

控制与决策

Control and Decision

基于改进深度森林的运动想象脑电分类方法

李红利, 郭伟, 张荣华, 修春波, 马欣

引用本文:

李红利, 郭伟, 张荣华, 修春波, 马欣. 基于改进深度森林的运动想象脑电分类方法[J]. *控制与决策*, 2023, 38(2): 468–474.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.0101>

您可能感兴趣的其他文章

Articles you may be interested in

基于脑电多特征融合的癫痫发作预测方法

A seizure prediction method based on EEG multi-feature fusion

控制与决策. 2023, 38(1): 161–170 <https://doi.org/10.13195/j.kzyjc.2021.0400>

基于增强深度特征和TSK模糊分类器的癫痫脑电信号识别

TSK fuzzy classifier based on enhanced deep feature for epilepsy EEG signal recognition

控制与决策. 2023, 38(1): 171–180 <https://doi.org/10.13195/j.kzyjc.2021.1031>

基于改进量子粒子群的K-means聚类算法及其应用

K-means clustering algorithm based on improved quantum particle swarm optimization and its application

控制与决策. 2022, 37(4): 839–850 <https://doi.org/10.13195/j.kzyjc.2020.1302>

人脸性别约束下的深度随机森林表情识别

Facial expression recognition using deep random forest under gender constraints

控制与决策. 2021, 36(7): 1693–1698 <https://doi.org/10.13195/j.kzyjc.2019.1703>

基于无标签、不均衡、初值不确定数据的设备健康评估方法

Equipment health risk assessment based on unlabeled, unbalanced data under uncertain initial condition

控制与决策. 2020, 35(11): 2687–2695 <https://doi.org/10.13195/j.kzyjc.2018.1493>

基于改进深度森林的运动想象脑电分类方法

李红利^{1†}, 郭伟¹, 张荣华², 修春波¹, 马欣³

(1. 天津工业大学 控制科学与工程学院, 天津 300387; 2. 天津工业大学 人工智能学院, 天津 300387;
3. 天津工业大学 电子与信息工程学院, 天津 300387)

摘要: 基于运动想象的脑电信号是用户在执行不同运动想象任务时采集到的不同脑区的电信号. 受到用户的大脑结构和头皮状态等因素影响, 采集到的运动想象任务信号之间混乱, 从而导致大量信号被错分. 鉴于此, 提出一种基于改进深度森林的运动想象任务信号分类方法. 首先, 利用变长粒子群算法强大的寻优能力, 为深度森林中每一层的随机森林和完全随机森林预测的类概率值搜寻最优权重; 然后, 将此权重赋予对应的类概率值, 以此实现对结果修正目的; 最后, 利用 BCI 竞赛 IV 的数据集 2a 评估所提出方法的有效性. 实验结果表明, 相比传统的深度森林, 该方法对四分类运动想象脑电信号实现了更高的分类准确率. 所提出方法根据分类器预测的结果进行学习, 对于提升分类器性能的研究具有重要意义.

关键词: 运动想象; 深度森林; 变长粒子群优化; 修正策略; 分类识别

中图分类号: TH79; TN911.7; R318

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.0101

开放科学(资源服务)标识码(OSID):



引用格式: 李红利, 郭伟, 张荣华, 等. 基于改进深度森林的运动想象脑电分类方法[J]. 控制与决策, 2023, 38(2): 468-474.

Classification method of motor imagery EEG based on improved deep forest

LI Hong-li^{1†}, GUO Wei¹, ZHANG Rong-hua², XIU Chun-bo¹, MA Xin³

(1. School of Control Science and Engineering, Tiangong University, Tianjin 300387, China; 2. School of Artificial Intelligence, Tiangong University, Tianjin 300387, China; 3. School of Electronic and Information Engineering, Tiangong University, Tianjin 300387, China)

Abstract: EEG signals based on motor imagery are electrical signals acquired from different brain regions when subjects perform different motor imagery tasks. Influenced by the factors such as the difference of brain structures and scalp states of different subjects, the acquired signals of different motor imagery tasks are usually confused, which will result in the misclassifications for a large number of motor imagery signals. A classification algorithm for motor imagery tasks based on improved deep forest is proposed. Firstly, the powerful optimization ability of the variable-length particle swarm algorithm is adopted to search for the optimal weights for probability values of each class predicted by the random forest and completely random forest in the deep forest. Secondly, the weights are assigned to the corresponding class probability values, so as to realize the purpose of the result correction. Finally, the data set 2a of BCI competition IV is adopted to evaluate the efficacy of the proposed algorithm. The results show that the proposed algorithm achieves a higher classification accuracy for the four classes of motor imagery signals in comparison with the traditional deep forest. The proposed algorithm can learn from the predicted results of the classifier, which is of great significance for the improvement of the classifier performance.

Keywords: motor imagery; deep forest; variable-length particle swarm optimization; correction strategy; classification recognition

0 引言

脑机接口 (brain-computer interface, BCI) 将人或动物大脑的电信号作为一个信号发生源与外部设备

进行连接, 从而实现人机交互的模式^[1]. 此电信号是通过外界或自发因素在大脑中产生的反应. 这种模式在医学领域得到了广泛应用, 不仅可以使功能障碍患

收稿日期: 2021-01-18; 录用日期: 2021-12-09.

基金项目: 国家自然科学基金项目 (62071328); 天津市技术创新引导专项基金项目 (21YDTPJC00540, 21YDTPJC00550).

责任编辑: 彭木根.

[†]通讯作者. E-mail: lihongliln@163.com.

者实现与环境交流的能力,还可以有效地恢复其受损的神经,从而改善功能障碍患者的生活质量^[2]。

运动想象(motor imagery, MI)是所有BCI范式中的一个重要实验范式。MI被定义为当人在没有实际运动的情况下,通过想象自己的肌肉或肢体运动的认知过程。由于MI特殊的性质,基于MI的BCI(MI-BCI)系统广泛应用于中风康复、轮椅或假肢的控制和娱乐应用等。尽管MI-BCI系统潜力无限,但仍很少在实验室外使用。主要原因是BCI经常无法正确识别用户的MI命令。据调查,15%~30%的用户似乎无法控制MI-BCI系统。如在两类MI-BCI中,6.7%的受试者分类正确率不足59%^[3]。因此,一个具有学习能力的分类器至关重要,以适应不同用户的状态。

近年来,在BCI系统中,深度学习逐渐应用于模式分类阶段^[4-6]。然而,有太多超参数的深度神经网络使其结构过于复杂,且需要大量的数据集训练网络模型,否则模型会陷入过拟合和局部最优。为了充分利用深度神经网络多层学习的优势,一种新的决策树集成方法深度森林(deep forest, DF)模型被提出。该模型同时结合了集成学习与深度学习的思想,有效避免了过拟合和超参数多的问题。

对于DF而言,每个实例均会通过所有级联层,导致CPU运行时间和内存显著增加。为此,Pang等^[7]引入置信度筛选机制实现对DF的改进。置信度筛选在每个级联层将实例分为易于预测和难以预测的子集,难以预测的子集会进入下一个级联层预测,而易于预测的子集在当前层预测。这样很大程度地减少了DF的内存需求和计算时间。Utkin等^[8]使用自适应的置信度筛选机制为DF模型中每个层的实例自适应加权,在当前层,此模型为错误分类的实例赋更大的值,为正确分类的实例赋更小的值,正确分类的实例便不会进入下一层,从而简化训练过程。Dong等^[9]提出了两种加权策略,第一种加权策略是根据森林的分类性能为其赋予相应的权重;另一种加权策略使用了排序优化方法。由于滑动窗口的不同特征向量对分类结果的影响不同,给DF的不同滑动窗口分配权重,以此捕获更多复杂和多样的特征。Zhu等^[10]提出的加权DF模型中包含加权类向量和预测类向量,其中加权类向量由 k 折交叉验证后的 $k-1$ 个加权类向量取平均后生成,预测类向量由Softmax函数为随机森林分配的权重生成。DF模型将当前级联层的输出与原始特征进行拼接作为下一个级联层的输入,即增强特征。大多数改进的DF模型仅考虑将权重分配给决策树、随机森林或训练实例,而没有从提升增强特征的

价值出发,改善DF的性能。

本文提出一种基于变步长粒子群的改进深度森林(VLPSO-WDF)模型,用于解决运动想象脑电信号(motor imagery-electroencephalography, MI-EEG)分类的问题。此模型根据DF中每一层的随机森林和完全随机森林的预测结果使用具有强大寻优能力的变长粒子群算法为其搜索权重,并将此权重赋予对应的预测结果,以此实现对结果修正的目的。传统DF模型由若干级联层组成,当前级联层的输出与原始特征拼接作为下一个级联层的输入,即增强特征。所提出赋权策略可使下一层得到更有价值的增强特征,从而有效地提高传统DF模型对MI-EEG数据分类的性能。所提出的策略可以推广至其他分类模型上,从而提高模型的性能。

1 数据结构与特征提取

1.1 数据结构

实验数据源于BCI Competition IV 2a组竞赛数据^[11]。该数据集在MI-BCI领域中广泛应用^[12-14],可对所提出方案的性能进行直观的评价。该数据集包含了9个受试者的MI-EEG数据。每个受试者的MI-EEG数据通过执行4种不同的MI任务得到,即执行左手(类1)、右手(类2)、双脚(类3)和舌头(类4)的MI。对于不同的受试者,每次实验采集22个通道的MI-EEG数据,共获得288组训练集和288组测试集。MI-EEG信号频率分布在8~30Hz,因此,选择在8~30Hz之间对受试者的数据进行带通滤波。

1.2 特征提取

共空间模式(common spatial pattern, CSP)用于特征提取阶段。CSP通过构建一种空间滤波器,使得不同类别的EEG信号在空间中表现出最大化的差异。在空间滤波器的构建中,需要分别计算两个不同类别的协方差矩阵,通过对协方差矩阵的对角化设计最优化的空间滤波器。

CSP广泛运用于脑电信号的特征提取^[15-16],四分类的MI-EEG信号通常采取“一对一”的特征提取方法^[17]。对于提取脑电信号的特征,CSP表现出良好的性能。因此,本文使用CSP算法提取脑电信号的特征。

2 研究方法

2.1 深度森林

深度森林算法的重要特性是级联森林。级联森林采用级联方式连接各层,并且每层均由随机森林和完全随机森林组成。图1为级联森林的结构,其中森林1为随机森林,森林2为完全随机森林。由图1可见,

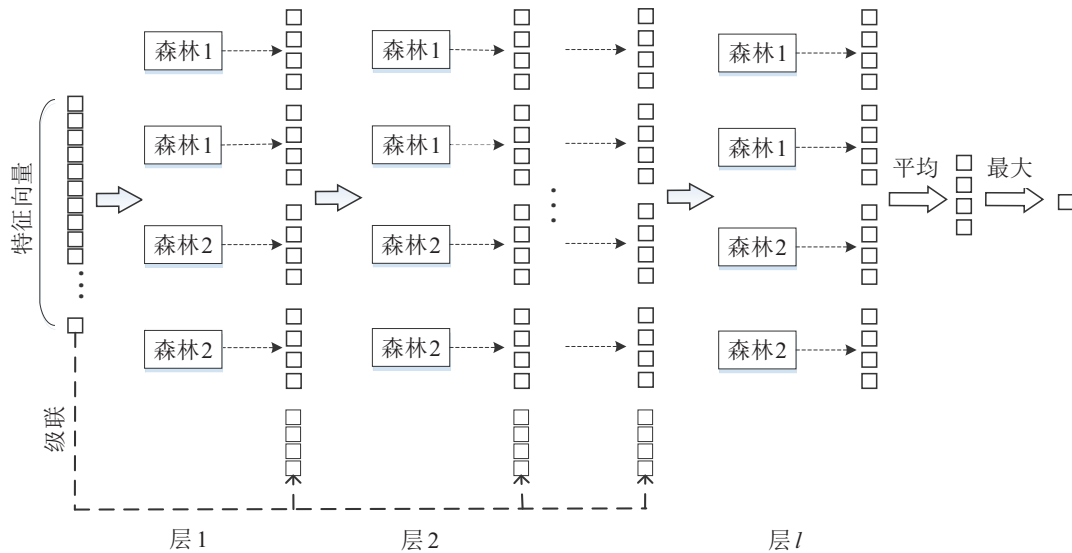


图1 深度森林结构

级联层中的每个森林均会对实例的特征输出一个4维的类别概率向量,且将当前级联层的输出与原始特征拼接作为下一个级联层的输入.当到达最后一层时,对各森林输出的类别概率向量取平均,最大类概率值对应的类别标签为最终的预测结果.这种思想类似于堆叠方法^[18].与堆叠方法相比,DF的每层均同时使用了原始特征和上一层的输出信息,这意味着特征向量会被不断增强.

对于随机森林和完全随机森林而言,每棵树均会对实例的特征产生一个类别概率向量,然后对同一森林中所有的树产生的类别概率向量取平均,以此生成一个对实例所属类别的分布估计值.

2.2 变长粒子群

粒子群 (particle swarm optimization, PSO) 是一种基于随机优化技术的算法.受到鸟群搜寻食物时聚集性社会行为的启发, Venter 等^[19] 提出了 PSO 算法. PSO 由若干相同大小的无质量的粒子组成,且每个粒子代表一个候选的解决方案.

在实际应用中,这些粒子往往会由于其相同的大小产生早熟收敛和局部搜寻能力差的问题.基于此,本文选择了变长粒子群 (variable-length pso, VLPSO) 算法^[20-21] 实现寻优的问题. VLPSO 提升了种群在搜索空间中的多样性. VLPSO 是在 PSO 的基础上提出来的,根据不同大小的粒子,将搜索空间集中在更小且更有效的区域,从而避免粒子掉入局部最优.

VLPSO 算法由若干粒子组成,每个粒子代表一个候选解,通过粒子间相互学习找到一个最优解. VLPSO 的每个粒子均由一个位置向量 p_i 和一个速度向量 v_i 表示,其中 i 为种群中第 i 个粒子.粒子的

速度决定粒子移动的快慢,位置决定移动的方向.粒子记录着搜寻到的历史最佳向量 $P_i^*(t)$,并与其他粒子共享而得到全局最佳向量 $P_g^*(t)$.

VLPSO 使用种群划分策略将整个种群划分在特定数量的区中.有

$$DivSize = \frac{PopSize}{NbrDiv}, \tag{1}$$

$$ParLen_v = MaxLen \frac{v}{NbrDiv}. \tag{2}$$

其中:每个区中的粒子数 (DivSize) 可通过种群大小 (PopSize) 和区的数量 (NbrDiv) 计算得到,如式 (1) 所示;第 v 个区中粒子的长度 (ParLen_v) 由式 (2) 得到,MaxLen 为所有粒子中的最大尺寸.

由于同一个区中粒子的长度相同,相同长度粒子的速度 v_i 和位置 p_i 更新遵循下式,即

$$v_i(t+1) = wv_i(t) + c_1r_1(P_i^*(t) - P_i(t)) + c_2r_2(P_g^*(t) - P_i(t)), \tag{3}$$

$$p_i(t+1) = p(t) + v_i(t+1). \tag{4}$$

其中: w 为粒子运动的惯性权重; c_1 和 c_2 分别为自我识别成分系数和社会成分系数且均为正常数; r_1 和 r_2 为 $[0, 1]$ 区间内均匀分布的随机数,用于维持种群多样性.而不同长度的粒子则需定义新的更新策略.

2.3 改进深度森林算法

对于那些难以区分的特征信号,分类模型很难对其作出决策.因此,需要找到一个可以对分类结果进行自适应调节的模型.本文考虑将权重分配给 DF 中每个随机森林和完全随机森林预测的类概率值,此权重在森林预测后的基础上通过 VLPSO 算法学习得到,以修正 DF 模型中森林预测的差异.本文将此算法称为 VLPSO-WDF,其结构如图2所示.

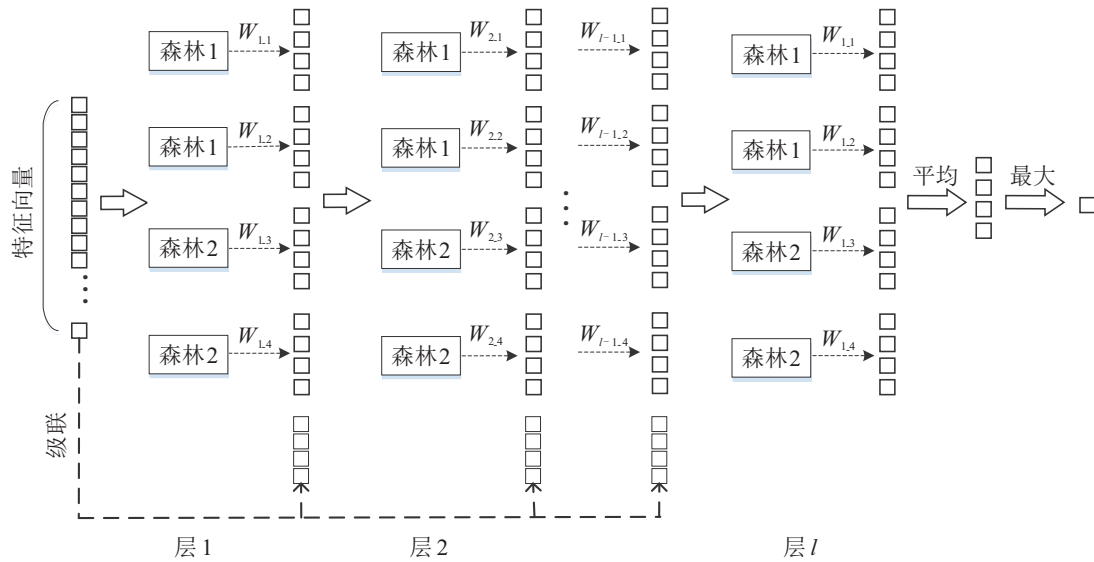


图2 VLPSO-WDF结构

对于VLPSO而言,每个粒子代表一个DF模型的权重配置.表示DF中每一层分类器的权重配置以二维实数矩阵 p_j 编码,DF模型权重配置以粒子实数矩阵 P_i 编码,有

$$p_j = \begin{bmatrix} w_{1,1} & \dots & w_{1,N} \\ \vdots & \ddots & \vdots \\ w_{L,1} & \dots & w_{L,N} \end{bmatrix}, j = 1, 2, \dots, l; \quad (5)$$

$$P_i = [p_1, p_2, \dots, p_l]^T. \quad (6)$$

其中: L 为每一层中随机森林的个数; N 为实例的类别数量; l 为DF的级联层数; $(w_{m-1}, \dots, w_{m-N})$ 为级联层中第 m 个随机森林预测的 N 个类别概率值的修正权重值, $m = 1, 2, \dots, L$.

实验开始,进入初始化阶段.根据式(1)将粒子划分在不同的区中,并根据式(2)设定区中粒子的长度.初始化所有区中粒子的信息,此时不同区中粒子的长度不同.为了降低过拟合风险,实例通过 k 折交叉验证生成训练数据和测试数据,并由DF中第 i 层的所有随机森林产生类概率矩阵 c_i ,生成的类概率矩阵与二维实数矩阵 p_j 的结构相同.初始化后的二维实数矩阵 p_j 通过式(7)为类概率矩阵 c_i 的概率值赋权.生成的赋权类概率矩阵 h 与原始特征连接作为级联中下一级的增强特征.有

$$h = p_j * c_i, \quad (7)$$

其中“*”为 p_j 与 c_i 的hadamard积.

初始化过程结束后进入优化过程.VLPSO中的粒子具有不同的长度,PSO中相同长度粒子的更新方程(3)和(4)不适用于不同长度的粒子.因此,需要定义新的更新策略,以处理不同长度的粒子实数矩阵.

在优化之前,种群中的每个粒子与全局最佳粒子进行比较,从而观察第 i 个粒子的实数矩阵 $P_i(t)$ 与全局最佳粒子实数矩阵 $P_g^*(t)$ 的大小是否存在差异.若 $P_i(t)$ 与 $P_g^*(t)$ 的大小相同,则根据式(3)和(4)进行粒子更新;若 $P_i(t)$ 的大小与 $P_g^*(t)$ 的大小存在差异,则需要为粒子定义新的更新策略,具体如下.

1)若 $P_i(t)$ 的行数(row_i)大于全局最佳粒子 $P_g^*(t)$ 的行数(row_g),则从 $P_i(t)$ 中随机选取 row_g 行构成 $P_i'(t)$,从 $v_i(t)$ 和局部最优解 $P_i^*(t)$ 中选取相应的 row_g 行构成 $v_i'(t)$ 和 $P_i^{*'}(t)$,分别为

$$P_i'(t) = P_i(t) \begin{pmatrix} \text{row}_g \\ \text{row}_i \end{pmatrix}, \quad (8)$$

$$v_i'(t) = v_i(t) \begin{pmatrix} \text{row}_g \\ \text{row}_i \end{pmatrix}, \quad (9)$$

$$P_i^{*'}(t) = P_i^*(t) \begin{pmatrix} \text{row}_g \\ \text{row}_i \end{pmatrix}. \quad (10)$$

$P_i(t)$ 、 $v_i(t)$ 和 $P_i^*(t)$ 选取 row_g 行后剩余的部分分别表示为 $\bar{P}_i'(t)$ 、 $\bar{v}_i'(t)$ 和 $\bar{P}_i^{*'}(t)$.因此,第 i 个粒子 $P_i(t)$ 分为两部分进行更新,即分别对 $P_i'(t)$ 和 $\bar{P}_i'(t)$ 更新,如下式所示:

$$v_i'(t+1) = wv_i'(t) + c_1r_1(P_i^{*'}(t) - P_i'(t)) + c_2r_2(P_g^*(t) - P_i'(t)),$$

$$P_i'(t+1) = P_i'(t) + v_i'(t+1), \quad (11)$$

$$\bar{v}_i'(t+1) = w\bar{v}_i'(t) + c_1r_1(\bar{P}_i^{*'}(t) - \bar{P}_i'(t)),$$

$$\bar{P}_i'(t+1) = \bar{P}_i'(t) + \bar{v}_i'(t+1). \quad (12)$$

$P_i'(t+1)$ 和 $\bar{P}_i'(t+1)$ 更新后按照更新前在 $P_i(t)$ 中的位置组合为 $P_i(t+1)$. $v_i'(t+1)$ 和 $\bar{v}_i'(t+1)$ 也同样组合为 $v_i(t+1)$.

2)若 row_i 小于 row_g ,则从 $P_g^*(t)$ 中随机选取 row_i

行构成 $P_g^*(t)$, 即

$$P_g^*(t) = P_g^*(t) \left(\frac{\text{row}_i}{\text{row}_g} \right), \quad (13)$$

$P_i(t)$ 的更新如下式所示:

$$v_i(t+1) = wv_i(t) + c_1r_1(P_i^*(t) - P_i(t)) + c_2r_2(P_g^*(t) - P_i(t)),$$

$$P_i(t+1) = P_i(t) + v_i(t+1). \quad (14)$$

在 VLPSO 的迭代过程中, 粒子通过两方面更新其速度和位置向量, 即粒子本身进化到当前迭代次数时的局部最优解和整个种群进化到当前迭代次数时的全局最优解. 每个粒子均通过评价函数计算其适应值, 评价函数 $f(x)$ 定义为 DF 模型的 10 折交叉验证精度. 在第 $t+1$ 次迭代中, 若第 i 个粒子的适应度值 $f(P_i)$ 优于该粒子当前的局部最优解, 则粒子的局部最优解的更新以及根据粒子群中所有粒子的局部最优解更新全局最优解的过程, 如下式所示:

$$P_i^* = \begin{cases} P_i^*(t), & f(P_i(t+1)) \leq f(P_i^*(t)); \\ P_i(t+1), & f(P_i(t+1)) > f(P_i^*(t)). \end{cases} \quad (15)$$

$$P_g^* = \max_P(f(P_1^*), f(P_2^*), \dots, f(P_l^*)). \quad (16)$$

在优化进程结束后, 最佳粒子出现, 从而得到 VLPSO-WDF 模型最佳的结构. 最佳粒子的确定代表 VLPSO-WDF 级联层的确定. 若最佳粒子 $P = [p_1, p_2, \dots, p_l]$, 则 VLPSO-WDF 便由 l 个级联层组合而成, 其中 p 为每一个级联层的权重配置.

在 VLPSO 算法中, 优化过程直至达到最大的迭代终止标准. 所提出 VLPSO-WDF 算法可以利用最优的权重值修正森林的预测结果, 并在多级联层中不断优化模型的分类能力. 通过此方法, 不仅能够提高最终的预测精度, 还可以通过 VLPSO 搜索到最佳粒子确定 DF 的级联层数. VLPSO-WDF 方法的流程如图 3 所示.

3 实验结果及讨论

本文在 Core i5 机器上的 Python 中成功实现并测试了 DF 和 VLPSO-WDF 分类器. 所有实验均是在 Anaconda 3 (Python 3.7.6) 环境中执行的, 该环境运行在 Intel(R) Core(TM) i5-8250U CPU 1.60 GHz 的 PC 上和 8 192MB RAM 的 Win 10 运行系统中.

为了验证 VLPSO-WDF 算法的性能, 实验中使用了 BCI Competition IV 2a 组竞赛数据. VLPSO 使用的参数为: 群体大小 $S = 12$, 粒子分区的数量 $\text{NbrDiv} = 4$ 和最大迭代的终止标准 $\text{iter}_{\max} = 6$. VLPSO 优化的变量为 DF 模型中每一个级联层的随机森林和完全随机森林预测类概率的权重值, 权重在 $[0, 1]$ 内随

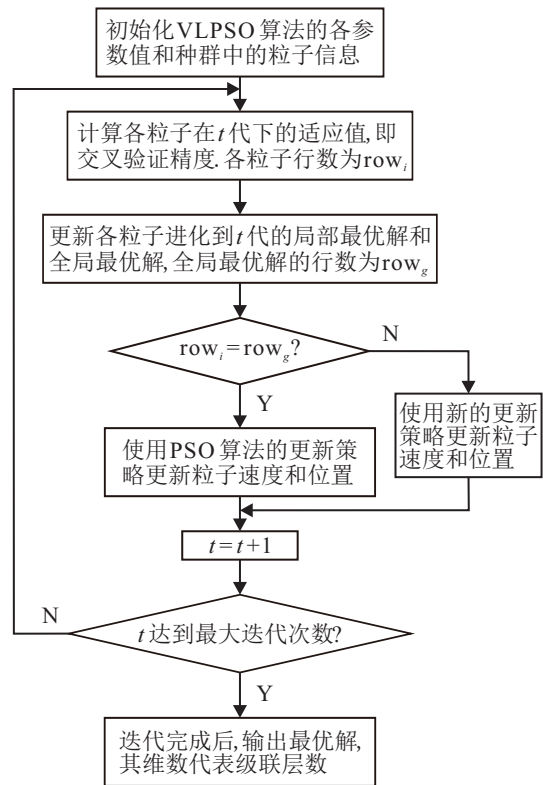


图 3 VLPSO-WDF 算法流程

机初始化, 然后通过 VLPSO 寻优. 在 DF 中的每一个级联层均包含 2 个随机森林和 2 个完全随机森林, 且每个森林均包含 1 000 个决策树. 级联层的数量由最佳粒子所在的分区决定.

VLPSO-WDF 算法在迭代中不断提高全局最佳粒子所带来的分类性能. 图 4 为 6 次迭代下对于表现最差的 3 个受试者 (受试者 2、受试者 4 和受试者 6) 的全局最佳粒子预测精度, 且每次迭代均由 12 个变长粒子进行寻优. 由图 4 可见, 随着 VLPSO 迭代次数的增长, 预测精度呈稳定增长的趋势. 若不考虑运算时间的因素, 更多的粒子和迭代次数可能实现更高的分类精度.




图 4 VLPSO 进化过程中全局最佳粒子精度的演变

所提出算法与传统的 DF 模型和 BCIC IV 中冠军使用的方法进行了比较, 表 1 为对比结果. 其中第 1 行为此次比较的所有方案, 第 2 行为评估方案性能的度量指标, 其余行为通过不同方案对受试者数据验证的

表1 本文方法与其他方法结果对比(1.0 = 100%)

受试者	VLPSO-WDF			DF			winner BCIC IV		
	ACC	F1	K	ACC	F1	K	ACC	F1	K
1	0.88	0.88	0.84	0.85	0.85	0.80	-	-	0.68
2	0.65	0.64	0.51	0.59	0.57	0.46	-	-	0.42
3	0.90	0.90	0.87	0.88	0.88	0.84	-	-	0.75
4	0.69	0.68	0.60	0.67	0.66	0.56	-	-	0.48
5	0.71	0.71	0.63	0.66	0.64	0.55	-	-	0.40
6	0.63	0.64	0.50	0.54	0.53	0.39	-	-	0.27
7	0.81	0.81	0.76	0.72	0.71	0.63	-	-	0.77
8	0.83	0.82	0.78	0.77	0.76	0.70	-	-	0.75
9	0.83	0.83	0.78	0.80	0.80	0.74	-	-	0.61
平均值	0.77	0.77	0.70	0.72	0.71	0.63	-	-	0.57

结果. BCIC IV中冠军使用的方法通过Kappa系数进行评价. 由表1可见,对于VLPSO-WDF算法,仅第7名受试者的Kappa值(0.76)略低于BCIC IV中第1名获得者的Kappa值(0.77),其余受试者的Kappa值均明显高于BCIC IV中第1名获得者. VLPSO-WDF算法得到的平均Kappa值(70%)高于BCIC IV中第1名获得者13%. 在分类性能上,所提出方法对传统的DF作出了明显的提升,且其分类精度优于大赛冠军使用的方法.

VLPSO-WDF算法使用了赋权策略以修正森林

预测的结果,为了分析赋权策略对分类模型的影响,表2为9个受试者的各个类信号通过VLPSO-WDF与传统DF的对比结果. 由表2可见,对于表现最差的受试者6,VLPSO-WDF相比于传统DF在类3的分类中提升了26%的正确率,且类2有11%的提升. 而对于受试者6的类1则降低了2%的分类正确率,这是由于在为实例的预测结果赋权后,对某些类的预测能力提升的同时其他类会受到影响. 由表2可见,所有受试者整体的预测结果均有明显提升,表明VLPSO-WDF可以更好地分类MI-EEG数据.

表2 受试者不同运动想象任务的分类精度

受试者	VLPSO-WDF				DF			
	类1	类2	类3	类4	类1	类2	类3	类4
1	0.99	0.86	0.72	0.94	0.96	0.84	0.67	0.94
2	0.41	0.56	0.99	0.62	0.25	0.56	0.97	0.60
3	0.84	1.00	0.90	0.88	0.84	1.00	0.79	0.88
4	0.34	0.84	0.81	0.79	0.39	0.81	0.75	0.74
5	0.87	0.92	0.47	0.61	0.90	0.88	0.36	0.51
6	0.58	0.62	0.57	0.74	0.60	0.51	0.31	0.74
7	0.58	1.00	0.72	1.00	0.54	0.93	0.44	1.00
8	0.95	0.93	0.74	0.72	0.95	0.87	0.72	0.54
9	0.71	0.82	0.83	0.98	0.71	0.75	0.75	0.98
平均值	0.70	0.84	0.75	0.81	0.68	0.79	0.64	0.77

4 结论

DF是一种决策树的集成方法,性能较于深度神经网络有很强的竞争力. 然而,传统DF模型中森林的错误预测会随着级数的增长被进一步放大. 因此,本文结合传统的深度森林模型,提出了一种根据DF中随机森林和完全随机森林预测结果进行学习的模型VLPSO-WDF. 该模型通过VLPSO算法强大的寻优能力,为DF模型中每个随机森林和完全随机森林预测的类概率值赋权,以此实现对预测结果的修正.

实验结果表明,所提出方法比BCI竞赛的获胜者高出13%的Kappa值. 通过对各个受试者数据的预测能力发现,相比于DF,VLPSO-WDF可以更好地分

类MI-EEG数据. 该模型的优势在于,其可根据分类器预测的结果进行学习,从而改善分类性能,且通过VLPSO算法为类概率值赋权的策略可进一步推广到其他分类模型上.

参考文献(References)

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

[2] 刘小变, 毕胜, 高小榕, 等. 基于运动想象的脑机交互康复训练新技术对脑卒中大脑可塑性影响[J]. 中国康复医学杂志, 2013, 28(2): 97-102.

(Liu X X, Bi S, Gao X R, et al. A new technique of rehabilitation training based on motor imagine using

- brain computer interface-functional electric stimulation system and it's effect on plasticity of brain of a stroke patient[J]. Chinese Journal of Rehabilitation Medicine, 2013, 28(2): 97-102.)
- [3] Guger C, Edlinger G, Harkam W, et al. How many people are able to operate an EEG-based brain-computer interface?[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society, 2003, 11(2): 145-147.
- [4] 张宪法, 郝矿荣, 陈磊. 免疫多域特征融合的多核学习 SVM 运动想象脑电信号分类[J]. 自动化学报, 2020, 46(11): 2417-2426.
(Zhang X F, Hao K R, Chen L. Motor imagery EEG classification based on immune multi-domain-feature fusion and multiple kernel learning SVM[J]. Acta Automatica Sinica, 2020, 46(11): 2417-2426.)
- [5] 郝矿荣, 原博炜, 陈磊, 等. 基于免疫堆叠降噪自编码网络的运动想象脑电信号识别[J]. 控制与决策, 2018, 33(4): 719-723.
(Hao K R, Yuan B W, Chen L, et al. Recognition of motor imagery EEG based on immune stacked denoising auto-encoders network[J]. Control and Decision, 2018, 33(4): 719-723.)
- [6] 孙京浩, 杨嘉雄, 王硕, 等. 基于 Actor-Critic 和神经网络的闭环脑机接口控制器设计[J]. 控制与决策, 2018, 33(11): 1967-1974.
(Sun J G, Yang J X, Wang S, et al. Design of closed-loop brain machine interface controller based on Actor-Critic and neural network[J]. Control and Decision, 2018, 33(11): 1967-1974.)
- [7] Pang M, Ting K M, Zhao P, et al. Improving deep forest by confidence screening[C]. IEEE International Conference on Data Mining. Singapore: IEEE, 2018: 1194-1199.
- [8] Utkin L V, Konstantinov A V, Chukanov V S, et al. A new adaptive weighted deep forest and its modifications[J]. International Journal of Information Technology & Decision Making, 2020, 19(4): 963-986.
- [9] Dong Y Y, Yang W K, Wang J W, et al. MLW-gcForest: A multi-weighted gcForest model towards the staging of lung adenocarcinoma based on multi-modal genetic data[J]. BMC Bioinformatics, 2019, 20(1): 578-598.
- [10] Zhu Y F, Fu S Y, Yang S H, et al. Weighted deep forest for schizophrenia data classification[J]. IEEE Access, 2020, 8: 62698-62705.
- [11] Brunner C, Leeb R, Müller-Putz G, et al. BCI Competition 2008-Graz data set A[J]. Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology, 2008, 16: 1-6.
- [12] Zheng M M, Yang B H, Xie Y L. EEG classification across Sessions and across subjects through transfer learning in motor imagery-based brain-machine interface system[J]. Medical & Biological Engineering & Computing, 2020, 58(7): 1515-1528.
- [13] Collazos-Huertas D, Caicedo-Acosta J, Castaño-Duque G A, et al. Enhanced multiple instance representation using time-frequency atoms in motor imagery classification[J]. Frontiers in Neuroscience, 2020, 14: 155.
- [14] Xie X F, Yu Z L, Gu Z H, et al. Bilinear regularized locality preserving learning on Riemannian graph for motor imagery BCI[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2018, 26(3): 698-708.
- [15] Jiang A M, Shang J, Liu X F, et al. Efficient CSP algorithm with spatio-temporal filtering for motor imagery classification[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society, 2020, 28(4): 1006-1016.
- [16] Tang Z, Li C, Wu J, et al. Classification of EEG-based single-trial motor imagery tasks using a B-CSP method for BCI[J]. Frontiers of Information Technology & Electronic Engineering, 2019, 20(8): 1087-1098.
- [17] Dong E Z, Zhu G X, Chen C, et al. Introducing chaos behavior to kernel relevance vector machine for four-class EEG classification[J]. PLoS One, 2018, 13(6): e0198786.
- [18] Wolpert D H. Stacked generalization[J]. Neural Networks, 1992, 5(2): 241-259.
- [19] Venter G, Jaroslaw S S. Particle swarm optimization[J]. AIAA Journal, 2003, 41(8): 129-132.
- [20] Wang B, Sun Y N, Xue B, et al. Evolving deep convolutional neural networks by variable-length particle swarm optimization for image classification[C]. IEEE Congress on Evolutionary Computation. Rio de Janeiro, 2018: 1-8.
- [21] Tran B, Xue B, Zhang M J. Variable-length particle swarm optimization for feature selection on high-dimensional classification[J]. IEEE Transactions on Evolutionary Computation, 2019, 23(3): 473-487.

作者简介

李红利(1978—), 男, 副教授, 博士, 从事神经信息处理与分析的研究, E-mail: lihonglin@163.com;

郭伟(1996—), 男, 硕士生, 从事神经信息处理与分析等研究, E-mail: 18635381821@163.com;

张荣华(1983—), 男, 副教授, 博士, 从事检测技术与自动化装置等研究, E-mail: zhangronghua@tiangong.edu.cn;

修春波(1978—), 男, 教授, 博士, 从事嵌入式系统设计与应用、智能控制与模式识别等研究, E-mail: xiuchunbo@tiangong.edu.cn;

马欣(1978—), 女, 副教授, 硕士, 从事生物信息检测与处理等研究, E-mail: maxin@tiangong.edu.cn.

(责任编辑: 魏冰)