

基于K近邻的运动想象分类中的噪声效益

陈佳卉,王友国,翟其清

(南京邮电大学理学院,江苏南京 210023)

摘要:关于脑电信号中的噪声处理问题一直是脑-机接口(BCI)领域的重点研究方向,通常认为噪声是有害的,所以针对脑电信号中的噪声处理往往以降噪或消噪为主。但是根据随机共振(SR)的思想,在非线性系统中噪声往往能增强信号处理,而脑电信号恰好具有非线性的特征,因此提出运用高斯噪声提高运动想象脑电信号的识别率。通过在脑电信号中加入独立的高斯噪声,将原始训练集与添加噪声的训练集串联起来增加训练样本量,考虑训练样本量增加与否和噪声加入的阶段(训练或/和测试);通过共空间模式(CSP)和小波包变换(WPT)提取分类特征,并用K近邻(KNN)算法进行分类。实验结果表明,只要加入适当强度的噪声,均可提高系统的分类准确率,出现随机共振现象;增加训练样本量的同时在训练集和测试集中加入适当强度相同的噪声,系统最大平均分类准确率相比不加噪声时增加9.28个百分点;K近邻算法的最大平均分类准确率相比决策树(DT)和支持向量机(SVM)而言整体更高,体现出K近邻算法的优越性和可靠性。

关键词:随机共振;高斯噪声;K近邻;运动想象;脑电信号

中图分类号:TP18

文献标识码:A

文章编号:1673-629X(2022)01-0079-06

doi:10.3969/j.issn.1673-629X.2022.01.014

Noise Benefits in Motor Imagery Classification Using K-nearest neighbor

CHEN Jia-hui, WANG You-guo, ZHAI Qi-qing

(School of Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: The problem of noise processing in EEG signal has always been a key research direction in the field of brain-computer interface (BCI), and it is usually considered that noise is harmful, so the noise processing in EEG signal often focus on noise reduction or cancellation. However, according to the principle of stochastic resonance (SR), noise can enhance signal processing in nonlinear systems, and EEG signals have nonlinear characteristics. Therefore, Gaussian noise is used to improve the recognition rate of motor imagery EEG signals. Adding independent Gaussian noise to EEG signals, the original training set connects with the noise-added training set to increase the training sample size. Considering whether training sample size increases or not and the stage of noise addition (training or/and testing). The classification features are extracted by common spatial pattern (CSP) and wavelet packet transform (WPT), and classified by K-nearest neighbor (KNN). The experimental results show that the accuracy of classification system can be improved and appear stochastic resonance as long as add the appropriate noise intensity. When increasing the training sample size and adding the appropriate noise of the same intensity to the training set and test set, the maximum average classification accuracy of system is 9.28 percentage points higher than that without noise. The maximum average classification accuracy of K-nearest neighbor is higher than that of decision tree (DT) and support vector machine (SVM), which reflects the superiority and reliability of K-nearest neighbor.

Key words: stochastic resonance; Gaussian noise; K-nearest neighbor; motor imagery; EEG signal

0 引言

运动想象(Motor Imagery, MI)是脑机接口(Brain Computer Interface, BCI)范式的任务之一,其脑电活动在想象运动前和期间都会发生变化^[1]。基于运动想象的脑机接口研究主要集中在对运动想象任务上的区

分,如想象左手、右手、舌头和双脚的运动。近年来,研究者们利用各种机器学习算法来提高运动想象的性能,如K近邻(K-Nearest Neighbor, KNN)、支持向量机(Support Vector Machine, SVM)、决策树(Decision Tree, DT)、线性判别分析(Linear

收稿日期:2021-02-08

修回日期:2021-06-10

基金项目:国家自然科学基金资助项目(62071248);江苏省研究生科研创新计划(KYCX20_0730)

作者简介:陈佳卉(1996-),女,研究生,研究方向为信号与信息处理;王友国,博导,教授,研究方向为随机共振理论与研究、信息理论及应用、编码理论及应用。

Discriminant Analysis, LDA) 和人工神经网络 (Artificial Neural Network, ANN) 等都取得了良好的分类性能^[2-6]。运动想象的特征提取也是提高分类准确率的必要条件,经典的特征提取算法主要分为以下几类:时域方法主要通过提取脑电信号的波形特征,如小波包变换 (Wavelet Packet Transform, WPT)^[7];频域方法最常见的是功率谱分析 (Power Spectral Density, PSD)^[8],根据脑电信号的 ERD 和 ERS 现象出现的特定频率范围来提取特征;空域方法是近年来运动想象领域常用的特征提取方法,主要通过空域滤波器对脑电信号的通道空间分布进行处理,共空间模式 (Common Spatial Pattern, CSP) 是最经典的空域方法^[9];此外,基于脑电信号的非线性和节律性,可以利用模糊熵 (Fuzzy Entropy, FuzzyEn) 算法进行脑电信号特征提取分析^[10]。好的特征提取算法与合适的机器学习算法相结合可以获得更好的分类效果。

目前的研究中,在脑电信号的预处理阶段,通常会采用一些方法进行信号降噪或去噪,虽然这样做能提高信号分辨率,但是也会损失部分信息。然而在非线性系统中,噪声效益或随机共振 (Stochastic Resonance, SR) 是一种比较普遍的现象,加入一定强度的噪声可以增强微弱信号的处理^[11-13]。因此,该文将随机共振思想与运动想象脑电信号识别相结合,探讨了高斯噪声如何提高二分类运动想象任务 (左手和右手) 的分类准确率。利用 K 近邻探讨噪声在运动想象分类中的作用,在原始脑电信号中加入独立的高斯噪声,考虑训练样本量增加与否和噪声加入的阶段 (训练或/和测试),提出了 5 种加噪情况。K 近邻使用文献 [14] 提出的共空间模式和小波包变换相结合的方法所提取的特征作为分类特征。在 BCI competition II 数据集 III 上测试该系统。实验结果表明,加入适当强度的噪声和增加训练样本量可以提高分类准确率,K 近邻算法在分类效果上整体优于决策树和支持向量机。

1 算法基本原理

1.1 小波包变换

利用小波包算法对运动想象脑电信号进行分析,可以对脑电信号按照低频段和高频段两类进行频带划分,在分解中,低频带中失去的信息由高频带捕获。小波包算法包括小波包分解和重构两个部分。

小波包分解算法:

$$\begin{cases} d_{i,j,2m} = \sum_k h(k-2i)d_{k,j+1,m} \\ d_{i,j,2m+1} = \sum_k g(k-2i)d_{k,j+1,m} \end{cases} \quad (1)$$

小波包重构算法:

$$\begin{aligned} d_{i,j+1,m} = & \sum_k h(i-2k)d_{i,j,2m} + \\ & \sum_k g(i-2k)d_{i,j,2m+1} \end{aligned} \quad (2)$$

式中, $d_{i,j,m}$ 表示第 j 层第 m 个节点的第 i 个小波包系数; $h(k)$ 、 $g(k)$ 为多分辨率分析中正交镜像滤波器的低通和高通滤波器系数^[15]。

1.2 共空间模式

CSP 主要应用于二分类任务下的空域特征提取算法,针对左右手运动想象脑电信号,经过 CSP 处理后增加了两类信号的差别,使得左右手信号达到区别最大化。

设 X_1 和 X_2 为运动想象左手和右手脑电信号矩阵,维数均为 $N \times T$, N 为脑电通道数, T 为单个通道的采样点数,则归一化协方差矩阵 R_1 和 R_2 为:

$$R_i = \frac{X_i X_i^T}{\text{tr}(X_i X_i^T)} \quad (i=1,2) \quad (3)$$

式中, X_i^T 为 X_i 的转置, tr 表示矩阵的秩。

$$R = \bar{R}_1 + \bar{R}_2 \quad (4)$$

式中, \bar{R}_1 和 \bar{R}_2 为平均协方差矩阵。因为 R 是正定矩阵,用奇异值分解定理进行特征分解:

$$R = U \Lambda U^T \quad (5)$$

式中, U 是特征向量矩阵, Λ 是特征值对角阵,对特征值进行降序排列,求得白化矩阵:

$$\begin{cases} P = \Lambda^{-\frac{1}{2}} U^T \\ S_1 = P R_1 P^T \\ S_2 = P R_2 P^T \end{cases} \quad (6)$$

对 S_1 和 S_2 进行主分量分解:

$$\begin{cases} S_1 = B \Lambda_1 B^T \\ S_2 = B \Lambda_2 B^T \end{cases} \quad (7)$$

由此得到投影矩阵即空间滤波器 W :

$$W = B^T P \quad (8)$$

对于信号 X_L 和 X_R 经过 W 滤波得到特征 Z_L 和 Z_R :

$$\begin{cases} Z_L = W \times X_L \\ Z_R = W \times X_R \end{cases} \quad (9)$$

特征向量 f_L 和 f_R 为:

$$\begin{cases} f_L = \frac{\text{var}(Z_L)}{\sum (\text{var}(Z_L))} \\ f_R = \frac{\text{var}(Z_R)}{\sum (\text{var}(Z_R))} \end{cases} \quad (10)$$

1.3 K 近邻

KNN 是一种典型的监督学习方法,该研究利用 KNN 解决非线性分类问题。KNN 训练阶段使用经过特征提取之后的训练集脑电信号 A^r 和相应类别标签

$\{y_i\}_{i=1}^N$, 其中 N 是训练集中脑电信号的数量。

根据欧氏距离公式:

$$L_2(x_i, x_j) = \sqrt{\sum_{l=1}^n |x_i^{(l)} - x_j^{(l)}|^2} \quad (11)$$

在测试阶段对输入的脑电信号 B^{\sim} , 在训练集中找到与其最邻近的 k 个脑电信号, 涵盖这 k 个脑电信号的 A^{\sim} 的邻域记作 $N_k(A^{\sim})$; 在 $N_k(A^{\sim})$ 中根据少数服从多数的分类规则决定 B^{\sim} 的类别 y (左或右)。

2 加噪脑电信号的运动想象分类系统

图 1 呈现了基于加噪脑电信号的运动想象分类系统, 该系统分为训练阶段和测试阶段。类似文献 [16], 通过将原始训练集与添加噪声的训练集串联起来来修改训练集。考虑到训练样本量的增加可能会掩盖单纯的向原始脑电信号中加入噪声所产生的噪声效益, 所以要分别考虑这两种情况下的噪声效益。在训练或测试过程中, 在特征提取之前向脑电信号中加入独立的高斯噪声。




图 1 运动想象分类系统

3 仿真实验

3.1 实验数据

实验使用的是 BCI Competition II (2003) 数据库中的 EEG 数据集 III。实验对象为 25 岁健康女性。实验共 7 组, 每组 40 次, 共 280 次, 所有实验都在同一天进行。如图 2 所示, 每次实验时长 9 秒; 实验对象 0~2 秒为放松状态; 2 秒时, 提示音指示实验开始, 显示器屏幕出现 1 秒的交叉图案“+”, 实验对象准备运动想象; 3~9 秒, 显示器屏幕显示一个向左或向右的箭头, 实验对象按照箭头方向想象左、右手的运动。所有实验数据都在 C3、Cz、C4 三个通道和 128 Hz 采样率下得到, 脑电信号频率 0~64 Hz。最终 280 次实验被随机分为 140 个训练样本和 140 个测试样本。




图 2 左右手运动想象过程

3.2 特征提取

图 3 呈现了通道位置和脑电信号特征提取与融合过程。脑电信号数据处理所选取的时间段在 4 秒到 7 秒, 选取的通道为 C3、C4^[17]。小波包变换使用 bior3.3 小波基对脑电信号进行 3 层小波包分解, 考虑到与运动想象 ERD 现象极为相关的 μ 节律 (8~12 Hz) 和 β 节律 (18~22 Hz), 所以选取 (3, 1)、(3, 2) 对应的频带进行系数重构, 并计算这 2 个频带的小波包系数的 L-2 范数, 提取 4 个特征向量; 使用共空间模式滤波脑电信号使左右手脑电信号样本间的距离最大化, 提取 4 个特征向量。因此, 每个脑电信号的特征由 4 个小波包特征和 4 个共空间特征组成, KNN 使用这 8 个特征进行分类。

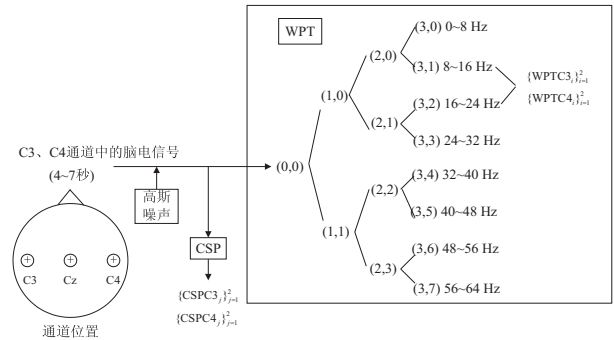


图 3 通道位置和特征提取与融合

3.3 加噪过程

该文使用 BCI Competition II 数据集 III 来测试分类系统, 其中训练集和测试集分别包含 140 个运动想象脑电信号 (70 个左侧运动信号和 70 个右侧运动信号)。在原始脑电信号中加入相互独立的高斯噪声 n , 噪声强度 σ (标准差) 范围 0.000 1~0.3。

记训练集为 A , 则 $A = \{a_i\} = \{a_1, a_2, \dots, a_{140}\}$; 记加噪训练集为 A' , 则 $A' = \{a_i + n_i\} = \{a_1 + n_{1,1}, a_2 + n_{1,2}, \dots, a_{140} + n_{1,140}\}$; 当重复加噪过程时, 记加噪训练集为 A_m , 则 $A_m = \{a_i + n_{m,i}\} = \{a_1 + n_{m,1}, a_2 + n_{m,2}, \dots, a_{140} + n_{m,140}\}$, 其中 $m (m = 1, 2, \dots, n, n \in N^*)$ 。重复加噪过程 9 次, 则 $m = 1, 2, \dots, 9$; 每次加入相互独立的高斯噪声, 则:

$$\begin{aligned} A_1 &= \{a_i + n_{1,i}\} = \\ &\quad \{a_1 + n_{1,1}, a_2 + n_{1,2}, \dots, a_{140} + n_{1,140}\} \\ A_2 &= \{a_i + n_{2,i}\} = \\ &\quad \{a_1 + n_{2,1}, a_2 + n_{2,2}, \dots, a_{140} + n_{2,140}\} \\ &\dots \\ A_9 &= \{a_i + n_{9,i}\} = \\ &\quad \{a_1 + n_{9,1}, a_2 + n_{9,2}, \dots, a_{140} + n_{9,140}\} \end{aligned}$$

然后将原始训练集 (不加噪声) 与加噪训练集串联起来, 可以起到增加训练样本量的效果, 此时的训练

样本量为 $(m + 1) \times 140$ 。

训练集串联 1 组:

$$G_1 = A \cup A_1 = \{a_1, \dots, a_{140}, a_1 + n_{1,1}, \dots, a_{140} + n_{1,140}\}$$

训练集串联 2 组:

$$G_2 = A \cup A_1 \cup A_2 = \{a_1, \dots, a_{140}, a_1 + n_{1,1}, \dots, a_{140} + n_{1,140}, a_1 + n_{2,1}, \dots, a_{140} + n_{2,140}\}$$

.....

训练集串联 9 组:

$$G_9 = A \cup A_1 \cup \dots \cup A_9 =$$

$$\{a_1, \dots, a_{140}, a_1 + n_{1,1}, \dots, a_{140} + n_{1,140}, \dots, a_1 + n_{9,1}, \dots, a_{140} + n_{9,140}\}$$

记测试集为 B , 则 $B = \{b_i\} = \{b_1, b_2, \dots, b_{140}\}$; 记加噪测试集为 B' , 则 $B' = \{b_i + n_i\} = \{b_1 + n_1, b_2 + n_2, \dots, b_{140} + n_{140}\}$ 。

将实验分为对照组和实验组, KNN 使用经过 CSP 和 WPT 特征提取之后的脑电信号数据集进行训练, 具体的噪声加入情况如表 1 所示。

表 1 脑电信号加噪情况

对照组	Case0	(原始脑电信号数据)训练集、测试集均不加入噪声
	Case1	(不增加训练样本量)只在训练集加入噪声
	Case2	(增加训练样本量)只在训练集加入噪声
实验组	Case3	只在测试集中加入噪声
	Case4	(不增加训练样本量)训练集和测试集均加入强度相同的噪声
	Case5	(增加训练样本量)训练集和测试集均加入强度相同的噪声

4 结果与讨论

KNN 中 k 值的选择会对分类结果产生影响, 一般来说 k 是不大于 20 的整数^[18], 所以该文取 $k = 1, 2, \dots, 20$, 查看 KNN 在测试集上相应的分类准确率 P , P 用正确分类输出数量 T 与测试集总数 140 的比率来表示。由图 4 可知, 当 $k = 5$ 时, 取得最高分类准确率 $P_{\max} = 79.29\%$ 。因此对于实验组中的加噪信号数据,

k 值依然取 5; 由于高斯噪声是随机产生的, 考虑到分类准确率可能随着每次实验加入高斯噪声而产生变化, 所以重复实验 10 次, 得出平均分类准确率 \bar{P} 。

$$P = \frac{T}{140} \times 100\% \tag{12}$$

$$\bar{P} = \frac{1}{10} \sum_{i=1}^{10} P_i \tag{13}$$




图 4 原始脑电信号中 k 值对 KNN 分类准确率的影响

图 5 呈现了五种加噪情况下 KNN 对加噪脑电信号的平均分类准确率的变化趋势, 噪声强度 σ 从 0.000 1 到 0.3。当原始脑电信号中加入适当强度的噪声时, 五种加噪情况下 KNN 的 \bar{P} 都会提高, 但是当

噪声强度过大时, \bar{P} 降低。

图 5 中五条线都呈现出先上升后下降的趋势, 并在一定的噪声强度时达到最高平均分类准确率, 出现了随机共振现象。




图 5 五种加噪情况下的 KNN 平均分类准确率

为了进一步验证实验的可靠性,该文在 KNN 分类的基础上,在相同的实验环境下,用 DT 和 SVM 分类器做进一步证明,结果如表 2 所示,三种方法的分类

结果均出现随机共振现象,KNN 分类器的分类结果整体优于 SVM 和 DT。

表 2 KNN、DT、SVM 的 \bar{P}_{max} 对比

	Case0	Case1	Case2	Case3	Case4	Case5
KNN	79.29%	85.71% (0.077 7)	87.14% (5 组 0.094 7)	80.71% (0.041 3)	86.43% (0.037 3)	88.57% (8 组 0.097 3)
SVM	80.71%	82.86% (0.017 7, 0.027 1)	85.00% (6 组 0.041 1)	84.29% (0.019 9)	85.00% (0.098 9)	87.86% (1 组 0.077 7)
DT	78.57%	80.71% (0.036 9)	86.43% (8 组 0.063 3)	82.14% (0.026 7,0.066 1)	85.00% (0.043 5)	87.14% (5 组 0.059 5)

以 KNN 为例分析五种不同的加噪情况下的最高平均分类准确率,其中 Case1 - \bar{P}_{max} = 85.71% ($\sigma \approx 0.077 7$), Case2 - \bar{P}_{max} = 87.14% ($\sigma \approx 0.094 7$, 训练集串联 5 组), Case3 - \bar{P}_{max} = 80.71% ($\sigma \approx 0.041 3$), Case4 - \bar{P}_{max} = 86.43% ($\sigma \approx 0.037 3$), Case5 - \bar{P}_{max} = 88.57% ($\sigma \approx 0.097 3$, 训练集串联 8 组),均高于对照组 Case0 - $P = 79.29%$,以上事实表明串联适当的加噪训练集数目或加入适当强度的噪声,可以提高 KNN 的分类准确率。

Case1 - \bar{P}_{max} 、Case3 - \bar{P}_{max} 和 Case4 - \bar{P}_{max} 相比于 Case0 - P 表明在不增加训练样本量的情况下,无论是在训练集还是测试集或是两者中均加入适当强度的噪声,都可以提高 KNN 的分类准确率,三者相较于 Case0 - P 分别增加 6.42 个百分点、1.42 个百分点、7.14 个百分点。

Case1 - \bar{P}_{max} 相比于 Case2 - \bar{P}_{max} , Case4 - \bar{P}_{max} 相比于 Case5 - \bar{P}_{max} 都表明在增加训练样本量的情况下,即训练集串联适当的加噪训练集数目,同时加入适当强

度的噪声,可以进一步提高 KNN 的分类准确率,其中 Case2 - \bar{P}_{max} 相较于 Case1 - \bar{P}_{max} 增加 1.43 个百分点, Case5 - \bar{P}_{max} 相较于 Case4 - \bar{P}_{max} 增加 2.14 个百分点。

Case1 - \bar{P}_{max} 相比于 Case4 - \bar{P}_{max} , Case2 - \bar{P}_{max} 相比于 Case5 - \bar{P}_{max} 都表明与只在训练集中加入噪声而言,在训练集和测试集中均加入适当强度相同的噪声,也可以进一步提高 KNN 的分类准确率,其中 Case4 - \bar{P}_{max} 相较于 Case1 - \bar{P}_{max} 增加 0.72 个百分点, Case5 - \bar{P}_{max} 相较于 Case2 - \bar{P}_{max} 增加 1.43 个百分点。

最后,得出在增加训练样本量即训练集串联适当的加噪训练集数目的情况下,并且在训练集和测试集中加入适当强度相同的噪声,即 Case5 时 KNN 的分类效果最好,最大平均分类准确率 ($\sigma \approx 0.097 3$, 训练集串联 8 组) 相较于 Case0 的最大分类准确率增加 9.28 个百分点。上述分析和结论对 DT 和 SVM 的分类结果同样适用,说明出现该随机共振现象不是偶然;并且 KNN 在 Case5 时的最大平均分类准确率高于 DT 和 SVM,相较于 Case0 的最大分类准确率的增加幅度也

最大,体现了 KNN 分类器的稳定性和优越性。

5 结束语

该文所提出的系统的分类准确率取决于高斯噪声强度和训练样本量。在原始脑电信号数据集中加入适当强度的高斯噪声可以提高系统的分类准确率,增加训练样本量可以进一步提高 K 系统的分类准确率,并且增加训练样本量的同时在训练集和测试集中加入适当强度相同的噪声系统可以获得最高的分类准确率。由于加入的噪声为高斯噪声,对于其他非高斯噪声,如均匀噪声、柯西噪声等,将来可以进一步探究它们在这五种加噪情况下是否会出现相同的随机共振现象。

参考文献:

- [1] SANEI S, CHAMBERS J A. EEG signal processing[J]. Computational Intelligence & Neuroscience, 2007, 2007(2): 1178-1181.
- [2] 储有兵,费胜巍,范 晔. 基于 WT-SVD-SVM 和 WT-SVD-KNN 的运动想象脑电信号特征提取及分类[J]. 东华大学学报:自然科学版, 2019, 45(6): 881-887.
- [3] 徐 欣,王 娜. 四类运动想象脑电信号的特征提取与分类[J]. 南京邮电大学学报:自然科学版, 2017, 37(6): 18-22.
- [4] 林 福,关 山. 基于 SJ-GDA 和 DT-KNN 的人工智能多类运动设计与研究[J]. 机械设计, 2020, 37(7): 110-115.
- [5] FU R, HAN M, TIAN Y, et al. Improvement motor imagery EEG classification based on sparse common spatial pattern and regularized discriminant analysis[J]. Journal of Neuroscience Methods, 2020, 343: 108833.
- [6] 刘颖轲. 基于人工神经网络的运动想象脑电信号分类研究[D]. 哈尔滨:哈尔滨工业大学, 2019.
- [7] 蔡 森,胡 萍. 基于小波包变换的右手和脚运动想象任务分类[J]. 中国医疗器械杂志, 2017, 41(3): 177-180.
- [8] KIM Chungsong, SUN Jinwei, LIU Dan, et al. An effective feature extraction method by power spectral density of EEG signal for 2-class motor imagery-based BCI[J]. Medical & Biological Engineering & Computing, 2018, 56(9): 1645-1658.
- [9] 段锁林,李 伟,潘礼正. 基于小波-共空间模式的脑电信号特征提取[J]. 现代电子技术, 2018, 41(23): 53-57.
- [10] 张学军,万东胜,孙知信. 基于 LMD 和模糊熵融合 CSP 的脑电信号特征提取方法[J]. 仪器仪表学报, 2020, 41(8): 226-234.
- [11] ZHAI Qiqing, WANG Youguo. Optimal and suboptimal noises enhancing mutual information in threshold system[J]. Fluctuation and Noise Letters, 2016, 15(2): 1650015.
- [12] OSOBA O, KOSKO B. The noisy expectation-maximization algorithm for multiplicative noise injection[J]. Fluctuation and Noise Letters, 2016, 15(1): 1650007.
- [13] AUDHKHASI K, OSOBA O, KOSKO B. Noise-enhanced convolutional neural networks[J]. Neural Networks, 2016, 78: 15-23.
- [14] 高 枫,鲁 昊,高 诺. 基于小波包和共同空间模型的运动想象脑电信号特征提取算法[J]. 生物医学工程研究, 2019, 38(4): 393-396.
- [15] 刘丽格,李天保,石鑫刚. 一种板间高速传输系统的设计与实现[J]. 无线通信技术, 2011, 37(4): 53-55.
- [16] SAMPANNA R, MITAIM S. Noise benefits in motor imagery classification using ensemble support vector machine [C]//IEEE biomedical circuits and systems conference. Lausanne, Switzerland: IEEE, 2014: 53-56.
- [17] 陆振宇,陆旭峰,杨瑞洪,等. 基于多特征融合的运动想象脑电信号分类研究[J]. 现代计算机, 2019(3): 3-7.
- [18] 哈林顿. 机器学习实战[M]. 北京:人民邮电出版社, 2013.