

基于希尔伯特变换联合卷积神经网络的 脑电信号识别方法

甘华生¹, 陈明生²

(1. 惠州城市职业学院, 广东 惠州 516000; 2. 广西科技大学 鹿山学院, 广西 柳州 545000)

摘要: 传统运动想象脑电信号识别方法需要人为提取大量特征, 识别性能受研究人员经验影响较大, 主观性强; 提出一种基于希尔伯特变换 (HT) 联合卷积神经网络 (CNN) 的运动想象脑电信号自动识别方法, 首先利用 HT 对原始 EEG 信号进行分析, 实现一维数据向二维幅-相图像转换的同时增加信息提取维度; 然后将其作为输入利用 CNN 层次化的对幅-相二维图像进行理解和解译, 自动提取特征并完成分类识别, 基于 BCI 竞赛中所用 Graz 数据集开展试验, 结果表明相对于传统特征提取方法, 文章所提算法在低、中、高信噪比条件下均能获得更好的识别性能, 具有更强的噪声鲁棒性。

关键词: 脑机接口; 深度学习; 特征提取; 卷积神经网络

EEG Signal Recognition Based on Hilbert Transform and Convolution Neural Network

GAN Huasheng¹, CHEN Mingsheng²

(1. Huizhou City Vocational College, Huizhou 516000, China;

2. Lushan College, Guangxi University of Science and Technology, Liuzhou 545000, China)

Abstract: Traditional recognition methods of motor imagery electroencephalogram (EEG) need to extract a lot of features artificially, and the recognition performance is greatly affected by the experience of researchers and has strong subjectivity. In this paper, an automatic recognition method of motor EEG signals based on deep learning is proposed. Firstly, the time-domain EEG is transformed into amplitude phase domain two-dimensional images by Hilbert transform, and then the convolution neural network is used to extract features and recognize different EEG signals. The experimental results based on Graz data set used in BCI competition show that the proposed algorithm can achieve better performance than the traditional feature extraction methods. It has better recognition performance, and has higher robustness under the condition of low signal-to-noise ratio.

Keywords: brain computer interface; deep learning; feature extraction; convolution neural network

0 引言

脑-机接口 (BCI, brain-computer-interface) 技术是一种不依赖于脑外周神经或肌肉系统, 利用计算机等外部辅助设备直接采集大脑皮层实时电信号从而实现外界与大脑神经系统建立交流和控制通路的一种新技术, 为科研人员研究人脑系统提供了新的手段, 在运动康复, 辅助控制, 影音娱乐等领域具有广泛的应用前景^[1-3]。

脑电信号 (EEG, electroencephalogram signals) 产生机理复杂, 是一种典型的非平稳和非线性的微弱信号, 如何准确、快速实现对不同意识活动对应脑电信号的区分是当前研究的热点和难点, 其中的关键环节是特征提取^[4]。目前常用的特征提取方法主要可以分为时域特征提取、频域特征提取和变换域特征提取 3 大类, 其中时域特征提取

方法以自回归模型和自适应自回归模型等为代表, 该类方法直接对脑电信号的时域回波进行建模, 并提取参数特征作为特征向量, 具有运算量小, 实时性高的优势, 但是由于脑电信号微弱性特征明显 (只有 μV 量级), 时域信号容易受噪声污染导致特征的可行性降低, 因此该类方法在低信噪比条件下的识别性能较差^[5-7]; 频域特征提取方法根据不同意识活动脑电信号在频域的分布范围不同从而提取特征, 以功率谱特征和频带能量特征为代表, 该类方法获取频域信息的代价是丢失了时域信息, 信息提取维度单一并且更适用于分析线性、平稳信号, 在面对非线性、非平稳脑电信号时性能出现明显下降^[8-10]; 变换域特征提取采用小波变换, 时频变换等方法将脑电信号转换至小波域或时-频域等变换域, 在变换域提取特征, 相对于时域特征和频域特征, 变换域特征可以同时获取多个域的特征信息, 特

收稿日期: 2021-05-12; 修回日期: 2021-06-08。

基金项目: 广东省普通高校青年创新人才项目 (2018GkQNCX086)。

作者简介: 甘华生 (1977-), 男, 广东紫金人, 大学本科, 主要从事人工智能方向的研究。

引用格式: 甘华生, 陈明生. 基于希尔伯特变换联合卷积神经网络的脑电信号识别方法[J]. 计算机测量与控制, 2021, 29(12): 184-187, 194.

征提取维度更广, 相对于单一维度特征通常能够获得更高的分类性能, 但是不同变换域特征的分类性能差异较大, 而如何找到最优的变换域及对应特征目前还没有较好的方法^[11-14]。

上述方法虽然能从不同维度提取差异信息实现脑电信号的分类识别, 但均采用人为提取特征的方式, 识别性能的优劣更多的是依靠研究人员的经验, 存在主观性强, 工作量大等问题。本文在上述研究的基础上, 将希尔伯特变换 (HT, Hilbert transform) 与卷积神经网络 (CNN, convolution neural network) 理论引入运动脑电信号分类识别领域, 首先利用 HT 将一维脑电信号转换为幅-相二维图像表征, 扩充特征提取维度, 然后采用 CNN 对图像进行层次化的理解和分析, 并自动提取特征完成分类识别。基于 Graz 数据的试验结果表明, 所提方法在低、中、高 3 种信噪比条件下分别可以获得 73.5%, 87.6% 和 91.7% 的正确识别结果, 并且只需 0.07 ms 即可完成对单个样本的有效识别, 具有较高的应用前景。

1 脑电信号的二维图像表征

由于直接采集到的脑电信号为实信号, 只包含幅度信息, 要将其转换至幅-相二维图像域, 需要对其进行变换并提取其中的相位信息。HT 是信号处理和通信等领域中广泛应用的一种信号分析方法, 通过对原始信号进行 90° 相位变换并且不改变频谱分量幅度的方式构造关于原始信号的解析信号^[15]。

对于任意时域信号 $s(t)$, 其 HT 被定义为 $s(t)$ 与 $h(t)$ 的卷积, 即:

$$\bar{s}(t) = H\{s(t)\} = s(t) * h(t) = \int_{-\infty}^{+\infty} \frac{s(\tau)}{\pi(t-\tau)} d\tau \quad (1)$$

其中: $*$ 表示卷积算子, $H(\cdot)$ 为希尔伯特变换算子, 根据傅里叶变换的卷积性质, 根据式 (1) 可以进一步得到 HT 的频域表示为:

$$\bar{s}(f) = s(f) \times h(f) \quad (2)$$

其中: $\bar{s}(f)$ 和 $s(f)$ 分别为 $\bar{s}(t)$, $s(t)$ 的频谱, $h(f)$ 为 $h(t)$ 的频谱, 其具体形式为:

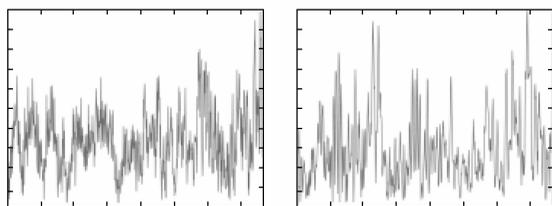
$$h(f) = \begin{cases} \exp\left(-j\frac{\pi}{2}\right) = -j, & f > 0 \\ \frac{1}{2} \left[\exp\left(-j\frac{\pi}{2}\right) + \exp\left(j\frac{\pi}{2}\right) \right] = 0, & f = 0 \\ \exp\left(j\frac{\pi}{2}\right) = j, & f < 0 \end{cases} \quad (3)$$

从式 (2) 和式 (3) 可以看出, $\bar{s}(f)$ 保留了 $s(f)$ 的所有频谱幅度信息, 同时相位翻转了 90°。利用 $\bar{s}(t)$ 和 $s(t)$ 可以按式 (4) 构造解析信号:

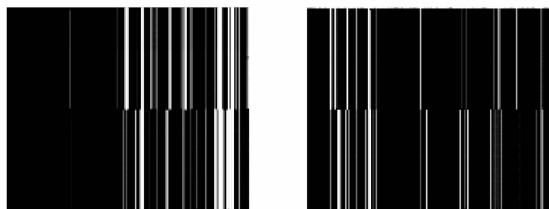
$$\bar{s}(t) = s(t) + j\bar{s}(t) = a(t)\exp(j\varphi(t)) \quad (4)$$

其中: $a(t) = \sqrt{s^2(t) + \bar{s}^2(t)}$ 为信号的幅度分量, $\varphi(t) = \text{atan}\left(\frac{\bar{s}(t)}{s(t)}\right)$ 为信号的相位分量。

将信号幅度分量和相位分量单独提取出来, 构建大小为 $2 \times N$ 的向量, 并进一步将其转换为高度为 2, 宽度为 N 的幅-相二维图像表征。图 1 (a) 和 (b) 分别给出了想象左手运动和想象右手运动脑电信号的一维时域波形图, 对其进行 HT 变换转换为二维幅-相灰度图的结果如图 1 (c) 和 (d) 所示。通过将一维信号转换为二维图像一方面能够将原始数据中包含的所有信息还原, 最大化的利用原始信号的信息, 避免了信息丢失, 另一方面这种建模方式得到的二维图像非常适合于卷积神经网络处理, 有利于后续构建高速处理框架, 提升算法实时性。



(a) 想象左手运动 (一维时域波形) (b) 想象右手运动 (一维时域波形)



(c) 想象左手运动 (二维幅-相图像) (d) 想象右手运动 (二维幅-相图像)

图 1 一维脑电信号的幅-相二维图像表征

2 基于深度学习的识别方法

2.1 基本原理

所提基于深度学习的脑电信号识别方法的目的是实现对想象左手运动和想象右手运动脑电信号的分类与识别, 将原始时域脑电信号表征为幅-相二维图像作为卷积神经网络 (CNN)^[16-19] 的输入, 利用 CNN 的自学习能力层次化的对输入图像进行分析和解译, 自动提取特征并实现分类输出。该方法首先需要完成卷积神经网络的结构设计, 然后利用训练数据对神经网络进行训练, 实现网络的自学习, 最后通过大量测试实验对神经网络参数进行调优, 从而得到最优的网络模型。

经过反复测试实验, 确定最优的 CNN 架构如表 1 所示, 其中 CNN 由 3 个卷积层和 3 个全连接层总共 6 层组成, 3 个卷积层和前 2 个全连接层使用 ReLU 作为激活函数, 最后一个全连接层使用 SoftMax 分类器完成分类判决。实验中使用 Categorical Crossentropy 作为模型的损失函数, 使用 Adam 作为优化器函数, 同时为了防止迭代过程中出现梯度弥散问题, 试验过程中在卷积层加入 40% 的 Dropout 处理。

2.2 卷积神经网络训练与优化

构建完成 CNN 网络模型后, 需要利用训练数据对模型参数进行训练和调优。训练过程采用批处理方式, 每次随机

表 1 最优 CNN 结构

网络层类型	参数	激活函数
卷积层 1	256 个大小为 1×3 的滤波器	ReLU
卷积层 2	66 个大小为 2×3 的滤波器	ReLU
卷积层 3	128 个大小为 1×3 的滤波器	ReLU
全连接层 1	512 个神经元	ReLU
全连接层 2	256 个神经元	ReLU
全连接层 3	8 个神经元	SoftMax

从训练样本集中抽取 64 个样本（批大小）进行训练，直到训练样本集全部被抽取后算是完成一轮训练，之后将数据顺序打乱再次进行下一轮迭代，每一轮迭代完成后都计算验证损失值（value_error），如果连续 2 次迭代得到的验证损失值之差小于预设参数，则表明网络训练充分，终止迭代过程并输出训练结果。

本文实验中 CNN 运行的软件环境为 Tensorflow 1.8, cuda 9.0, keras 2.2, 软件运行的硬件平台为 Interl Xeon E5 2630 CPU 和 Navia Quadro K4200GPU。图 2 给出了模型训练过程中 value_error 的变化曲线，可以看出经过约 40 次迭代后，value_error 的值达到稳定，几乎不再发生变化，表明网络模型训练充分。

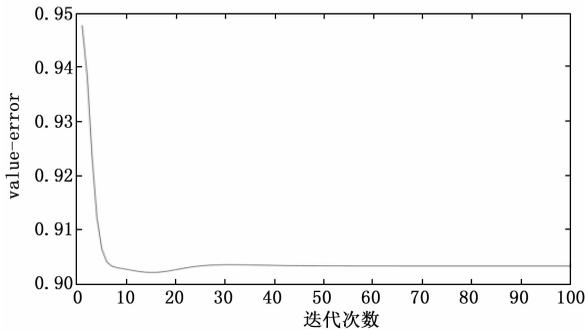


图 2 验证损失值随迭代次数变化曲线

3 实验结果与分析

3.1 试验数据

为了验证所提方法的识别性能，采用 BCI2003 国际竞赛公开的标准运动脑电信号数据集开展试验。数据集获取的被试对象为 25 岁女性志愿者，试验过程中，被试志愿者被要求根据眼前的屏幕提示进行想象左手或者想象右手运动，与此同时利用搭载 EEG 放大器的计算机辅助设备对被试志愿者的脑电信号进行同步采集，采样频率设置为 128 Hz，采用差分电极从国际标准的 10~20 导联系统中的 C3 和 C4 两个通道获取。一次有效实验的时间为 9 s，具体流程如图 3 所示，数据采集步骤包含 3 个阶段：

- 1) $0 \leq t < 2$ s, 准备时间，被试志愿者前方显示屏不开机，处于黑屏状态，提示被试志愿者放松；
- 2) $T=2$ s, 试验开始提示，被试志愿者前方显示屏出现十字光标，提示被试志愿者试验马上开始；
- 3) $3 \leq t < 9$ s, 试验时间，当显示屏上出现“向左”

或“向右”箭头时，被试志愿者被要求按照光标提示方向进行想象左手或者右手在运动。

由于每次试验的有效数据为第 3~9 s 之间的数据，每组数据的采样信号长度为 768 个采样点。试验数据集中总共包含 280 组试验样本，其中想象左手运动 140 组，想象右手运动 140 组。

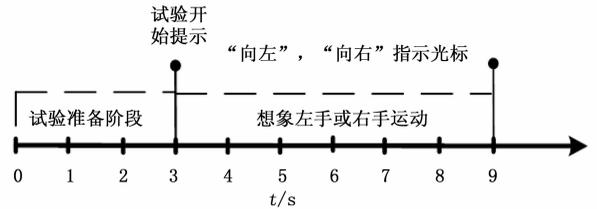


图 3 1 次试验时间流程图

3.2 识别准确率

试验过程中，利用想象左手运动和想象右手运动脑电信号测试数据集对训练好的 CNN 模型进行测试，图 4 给出了不同信噪比条件下的所提方法的正确识别率，为了进行对比，图 4 中同时给出了在相同条件下利用文献 [20] 所提小波方法进行分类的结果，选取 db4 小波基，分解层数设置为 6。图 4 中每组数据的获取是在训练数据和测试数据处于相同信噪比水平下进行试验获得，例如信噪比为 5 dB 时的识别结果是采用信噪比为 5 dB 的训练数据和信噪比为 5 dB 的测试数据开展试验得到的结果。

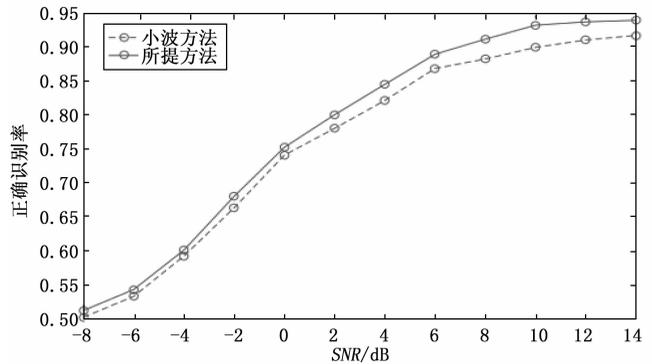


图 4 不同信噪比条件下的识别性能

从图 4 可以看出，两种方法的识别性能随着信噪比的提升都出现了上升趋势。当信噪比在 0 dB 以下时，两种方法的识别性能差别不大，所提方法的性能略优于小波方法，正确识别率相对于小波方法的提升在 2% 以内，当信噪比高于 0 dB 时，所提方法的正确识别率明显优于小波方法，性能提升超过 3%。

实际工程应用过程中，往往难以获得与测试数据信噪比水平完全一致的训练数据，通常训练数据与测试数据的信噪比水平存在一定的差异，为了验证所提方法在这种情况下下的识别性能，将数据集根据信噪比水平划分为低信噪比，中信噪比和高信噪比 3 种数据子集，其中低信噪比数据子集中的信噪比水平为 -8~ -2 dB，中信噪比数据子集

中的信噪比水平为 0~6 dB, 高信噪比数据子集中的信噪比水平为 8~14 dB, 试验中随机从数据子集中选取 80% 的数据作为训练数据完成神经网络模型训练, 剩余 20% 数据作为测试数据, 验证所提方法的识别性能, 每个数据子集重复进行 5 次试验, 并将结果进行平均。表 2 给出了所提方法和小波方法的识别性能, 可以看出所提方法在低, 中, 高 3 种信噪比条件下获得的识别结果均优于小波方法, 3 种情况下的识别性能分别提升 3.7%, 5.2% 和 4.8%, 究其原因在于所提方法利用幅一相二维图像对原始一维数据进行表征, 使数据中的幅度和相位信息得到了更直接的表达, 充分利用了数据中的有效信息。

表 2 不同信噪比条件下 2 种方法的正确识别率 %

识别方法	低信噪比	中信噪比	高信噪比
所提方法	73.5	87.6	91.7
小波方法	69.8	82.4	86.9

3.3 识别处理时间

对于运动脑电信号识别问题, 希望 BCI 技术能够实时地完成脑电信号的解译, 因此算法的运算效率是正确识别率外的另一项重要指标。为了验证所提方法对单个测试样本的处理时间, 将测试阶段的批处理大小作为变量, 使其在 [1, 2, 4, 8, 16, 32, 64, 128] 之间取值, 在不同批处理大小情况下对单个测试样本的识别时间进行统计计算, 图 5 给出了对应的结果。

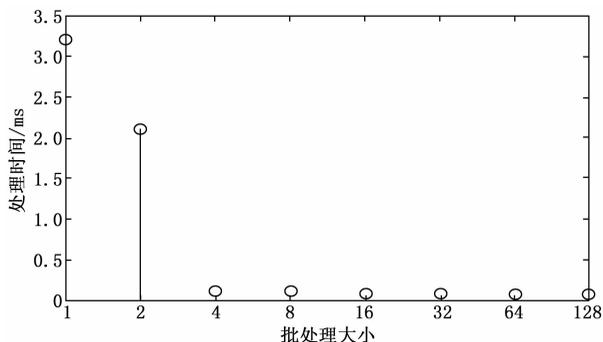


图 5 单个样本识别时间与批处理大小的关系

从图 5 可以看出, 算法的运算效率与批处理大小密切相关, 当批处理大小为 1 时, 即每次输入 1 个测试样本进行分析识别, 算法所需时间约为 3.2 ms, 随着批处理大小的增加, 算法对每个测试样本进行分析识别的时间逐渐减小, 最终稳定在 0.07 ms 左右, 这与 CNN 的并行计算能力一致, 因此在实际工程应用过程中, 应该将多个测试样本同时输入模型进行分析识别以提升算法的实时性。

4 结束语

传统基于人工特征提取的运动脑电信号分类识别方法存在主观性强, 信息利用率低的问题, 并且特征提取和模式分类是相互独立的 2 个过程, 不能实现联合优化, 因此传统方法普遍识别性能不高。提出一种基于 HT 联合 CNN

的运动想象脑电信号识别方法, 利用 HT 将脑电信号转换至幅一相二维图像域, 然后利用 CNN 对其中包含的信息进行层次化的理解和解译, 自动完成特征提取和模式分类。相对于传统方法, 本文通过 HT 将信号提取维度从一维扩展至二维, 增加了信号中的相位信息, 同时 CNN 从大数据角度去自动化学目标的抽象特征, 通过多层神经网络结构来进行目标高层特征提取, 同时网络学习过程实现了特征提取和模式分类的联合优化。基于 Graz 数据的实验结果表明, 所提算法相对于小波方法可以获得更优的识别性能, 在低、中、高 3 种信噪比条件下正确识别率分别提升 3.7%, 5.2% 和 4.8%。同时为了提升所提算法的运算效率和实时性, 建议在实际使用过程中尽量采用批处理方式, 此时对单个测试样本的分析识别时间约为 0.07 ms。

参考文献:

- [1] PFURTSCHELLER G, NEUPER C, GUGER C, et al. Current trends in Graz brain-computer interface (BCI) research [J]. IEEE Trans. on Rehab. Eng., 2000, 8 (2): 216-219.
- [2] 冀常鹏, 李蓓蕾. 心电信号识别方法的研究与实现 [J]. 计算机应用与软件, 2018, 35 (3): 173-177.
- [3] KEVRIC J, SUBASI A. Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system [J]. Biomedical Signal Processing and Control, 2017, 31: 389-406.
- [4] WOLPAW J R, BIRBAUMER N, McFARLAND D J, et al. Brain-computer interfaces for communication and control [J]. ClinNeurophysiol, 2002, 113 (6): 767-791.
- [5] ANDERSON C W, STOLZ E A, SHAMSUNDER S. Multivariate auto regressive models for classification of spontaneous electroencephalographic signals during mental tasks [J]. IEEE Trans. on Biomed. Engineering, 1998, 45 (3): 277-286.
- [6] BURKE D P, KELLY S P, de CHAZAL P, et al. A parametric feature extraction and classification strategy for brain-computer interfacing [J]. IEEE Trans. on Neural System Rehabilitation Engineering, 2005, 13 (1): 12-17.
- [7] 程龙龙, 明东, 刘双迟, 等. 脑机接口研究中想象动作电位的特征提取与分类算法 [J]. 仪器仪表学报, 2008, 29 (8): 1773-1778.
- [8] 段锁林, 尚允坤, 潘礼正. 多类运动想象脑电信号特征提取与分类 [J]. 计算机测量与控制, 2016, 24 (2): 283-287.
- [9] 徐宝国, 宋爱国, 费树岷. 在线脑机接口中脑电信号的特征提取与分类方法 [J]. 电子学报, 2011, 39 (5): 1025-1030.
- [10] 彭仁旺. 基于经验模态分解和 SVM 的脑电信号分类方法 [J]. 计算机测量与控制, 2020, 28 (1): 189-194.
- [11] 王登, 苗夺谦, 王睿智. 一种新的基于小波包分解的 EEG 特征抽取与识别方法研究 [J]. 电子学报, 2013, 41 (1): 193-198.
- [12] 柯海森, 双嘉伟. 基于 ELM 运动想象脑电信号的分类 [J]. 计算机应用与软件, 2016, 33 (10): 187-206.

(下转第 194 页)