

引用格式: 谷学静, 位占锋, 刘海望, 等. 基于小波包和串并行 CNN 的脑电信号分类[J]. 微电子学与计算机, 2021, 38(6): 60-65. [GU X J, WEI Z F, LIU H W, et al. EEG signal recognition based on wavelet packet and serial parallel CNN[J]. Microelectronics & Computer, 2021, 38(6): 60-65.]

基于小波包和串并行 CNN 的脑电信号分类

谷学静^{1,2}, 位占锋^{1,2}, 刘海望^{2,3}, 郭 俊^{1,2}, 沈 攀^{1,2}

(1 华北理工大学 电气工程学院, 河北 唐山 063000; 2 唐山市数字媒体工程技术研究中心, 河北 唐山 063000; 3 华北理工大学轻工学院 电气工程学院, 河北 唐山 063000)

摘 要: 针对运动想象脑电信号(EEG)的非线性、非平稳性特点, 提出了一种结合小波包变换(WPT)和串并行卷积神经网络(SPCNN)的脑电信号分类方法. 在小波包变换过程中, 对脑电信号进行时频分解, 选取与运动想象密切相关的频率段进行重构, 重构后的脑电信号保留了有效的时频信息. 考虑到脑电信号不同通道之间以及通道内的特征, 构建了 SPCNN 网络模型自动提取有效的特征并进行分类. 利用公开的竞赛数据集 BCI competition IV 2b 进行验证, 结果表明: 该方法能自适应的提取到有效特征, 平均分类准确率达到 84.77%, 比卷积神经网络提高了 6.49%, 为脑机接口系统的研究提供了一种分类方法.

关键词: 运动想象脑电信号; 小波包变换; 卷积神经网络; 特征提取

中图分类号: TP391

文献标识码: A

文章编号: 1000-7180(2021)06-0060-06

EEG signal recognition based on wavelet packet and serial parallel CNN

GU Xue-jing^{1,2}, WEI Zhan-feng^{1,2}, LIU Hai-wang^{2,3}, GUO Jun^{1,2}, SHEN Pan^{1,2}

(1 College of Electrical Engineering, North China University of Science and Technology, Tangshan 063000, Hebei China;
2 Tangshan Digital Media Engineering Technology Research Center, Tangshan 063000, Hebei China;
3 College of Electrical Engineering, Qing Gong College, North China University of
Science and Technology, Tangshan 063000, Hebei China)

Abstract: Aiming at the non-linear and non-stationary characteristics of motor imagery ElectroEncephaloGram (EEG) signals, a novel EEG signal classification method combining wavelet packet transform (WPT) and serial-parallel convolutional neural network(SPCNN) is proposed. In the process of wavelet packet transform, the EEG signal is decomposed in time and frequency, and the frequency band closely related to motor imagination is selected for reconstruction. The reconstructed EEG signal retains effective time-frequency information. Then, considering the features between and within the different channels of the EEG signal, the SPCNN network model is constructed to automatically extract the effective features and classify them. Use the public competition data set BCI competition IV 2b to verify, the results show that the method can adaptively extract effective features, and the average classification accuracy reaches 84.77%, which is 6.49% higher than the convolutional neural network. It provides a classification method for the research of brain-computer interface systems.

Key words: motor imagery EEG; wavelet packet transform; convolutional neural network(CNN); feature extraction

1 引言

脑机接口通过脑电设备采集大脑头皮信号,经过信号处理等一系列操作,将信号转换为操作指令,进而控制外部设备,为一些运动障碍患者提供了一个与外界交流的通道.随着运动障碍患者以及老龄化人口的增长,基于运动想象的研究具有重要的社会意义和价值^[1].

运动想象脑电信号(motor imagery electroencephalography, MI-EEG)具有非线性、非平稳等特点,针对 MI-EEG 的特征提取与分类成为了人们一直需要处理的难题. MI-EEG 是非平稳信号,它的频率随时间发生变化,包含了大量的时频信息,ERS/ERD 现象在识别 MI-EEG 中是一个很重要的依据^[2].小波包变换(wavelet packet transform, WPT)相比小波变换(wavelet transform, WT)是一种更加精细的时域分析方法,既可以对低频部分进行分解,也可以对高频部分进行分解^[3],完整地保留了低高频信息,提高了 EEG 的时域分辨率.

深度网络模型具有强大的自动提取最优特征的能力,近年来被人们大量的应用到 EEG 的识别中,卷积神经网络(Convolutional Neural Network, CNN)是其中的一种代表^[4].Zhang 等人利用短时傅里叶变换对原始 EEG 分析,将时频图像作为 CNN 的输入,以收敛速度和分类精度作为指标选取了合适的激活函数,其提出的模型具有很好地分类精度^[5].程时伟等人在减少脑电采集通道,增加分类数目的前提下,利用脑电数据训练出基于 CNN 的分类模型,并实现了人-机器人之间的实时交互^[6].Dose 等人使用 CNN 来学习广义特征和降维,建立了一个端到端的模型来对原始脑电信号分析和处理^[7].唐智川等人基于脑电信号时空信息结合的特性,针对性地设计了一个 5 层的 CNN 结构进行分类,并成功应用于上肢康复外骨骼的实时控制^[8].孔祥浩等人提出了 CSP 与 CNN 相结合的脑电特征提取方法,通过 CNN 网络对经过 CSP 处理的特征矩阵二次特征提取,筛选出最优特征集,为脑电特征提取问题提供了一个新的思路^[9].但是,他们都没有考虑到不同通道之间的特征,不同通道之间存在着相关性,这部分信息的丢失会对后续的分类产生一定影响.

针对上述存在的问题,本文提出了一种结合 WPT 和串并行卷积神经网络(Serial Parallel Convolutional Neural Network, SPCNN)的脑电信号分

类方法.首先,对预处理的 EEG 进行小波包分解,选取属于 Mu 和 Beta 节律的小波节点对应的 EEG 进行重构.然后,将处理好的信号输入到并列双卷积核的网络模型中,网络内部自动进行最优化的特征提取,最后,将特征输入给 Softmax 分类器分类.实验结果表明,该方法能筛选出有效地信息并有利于后续的自动提取特征及分类,提高了分类准确率.

2 小波包变换

传统的小波变换对信号的低频部分进行分解,会忽略高频部分,对于包含了大量细节信息和边缘信息的信号来说,小波包变换既可以对信号的低频部分进行分解,也可以对高频部分进行分解,对信号的分析更加的精细,这种分解对于 EEG 来说没有冗余,也没有疏漏,可以很好地时频分析.本文选取分解的属于运动想象部分的节点系数进行重构.

设小波包树节点标注为 (j, n) . j 代表小波包树的层数, n 代表相应层数下节点的个数,那么第 k 点的小波包分解系数为:

$$d_j^{2n}(k) = \sum_{l \in Z} h_{l-2k} d_{j-1}^n(l) \quad (1)$$

$$d_j^{2n+1}(k) = \sum_{l \in Z} g_{l-2k} d_{j-1}^n(l) \quad (2)$$

经过小波包分解,每一个节点都对应着相应的频段,信号采样率为 f_s ,则第 j 层各个节点对应的频段分别为:

$$\left\{ \left[0, \frac{f_s}{2^{j+1}}\right]; \left[\frac{f_s}{2^{j+1}}, \frac{2f_s}{2^{j+1}}\right]; \left[\frac{2f_s}{2^{j+1}}, \frac{3f_s}{2^{j+1}}\right]; \dots; \left[\frac{(2j-1)f_s}{2^{j+1}}, \frac{f_s}{2}\right] \right\}$$

因此可以确定每个节点对应的频率,选取合适的节点进行脑电信号的重构,第 $j-1$ 层、第 k 点的重构公式为:

$$d_{j-1}^n(k) = \sum_{l \in Z} h_{k-2l} d_j^{2n}(l) + \sum_{l \in Z} g_{k-2l} d_j^{2n+1}(l) \quad (3)$$

3 串并行卷积神经网络

3.1 串并行卷积神经网络

对于多通道脑电信号,为了更加有效的进行特征提取,提取到 EEG 中每一个通道的内部特征以及通道之间的特征,本文采取并列使用双卷积核的 SPCNN 模型来训练.其模型如图 1 所示,主要分为以下 5 个部分.

(1)输入层:输入数据为经过小波包重构的特定频段信号脑电数据.

(2)卷积层 1:采用并列的双卷积核分别对输入数据进行卷积操作,两个卷积核的大小是不同的,分别为 1×15 和 3×6 .多通道脑电信号包含时间和通道两个方面的信息,其中 1×15 卷积核只是在时间方面卷积,进行一维卷积运算,这种特殊的卷积核并不会有混杂的两种信息,可以提取到充足的时间信息. 3×6 大小的卷积核在时间和通道两方面同时卷积,可以提取到每个通道关联性的信息,在该层使用 16 种滤波器,卷积步长为 1×1 ,使用 ReLU 激活函数,padding 参数选值为 SAME,卷积时可以对输入矩阵边缘补零,防止数据丢失.最大池化层 1 选取 1×5 ,拼接层 1 则把两个卷积核得到的特征图按照对应行拼接起来.

(3)卷积层 2:同样使用两个不同大小的卷积核,分别为 1×10 和 3×3 ,分别对拼接层 1 的输出进行卷积操作.在该层使用 32 种滤波器,卷积步长为 1×1 ,使用 ReLU 激活函数,padding 参数选值为 SAME,最大池化层 2 选取 1×5 ,拼接层 2 则把两个卷积核得到的特征图按照对应行拼接起来.

(4)全连接层:使用了两个全连接层,全连接层 1 神经元个数设为 300 个,本文做的是左右手两分类的任务,因此全连接层 2 神经元个数设为 2 个,代表了两分类问题.同时两个全连接层之间加入了 dropout 层,来防止模型过拟合.

(5) 输出层:使用 Softmax 函数用于左右手的分类,可以将分类的结果以概率的形式展示出来.给定输入 x 属于第 i 类的一种原始度量 $h(x, y_i)$,函数公式为:

$$p(y = i | x) = \frac{e^{h(x, y_i)}}{\sum_{j=1}^n e^{h(x, y_j)}} \tag{4}$$

神经网络算法需要引入非线性的激活函数,较为常见的激活函数有 sigmoid、tanh、ReLU 等等. ReLU 函数和 sigmoid、tanh 函数相比,导数更加好求,反向传播就是不断的更新参数的一个过程,ReLU 函数导数不复杂形式简单,可以使网络训练更快,因此本文选择 ReLU 函数作为激活函数. 优化器选择了常用的随机梯度下降优化器(stochastic gradient descent,SGD),损失函数选择常用的均方误差(L2). 训练参数的设置如表 1 所示.

表 1 网络主要参数设置

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)




图 1 串并行卷积神经网络结构图

3.2 基于 WPT 和 SPCNN 的 MI-EEG 特征提取方法

基于 WPT 和 SPCNN 的 MI-EEG 特征提取与分类算法如图 2 所示,该算法主要包括 3 个处理部分:

(1)对获取的实验数据进行预处理,以获得更加纯净的脑电信号,有利于后续的操作处理. 首先进行一个去均值的处理,以防止数据拟合,随后进行 8~30Hz 的带通滤波,因为运动想象过程中,主要和 Mu 节律和 Beta 节律有关系,而这两个节律在 8~




图 2 算法流程

30Hz 之间,所以对 EEG 进行一个 8~30Hz 的带通滤波,最后进行归一化处理,归一化后既可以加快梯

度下降求最优解的速度,提高收敛效率,又能提高精度.

(2)对预处理的 EEG 通过式(1)(2)进行小波包分解,计算出分解的子空间对应的频段信息,选取涵盖 Mu 节律和 Beta 节律对应的节点,通过式(3)进行信号的重构.

(3)将重构好的脑电信号通过图 1 的 SPCNN 网络模型中,进行卷积降采样以及分类操作,输出分类结果.

4 实验分析

4.1 实验数据来源

本文实验数据来源于 2008 年 BCI 竞赛数据集 2b,实验者都是右撇子,视力正常或已矫正,共有 9 名志愿者参与,所有志愿者都坐在扶手椅上,看着一个距离大约 1 米远的大屏幕显示器,每人进行 5 组实验数据的采集,分别为 01T、02T、03T、04E 以及 05E,其中 01T、02T、03T 为训练数据,04E、05E 为测试数据. 01T、02T 数据采用的是无反馈实验范式,03T、04E 以及 05E 采用的是有反馈实验范式,实验范式如下图 3、图 4. 采样频率为 250 Hz,所有数据都已经过 0.5~100 Hz 的带通滤波,50 Hz 工频陷波.




图 3 01T、02T 的实验范式




图 4 03T、04E、05E 的实验范式

4.2 小波基函数的确定以及节点的选择

小波基函数的选择对于脑电信号的特征提取以及分类识别会有一定的影响,脑电数据是通过外部设备采集的离散数据,因此进行小波包变换时,应该选取适用于离散小波变换的,本文通过经验选取了几种常见的离散小波变换的小波基,分别为 haar, db2,db4,sym2,coif3. 然后通过实验进行比较,选取

不同的小波基,分类准确率会有所不同,以此来确定合适的小波基函数. 如下图 5 所示,db4 相比其他几种来说,分类效果具有一定的优势,因此在后续的研究中选取 db4 作为小波基函数.




图 5 小波基函数的选择

本文使用 db4 小波对 MI-EEG 进行分解,数据采样频率为 250 Hz,利用小波包对数据进行第一层分解后得到低频部分(频率范围 0~62.5 Hz)和高频部分(62.5~125 Hz),由于子带成分中包含了多个特征频带,所以要继续分解,以此类推,当分解到第 4 层时,节点(4,1)和 Mu 节律频率范围比较接近,节点(4,2)(4,3)和 Beta 节律频率范围比较接近,根据式(3)重构特定频段的 MI-EEG.

4.3 WPT 对识别结果的对比研究

为了验证 WPT 对于识别结果的影响,基于相同的实验数据,对数据进行分析 and 处理. 本次实验选取四个受试者采集的数据,第 1 个实验直接把原始信号输入到 SPCNN 网络中分类,第 2 个实验把经过 WPT 处理重构好的信号输入到 SPCNN 网络中分类,都采用 Softmax 分类器,做一个对比实验. 图 6 显示了两种方法的分类准确率.




图 6 WPT 对实验结果的影响

从图 6 可以看出,四名受试者的分类准确率都是经过小波包处理的识别效果较好,这是因为没有经过小波包处理的数据含有一些无效的杂乱信息,影响了后续的分类识别,通过小波包变换可以筛选出更加精细的信号,有利于提取更加具有代表性的特征以及提高了分类准确率.

4.4 多种特征提取方法的的对比研究

为了验证本文提出的结合 WPT 和 SPCNN 识别方法的有效性,基于竞赛数据集 BCI competition IV 2b,将本文所提方法与经典的 CSP、CNN、DBN 进行对比分析,分类准确率和 Kappa 值如表 2、3 所示.

从表 2 可以看出,本文所用方法的分类准确率均高于其他经典分类算法.用相同的方法时,对于不同的受试者,分类准确率有较大的差异,这是因为脑电信号具有个体差异性,在提取脑电信号过程中,每个人的心理状态、身体状况等都会对信号的采集产生一定的影响,从而影响到采集的脑电信号的质量,进而对识别效果产生影响.对于相同的数据,本文采用的方法分类准确率大大提高,平均准确率达到了 84.77%,比传统方法最高的 78.28% 提高了 6.49%,分类效果得到了显著提升,证明了本方法的有效性.

表 2 本文方法与其他方法分类准确率对比(%)

受试者	CSP	DBN	CNN	本文方法
第 1 名	66.56	66.56	72.22	83.47
第 2 名	57.81	62.50	61.03	67.62
第 3 名	61.25	60.00	61.11	67.49
第 4 名	94.06	96.87	98.65	99.40
第 5 名	80.63	82.19	86.48	91.42
第 6 名	75.00	77.50	79.17	86.42
第 7 名	72.50	76.56	78.47	84.16
第 8 名	89.38	88.75	86.18	93.04
第 9 名	85.63	85.94	81.25	89.94
平均值	75.86	77.43	78.28	84.77

如表 3 所示,将本文方法与其他方法的 Kappa 值进行比较,本文方法的 Kappa 值均大于其他方法. Kappa 值是评价分类结果一致性和可信度的一种重要指标,这个系数的值越高,则代表模型实现的分类准确率越高.本文方法的平均 Kappa 值达到了 0.70,比其他方法中的最高的 0.56 高出了 0.14,另外,0.70 落在了 0.61~0.80 之间,表明了具有高度的一致性,再次证明了本方法的有效性.

表 3 本文方法与其他方法 Kappa 值对比

受试者	CSP	DBN	CNN	本文方法
第 1 名	0.33	0.33	0.44	0.67
第 2 名	0.16	0.25	0.22	0.35
第 3 名	0.23	0.20	0.22	0.35
第 4 名	0.88	0.94	0.97	0.99
第 5 名	0.61	0.64	0.73	0.83
第 6 名	0.50	0.55	0.58	0.73
第 7 名	0.45	0.53	0.57	0.68
第 8 名	0.79	0.78	0.72	0.86
第 9 名	0.70	0.72	0.63	0.80
平均值	0.52	0.55	0.56	0.70

5 结束语

针对 EEG 非线性、非平稳性的特点,本文提出了结合 WPT 和 SPCNN 的脑电信号识别方法,该方法能够自适应的对采集的 EEG 进行分解与重构,选取与运动想象有紧密连续的时频信号,将信号通过训练好的网络模型中,网络内部自动有效的提取到高效的特征,进行分类识别.实验结果分类准确率以及 Kappa 系数的显著提高,证明了本文方法的有效性.在今后的工作中,可以将这种方法应用于共融机器人中,通过脑机接口系统控制,从而可以准确理解人体行为意图,更自然的匹配执行动作,进一步实现人-机互动协作.

参考文献:

[1] 唐贤伦,李伟,马伟昌,等. 基于条件经验模式分解和串并行 CNN 的脑电信号识别[J]. 电子与信息学报, 2020, 42(4): 1041-1048. DOI: 10.11999/JEIT190124.
TANG X L, LI W, MA W C, et al. Conditional empirical mode decomposition and serial parallel CNN for ElectroEncephaloGram signal recognition[J]. Journal of Electronics & Information Technology, 2020, 42(4): 1041-1048. DOI: 10.11999/JEIT190124.

[2] ZHANG R L, ZONG Q, DOU L Q, et al. Hybrid deep neural network using transfer learning for EEG motor imagery decoding[J]. Biomedical Signal Processing and Control, 2021, 63: 102144. DOI: 10.1016/J.BSPC.2020.102144.

[3] 陈景霞,郑茹,贾小云,等. 共空间模式结合小波包分解的脑电情感分类[J]. 计算机工程与应用, 2019, 55(1): 149-153. DOI: 10.3778/j.issn.1002-8331.1804-0281.

- CHEN J X, ZHENG R, JIA X Y, et al. EEG emotion classification based on common spatial patterns and wavelet packet decomposition[J]. Computer Engineering and Applications, 2019, 55(1): 149-153. DOI: 10.3778/j.issn.1002-8331.1804-0281.
- [4] 李明爱, 张梦, 孙炎珺. 基于小波包和深度信念网络的脑电特征提取方法[J]. 电子测量与仪器学报, 2018, 32(1): 111-118. DOI: 10.13382/j.jemi.2018.01.015.
- LI M A, ZHANG M, SUN Y J. EEG feature extraction method based on wavelet packet and deep belief network[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(1): 111-118. DOI: 10.13382/j.jemi.2018.01.015.
- [5] ZHANG J, YAN C G, GONG X L, et al. Deep convolutional neural network for decoding motor imagery based brain computer interface[C]//Proceedings of the 2017 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). Xiamen: IEEE, 2017: 1-5. DOI: 10.1109/ICSPCC.2017.8242581.
- [6] 程时伟, 周桃春, 唐智川, 等. CNN 实现的运动想象脑电分类及人-机器人交互[J]. 软件学报, 2019, 30(10): 3005-3016. DOI: 10.13328/j.cnki.jos.005782.
- CHENG S W, ZHOU T C, TANG Z C, et al. CNN based motor imagery EEG classification and human-robot interaction[J]. Journal of Software, 2019, 30(10): 3005-3016. DOI: 10.13328/j.cnki.jos.005782.
- [7] DOSE H, MOLLER J S, IVERSEN H K, et al. An end-to-end deep learning approach to MI-EEG signal classification for BCIs[J]. Expert Systems with Applications, 2018, 114: 532-542. DOI: 10.1016/j.eswa.2018.08.031.
- [8] 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. DOI: 10.11897/SP.J.1016.2017.01367.
- TANG Z C, ZHANG K J, LI C, et al. Motor imagery classification based on deep convolutional neural network and its application in exoskeleton controlled by EEG[J]. Chinese Journal of Computers, 2017, 40(6): 1367-1378. DOI: 10.11897/SP.J.1016.2017.01367.
- [9] 孔祥浩, 马琳, 薄洪健, 等. CNN 与 CSP 相结合的脑电特征提取与识别方法研究[J]. 信号处理, 2018, 34(2): 164-173. DOI: 10.16798/j.issn.1003-0530.2018.02.006.
- KONG X H, MA L, BO H J, et al. Research on EEG feature extraction and recognition method based on CNN and CSP[J]. Journal of Signal Processing, 2018, 34(2): 164-173. DOI: 10.16798/j.issn.1003-0530.2018.02.006.

作者简介:

谷学静 女,(1972-),博士,教授.研究方向为虚拟现实,人机交互.

位占锋(通讯作者) 男,(1996-),硕士研究生.研究方向为虚拟现实,脑机接口技术. E-mail:2621685442@qq.com

刘海望 男,(1986-),硕士,讲师.研究方向为虚拟现实,人机交互.

郭俊 男,(1994-),硕士研究生.研究方向为三维建模技术.

沈攀 男,(1995-),硕士研究生.研究方向为手势交互,姿态识别.

(上接第 59 页)

- [13] NGUYEN N H, DOGANCA Y K. Instrumental variable based Kalman filter algorithm for three-dimensional AOA target tracking[J]. IEEE Signal Processing Letters, 2018, 25(10): 1605-1609. DOI: 10.1109/LSP.2018.2869108.
- [14] HENDERSON H V, SEARLE S R. On deriving the inverse of a sum of matrices[J]. Siam Review, 1981, 23(1): 53-60. DOI: 10.1137/1023004.

作者简介:

林杰 男,(1993-),硕士研究生.研究方向为无线电导航定位.

齐望东(通讯作者) 男,(1968-),博士,教授,博士生导师.研究方向为网络安全、导航定位与信号处理. E-mail: wangdongqi@gmail.com.

赵跃新 男,(1992-),博士研究生.研究方向为无线电导航定位.

刘鹏 男,(1981-),博士,副教授.研究方向为无线电导航定位、网络安全.