

基于卷积网络的运动想象脑电自制数据集分类算法研究

蔡辰玥

天津工业大学电气工程与自动化学院, 天津
Email: 649995774@qq.com

收稿日期: 2021年1月8日; 录用日期: 2021年1月22日; 发布日期: 2021年1月29日

摘要

运动想象脑电信号分类已成为脑计算机接口研究领域的一个热点。本文通过实验室设备进行脑电采集并制作自己的数据集, 同时将卷积神经网络与传统方法进行结合, 提出了一种基于短时傅里叶变换和连续小波变换对原始数据进行特征提取使用卷积神经网络进行分类的算法。利用特征提取算法提取时频特征制成时频图并使用卷积神经网络快速学习特征进行分类。试验结果表明, 该算法在运动想象脑电公共数据集中有着96%的准确率, 在自制数据集上准确率达到92%左右, 证明了该算法在运动想象脑电分类上的可行性。

关键词

脑机接口, 卷积神经网络, 短时傅里叶变换, 连续小波变换, 特征提取, 运动想象, 脑电图

Research on Classification Algorithm of Self-Made Data Set of Motor Imagination EEG Based on Convolutional Network

Chenyue Cai

School of Electrical Engineering and Automation, Tiangong University, Tianjin
Email: 649995774@qq.com

Received: Jan. 8th, 2021; accepted: Jan. 22nd, 2021; published: Jan. 29th, 2021

Abstract

Motor imaging EEG signal classification has become a hot spot in the field of brain computer interface research. This paper uses laboratory equipment to collect EEG and make its own data set. At

the same time, it combines convolutional neural networks with traditional methods to propose a feature extraction method based on short-time Fourier transform and continuous wavelet transform. Convolutional neural network classification algorithm uses feature extraction algorithm to extract time-frequency features to make time-frequency map and uses convolutional network to quickly learn features for classification. The test results show that the algorithm has an accuracy rate of 96% in the motor imagery EEG public data set, and the accuracy rate is about 92% on the self-made data set, which proves the feasibility of the algorithm in motor imagery EEG classification.

Keywords

Brain-Computer Interface, Convolutional Neural Network, Short-Time Fourier Transform, Continuous Wavelet Transform, Feature Extraction, Motor Imagery, EEG

Copyright © 2021 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

脑-机接口(Brain-Computer Interface, BCI)是一种可使人脑直接与外部计算机或机器进行通信的系统,它通过检测中枢神经系统活动并将其转化为人工输出来替代、修复、增强、补充或改善中枢神经系统的正常输出[1] [2] [3] [4]。根据大脑在 BCI 系统中的不同应用方式,可以将 BCI 系统分成主动式、被动式和反应式三种类型[5]。基于运动想象(Motor Imagery, MI)的 BCI 系统已显示出与实际运动执行时类似的大脑通路。它显示了在没有剩余运动功能的情况下可以替代锻炼或防止疲惫的希望,研究表明其可通过功能性电刺激设备提供适当的反馈,促进神经可塑性并增强学习过程。这最终可以帮助偏瘫性中风患者更快更好地康复[6]。

基于 MI 的 BCI 系统中的运动想象脑电(motor imagery EEG, MI-EEG)反映了大脑在做相关动作想象时的电位活动,并且在进行不同的 MI 任务时会激发相对应大脑皮层区域的响应[7]。信号处理是 MI-BCI 系统中非常重要的一环,它主要包含了特征提取和分类算法这两部分的设计。MI 任务下常用的频域和空间信息特征提取包括谱分析、自回归、和共空间模式(common spatial pattern, CSP)等[8] [9]。其中 CSP 算法的性能在 MI 分类任务中准确率相对较高。最近的一项研究中,Zhang 等介绍了一种新的方法,该方法在 CSP 基础上引入了稀疏贝叶斯学习算法用于有效特征的选择,实验结果表明了该方法的有效性,有望开发出有效的分类器改善 MI 分类性能[10],但传统 CSP 容易受到噪声干扰,且未考虑时域内的可分性。Han 等应用频域中的最小范数估计法对运动相关的皮质节律调制进行源分析,实现了对光标的一维控制[11],但其缺少对三维控制的可靠性研究。MI-BCI 系统中常见的分类算法包括线性判别分析(linear discriminant analysis, LDA)、支持向量机(support vector machine, SVM)、人工神经网络(artificial neural networks, ANNs)和模糊系统[12]等。过去十几年,研究人员分析了不同类型的 ANNs,在不同 ANNs 的架构中,最常用的架构是多层感知器(multilayer perceptron, MLP)。这种 MLP 具有近似任何函数的能力,然而当设计高噪声水平的 EEG 信号时,会导致过度拟合的问题[13]。最近的一项研究中,Hettiarachchi 等研究了功能链神经网络作为 MI-BCI 应用多类分类器的适用情况,结果表明,该方法能有效弥补 MLP 的缺陷,可用于实时 MI-BCI 控制[14],但其收敛速度较慢,训练时间过长。

本文结合当前发展趋势，将卷积神经网络结合到传统分类方法上，应用了短时傅里叶变换和连续小波变换与卷积神经网络结合对运动想象原始脑电信号进行分类，并且得到了比较好的分类准确性。同时还创建了自己的脑电数据集，为以后的运动想象脑电信号研究提供数据支撑。

2. 数据和方法

2.1. 数据来源

本次实验所用数据来自 2005 年 BCI Competition III Datasets IIIa 公开数据集和自制数据集。自制数据集数据采集实验按照公开数据集实验批次模拟而成，用以方便实验结果对比。实验中共征集 8 名志愿者进行脑电采集实验，受试者均为右利手 24 岁左右成年男性，受试者放松的坐在有扶手的椅子上进行运动想象任务，实验根据随机的提示执行左手，右手，脚或舌头运动的想象。该实验进行多次(至少 5 次)，每次执行 48 次想象。试验开始后，前 2 秒放松，显示器上显示十字箭头。在 $t = 2\text{ s}$ 时，提示音响起指示试验开始。然后从 $t = 3\text{ s}$ 开始出现向左，向右，向上或向下的提示箭头显示 4 秒钟；同时要求受试者想象左手，右手，舌头或脚的运动，直到箭头在 $t = 7\text{ s}$ 消失。在每次想象任务中，以随机顺序将 4 个提示中的每个提示显示 5 次。该实验使用 Neuroscan 的 8 通道 EEG 放大器进行数据采集。脑电图是以 250 Hz 为采样频率，每名受试者最后通过 10 次采集实验得到五组实验数据，每组实验进行 48 此运动想象，总共 2400 个训练样本数据；还采集了 600 个测试样本数据用以为网络验证性能。实验范式与脑电导联电极图如图 1 和图 2 所示。




Figure 1. Experimental paradigm time
图 1. 实验范式的时间

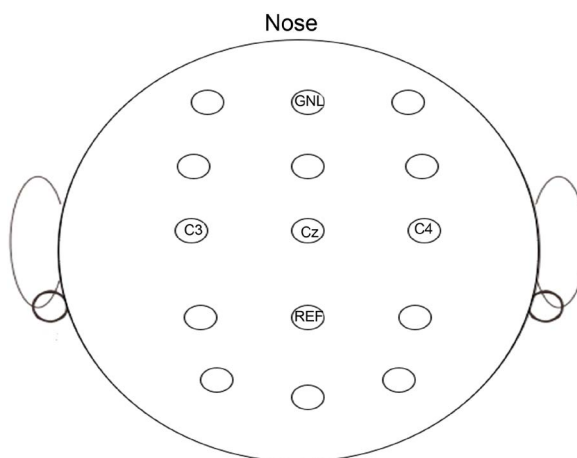


Figure 2. Location of EEG electrodes
图 2. 脑电电极位置

2.2. 研究方法

首先对采集到的数据和公共数据进行带通滤波、伪迹去除等预处理操作，然后将预处理过的脑电数

据进行特征提取，特征提取算法使用连续小波变换(Continuous Wavelet Transform, CWT)和短时傅里叶变换(Short-Time Fourier Transform, STFT)，连续小波变换通过向下拆分信号，最终得到低频信息特征，短时傅里叶变换通过设置较窄的时间窗口对脑电信号进行高频特征提取。经过这两种方式处理过的时频图能够完美的包含脑电信号的低频与高频信息。如图 3 所示为信号经过短时傅里叶变换后并拼接 C3、C4 通道信息的右手运动想象时频图。由图可以看出 C3 通道的颜色明显比 C4 通道深，通过此现象可以证明右手运动想象是的对侧大脑感觉运动区能量变化特性。本次实验为了增加数据量从而更好地进行卷积网络的训练，本次连续小波变换采用了 Morlet Wavelet 和 Frequency B-Spline Wavelets 两种核心算法分别对脑电数据进行特征提取计算。




Figure 3. Time-frequency characteristic diagram
图 3. 时频特征图

Morlet Wavelet 使用 “morl” 字符串导入连续小波变换中：

$$\psi(t) = \exp\left(\frac{t^2}{2}\right) \cos(5t) \tag{1}$$

Frequency B-Spline Wavelets 使用 “fbspm-B-C” 字符串导入连续小波变换中：

$$\psi(t) = \sqrt{B} \left[\frac{\sin\left(\pi B \frac{t}{M}\right)}{\pi B \frac{t}{M}} \right]^M \exp^{2j\pi Ct} \tag{2}$$

其中 M 是样条顺序， B 是带宽， C 是中心频率。

短时傅里叶变换算法为给定一个时域信号 $x[n]$ ，一个窗口 $\omega(n)$ 和一个跃点 $H = nperseg - noverlap$ ，时间索引为 t 的窗口帧为：

$$x_t[n] = x[n] \omega[n - tH] \tag{3}$$

重叠相加(OverLapAdd, OLA)重建方程为：

$$x[n] = \frac{\sum_t x_t[n] \omega[n - tH]}{\sum_t \omega^2[n - tH]} \tag{4}$$

其中所采用的窗口是 “hann” 汉恩窗口，其定义为：

$$\omega(n) = 0.5 - 0.5 \cos\left(\frac{2\pi n}{M-1}\right) \quad 0 \leq n \leq M-1 \tag{5}$$

其中 M 代表输出窗口中的点数，如果为零或更少则输出空数组。

经过以上方式进行数据特征提取生成时频图传入 CNN 中，此网络由输入输出层、卷积-池化层、全连接层组成。由于卷积池化层对数决定了卷积网络的深度，本文经过实验验证决定使用四对卷积池化层网络进行实验。本次实验卷积网络具体结构如下：第一层为输入层，第二、五、八、十一层为卷积层，第三、六、九、十二层为池化层、第四、七、十、十三、十五为 dropout 层、第十四层为全连接层、第十六层为输出层。其各层参数与内容具体描述如下。

1) 第 1 层为输入层，输入样本为 $64 \times 64 \times 3$ 的矩阵，其中 3 代表所输入样本为 RGB 样本， 64×64 代表输入样本尺寸的长宽，宽度组成为 C3 和 C4 的时间频谱图组合拼接而成。

2) 第 2、5、8、11 成为卷积层，第 2 层主要作用是提取输入样本的频谱特征。该层使用了 32 个滤波器对数据进行映射，第 4 层滤波器个数为 64 个，第 6 层滤波器个数为 128 个，第 8 层滤波器个数为 256 个，卷积核大小均为 3×3 。

3) 第 3、6、9、12 层为池化层，该层作用相当于用过池化函数对上一层提取到的特征进项压缩近似于第二次特征提取，通常被称为下采样层。池化层的池化函数中普遍使用最大池化函数或均匀池化函数，本文所用池化函数为最大池化函数。池化操作能够提高该网络的鲁棒性和统计效率，本文中该层的核设置为 2×2 。

4) 第 4、7、10、13、15 层为 dropout 层，该层的作是通过一定概率来暂时将网络中的神经元丢弃，从而达到减缓过拟合的功能。该层的参数设置为 0.25。

5) 第 14 层为全连接层，该层将所有特征值相连并将输出传送给分类器，总共设置神经元 4096 个。

6) 第 16 层为输出层，该层使用 softmax 函数进行分类结果输出，包含了四个神经元，代表四分类问题(左手、右手、舌头和脚的 MI 任务)。

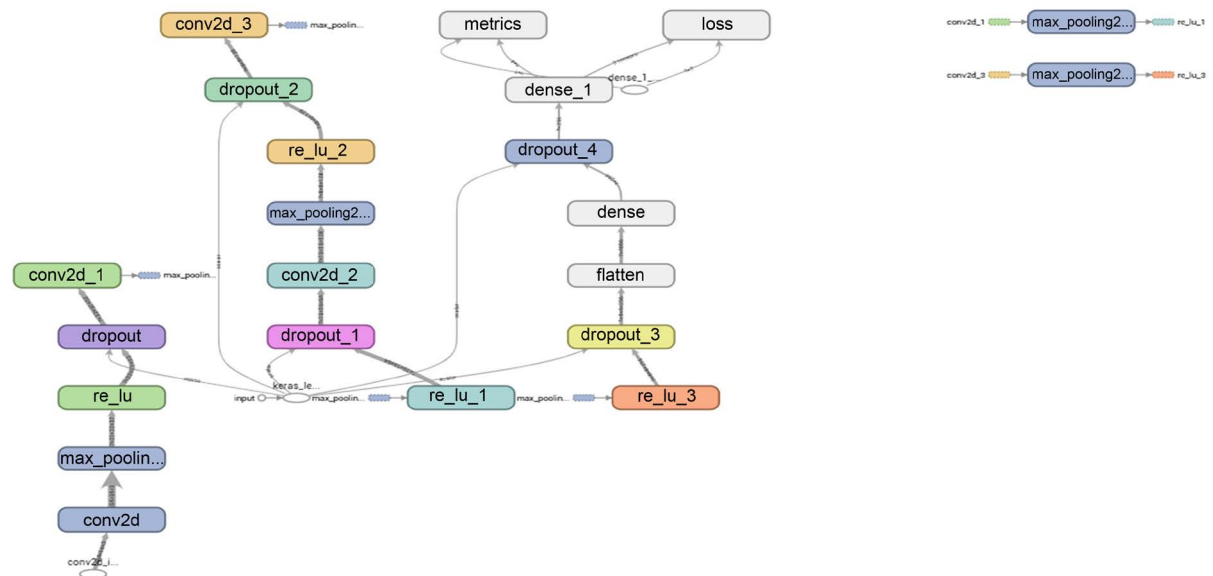


Figure 4. Convolutional network topology diagram

图 4. 卷积网络拓扑图

如图 4 所示，确定了网络结构后进行神经网络的训练，神经网络算法需要各种激活函数的引用，其中 sigmoid、tanh 和 ReLU 等激活函数是几个常用函数。综合文献查阅了解到，目前大多数卷积神经网络中使用的激活函数为 ReLU 函数，其优点相比于 sigmoid 和 tanh 激活函数有计算速度快、不饱和、稀疏

等特性，所以本文中所采用的激活函数也为 ReLU 函数。优化器方面选择了较为常用的随机梯度下降优化器(stochastic gradient descent, SGD)。损失函数选择常见的交叉熵损失函数。确定了神经网络的各网络层次函数后，在各个函数确定下进一步确定学习速率、训练迭代次数和每批次训练数据的大小等参数。在其他参数固定情况下改变其中一种参数，进行多次循环训练验证实验得出所有不同情况下的网络分类性能。如图 5 所示，不同参数对应分类准确率。




Figure 5. Classification accuracy of different parameters

图 5. 不同参数的分类准确率

综合整体分析在学习率为 0.1 时所有参数输入大小的准确率均高于其他学习率，故选择学习率参数为 0.1。类似的确定训练迭代次数 500 和每批次训练数据大小 64，整合所有最优参数得出如表 1 所示，所有训练参数确定后具体数值参考设置表。其内的参数均为各项相对最优。

Table 1. Training parameter settings

表 1. 训练参数设置

参数	数值
每批次训练数据大小	64
训练迭代次数	500
学习速率	0.1
激活函数	ReLU
优化器	随机梯度下降(SGD)
损失函数	交叉熵(cross entropy)

3. 实验结果分析

将本文方法计算得到的实验结果与文献[15]中的方法 fbcs-p-svm 计算得到的结果进行对比，其分类识别正确率如表 2 所示。从表 2 看出，相比两种算法，本文算法得到的分类正确率在所有受试者数据上均有不同程度的提高。可以看出基于卷积神经网络分类算法得到的结果在一定程度上优于传统算法。针对以上结果，本文做了如下分析。

Table 2. Comparison of classification accuracy between this method and other method
表 2. 本文方法与其他方法分类准确率对比

数据	fbcsp-svm	本文方法
k3b	82.22	96.17
k6b	75.56	89.73
l1b	80.00	91.33
S0	72.64	92.83
S1	77.51	88.67
S2	64.05	87.36
S3	58.98	75.53
S4	95.76	95.26
S5	85.61	88.78
S6	76.80	80.23
S7	75.05	81.70

如表 2 所示，在公开数据集上本文所用方法分类结果普遍高于传统的分类结果，在自制数据集上本文的分类方法同样比传统分类方法的分类性能更好。从表中可以看出，本文在 S2 和 S3 受试者上分类准确率比较低，本文通过计算两名受试者各自左手、右手运动想象时的特征图和能量特征的平均值，发现受试者在进行两类运动想象时，计算得到的能量差异并不显著。因此，在这种情况下，使用小波包分解方法计算信号量特征时，C3 和 C4 两个通道的能量分布较为相近，影响了分类识别的正确率。而在其他受试者上，两类信号在 C3 及 C4 通道上的能量分布有一定的差异性。

网络训练结果如图 6 所示曲线最后趋于稳定，说明此网络对当前所用数据集有较好的分类能力，并且此网络能够快速收敛并趋于稳定，满足运动想象分类算法的基本要求。




Figure 6. Accuracy curve of network training

图 6. 网络训练准确率曲线

4. 结论

本文通过实验室设备进行脑电数据采集，建立了一个小型运动想象脑电信号数据集，并通过连续小波变换和短时傅里叶变换对此数据和公开数据进行特征提取，结合两种特征提取算法各自的优点进行特

征互补, 再通过卷积神经网络对此特征进行学习并分类。根据分类结果可知, 本文所用方法能够有效提高运动想象脑电信号的分类准确率。但在数据集的样本数量上还有待扩充, 希望后期进行扩充以增强本文方法的泛化能力, 从而提高此网络算法的分类性能。为后续 BCI 控制外部设备提供更加精准高效的指令, 来完成相应运动想象控制外部设备达到脑控设备的实际应用。

参考文献

- [1] Schalk, G., McFarland, D.J., Hinterberger, T., Birbaumer, N. and Wolpaw, J.R. (2004) BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE Transactions on Biomedical Engineering*, **51**, 1034-1043. <https://doi.org/10.1109/TBME.2004.827072>
- [2] Wolpaw, J. and Wolpaw, E.W. (2012) Brain-Computer Interfaces: Principles and Practice. Oxford University Press, Oxford. <https://doi.org/10.1093/acprof:oso/9780195388855.001.0001>
- [3] Huang, C., Shan, X., Lan, Y., Liu, L., Cai, H., Che, W., Hao, Y., Cheng, Y. and Peng, Y. (2018) A Hybrid Active Contour Segmentation Method for Myocardial D-SPECT Images. *IEEE Access*, **6**, 39334-39343. <https://doi.org/10.1109/ACCESS.2018.2855060>
- [4] Huang, C., Xie, Y., Lan, Y., Hao, Y., Chen, F., Cheng, Y. and Peng, Y. (2018) A New Framework for the Integrative Analytics of Intravascular Ultrasound and Optical Coherence Tomography Images. *IEEE Access*, **6**, 36408-36419. <https://doi.org/10.1109/ACCESS.2018.2839694>
- [5] 李鹏海, 许敏鹏, 万柏坤, 等. 视觉诱发电位脑-机接口实验范式研究进展[J]. 仪器仪表学报, 2016, 37(10): 2340-2351.
- [6] Dose, H., Möller, J.S., Iversen, H.K., et al. (2018) An End-to-End Deep Learning Approach to MI-EEG Signal Classification for BCIs. *Expert Systems with Applications*, **114**, 1016. <https://doi.org/10.1016/j.eswa.2018.08.031>
- [7] 葛荣祥, 胡建中. 基于深度学习框架的多类运动想象脑电分类研究[J]. 江苏科技大学学报(自然科学版), 2019, 33(4): 61-66.
- [8] D’Croz-Baron, D., Ramirez, J.M., Baker, M., et al. (2012) A BCI Motor Imagery Experiment Based on Parametric Feature Extraction and Fisher Criterion. In: *International Conference on Electrical Communications and Computers*, IEEE, Cholula, 257-261. <https://doi.org/10.1109/CONIELECOMP.2012.6189920>
- [9] Jamaloo, F. and Mikaeili, M. (2015) Discriminative Common Spatial Pattern Sub-Bands Weighting Based on Distinction Sensitive Learning Vector Quantization Method in Motor Imagery Based Brain-Computer Interface. *Journal of Medical Signals and Sensors*, **5**, 156-161. <https://doi.org/10.4103/2228-7477.161482>
- [10] Zhang, Y., Wang, Y., Jin, J., et al. (2017) Sparse Bayesian Learning for Obtaining Sparsity of EEG Frequency Bands Based Feature Vectors in Motor Imagery Classification. *International Journal of Neural Systems*, **27**, Article ID: 1650032. <https://doi.org/10.1142/S0129065716500325>
- [11] Yuan, H., Doud, A., Gururajan, A., et al. (2008) Cortical Imaging of Event-Related (De)synchronization during Online Control of Brain-Computer Interface Using Minimum-Norm Estimates in Frequency Domain. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **16**, 425-431. <https://doi.org/10.1109/TNSRE.2008.2003384>
- [12] Ramadan, R.A. and Vasilakos, A.V. (2017) Brain Computer Interface: Control Signals Review. *Neurocomputing*, **223**, 26-44. <https://doi.org/10.1016/j.neucom.2016.10.024>
- [13] Mohamed, S., Haggag, S., Nahavandi, S., et al. (2017) Towards Automated Quality Assessment Measure for EEG Signals. *Neurocomputing*, **237**, 281-290. <https://doi.org/10.1016/j.neucom.2017.01.002>
- [14] Hettiarachchi, I.T., Babaei, T., Nguyen, T., et al. (2018) A Fresh Look at Functional Link Neural Network for Motor Imagery-Based Brain-Computer Interface. *Journal of Neuroscience Methods*, **305**, 28-35. <https://doi.org/10.1016/j.jneumeth.2018.05.001>
- [15] Ang, K.K., Chin, Z.Y., Wang, C., et al. (2012) Filter Bank Common Spatial Pattern Algorithm on BCI Competition IV Datasets 2a and 2b. *Frontiers in Neuroscience*, **29**, 39. <https://doi.org/10.3389/fnins.2012.00039>