域特征, F_3 为 CSSD 法对 N 导脑电信号所提取的空域特征. f_{1i}, f_{2i} 分别表示第 i 导信号的时域特征与频域特征, f_3 为空域特征, $\|\cdot\|$ 表示求 2-范数, M_1 为时间点数, M_2 为频率点数, m 为 CSSD 算法从特征向量矩阵中选取的对应于某一任务的特征向量的个数, T 表示转置运算.

3.4 LVQ 神经网络分类器

LVQ 神经网络由 Kohonen 竞争算法演化而来, 是一种在有教师状态下对竞争层进行训练的学习算法. 该网络由三层神经元组成, 即输入层、竞争层和线性输出层. 它可以通过监督学习完成对输入向量的准确分类, 在模式识别和优化领域有着广泛的应用. LVQ 神经网络具有结构简单、学习速度快及需要存储空间小等优点, 本文选用 LVQ 神经网络作为分类器, 实现对不同想象任务的脑电分类.

LVQ 神经网络的学习算法有 LVQ1 和 LVQ2 两种. LVQ1 的基本思想是: 计算距离输入向量最近的竞争层神经元, 从而找到与之相连接的线性输出层神经元. 若输入向量的类别与线性输出层神经元所对应的类别一致, 则对应的竞争层神经元权值沿着输入向量的方向移动; 反之, 若两者的类别不一致, 则对应的竞争层神经元权值沿着输入向量的反方向移动. 在 LVQ1 算法中, 只有一个神经元可以获胜, 对权值更新调整. 而 LVQ2 则进一步引入“次获胜”神经元, 获胜神经元与“次获胜”神经元的权值向量都需更新. 由于 LVQ1 算法较为简单, 且训练时间短, 本研究选择 LVQ1 设计分类器.

4 实验与分析

研究表明, 当人们想象单侧肢体运动时, 大脑对侧运动感觉区的皮质开始激活, 代谢和血流增加, 脑电的 α 频谱和 β 频谱振荡的幅度减小或阻滞, 这种现象被称为事件相关去同步 (Event-Related Desynchronization, ERD)^[9]. H Henrik Ehrsson^[10] 的研究进一步表明, 当人们想象手、脚及舌头运动时, 来自脑膜下的 ECoG 与 EEG 信号具有类似的特征, 都能够激活 ERD 电生现象, 反映运动传感皮层不同的变化过程, 而不同想象任务所激活的 ERD 程度也有所不同. 图 3 给出了左手小指和舌头两种运动想象 ECoG 数据中任意 2 导联 (包括导联 21 和 22) 的训练数据与测试数据对应 8-30Hz 频段的 AR (autoregressive) 模型功率谱变化, 这里, 训练数据和测试数据记录时间相隔一周. 显然, 手指和舌头两种不同运动想象任务 ERD 现象间的强弱不同导致其脑电信号的功率谱存在差异, 而且这种差异随着时间的推移和大脑状态的改变而时变, 并与导联位置有关. 这些特点将成为手指和舌头运动想象 ECoG 数据分类的基本依据.




图3 部分导联训练数据与测试数据功率谱对比

4.1 数据预处理

在对脑电信号进行特征提取之前, 需对信号进行有效的预处理, 以增强信号的信噪比, 并获取 ERD 生理现象较明显的脑电数据. 预处理的具体过程如下.

4.1.1 降维与滤波

首先, 将 Data set I 中训练集和测试集的采样率由 1000Hz 均降低至 100Hz, 以降低数据存储量和提高分类效率. 其次, 采用共平均参考 (Common Average Reference, CAR) 对下采样的数据重定参考点, 以消除在头皮上广泛分布的电位成分, 增强两种任务之间的信号差别并减小伪像的影响. 最后, 利用 FIR 滤波器对信号进行 8-30Hz 频段带通滤波, 以获取 ERD 生理特征较为明显的的数据段.

4.1.2 导联选择

ERD 现象产生于特定的脑区域, 当执行左手小指或舌头想象运动之一时, 只有少量的电极被激活, 而大多数电极处于静止状态. 图 4 给出任意 4 导联 (包括导联 21~24) 处执行左手小指与舌头两种运动想象任务时训练数据的 AR 模型功率谱变化情况. 可见, 不同的




图4 部分导联不同运动想象功率谱对比

运动想象任务在各导联处产生的 ERD 现象的强弱程度均不相同,即每个导联上的脑电信号对脑任务的分类识别贡献不同.无关或冗余的导联不仅会增加系统的复杂度,且影响模式识别的精度和速度.本节将定义一种相对距离准则,衡量各导联对任务识别的贡献度,以选取较优的脑电极组合.

图4表明,想象左手小指与舌头两种任务的功率谱在8-14Hz之间差别最为明显,故选择该频段两类任务的训练样本功率谱之差来定义相对距离 $h(k)$,如式(24):

$$h(k) = \frac{\left| \sum_{f \in f_s} P_{1,k}(f) - \sum_{f \in f_s} P_{2,k}(f) \right|}{\left| \sum_{f \in f_s} P_{1,k}(f) + \sum_{f \in f_s} P_{2,k}(f) \right|} \quad (24)$$

其中, $P_{i,k}(f)$ 为第 i 类任务第 k 导联的功率谱密度, $i=1$ 代表想象左手小指, $i=2$ 代表想象舌头; f 表示频率, f_s 表示选择频段内全部频率点的集合.

对式(24)分析可知: $h(k) \in [0, 1]$, $h(k)$ 越大,则表示该导联两类想象任务功率谱差别越大,即该导联对想象任务的识别贡献度越高.为此,可计算出所有导联的相对距离,如图5所示.本文仅选取贡献度最大的10导信号进行深入分析,具体包括导联12、21、29、30、31、37、38、39、40和46,这将有利于提高系统的实时性.图6展现了电刺激识别的植入 8×8 电极阵列在皮层上的位




图5 各导联的识别贡献度




图6 电刺激识别植入电极的皮层位置

置^[7].其中,红色的实心圆点表示位于运动皮层区域的电极.基于相对距离准则优选的10个导联均位于电刺激识别的运动皮层区域,在图中用蓝色方框表示.可见,选出的10个导联上的脑电信号含有丰富的运动想象识别信息,同时证明本文提出的导联选择方法的正确性与有效性.

4.2 基于 HCSSD 的特征提取

首先,对 Data set I 左手小指/舌头运动想象脑电数据进行 HHT 变换,计算瞬时能量谱与边际能量谱,以提取时域特征 F_1 和频域特征 F_2 .针对 HHT 计算量较大、提取的特征维数较高问题,本文从优选的10导信号中仅挑选贡献度最大的单导信号(即导联38)进行时-频特征提取.图7为想象左手小指与想象舌头运动时,训练数据集在导联38处脑电信号的平均 Hilbert 能量谱.结合 Data set I 左手小指/舌头运动想象脑电数据采集实验的设计过程及图7可知,在3.5~4s时间段及8~14Hz频率段想象左手小指与舌头运动所激活的 ERD 现象强弱差异最明显,从而决定了时-频特征的时间、频率选择范围.




图7 想象左手小指与舌头时38导联脑电信号的平均Hilbert能量

计算选定频率段与时间段内训练样本的 Hilbert 平均瞬时能量谱和 Hilbert 平均边际能量谱如图8.显然,




图8 导联38的瞬时能量谱与边际能量谱

想象左手小指与想象舌头两种任务时的时域能量与频域能量分布差别突出,充分体现了两种运动想象任务的时-频特征。

下面将基于 CSSD 对优选的 10 导 ECoG 信号进行空间特征提取.首先构造空间滤波器 $\mathbf{W} \in \mathbf{R}^{2m \times N}$ ($N = 10$)对信号进行滤波,并进一步由式(22)计算两种想象运动的空域特征 \mathbf{F}_3 .其中, m 为从分解的特征向量矩阵中选取的对应于某一任务的特征向量个数. m 的取值对识别结果有一定影响.若 m 取值较小,则选择的特征向量个数较少,不足以反映不同类别间的差别,而 m 增大时,特征数目增加的同时噪声也随之增加,同样会影响分类性能.本研究将采取遍历法,从 1 至 $\text{int}(N/2)$ 之间选取 m 的值,以使识别率达到最大。

4.3 基于 LVQ 的分类方法

选用 LVQ 神经网络作为 ECoG 信号的分类器,验证特征信息的有效性. LVQ 神经网络的输入层神经元个数为基于 HCSSD 提取并进行串行特征融合的时-频-空特征向量 \mathbf{F} 的维数,竞争层神经元的个数选择 10 个,输出层神经元的个数为 2.网络学习速率设定为 0.01,对网络输出进行编码,“1”代表想象左手小指,“2”代表想象舌头。

利用 HCSSD 提取训练样本的特征,并用以训练 LVQ 网络分类器,进而提取测试样本的特征,并利用已训练好的 LVQ 网络对其进行分类.采用遍历法可以得到,当 $m = 1$ 时,识别准确率达到最大值 92%.可见,HCSSD 能自适应地抽取不同时间段脑电特征,增强了识别方法的鲁棒性及泛化能力。

4.4 实验分析

4.4.1 特征选择对识别结果的影响

为进一步说明本文提出的多域特征融合方法对脑电信号特征描述的准确性和有效性,分别将时域能量特征 \mathbf{F}_1 、频域能量特征 \mathbf{F}_2 、空域特征 \mathbf{F}_3 以及任意两种特征进行融合构成特征向量,采用 LVQ 神经网络进行分类,且保持网络参数设置不变.将其分类结果与本研究提出的基于 HCSSD 的分类结果进行比较,具体见表 1.表中“+”代表串行特征融合.可见,在相同的实验条件下,本研究提出的基于 HCSSD 的时-频-空多域串行特征融合方法能够有效选择脑电信号的特征信息并确保信息的完整性,获得较好的分类效果。

表 1 特征组合方式及识别结果比较

| 特征向量 | \mathbf{F}_1 | \mathbf{F}_2 | \mathbf{F}_3 | $\mathbf{F}_1 + \mathbf{F}_2$ | $\mathbf{F}_1 + \mathbf{F}_3$ | $\mathbf{F}_2 + \mathbf{F}_3$ | $\mathbf{F}_1 + \mathbf{F}_2 + \mathbf{F}_3$ |
|-------|----------------|----------------|----------------|-------------------------------|-------------------------------|-------------------------------|--|
| 识别率/% | 73 | 53 | 91 | 74 | 88 | 90 | 92 |

4.4.2 导联数量对识别结果的影响

图 9 反映了基于 CSSD 或 HCSSD 提取脑电特征,采用相同的 LVQ 神经网络分类器时,脑电信号导联数目

对识别结果的影响.显而易见,CSSD 法对导联数量的敏感性极强,导联数目的减少使脑电识别率显著降低,而 HCSSD 法在基于 CSSD 抽取空域特征的同时,引入基于 HHT 的时-频特征,有效增强了识别方法的稳健性与有效性,即在少量导联的情况下,HCSSD 法仍可获得较高的识别准确率,使便携式 BCI 系统在康复领域的应用成为可能。

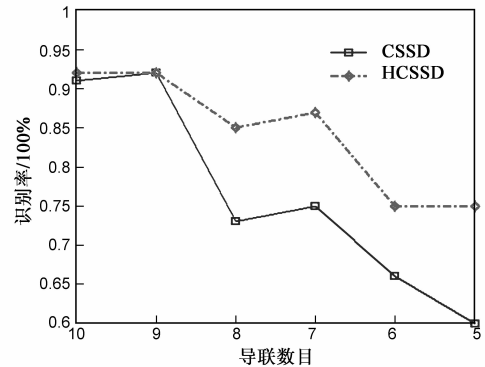


图 9 导联数目对识别率的影响

4.4.3 多种识别方法的结果比较

表 2 给出了针对相同的 Data set I 脑电数据,采用本文识别方法及脑机接口竞赛“BCI Competition III”中 27 个参赛队获得前三名的识别方法和相应结果.本文方法不仅以 92% 的平均识别率位居第一,而且本文仅选用了 10 导信号进行分析,远少于竞赛第一名获胜者所选取的导联数目(64),充分证明 HCSSD 具有自适应性好、鲁棒性强等特点。

表 2 脑机接口大赛前三名及本文识别方法与结果

| 作者 | 特征提取方法 | 分类方法 | 识别率 |
|----------------------------|-----------------|---------|-----|
| Qingguo Wei ^[6] | CSSD + 均值 + FDA | SVM | 91% |
| P S Hammon ^[11] | AR + 功率谱 + 小波系数 | 正则化逻辑回归 | 87% |
| M Sapinski ^[12] | 均值 + 功率谱 | 逻辑回归 | 86% |
| 本文作者 | HCSSD | LVQ | 92% |

5 结论

提出一种基于 HHT 和 CSSD 的自适应特征提取方法,即 HCSSD 法.该方法依据不同运动想象任务在各导联处产生的 ERD 强弱差异优选电极组合,进而利用 HHT 和 CSSD 对部分优选电极的脑电信号进行分析,获取相应的时-频域特征和空域特征,并对其进行串行特征融合.对第三届国际标准数据库 Data set I 中的运动想象 ECoG 数据进行实验研究,结果表明,HCSSD 方法在较少导联的前提下提高了脑电信号的识别准确率,具有较好的自适应性和稳健性,对运动想象脑电在康复领域的深入研究和实际应用具有重要意义。

参考文献


- [1] M J Fu, et al. Assessment of EEG event-related desynchronization in stroke survivors performing shoulder-elbow movements [A]. Proceedings of the 2006 IEEE International Conference on Robotics and Automation [C]. Orlando: Institute of Electrical and Electronics Engineers, 2006. 3158 – 3164.
- [2] L R Hochberg, et al. Neuronal ensemble control of prosthetic devices by a human with tetraplegia [J]. Nature, 2006, 442 (7099): 164 – 171.
- [3] 王磊. 基于运动想象的脑电信号分类与脑机接口技术研究[D]. 天津: 河北工业大学, 2008.
Wang Lei. Electroencephalogram Classification and Brain Computer Interface Research Based on Motor Imagery [D]. Tianjing: Hebei University of Technology, 2008. (in Chinese)
- [4] 徐晓刚, 徐冠雷, 王孝通, 等. 经验模式分解(EMD)及其应用[J]. 电子学报, 2009, 37(3): 581 – 585.
Xu Xiao-gang, Xuguan-lei, Wang Xiao-tong, et al. Empirical mode decomposition and its application [J]. Acta Electronica Sinica, 2009, 37(3): 581 – 585. (in Chinese)
- [5] Yunhua Wang, Patrick Berg, Michael Scherg. Common spatial subspace decomposition applied to analysis of brain responses under multiple task conditions: a simulation study [J]. Clinical Neurophysiology, 1999, 110(4): 604 – 614.
- [6] 魏庆国. 基于运动想象的脑-机接口分类算法的研究[D]. 北京: 清华大学, 2006.
Wei Qingguo. Studies on Classification Algorithms of Motor Imagery-Based Brain-Computer Interfaces [D]. Beijing: Tsinghua University, 2006. (in Chinese)
- [7] T N Lal, et al. Methods towards invasive human brain computer interfaces [A]. Advances in Neural Information Processing Systems [C]. Cambridge MA: MIT Press, 2005. 737 – 744.
- [8] 王慧, 刘正士, 汪家慰, 等. 测试高分辨率 ADC 有效位数的 HHT 方法[J]. 电子学报, 2009, 37(9): 2072 – 2076.
- Wang Hui, Liu Zheng-shi, Wang Jia-wei, et al. The HHT method for testing the effective numbers of bits of high-resolution analog to digital convert [J]. Acta Electronica Sinica, 2009, 37(9): 2072 – 2076. (in Chinese)
- [9] G Pfurtscheller, F H Lopes da Silva. Event-related EEG/MEG synchronization and desynchronization: basic principles [J]. Clinical Neurophysiology, 1999, 110(11): 1842 – 1857.
- [10] H H Ehrsson, S Geyer, E Naito. Imagery of voluntary movement of fingers, toes, and tongues activates corresponding body-part-specific motor representations [J]. J Neurophysiol, 2003, 90(5): 3304 – 3316.
- [11] P S Hammon, V R Sa. Preprocessing and meta-classification for brain-computer interfaces [J]. IEEE Transactions on Biomedical Engineering, 2007, 54(3): 518 – 525.
- [12] B Blankertz, et al. Results of the BCI Competition III [OL]. <http://www.bbci.de/competition/iii/results>, 2005.

作者简介



李明爱 女, 1966 年生, 河南鹤壁人, 2006 年于北京工业大学获得博士学位, 现为北京工业大学副教授、硕导, 主要从事脑机接口、智能信息处理与模式识别等领域的研究。

E-mail: limingai@bjut.edu.cn



崔燕 女, 1987 年生, 江苏盐城人, 2010 年获得南京工程学院学士学位, 现为北京工业大学模式识别与智能系统专业硕士研究生, 主要研究方向为脑机接口、信息处理与模式识别。