

改进孪生网络的脑电信号处理方法

杨怀花, 叶庆卫, 罗慧艳, 陆志华

(宁波大学 信息科学与工程学院, 浙江 宁波 315211)

摘要: 针对运动想象脑机接口系统中分类准确率低的问题, 提出一种改进孪生网络的脑电信号分类方法, 把原孪生网络中的两个子网络扩充成 3 个子网络, 并设计了新的学习样本采集方法和距离函数; 脑电信号经过小波变换及经验模态分解, 利用自相关系数筛选得到预处理后的小波分量, 然后随机分割成训练集和测试集, 从训练集中按照新的学习样本采集方法获得学习样本集, 将其输入 3 个权重共享的子网络进行训练, 使用新的距离函数进行相似度的对比, 最后计算测试样本特征与训练集中标签为 1 和标签为 0 样本特征相似度, 选择最高相似度样本标签作为该待测样本的类别; 通过对国际公开 BCI Competition II Data set III 和 The largest SCP data of Motor-Imagery 数据集进行仿真, 此算法分类准确率高达 94.29%; 与现有性能较高的算法进行对比, 其有效的提高了分类准确率, 能更好地进行脑电信号分类识别。

关键词: 运动想象脑电; 小波变换; 自相关系数; 经验模态分解; 孪生网络

EEG Signal Processing Method Based on Improved Siamese Network

YANG Huaihua, YE Qingwei, LUO Huiyan, LU Zhihua

(Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo 315211, China)

Abstract: In order to solve the problem of low classification accuracy in motor imagination brain-computer interface system, an improved EEG signal classification method based on the siamese network was proposed. Two subnetworks in the original siamese network were expanded into three subnetworks, and a new learning sample collection method and the distance function are designed. After wavelet transform and empirical mode decomposition, EEG signals are screened by auto-correlation function threshold to obtain the pre-processed wavelet component. Then it is divided randomly into training set and test set, and the learning sample set is obtained from the training set according to the new learning sample collection method, and the learning sample set is input into three sub-networks with shared weights for training, and the new distance function is used to compare the similarity. Finally, the feature similarity between the test sample features and the samples labeled 1 and 0 in the training set is calculated, and the sample label with the highest similarity is selected as the category of the samples to be tested. Through the simulation of international open BCI Competition II Data Set III and the data set of the largest SCP data of motor-imagery, the classification accuracy of this algorithm is up to 94.29%. Compared with the existing algorithms with higher performance, it effectively improves the classification accuracy and can better classify and recognize eeg. signals.

Keywords: motor imagery electroencephalogram; wavelet transform; autocorrelation coefficient; empirical mode decomposition; siamese network

0 引言

脑机接口 (BCI, brain computer interface) 是一种不依赖大脑外周神经与肌肉组成的正常输出通路, 通过对大脑活动产生的信号进行分析, 提取其中包含的动作意图, 控制外部设备的新型人机交互方式^[1]。脑机接口技术的研究对临床康复^[2]、信息交流^[3]以及休闲娱乐等领域的发展均具有较高的价值。目前, 脑机接口方向的研究众多, 运动想象脑电信号 (MI-EEG, motor imagery electroencephalogram) 作为自发性脑电一直以来受到研究学者的广泛关注。

MI-EEG 信号是一种时变性很强的非平稳信号, 因此如何有效的对其进行特征提取和分类成为了目前研究的重点。

当前脑电信号特征提取的研究主要分为 4 个方面: 时域、频域、时频域以及空间域等, 常见的分析方法主要包括小波变换^[4] (WT, wavelet transform)、希尔伯特黄变换^[5] (HHT, hilbert-huang transform)、公共空间模式^[6-8] (CSP, common spatial pattern)、独立分量分析^[9] (ICA, independent component analysis) 等, 常用的分类方法主要包括线性判别分析^[10] (LDA, linear discriminant analysis)、

收稿日期: 2021-09-08; 修回日期: 2021-11-02。

基金项目: 国家自然科学基金(61071198); 国家自然科学基金(51675286)。

作者简介: 杨怀花 (1995-), 女, 山东临沂人, 硕士研究生, 主要从事信号处理方向的研究。

叶庆卫 (1970-), 男, 浙江衢州人, 博士, 教授, 主要从事信号检测、最优化搜索、视频识别与跟踪方向的研究。

陆志华 (1983-), 男, 浙江金华人, 博士, 副教授, 主要从事信号处理、多运动目标的实时跟踪、统计信号处理算法研究和应用方向的研究。

引用格式: 杨怀花, 叶庆卫, 罗慧艳, 等. 改进孪生网络的脑电信号处理方法[J]. 计算机测量与控制, 2022, 30(3): 211-216.

支持向量机^[11] (SVM, support vector machines)、贝叶斯线性回归^[12]、卷积神经网络^[13] (CNN, convolutional neural networks) 等。由于深度学习的快速发展,神经网络成为了脑电信号识别分类的重要方法。

目前针对运动想象脑机接口系统中分类准确率低等问题,研究者们提出了很多改进方法。文献 [14] 提出了一种基于滑动窗口信息极大化原则 (Infomax, information maximization) 算法的动态独立分量分析方法。文献 [15] 提出了一种优化多球面支持向量数据 (SVDD, support vector data description) 的模糊聚类方法,并通过多个运动想象数据集的实验,完成了对运动想象脑电信号数据的较好的表达。文献 [16] 提出一种新的基于沃尔什哈达玛变换的特征提取方法,将提取的特征通过人工神经网络进行分类,得到较为准确的结果。文献 [17] 提出将从脑电信号中提取的时间、频率和位置信息,组合成 2D 信息输入到卷积神经网络 (CNN, convolutional neural network) 和堆栈自编码器 (SAE, stacked auto encoder) 结合的深度网络,得到较高的分类准确率。

基于以上的研究内容,本文提出一种 3 个权重共享子网络构成的改进孪生网络,将经小波变换结合经验模态分解预处理后的信号输入此网络,实现对脑电信号的特征提取和分类。通过对两个数据集的仿真,相比现有算法均取得更好的分类准确率,表明此方法能更好的应用到 MI-EEG 信号的分类识别,并具有一定普遍性。

1 算法原理

1.1 孪生网络改进原理

经典孪生神经网络由两个子网络构成,这两个子网络之间结构相同,并且共享权重和偏置等参数。若样本 (x_1, x_2) 和标签 y 输入孪生神经网络,其中输入样本类别相同标签 y 为 1,相反标签为 0,通过权重共享的子网络提取样本的低维特征,计算特征的距离度量样本相似度。代价函数为对比损失函数公式如下:

$$L(w, (y, x_1, x_2)) = yD_w^2 + (1 - y)\max(m - D_w, 0)^2 \quad (1)$$

其中: D_w 为输入样本经过孪生神经网络提取的低维特征之间的欧式距离,公式为 $D_w(x_1, x_2) = \|f(x_1) - f(x_2)\|$, $f(x_1), f(x_2)$ 分别表示样本 x_1, x_2 经过神经网络映射出的低维特征, y 为样本标签, \max 表示最大值, m 为设定的阈值。

表 1 网络结构

网络层	节点数	激活函数
隐藏层 1	256	relu
隐藏层 2	128	relu
隐藏层 3	64	relu
隐藏层 4	128	relu
输出层	64	sigmoid

本文提出一种 3 个权重共享的子网络孪生系统如图 1 所示,其主要包括两部分:特征提取和相似度计算。在特征提取部分,本文选取 5 层的全连接神经网络。表 1 是网络结构的详细说明。为了防止过拟合现象,每层全连接层后使用 dropout 函数。对于大部分数据来说, ReLu 激活函数具有更好的拟合能力。因此隐藏层选取非线性的 Relu 作为激活函数,输出层则使用 sigmoid 激活函数,使得结果介于 0 到 1。

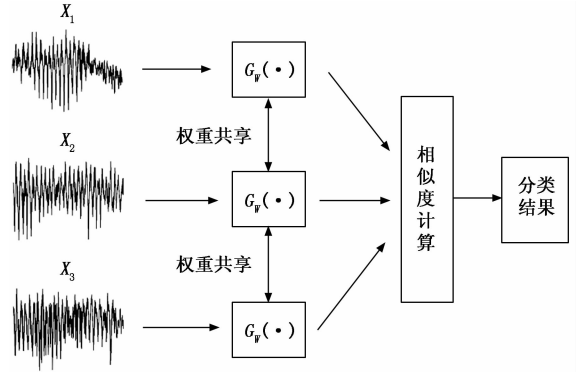


图 1 改进孪生网络框架

当输入脑电信号样本组合 x_1, x_2, x_3 时,通过 3 个共享权值的子网络提取低维特征,计算样本特征之间的平均距离来表示样本之间的差异,最后利用这个距离进行相似度判断。本文提出一种新的距离函数,如公式 2 所示:

$$D_w(x_1, x_2, x_3) = \frac{\|f(x_1) - f(x_2)\| + f(x_1) - f(x_3)}{2} \quad (2)$$

其中: x_1 和 x_2, x_3 为输入的样本序列, $f(x_1), f(x_2)$ 和 $f(x_3)$ 为经过神经网络提取的低维特征, $D_w(x_1, x_2, x_3)$ 为特征之间的平均距离,采用公式 (1) 作为损失函数进行训练。此距离函数消除了样本因随机选取产生的偶然性误差,使分类系统更加稳定,一定程度的提高了分类的准确度。

1.2 学习样本集采样算法

设预处理后的训练集为 $\mathbf{X}_{train}, \mathbf{Y}_{train}$, 其中 \mathbf{X}_{train} 为预处理后的小波分量训练集信号, \mathbf{Y}_{train} 为训练集样本标签。

1) 根据样本标签 \mathbf{Y}_{train} , 将信号集 \mathbf{X}_{train} 分为负训练样本集 $\mathbf{X}_{train}^{(0)}$ 和正训练样本集 $\mathbf{X}_{train}^{(1)}$;

2) 定义一个学习样本组 $(x_{v1}^{(i)}, x_{v2}^{(i)}, x_{v3}^{(i)}, g^{(i)})$ 为第 i 个学习样本组; 其中 $x_{v1}^{(i)}$ 为在 \mathbf{X}_{train} 中随机抽取的一条信号, 记为 $x_{v1}^{(i)} \in \mathbf{X}_{train}$; $x_{v2}^{(i)}, x_{v3}^{(i)}$ 为在 $\mathbf{X}_{train}^{(0)}$ 中随机抽取两条信号或者在 $\mathbf{X}_{train}^{(1)}$ 中随机抽取两条信号, 若 $x_{v2}^{(i)}, x_{v3}^{(i)}$ 为在 $\mathbf{X}_{train}^{(0)}$ 中随机抽取的两条信号, 记为 $x_{v2}^{(i)}, x_{v3}^{(i)} \in \mathbf{X}_{train}^{(0)}$, 若 $x_{v2}^{(i)}, x_{v3}^{(i)}$ 为在 $\mathbf{X}_{train}^{(1)}$ 中随机抽取两条信号, 记为 $x_{v2}^{(i)}, x_{v3}^{(i)} \in \mathbf{X}_{train}^{(1)}$ 。从而确定第 i 个学习样本组标签 $g^{(i)}$, 其公式为:

$$g^{(i)} = \begin{cases} 1, & y_{v1}^{(i)} = y_{v2}^{(i)} \\ 0, & y_{v1}^{(i)} \neq y_{v2}^{(i)} \end{cases} \quad (3)$$

其中: $y_{v1}^{(i)}$ 为样本 $x_{v1}^{(i)}$ 的标签, $y_{v2}^{(i)}$ 为样本 $x_{v2}^{(i)}$ 的标签。

3) 令 $i = 1, \dots, n$, 因此可以得到包含 n 个样本组的学习样本集。

1.3 测试集样本采集

设预处理后的测试集为 \mathbf{X}_{test} 、 \mathbf{Y}_{test} , 其中: \mathbf{X}_{test} 为预处理后的小波分量测试信号集, \mathbf{Y}_{test} 为测试集样本标签。

1) 定义 $(x_{te1}^{(i)}, x_{tr0_2}^{(s)}, x_{tr1_3}^{(s)}, 1^{(i)})$ 为第 i 个测试样本 $x_{te1}^{(i)}$ 的第 s 个正测试样本组, 其中 $x_{tr1_2}^{(s)}, x_{tr1_3}^{(s)}$ 为在 $\mathbf{X}_{\text{train}}^{(1)}$ 中随机抽取两条信号。

2) 定义 $(x_{te1}^{(i)}, x_{tr0_2}^{(s)}, x_{tr0_3}^{(s)}, 0^{(i)})$ 为第 i 个测试样本 $x_{te1}^{(i)}$ 的第 s 个负测试样本组, 其中 $x_{tr0_2}^{(s)}, x_{tr0_3}^{(s)}$ 为在 $\mathbf{X}_{\text{train}}^{(0)}$ 中随机抽取两条信号。

3) 令 $s = 1, \dots, M$, 因此可以得到测试样本 $x_{te1}^{(i)}$ 含 M 个样本组的正负测试样本集。将正负测试集分别代入训练好的模型, 得到正负测试集的平均距离, 分别记为 $L_{te1}^{(i)}, L_{te0}^{(i)}$ 。因此得到测试样本 $x_{te1}^{(i)}$ 的预测标签:

$$t^{(i)} = \begin{cases} 1, & L_{te1}^{(i)} \leq L_{te0}^{(i)} \\ 0, & L_{te1}^{(i)} > L_{te0}^{(i)} \end{cases} \quad (4)$$

4) 令 $i = 1, \dots, l$, 其中 l 为预测样本长度。即依次对测试集 \mathbf{X}_{test} 中所有样本进行上述操作, 可得到 \mathbf{X}_{test} 的预测标签。

1.4 信号预处理过程

脑电信号是一种非线性、非平稳的信号, 小波变换是在一种时频域分析方法, 更好的分析和处理了非平稳信号, 早在 1996 年就被应用于运动想象脑电信号的去噪处理。对信号 $x(t)$ 进行分解, 其离散小波函数表示为:

$$W_{j,k} = \int_R x(t) \bar{\psi}_{j,k}(t) dt \quad (5)$$

其中: $\psi_{j,k}(t)$ 为基本小波。

由于脑电信号的电压普遍在 μV 量级, 这一特点导致 EEG 信号极易受到眼动、肌电、高频噪声等干扰。因眼动干扰处于低频段并与脑电信号重叠, 使得其去除较为复杂, 而肌电和噪声则处于高频段。若将噪声相关的频段直接去除, 则会导致一部分重要信息丢失, 因此本文选取小波分量的最低频段和最高频段进行经验模态分解 (EMD, empirical mode decomposition), 通过自相关函数将 EEG 信号与噪声信号尽可能进行分离。

EMD 分解是一种非线性滤波器, 将信号分解为若干个 IMF, 其中 IMF 需要满足以下两个条件:

- 1) 整个数据中, 极值点和过零点数目相等或最多相差为 1。
- 2) 在任意一点, 由局部极大值定义的包络和由局部极小值定义的包络的均值等于 0。

自相关函数选取的是脑电自身信号与时延后的信号之间的相似度, 其表达式为:

$$\text{covx} = \frac{\text{Cov}(x(t), x(t - \Delta\tau))}{\sqrt{\text{var}(x(t))} \sqrt{\text{var}(x(t - \Delta\tau))}} \quad (6)$$

其中: $x(t)$ 为原始运动想象脑电信号, $\Delta\tau$ 为延时长度,

Cov 表示协方差, var 则为方差。干扰噪声一般表现为低频、高幅度, 因此对于含噪声成分较高的 IMF 分量, 自相关函数较高。而脑电信号具有随机性较强、时变复杂等特点, 因此其值较低。通过设定自相关阈值, 筛选出脑电信号相关的 IMFs 分量进行重构, 得到“纯净”的小波系数。

1.5 总体算法流程

算法流程如图 2 所示, 主要步骤为:

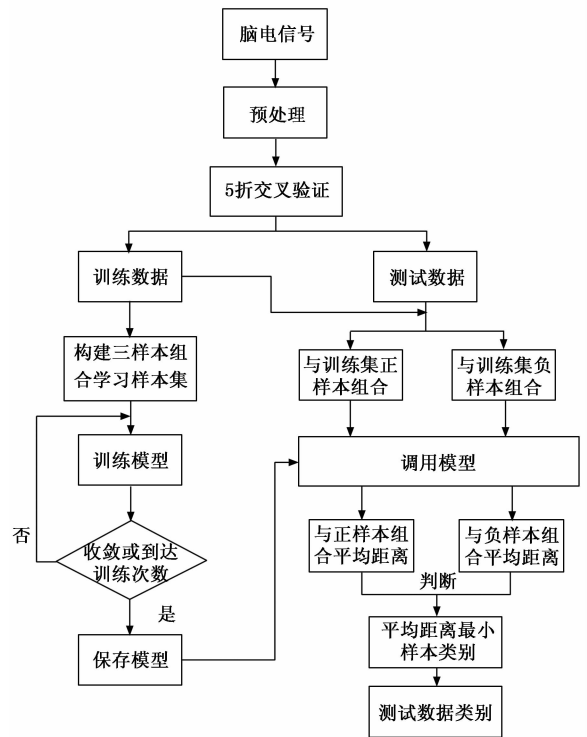


图 2 算法流程

1) 将脑电信号进行预处理, 然后经过 5 折交叉验证法将信号集分成训练数据和测试数据。

2) 根据 1.2 节学习样本集采样算法构建三样本组合学习样本集, 将其作为三权值共享的孪生神经网络的输入, 根据对比损失函数, 利用全连接神经网络更新权值和偏置等参数。当模型收敛或者到达设定次数时, 模型训练结束, 保存模型。

3) 在测试过程中, 根据 1.3 节依次对所有测试样本构造正负测试样本集, 对比正负测试样本集平均距离, 选择最小平均距离 (即相似度最高) 所对应的类别作为该待测样本的类别号。

2 实验仿真与分析

2.1 实验数据

本文提出的方法得到来自 The largest SCP data of Motor-Imagery 和 BCI Competition II Data set III 两个数据集的验证, 接下来对其进行介绍。

数据集 1 来自公开标准数据集 BCI Competition II Data set III, 该组数据是通过年龄为 25 岁的健康女性进行想象

左右手实验获得的。本实验共进行了 7 组，每组 40 次，共进行了 280 次试验。每一次试验持续时间为 9 秒，在 0~2 秒时为休息时间；在第 2 秒时进行语音提示；第 3 秒开始屏幕上出现一个箭头，同时要求受试者进行相应的运动想象。数据的采集电极放置在国际标准的 10~20 导联系统 c_3 、 c_2 、 c_4 位置，其中采样频率为 128 Hz。实施示意图如图 3 所示。




图 3 实施示意图

数据集 2 来自 2018 年提出的国际标准脑电信号数据库 The largest SCP data of Motor-Imagery 中的 CLA 左右手运动想象数据集，此数据集是由 7 名健康受试者 (S1~S7) 面对图形用户界面 (eGUI) 的相应提示执行左手、右手运动想象。数据的采集电极放置符合 10~20 导联标准，每组数据包含 21 个通道的 EEG 信号，采样频率为 200 Hz。实验过程中，图形用户界面上显示一个左右手两类刺激信号，动作信号在屏幕上保持 1 秒，同时受试者执行了一次相应的心理意象，随后暂停 1.5~2.5 s 后结束单次试验，每段记录持续 50~55 分钟。对于 7 名实验对象采集的数据信息如表 2 所示。

表 2 数据集信息

实验对象	采集次数	样本个数
S1	1	642
S2	3	1 908
S3	3	1 907
S4	1	635
S5	3	1 904
S6	3	2 253
S7	3	1 848

2.2 预处理过程

图 4 分别为数据集 1 左右手运动想象时通道 c_3 、 c_2 、 c_4 的平均能量。由图 (a) 可知， c_2 通道的左右手想象运动能量几乎没有区别，由图 (b) 和图 (c) 可知 c_3 、 c_4 通道 3.5~9 时间段的平均能量差别较大，因此本文选取 3.5~9 时间段的 c_3 、 c_4 通道脑电信号进行小波变换。

在进行小波变换时，小波基^[18-19]和自相关系数阈值的选取对脑电信号的处理影响较大。本文通过选取部分小波基用于离散小波变换，分别为 demey、db2、sym3、haar，经过多次实验对比，发现选取 demey 小波基分类准确率更高，稳定性更强。相关系数阈值是一个重要的参数，其值直接影响了伪迹与脑电信号的分离，在保持其他条件不变的情况下，采用不同阈值得到分类准确率。经过多次试验当阈值等于 0.9 时，正确率高达 90% 以上，因此本文选取

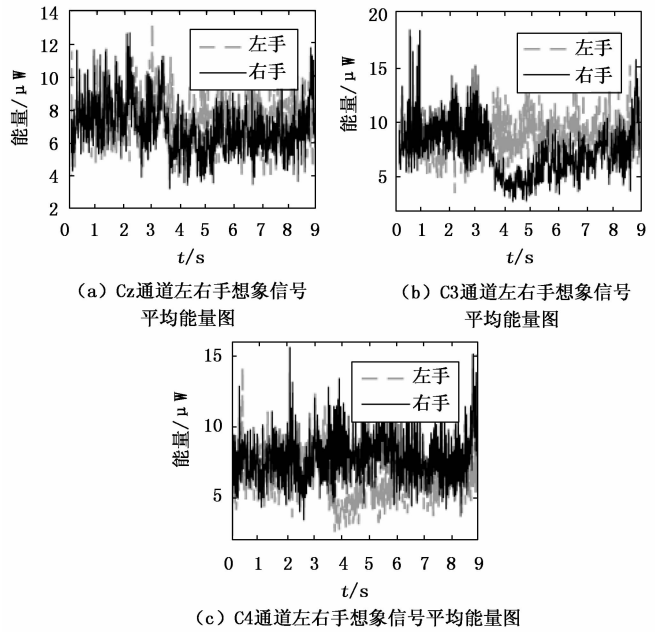


图 4 各通道的信号平均能量图

0.9 为相关函数阈值。

数据集 1 选取脑电信号样本 3.5~9 时间段的 C_3 、 C_4 通道脑电信号分别进行 4 层小波变换，其中选用 demey 为小波基，然后对小波分量的低频部分 A_4 和高频段 D_1 进行经验模态分解，将 IMF_s 分量的自相关函数值小于 0.9 的进行重构，得到“干净”的小波分量，然后将各个通道的小波分量进行串接。

数据集 2 对 21 通道脑电信号进行 5 层小波变换，其中选用 demey 为小波基，然后对小波分量的低频部分 A_4 和高频段 D_1 进行经验模态分解，将 IMF_s 分量的自相关函数值小于 0.9 的进行重构，得到“干净”的小波分量，然后将各个通道的小波分量进行串接。

2.3 评价指标

分类精准度被用来直接衡量信号分类的准确率，其公式为：

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

其中：TP 和 TN 为左右手想象信号正确识别样本数量，FP 和 FN 为左右手想象信号错误识别样本数量。

Kappa 值是一个信号分类一致性的评价指标，其公式为：

$$kappa = \frac{p_0 - p_e}{1 - p_e} \quad (8)$$

其中： p_0 是总的分类正确率。对于二分类而言，每一类实际样本数为 r_1 、 r_2 ，则每一个类别中预测样本个数 p_1 、 p_2 ， p_e 则为：

$$p_e = \frac{r_1 \times p_1 + r_2 \times p_2}{n \times n} \quad (9)$$

2.4 实验结果

下面运用数据集 1，对脑电信号进行预处理后，分别通

过经典孪生神经网络和改进后的孪生神经网络进行脑电信号特征提取和分类, 同时得到两种方法在测试集上的分类混淆矩阵如图 5 所示。由图 5 可知, 改进孪生网络在左右手想象信号相比经典孪生网络均具有更好的可分性, 测试集上的识别精度更高。




图 5 经典和改进后孪生网络混淆矩阵

将本文的算法与目前性能较高的现有算法进行对比, 其中用到对比算法主要有文献 [14] 中基于滑动窗口 Info-max 算法的动态独立分量分析方法, 记为 ICA, 文献 [15] 使用 AR 算法和优化多球面支持向量数据的模糊聚类方法相结合的方法, 记为 AR-SVDD。文献 [16] 中基于快速沃尔什哈达玛变换的特征提取方法, 并结合 ANN 分类器进行分类, 记为 FWHT-ANN。文献 [17] 中 CNN 结合 SAE 提出的一个新的深度网络, 记为 CNN-SAE 算法。文献 [20] 提出的 Renyi 熵特征提取方法, 结合 BLDS 分类器对信号进行处理, 记为 Renyi-BLDA。将经过小波变换结合经验模态分解预处理后的信号, 输入经典孪生神经网络进行特征提取和分类的方法, 记为 WT_emd_siamese。分类结果如表 3 所示。

表 3 不同特征提取算法的分类正确率

算法	分类正确率/%
ICA ^[12]	87.14
AR-SVDD ^[13]	89.29
FWHT-ANN ^[14]	88.87
CNN-SAE ^[15]	90.00
Renyi-BLDA ^[16]	81.23
WT_emd_siamese(经典孪生网络)	87.50
本文算法	94.29

从表 3 可知, 本文算法分类准确率均高于其他算法,

其准确率提高了 4.29~13.06%, 表明所提算法能更好地实现脑电信号处理。WT_emd_siamese 算法分类正确率到达 87.50%, 进一步证明了小波变换、经验模态分解结合孪生网络方法的可行性, 这为运动想象脑电信号处理提供了一种新思路。

2.5 算法在不同数据集的进一步验证

为了进一步验证算法的有效性, 对数据集 2 进行测试, 并采用目前较为常用并取得较好结果的 csp 算法结合 svm 分类器办法进行基准验证, 结果如表 4 所示。由结果可知, 此方法平均分类正确率高达 90.36%, 相对 csp_svm 分类性能提升了 12.5%, 且最高达到 97.43%, 去除数据集 S2 和 S6 实验对象, 平均分类准确率高达 94.30%, 进一步证明了此算法在脑电信号识别方面具有较好性能。此外, 本文提出算法 kappa 值高达 0.907, 其具有较好的一致性, 分类结果可靠。

表 4 数据集 2 所有受试者分类正确率

MI	本文算法	Csp_svm/%
S1	94.86	82.87
S2	81.08	65.46
S3	97.43	83.22
S4	89.13	76.38
S5	94.12	85.29
S6	79.97	63.01
S7	95.94	88.80
平均正确率	90.36	77.86
除 S2、S6 外平均正确率	94.30	83.31
除 S2、S6 外 Kappa	0.907	0.733

图 6 显示了在数据集 2 上两种算法测量的总分类混淆矩阵, 如图 6 中数据显示, 本文所提出的算法, 相比 csp_




图 6 混淆矩阵

svm 脑电信号处理办法,无论在左手还是右手识别中精确度都得到极大地提升,其中左手识别精度到达 96.7%,这也证明了本文算法在运动想象任务中发挥着积极地作用。

3 结束语

本文提出一种 3 个权重系数共享子网络构成的改进孪生网络脑电信号的分类方法。通过小波变换结合经验模态分解,对信号进行预处理,然后将预处理的小波分量通过改进的孪生神经网络系统进行特征提取和分类。将改进后的孪生网络与经典孪生网络相比,利用新的距离函数消除了偶然误差性,提高了分类正确率,使分类系统更加稳定,同时在特征提取部分选择简单的全连接神经网络,在保证分类性能的同时,极大地降低了系统的复杂性。通过对 BCI Competition II Data set III 数据集进行仿真,本文提出的算法取得了 94.29% 的分类准确率,与现有的研究结果进行对比,可以更有效地进行运动想象脑电信号的分类。利用 The largest SCP data of Motor-Imagery 数据集进一步验证,结果表明本文提出的方法在相同的数据类型下依旧保持优异的性能。因此在接下来的研究过程中,可将此方法应用到其他类型的脑电信号分析,这为脑电信号处理提供了一种新思路。

参考文献:

- [1] DONG C, LOY C C, HE K, et al. Image Super-Resolution Using Deep Convolutional Networks [J]. *IEEE transactions on pattern analysis and machine intelligence*, 2016, 38 (2): 295 - 307.
- [2] KAI KA, GUAN C. Brain-Computer Interface for Neurorehabilitation of Upper Limb After Stroke [J]. *Proceedings of the IEEE*, 2015, 103 (6): 944 - 953.
- [3] CORRALEJO R, NICOLÁS LF, ALVAREZ D, et al. A P300 - based brain - computer interface aimed at operating electronic devices at home for severely disabled people [J]. *Medical & Biological Engineering & Computing*, 2014, 52 (10): 861 - 872.
- [4] 徐宝国, 宋爱国. 基于小波包变换和聚类分析的脑电信号识别方法 [J]. *仪器仪表学报*, 2009, 30 (1): 25 - 28.
- [5] TAMBURRO G, FIEDLER P, STONE D, et al. A new ICA-based fingerprint method for the automatic removal of physiological artifacts from EEG recordings [J]. *PeerJ*, 2018, 6 (5): 1 - 35.
- [6] PARKH J, KIM J, MIN B, et al. Motor imagery EEG classification with optimal subset of wavelet based common spatial pattern and kernel extreme learning machine [C] // 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2017: 2863 - 2866.
- [7] MAHMOOD A, ZAINAB R, AHMAD R B, et al. Classification of multi-class motor imagery EEG using four band common spatial pattern [C] // 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2017: 1034 - 1037.
- [8] 曾庆山, 范明莉, 宋庆祥. 基于 CSP 与卷积神经网络算法的多类运动想象脑电信号分类 [J]. *科学技术与工程*, 2017, 17 (27): 144 - 149.
- [9] 吴孙勇, 潘福标, 邓凯文. 基于希尔伯特-黄变换的小鼠脑电信号相关性分析 [J]. *科学技术与工程*, 2018, 18 (31): 126 - 132.
- [10] IBRAHIM W, ABADDEH. M S Protein fold recognition using Deep Kernelized Extreme Learning Machine and linear discriminant analysis [J]. *Neural Computing and Applications*, 2019, 31 (8): 4201 - 4214.
- [11] ZHENG W F, XU F Z, SHU M L, et al. Classification of motor imagery electrocorticogram signals for brain-computer interface [C] // 9th International IEEE/EMBS Conference on Neural Engineering, 2019: 530 - 533.
- [12] SINGH VP, KUMAR P. Naïve bayes classifier for word sense disambiguation of Punjabi language [J]. *Malaysian Journal of Computer Science*, 2018, 31 (3): 188 - 199.
- [13] 陈景霞, 王丽艳, 贾小云, 等. 基于深度卷积神经网络的脑电信号情感识别 [J]. *计算机工程与应用*, 2019, 55 (18): 103 - 110.
- [14] GUO X J, WU X P. Motor imagery EEG classification based on dynamic ICA mixing matrix [C] // 2010 4th International Conference on Bioinformatics and Biomedical Engineering. New York: IEEE Press, 2010: 1 - 4.
- [15] NGUYEN P, TRAN D, LE T, et al. Multi-sphere support vector data description for brain-computer interface [C] // 2012 Fourth International Conference on Communications and Electronics (ICCE). New York: IEEE Press, 2012: 318 - 321.
- [16] SAKA K, AYDEMIR Ö, ÖZTÜRK M. Classification of EEG signals recorded during right/ left hand movement imagery using fast Walsh Hadamard transform based features [C] // 2016 39th International Conference on Telecommunications and Signal Processing (TSP). New York: IEEE Press, 2016: 413 - 416.
- [17] TABAR YR, HALICI U. A novel deep learning approach for classification of EEG motor imagery signals [J]. *Journal of Neural Engineering*, 2017, 14 (1): 1 - 11.
- [18] 魏宝琴, 白萍. 优小波基的选取原则 [J]. *甘肃科技*, 2007, 23 (10): 42 - 43.
- [19] 张恒, 潘仲明. 平稳小波去噪算法中的参数选择 [J]. *国防科技大学学报*, 2019, 41 (4): 165 - 170.
- [20] CHEA-YAU KEE, Ponnambalam S G, Chu-Kiong Loo. Binary and multi-class motor imagery using Renyi entropy for feature extraction [J]. *Neural Computing and Applications*, 2017, 28 (8): 2051 - 2062.