

DOI: 10.19650/j.cnki.cjsi.J1905522

基于多特征卷积神经网络的运动想象脑电信号分析及意图识别*

何 群, 邵丹丹, 王煜文, 张园园, 谢 平

(燕山大学电气工程学院 河北省测试计量技术及仪器重点实验室 秦皇岛 066004)

摘 要:为了准确提取个体运动想象脑电信号的最优时段和频段特征以及有效提高其分类准确率,结合卷积神经网络和集成分类方法提出一种多特征卷积神经网络(MFCNN)算法,对运动想象脑电信号进行分类识别。首先对脑电信号进行预处理,然后将原始信号、能量特征、功率谱特征以及融合特征分别输入到卷积神经网络中得到其训练模型,最后通过加权投票的集成分类方法得到最终的分类结果。并利用 2008 年 BCI 竞赛 Datasets 2b 数据集和实测数据对所提出的方法进行实验分析。结果表明,所提的 MFCNN 方法可有效提高运动想象识别率,实验中所有受试者的平均分类正确率和平均 Kappa 值分别为 78.6% 和 0.57,为运动想象类脑机接口的应用提供了新的思路和方法。

关键词: 脑机接口;卷积神经网络;集成分类;运动想象

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

Analysis and intention recognition of motor imagery EEG signals based on multi-feature convolutional neural network

He Qun, Shao Dandan, Wang Yuwen, Zhang Yuanyuan, Xie Ping

(Key Laboratory of Measurement Technology and Instrumentation of Hebei Province, Institute of Electric Engineering, Yanshan University, Qinhuangdao 066004, China)

Abstract: In order to accurately extract the optimal time period and frequency band features of individual motor imagery EEG signals and effectively improve its classification accuracy, combining convolutional neural network and integrated classification method, a new multi-feature convolutional neural network (MFCNN) algorithm is proposed to classify and identify motor imagery EEG signals. Firstly, the EEG signal is preprocessed, then the original signal, energy feature, power spectrum feature and fusion feature are inputted into the convolutional neural network to obtain their respective training models. Finally, the final classification result is obtained with the weighted voting based integrated classification method. The experiment analysis of the proposed method was carried out using the 2008 BCI competition Datasets 2b dataset and the actually measured data. The results show that the proposed MFCNN method can effectively improve the recognition rate of motor imagery. The average classification accuracy and average Kappa value of all the subjects in the experiment are 78.6% and 0.57, respectively. The proposed method provides a new idea and solution for the application of motor imagery brain-computer interface.

Keywords: brain-computer interface(BCI); convolutional neural network(CNN); integrated classification; motor imagery

0 引 言

脑机接口(brain-computer interface, BCI)通过解码人类进行思维活动时的脑神经活动信息,构建了大脑与外

部世界的直接信息传输通路^[1-2]。由于采集脑电信号(electroencephalography, EEG)^[3]的设备具有便携、运行成本低、操作便捷以及适用人群广等优点,所以在 BCI 中应用最为广泛^[4]。研究发现,当人某一侧肢体运动或想象运动时,其对侧大脑皮层 EEG 的 μ 节律和 β 节律

收稿日期:2019-08-27 Received Date:2019-08-27

* 基金项目:国家自然科学基金(61673336,61901407)、中国博士后科学基金(2019M651066)项目资助

频段幅值降低,出现事件相关去同步现象,即(event-related desynchronization, ERD)现象;而同侧大脑的 EEG 的 mu 节律和 beta 节律频段幅值升高,出现事件相关同步现象,即(event-related synchronization, ERS)现象^[5]。在运动想象(motor imagery, MI)^[6]分类识别中,不同受试者的最优时段和最优响应频段并不相同,经验主义的判断无法有效选择每个受试者的最优时段和频段^[7]。

如何有效地提取特征是运动想象脑电信号意图识别的重要研究内容,而每个受试者的最优时频段的选择是特征有效提取的关键。文献[8]提出一种基于希尔伯特-黄变换(Hilbert-Huang transform, HHT)的运动想象脑电识别方法,将前 3 阶分量的平均瞬时能量特征和 6 阶的 AR 模型系数作为分类器的输入特征,文中选择 5.5~7.5 s 数据作为最优时段数据。文献[9]中为了有效确定单个受试者的最优滤波频带,提出了一种多策略变异算子和时变非线性交叉因子差分进化算法进行频带的选择,有效确定了受试者的最优频段,避免了手动选择。文献[10]中提出了一种改进的共同空间模式(common spatial pattern, CSP)特征提取算法,该方法通过巴氏距离有效选择出了最佳频率段,有效提高了 MI 分类识别率。

与传统的 EEG 信号特征提取方法相比,卷积神经网络(convolutional neural network, CNN)^[11-12]可以在网络内部自动进行最优化的特征提取和解码,使用 CNN 进行 EEG 特征提取更方便。文献[13]中根据 EEG 信号时间和空间特性,针对性的设计了一个 5 层的 CNN 来进行 MI 分类识别。文献[14]中,将 EEG 信号通过快速傅里叶变换转变成谱地形图,然后将其输入到深度循环神经网络中,从而得到其分类结果。上述方法基于单一输入的分析方法,分别实现 EEG 信号的分类,为了进一步提高运动想象 EEG 信号的分类效果,需从多特征角度深入研究 EEG 瞬态非线性特征的提取方法。

本文结合 CNN 和集成分类方法提出了一种多特征卷积神经网络(multi-features convolutional neural network, MFCNN)算法,并将其应用于运动想象 EEG 信号分类中,该算法充分利用 CNN 的自动提取最优特征的能力,综合考虑了不同特征分类效果的差异性,避免了单一特征可能造成的信息遗漏,并通过加权投票的集成分类方法,进而获得准确率较高的分类结果。

1 数据来源和预处理

1.1 数据来源

本文实验数据来源于 2008 年国际 BCI 竞赛 Datasets 2b,实验中共有 9 名受试者,实验数据包含 3 个通道,分别是 C3、C4 和 Cz,采样率为 250 Hz。每名受试者的实验数据包含 5 个部分,分别是 01T、02T、03T、04E 以及 05E,

其中,01T、02T、03T 表示训练数据,04E 和 05E 表示测试数据;01T、02T 的实验范式相同,03T、04E、05E 的实验范式相同,具体实验范式如图 1 所示。每名受试者包含的试次略有不同,详情请见文献[15]。




图 1 竞赛数据实验范式

Fig.1 The experiment paradigms of the competition data

实测数据来自 3 位精神状况良好,身体健康的在校研究生,均为男性且无神经系统病史,年龄在 24~26 岁。数据采集设备为 neuracle 公司所产 64 导无线脑电采集系统,采样通道包含 C3、C4、Cz,采样频率为 1 000 Hz。每个受试者进行两组实验,每组数据包含 100 个实验,前一组数据作为训练集,后一组数据作为测试集,所采用的刺激范式如图 2 所示。实验在一个安静舒适环境下进行,受试者坐在椅子上,使全身肌肉处于放松状态,不产生肌肉紧张与实际运动。要求受试者根据屏幕提示想象向左或向右运动。实验开始时,屏幕中央出现不断缩小的实心圆提醒受试者集中精神,此过程持续 2 s 时间,第 2 s 时,实心圆向右或向左移动,受试者跟随实心圆移动方向进行向右或向左运动想象,第 6 s 时,实心圆消失,屏幕变为空白提示受试者想象过程结束,之后有 4 s 时间供受试者休息。




图 2 实测数据实验范式

Fig.2 The experiment paradigm of the actually measured data

1.2 预处理

为了更好地提取 EEG 信号的特征,需要对 EEG 数据进行简单的预处理。首先,将 EEG 数为“NaN”的数据置 0,因为运动想象诱发的 ERD/ERS 现象主要集中在 mu 节律(8~13 Hz)和 beta 节律(14~30 Hz),故采用 8~30 Hz 的 6 阶巴特沃斯带通滤波器对原始数据进行滤波,

其阻带截止频率为 5~33 Hz,阻带衰减为 50 dB,通带衰减为 0.5 dB,以此提高 EEG 信号的信噪比。

2 研究方法

EEG 信号具有时空特性。因此在特征提取部分需要




图3 MFCNN 结构

Fig.3 The structure of MFCNN

2.1 能量特征

EEG 信号经过预处理后,由式(1)求得其能量特征,式(1)如下所示。

$$ES_N = \begin{cases} \frac{1}{N} \sum_{n=1}^N f_n^2, & N < f_s \\ \frac{1}{f_s} \sum_{n=N-f_s+1}^N f_n^2, & N \geq f_s \end{cases} \quad (1)$$

式中: f_n^2 指第 n 个采样点瞬时幅值的平方; ES_N 表示最后求出的平均瞬时能量特征; f_s 是采样频率。当 $N < f_s$ 时,计算 N 个采样点的之前所有数据平方的平均;当 $N \geq f_s$ 时,计算 N 个采样点之前 f_s 个数据平方的平均。

2.2 功率谱特征

相对于经典谱估计中的窗函数法,最大熵谱估计的方法提高了分辨率,并适用于较短数据的情况。故使用最大熵谱估计的方式计算运动想象 EEG 信号的功率谱。

若某随机信号 $x(n)$ 在时延为 $1 \sim M$ 点上的自相关函数值 $r_{xx}(m)$, ($m = 1, \dots, M$) 为已知时,则其最大熵谱估计的表达式为:

$$P(\omega) = \frac{P_M}{f | 1 + \sum_{m=1}^M \alpha_m e^{-j\omega m} |^2} \quad (2)$$

式中: P_M 是功率; P_M 和 α_m 是 Yule-Walker 方程的解; P_M 是 M 阶预测误差滤波器的输出功率; a_m 是模型参数; ω 为频率; f 为采样频率。在本文中, $M = 6$ 。

2.3 融合特征

原始信号、能量特征和功率谱特征包含了不同的脑

考虑时间和空间特征。首先,将训练数据的原始信号、能量特征、功率谱特征以及融合特征分别输入 7 层的 CNN 网络中,然后通过训练得到 4 个不同的训练模型,再将测试数据的原始信号、能量特征、功率谱特征以及融合特征分别输入到训练好的模型中,最后,通过加权投票的方法得到其最终的分类结果。MFCNN 网络具体结构如图 3 所示。

电信息,为了避免信息遗漏,将 3 种特征融合,即融合特征。原始信号用矩阵 X 表示,能量特征用矩阵 ES 表示,功率谱特征用矩阵 P 表示,融合特征是前 3 种特征的拼接,用矩阵 F 表示,则其表达式为:

$$F = [X, ES, P] \quad (3)$$

2.4 MFCNN 的构建

如图 3 所示,MFCNN 的输入特征分别是原始信号、能量特征、功率谱特征以及融合特征。为了确定 MFCNN 的网络结构,首先需要确定网络层数、卷积核大小及池化核大小等参数。本文以 BCI 竞赛数据为例来对上述几种参数进行讨论分析。由于 MFCNN 的结构主要由输入层、卷积-池化层、全连接层和加权分类层构成,卷积-池化层的对数决定了网络的深度。本文重点讨论不同卷积-池化层对数对最终分类精度的影响,其范围为 $1 \sim 4$,结果如图 4 所示。




图4 不同网络结构的分类正确率

Fig.4 The classification accuracy of different network structures

由图 4 可以看出,当卷积-池化层对数为 2 时,MFCNN 的分类性能最优。当层数继续增加时,分类精度反而会降低,主要原因是由于数据样本太少,网络层数过多而导致过拟合问题的出现。

不同的卷积核和池化层核对模型分类性能的影响结果如表 1 所示。表 1 讨论了第 1 对卷积-池化层的卷积核和池化层核的大小,由表 1 可知,当第 2 层的卷积核大小为 $[100\times 1]$,第 3 层的池化层核大小为 $[4\times 1]$ 时,分类性能最好。类似地,优化确定第 4 层的卷积核大小和第 5 层的池化层核大小分别为 $[1\times 2]$ 和 $[4\times 1]$ 。

表 1 不同的卷积核和池化层核的分类正确率
Table 1 The classification accuracies of different convolution kernels and pooling kernels (%)

池化层核	卷积核 [50×1]	卷积核 [100×1]	卷积核 [150×1]	卷积核 [200×1]
[2×1]	72.54	72.01	72.01	71.69
[3×1]	70.92	71.80	66.20	71.23
[4×1]	71.23	74.86	71.06	73.20
[5×1]	72.96	69.51	73.03	70.56
[6×1]	72.22	72.78	70.32	72.46
[8×1]	70.88	73.10	69.96	73.24

经过上述选取的优化参数确定最终的 MFCNN 网络结构如下:每一类特征输入的 CNN 都由 7 层网络组成,第 1 层是输入层,第 2 和 4 层是卷积层,第 3 和 5 层是池化层,第 6 层是全连接层,第 7 层是输出层。各网络层形容和具体参数如下。

1) 第 1 层为输入层,每种输入样本为 $1\,000\times 2$ 的输入矩阵,其中 2 代表通道数(C3 和 C4 通道),1 000 表示每个通道中的采样点,因为运动想象的时间是 3~7 s,所以输入只使用 4 s 的数据,即 $4\times 250=1\,000$ 个采样点;

2) 第 2 层是卷积层,主要作用是提取第 1 层的输入信号在时间上的特征。该层的一个重要特性是权值共享,通过权值共享原则极大地减少了权值参数。在该层使用 16 种滤波器,每种滤波器去卷积输入信号就得到不同特征的映射,卷积核的大小设置为 $[100\times 1]$;

3) 第 3 和 5 层是池化层,该层又被称为下采样层,相当于二次特征提取的过程,该层的主要作用是通过池化函数对上一层得到的特征进行压缩,其中比较常见的池化函数是最大池化函数和均匀池化函数,本文使用的是最大池化函数。池化操作不仅可以极大地提高了网络的统计效率,而且能够使网络获得某种不变性以增强自身的鲁棒性,池化层核的大小设置为 $[4\times 1]$;

4) 第 4 层是卷积层,与第 2 层卷积层的作用不同,该层的主要作用是对 EEG 信号进行空间滤波。在该层

使用 32 种滤波器,原始信号、能量特征、功率谱特征输入的卷积核大小设置为 $[1\times 2]$,融合特征输入的卷积核的大小设置为 $[1\times 6]$;


5) 第 6 层是全连接层,该层的作用是连接所有的特征,并将输出值送给分类器,神经元的个数为 1 024 个;

6) 第 7 层为输出层,该层主要作用是输出分类结果,包含 2 个神经元,代表了二分类问题(左手 MI 或右手 MI)。

2.5 MFCNN 模型训练

MFCNN 模型的训练是分别对 4 种输入信号的训练,从而得到 4 个最优的训练模型。模型的训练过程分为两个阶段,第 1 个阶段是数据由低层次向高层次传播的阶段,即前向传播阶段;另外 2 个阶段是,当前向传播得到的结果与预期不符时,将误差从高层次向低层次进行传播训练的阶段,即反向传播阶段。4 个训练模型的参数设置如下。

神经网络算法需要引入非线性的激活函数,sigmoid、tanh 以及 ReLU 等激活函数较为常用。目前,在大部分的 CNN 中采用的都是 ReLU 激活函数,相比于 sigmoid、tanh 激活函数,它具有不饱和、计算快、稀疏等特性,故本文中选用了 ReLU 激活函数。优化器选择了常用的随机梯度下降优化器(stochastic gradient descent,SGD),并且引入了动量优化,加速 SGD 在相关方向上前进,并抑制震荡,一般动量项 momentum 取 0.9 附近。损失函数选用常见的均方误差(L2)。进一步需要确定学习速率、训练迭代次数和每批次训练数据的大小等参数。首先确定学习速率,在另外两个参数固定的前提下,学习速率对模型分类性能的影响结果如图 5(a)所示,当学习速率为 0.01 时,分类性能最好。类似地,先后优化确定训练迭代次数和每批次训练数据的大小分别为 50 和 20,如图 5(b)和(c)所示。






图 5 不同训练参数的分类性能

Fig.5 The classification performance of different training parameters

经过上述选取参数的比较确定训练参数设置如表 2 所示。

表 2 训练参数设置

Table 2 Training parameter setting

参数	数值
训练迭代次数	50
每批次训练数据的大小	20
学习速率	0.01
激活函数	ReLU
优化器	随机梯度下降(SGD)
损失函数	均方误差(L2)

2.6 集成分类

假设每个训练好的模型的训练集的分类正确率为 $A=[A_1,A_2,\cdots,A_M]$, 则权重计算如下:

$$\omega_i=A_i/\sum_{i=1}^MA_i\quad i=1,2,\cdots,M\tag{4}$$

在集成分类中,若基分类器的分类正确率低于 0.5,则会降低集成分类的分类效果,故最终的权重如下:

$$\omega_i=\begin{cases}0,&A_i<0.5\\ \omega_i,&A_i>0.5\end{cases}\quad i=1,2,\cdots,M\tag{5}$$

假定有 M 个待集成的基分类器 $C_i(i=1,2,\cdots,M)$, 每个基分类器的预测标签结果为 $C_i(n)$, n 为数据集的样本数。集成分类结果为 $\hat{C}(n)$, 则有:

$$\hat{C}(n)=f(C_1(n),C_2(n),\cdots,C_m(n),\omega_1,\omega_2,\cdots,\omega_M)\tag{6}$$

式中: ω_i 是 $C_i(n)$ 的权重,且满足 $\sum_{i=1}^M\omega_i=1$, f 为集成规则。

f 的具体规则为:假设分类结果为左手的有 k 个基分类器的,分类结果为右手的有 l 个基分类器,若 $\sum_{i=1}^k\omega_i>\sum_{i=1}^l\omega_i$, 则集成分类的结果为想象左手运动, 否则为想象右手运动。本文中 $M=4$ 。

3 实验结果与分析

3.1 特征融合及对比

为了验证本文方法的有效性,将本文方法分别与另外 5 种方法进行了对比分析,6 种不同方法的详细描述如表 3 所示。前 4 种方法分别是将原始信号、能量特征、功率谱特征、融合特征分别作为 7 层 CNN 的输入,最后通过 Softmax 分类器输出其分类结果,其中融合特征指的是将原始信号、能量特征以及功率谱特征融合后的特征;方法 5 是将前 3 种特征分别输入到 CNN,最后通过集成分类的方法输出其分类结果;本文方法是在方法 5 的基础上增加了融合特征作为 CNN 的输入。

表 3 不同方法的描述

Table 3 Description of different methods

分类方法	输入信号				分类器
方法 1	原始信号	-	-	-	Softmax
方法 2	-	能量	-	-	Softmax
方法 3	-	-	功率谱	-	Softmax
方法 4	-	-	-	融合	Softmax
方法 5	原始信号	能量	功率谱	-	集成
本文方法	原始信号	能量	功率谱	融合	集成

图 6 所示为 6 种分类方法的受试者(前 9 名受试者来源于竞赛数据,后 3 名受试者来源于实测数据)工作特征曲线(receiver operating characteristic curve, ROC)以及 ROC 曲线下面积(area under the ROC curve, AUC),AUC 最大的方法分类性能最佳,故通过图 6 可以对 6 种方法的分类性能进行有效评估。针对竞赛数据进行分析,首先,对比前 3 种方法的 AUC 值,可以看出,在第 3、4、7、8 名受试者中,方法 1 的 AUC 值最大;在第 2、9 名受试者中,方法 2 的 AUC 值最大;在第 1、5、6 名受试者中,方法 3 的 AUC 值最大。可以看出,单一的输入信号并不能使每名受试者的分类性能达到最优。再对比前 4 种方法,在第 2、5、8、9 名受试者中,方法 4 的 AUC 值最大,说明简单的融合并不能明显提高其分类性能。再对比方法 1、2、3、5,仅在第 5 和第 7 名受试者中,方法 5 的 AUC 值不是最大,说明集成分类的方法较单一输入的方法,其分类性能有了明显的提高。对比这 6 种方法,发现除了第 5、7、8 名受试者外,本文方法的 AUC 值最大,而方法 5 在第 8 名受试者中,其 AUC 值最大,在第 3、4、7、9 名受试者中与本文方法 AUC 值相同,可以看出,本文方法相比其他方法,其分类性能有显著的提高。针对实测数据进行分析,由于实测数据的质量不及竞赛数据,总体的效果较差。但相对来说,在第 10 名受试者中,本文方法的

AUC 值与方法 4 并列最大,在第 11 名受试者中,本文方法的 AUC 值与方法 5 并列最大,在第 12 名受试者中,本文方法的 AUC 值虽位列第 3 但与最大 AUC 值差距不大,可以看出本文方法在实测数据上也有较好的分类性能。




图6 12名受试者在6种不同方法下对测试集分类生成的ROC曲线(S1~S12)
Fig.6 The ROC curves generated in the classification of test sets for twelve subjects with six different methods (S1~S12)

表4所示为12名受试者在6种不同方法下的分类正确率,对比前3种方法可知,方法3具有最好的分类性能,其平均分类正确率可达74.1%,方法1和2的平均分类正确率一样为71.7%,但方法1的误差为15.4,说明方法2的稳定性相对来说要好。对比方法1、2、3、5,可以发现方法5的平均分类正确率为74.8%,高于前3种方法,说明集成分类的方法提高了单一输入的分类效果。方法4虽然没能明显提升单个受试者的最高分类正确率,但

相比单个特征的输入,该方法的平均分类正确率达到了76.4%,比方法3的平均分类正确率提升了2.3%,比方法5的平均分类正确率1.6%,说明方法4相比方法5,通过特征之间的卷积操作,获得了更多对分类有益的特征。由表4可知,本文方法的平均分类正确率为78.6%,高于其他5种方法,说明在集成分类中加入融合特征后,提高了集成分类的分类性能,分类结果也再次证明了本文方法在竞赛数据和实测数据上都具备有效性。

表 4 6 种方法的分类正确率和本文方法的 *Kappa* 值

Table 4 The classification accuracies of six methods and *Kappa* value of the proposed method

受试者	正确率/%						本文方法的 <i>Kappa</i> 值
	方法 1	方法 2	方法 3	方法 4	方法 5	本文方法	
第 1 名	71.9	67.5	69.1	77.2	70.9	74.4	0.49
第 2 名	58.6	61.8	61.8	62.1	62.9	63.2	0.26
第 3 名	63.4	58.8	57.5	60.6	60.9	63.1	0.26
第 4 名	97.2	96.3	94.4	96.6	97.8	97.5	0.95
第 5 名	60.3	64.7	91.3	92.8	75.6	93.4	0.87
第 6 名	80.9	76.9	87.2	85.6	87.5	87.5	0.75
第 7 名	82.8	76.3	74.4	79.1	80.0	82.2	0.64
第 8 名	93.1	91.9	89.4	92.8	93.1	93.8	0.88
第 9 名	83.4	85.9	82.2	86.9	87.5	90.0	0.80
第 10 名	59.2	62.5	59.2	63.3	65.0	70.0	0.40
第 11 名	50.0	57.5	58.3	59.2	55.8	61.7	0.23
第 12 名	59.2	60.8	64.2	60.0	60.8	66.7	0.33
平均值	71.7±14.7	71.7±12.9	74.1±13.5	76.4±14.0	74.8±13.6	78.6±13.0	0.57

另外,实验中利用 Friedman 检验验证本文方法所得识别率与其他 5 种方法所得识别率存在显著性差异,Friedman 检验所得 *p* 值如表 5 所示。通过表 5 可以看出,所得 *p* 值均小于 0.05,这表明,在给定显著性水平为 0.05 的情况下,本文方法相对于其他方法的性能改善具有统计学意义。

表 5 本文方法与其他方法进行 Friedman 检验所得 *p* 值

Table 5 The *p* values obtained in Friedman test for the proposed method and other methods

方法	方法 1	方法 2	方法 3	方法 4	方法 5
本文方法	0.020 9	0.000 5	0.000 5	0.003 9	0.006 7

3.2 与其他文献方法对比

为了进一步验证本文方法的有效性,对比了近期使用相同数据集的文献的分类正确率和 *Kappa* 值如表 6、7 所示。在文献[16]中,构建了基于 CNN 和堆叠自编码器(stacked auto-encoder, SAE)的两层特征提取框架,并与 CNN 方法进行了对比分析,实验证明了所提方法的有效性;在文献[17]中,提出了一个新的处理框架,在这个框架内,相空间轨迹进行了重构,并且通过分析这个轨迹的形状确定大脑在不同思维状态下的隐含动态,文中使用仿射不变矩和距离序列两组特征来对相空间轨迹性能进行估计,通过组合这两组特征,从而获得了较好的分类效果;文献[15]中,提出一种融合单通道时-频特征和多通道耦合特征的运动想象脑电分析方法策略,取得了较好的识别结果;文献[18]为 2008 年 BCI 竞赛冠军所用方法。

在表 6 中,从分类正确率的角度进行对比,对于第 5、6、7、9 名受试者,本文方法有一定优势;而对于除第 2 名受试者外的其他受试者,本文方法所得分类正确率仅次于其他文献中的最优方法。此外,本文方法的平均分类正确率为 82.8%,高于其他文献方法,且比其他文献中最高的平均分类正确率 80.2% 高出了 2.6%。

表 6 本文方法与其他方法分类正确率对比

Table 6 Comparison of the classification accuracy for the proposed method and other methods (%)

受试者	文献[15]	文献[16]	文献[17]	本文方法
第 1 名	71.6	78.1	68.9	74.4
第 2 名	64.3	63.1	65.3	63.2
第 3 名	58.4	60.6	63.9	63.1
第 4 名	97.5	95.6	97.7	97.5
第 5 名	88.4	78.1	91.6	93.4
第 6 名	82.5	73.8	74.0	87.5
第 7 名	80.0	70.0	81.0	82.1
第 8 名	92.5	71.3	94.8	93.8
第 9 名	85.9	85.0	84.9	90
平均值	80.1	75.1	80.2	82.8

如表 7 所示,对比了本文方法与其他文献方法的 *Kappa* 值,对于除第 2、3、8 名受试者外的其他受试者,本文方法有一定优势;而对于第 3 和第 8 名受试者,本文方法所得 *Kappa* 值也只仅次于其他文献中的最优方法。另

外,本文方法的平均 *Kappa* 值为 0.66,比 2008 年 BCI 竞赛冠军的 0.6 高出了 0.06,比其他文献中最高的 0.62 高出了 0.04。通过平均分类正确率和 *Kappa* 值的对比分析,进一步证明了本文方法的优势和有效性。

表 7 本文方法与其他方法最大 *Kappa* 值对比

Table 7 Comparison of the maximal *Kappa* value for the proposed method and other methods

受试者	文献[15]	文献[17]	文献[18]	本文方法
第 1 名	0.48	0.39	0.4	0.49
第 2 名	0.29	0.31	0.21	0.26
第 3 名	0.19	0.28	0.22	0.26
第 4 名	0.95	0.95	0.95	0.95
第 5 名	0.78	0.83	0.86	0.87
第 6 名	0.65	0.48	0.61	0.75
第 7 名	0.60	0.62	0.55	0.64
第 8 名	0.88	0.90	0.85	0.88
第 9 名	0.72	0.70	0.74	0.80
平均值	0.62	0.61	0.60	0.66

4 结 论

本文提出了一种基于 MFCNN 的运动想象 EEG 信号分类识别算法,克服了运动想象 EEG 信号中需要人工选择单个受试者最优时段和频段的困难,同时提高了单一信号输入的 CNN 算法分类识别率。本文方法能够利用 CNN 的能力快速而有效地自动选择出个体最优时段和频段特征,在个体最优分类正确率和 9 名受试者的平均分类正确率都有了明显的提高,为基于运动想象 EEG 信号的 BCI 研究提供了一种新的思路。

参考文献

[1] WOLPAW J R, BIRBAUMER N, HEETDERKS W J, et al. Brain-computer interface technology: a review of the first international meeting [J]. Rehabilitation Engineering, IEEE Transactions on, 2000, 8 (2): 164-173.

[2] 徐宝国,何小杭,魏智唯,等. 基于运动想象脑电的机器人连续控制系统研究[J]. 仪器仪表学报,2018, 39(9):10-19.

XU B G, HE X H, WEI ZH W, et al. Research on continuous control system for robot based on motor imagery EEG [J]. Chinese Journal of Scientific Instrument, 2018, 39(09): 10-19.

[3] 谢平,陈晓玲,苏玉萍,等. 基于 EMD-多尺度熵和 ELM

的运动想象脑电特征提取和模式识别[J]. 中国生物医学工程学报, 2013,32(6):641-648.

XIE P, CHEN X L, SU Y P, et al. Feature extraction and recognition of motor imagery EEG based on EMD-multiscale entropy and extreme learning machine [J]. Chinese Journal of Biomedical Engineering, 2013, 32(6): 641-648.

[4] 张丹,李佳蔚. 探索思维的力量探索思维的力量:脑机接口研究现状与展望[J]. 科技导报,2017, 35(9): 62-67.

ZHANG D, LI J W. Exploring the power of mind: Status and prospect of brain-computer interfaces[J]. Science & Technology Review, 2017,35(9):64-69.

[5] PFURTSCHELLER G, DA SILVA F H L. Event-related EEG/MEG synchronization and desynchronization: Basic principles [J]. Clinical Neurophysiology, 1999, 110(11): 1842-1857.

[6] 明东,王坤,何峰,等. 想象动作诱发生理信息检测及其应用研究:回顾与展望[J]. 仪器仪表学报,2014, 35(9):1921-1931.

MING D, WANG K, HE F, et al. Study on physiological information detection and application evoked by motor imagery: Review and prospect [J]. Chinese Journal of Scientific Instrument, 2014, 35(9): 1921-1931.

[7] 何群,王煜文,杜硕,等.基于自适应无参经验小波变换和选择集成分类模型的运动想象[J].物理学报,2018, 67(11):284-295.

HE Q, WANG Y W, DU SH, et al. Motor imagery based on adaptive parameterless empirical wavelet transform and selective integrated classification [J]. Acta Physica Sinica, 2018, 67(11): 284-295.

[8] 孙会文,伏云发,熊馨,等. 基于 HHT 运动想象脑电模式识别研究[J]. 自动化学报,2015,41(9):1686-1692.

SUN H W, FU Y F, XIONG X, et al. Identification of EEG induced by motor imagery based on hilbert-huang transform[J]. Acta Automatica Sinica, 2015, 41(9): 1686-1692.

[9] 胡春海,李涛,刘永红,等. 基于改进差分进化算法的运动想象脑机接口频带选择[J]. 计量学报,2018, 39(2):276-279.

HU CH H, LI T, LIU Y H, et al. Motor imagery brain computer interface band selection based on improved differential evolution algorithm [J]. Acta Metrologica Sinica, 2018,39(2): 276-279.

[10] 唐智川,孙守迁,张克俊. 基于运动想象脑电信号分类

- 的上肢康复外骨骼控制方法研究[J]. 机械工程学报, 2017, 53(10): 60-69.
- TANG ZH CH, SUN SH Q, ZHANG K J. Research on the control method of an upper-limb rehabilitation exoskeleton based on classification of motor imagery EEG[J]. Journal of Mechanical Engineering, 2017, 53(10): 60-69.
- [11] DENG L, HINTON G, KINGSBURY B. New types of deep neural network learning for speech recognition and related applications: An overview[C]. IEEE International Conference on Acoustics, Speech and Signal Processing, 2013, doi:10.1109/ICASSP.2013.6639344.
- [12] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Imagenet classification with deep convolutional neural networks[C]. Advances in Neural Information Processing System, 2012, 25(2): 1097-1105.
- [13] 唐智川, 张克俊, 李超, 等. 基于深度卷积神经网络的运动想象分类及其在脑控外骨骼中的应用[J]. 计算机学报, 2017, 40(6): 1367-1378.
- TANG ZH CH, ZHANG K J, LI CH, et al. Motor imagery classification based on deep convolutional neural network and its application exoskeleton controlled by EEG[J]. Chinese Journal of Computers, 2017, 40(6): 1367-1378.
- [14] BASHIVAN P, RISH I, YEASIN M, et al. Learning representations from EEG with deep recurrent-convolutional neural networks [J]. Computer Science, 2015, arXiv:1511.06448.
- [15] 何群, 杜硕, 张园园, 等. 融合单通道框架及多通道框架的运动想象分类[J]. 仪器仪表学报, 2018, 39(9): 20-29.
- HE Q, DU SH, ZHANG Y Y, et al. Classification of motor imagery based on single-channel frame and multi-channel frame [J]. Chinese Journal of Scientific Instrument, 2018, 39(9): 20-29.
- [16] TABAR Y R, HALICI U. A novel deep learning approach for classification of EEG motor imagery signals [J]. Journal of Neural Engineering, 2016, 14(1): 016003.
- [17] SAYED K, KAMEL M, ALHADDAD M, et al. Characterization of phase space trajectories for brain-computer interface[J]. Biomedical Signal Processing and Control, 2017, 38(9): 55-66.
- [18] ANG K K, CHIN Z Y, WANG C, et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b[J]. Frontiers in neuroscience, 2012, 29(6): 39.

作者简介



何群, 2005 年于燕山大学获得博士学位, 现为燕山大学副教授, 主要研究方向为机械故障诊断、基于生理信号的辅助驾驶等。

E-mail: hq@ysu.edu.cn

He Qun received his Ph. D. degree from Yanshan University in 2005. Now, he is an associate professor in Yanshan University. His main research interests include mechanical fault diagnosis and assisted driving based on physiological signals.