

· 生物电子学 ·

基于AdaBoost的脑机接口分类算法研究

田 银^{1,2}, 李沛洋^{1,2}, 徐 鹏²

(1. 重庆邮电大学生物信息学院 重庆 南岸区 400065; 2. 电子科技大学神经信息教育部重点实验室 成都 610054)

【摘要】依据AdaBoost思想对BP神经网络、线性判别式以及支撑向量机三种传统分类器进行强化训练形成强分类器。在传统训练的基础上,根据分类器的映射特点选择相应的预处理方法和权值分布函数,降低分类器对数据特点的依赖性,提高AdaBoost的训练效果。对基于左右手运动想象的实际脑电数据进行模式分类,发现采用该思想训练的强分类器能不同程度地提高分类效果。该算法具有一定的推广意义,也证实了AdaBoost算法在脑机接口技术开发中的应用潜力。

关键词 脑机接口; 分类器; 脑电信号; 运动想象; 支撑向量机

中图分类号 R318

文献标志码 A

doi:10.3969/j.issn.1001-0548.2013.05.029

Brain-Computer Interface Classification Based on AdaBoost

TIAN Yin^{1,2}, LI Pei-yang^{1,2}, and XU Peng²

(1. College of Bio-Information, Chongqing University of Posts and Telecommunications Nan'an Chongqing 400065;

2. Key Laboratory for NeuroInformation of Ministry of Education, School of Life Science and Technology,

University of Electronic Science and Technology of China Chengdu 610054)

Abstract Using the adaptive boosting (AdaBoost) algorithm, the traditional classifiers, i.e. the BP neural network, the support vector machine (SVM) and the linear discriminant analysis (LDA) classifier, are trained into stronger ones. Based on traditional classifiers, the function weights and data processing are first adjusted according to the mapped output of classifiers. This method could effectively decrease the dependence on data features. These trained classifiers are then used to identify a group of data elicited by motor imagery. Based on the AdaBoost algorithm, the trained classifiers can obtain higher classification accuracy than the traditional ones. These results confirm the potential valuation of AdaBoost algorithm in BCI applications.

Key words brain-computer interface; classifier; EEG; motor imagery; support vector machine

脑机接口(brain-computer interface, BCI)为人脑与外围设备提供了一种直接的联系通道。通过这种通道,大脑不需要外周神经与肌肉组织的协同工作就可直接向外界传递出信息,从而控制计算机等辅助设备完成某些任务。一个BCI系统包括信号采集、数据处理以及外设与接口3个部分。在数据处理中,EEG信号的模式分类是BCI系统能否翻译出大脑信息的关键^[1-2]。

目前,用于脑机接口的模式分类方法很多,但由于各种算法对应的数学性质自身存在着一定的不足,对数据依赖性较强,难以推广。如BP神经网络^[3-6]由于其学习速率固定,致使收敛度较慢,并且权值在更新时具有一定的随机性,不易控制其训练过程;线性判别式分类器(linear discriminant analysis, LDA)属于稳态分类器,一般对训练集的数据特点有较严格的要求,致使其应用受到一定的限制,并且也易

引发维数灾难;支撑向量机(support vector machine, SVM)分类算法虽然解决了维数灾难,泛化效果好,但是由于其在训练分类器时会更关注最小风险度,因而忽略了一些重要的信息^[7-8]。AdaBoost思想在弱分类器的基础上不断将分类结果反馈作用到训练集数据上,形成强分类器,从而提高了分类的准确率。它对数据特点的依赖性较低,且生成的强分类器有较好的分类效果^[9]。本文选择BP神经网络、SVM及LDA等3种传统分类器作为弱分类器,在此基础上依据AdaBoost思想对上述分类器进行强化训练形成强分类器,以期提高传统分类器的分类效果,为模式分类提供了一种新的研究思路。

1 方法

本文提出的分类算法是依靠AdaBoost思想对传统分类器(本文选择了BP神经网络分类器、SVM分

收稿日期: 2012-06-19; 修回日期: 2013-01-11

基金项目: 国家自然科学基金(31100745, 61175117, 31170953); 重庆市教委项目(KJ110502)

作者简介: 田银(1972-), 女, 副教授, 主要从事脑电信号处理、认知神经科学方面的研究。

类器、LDA分类器)进行训练,形成强分类器,并使用强分类器对数据进行分类。

1.1 运动想象脑电数据

本文所采用的数据来源于BCI competition III的IVa数据集,该数据采集的是一个被试者在进行左右手运动想象任务时的EEG信号。其中,训练集有210个样本,测试集有280个样本。在训练集样本和测试集样本中,左右手运动想象的相关信息各占一半。

在对数据进行特征提取时,使用的带通滤波器的通带范围是11~27 Hz,在滤波后使用共空间模式(common spatial pattern, CSP)法提取μ节律的相关特征,并用6个独立的CSP滤波器进行记录,形成数据样本中的6个特征值。用“1”表示与之对应的训练样本是左手运动想象电位的特征值;用“-1”表示与之对应的训练样本是右手运动想象电位的特征值。算法的实现流程主要分为数据预处理、弱分类器构建、弱分类器训练及预测、强分类4个部分构成。

1.2 数据预处理, 权值初始化

对于神经网络类分类器,在分类前将数据进行归一化处理可以消除各维数据间数量级的差别,避免输入输出数据数量级差别较大而增大网络的预测误差,从而提高分类的准确率。但是归一化处理将改变线性判别式分析中最大特征值所对应的特征向量的分布,并使由训练数据映射成的一维分类平面中的两类值之间的距离较接近,降低了分类阈值的判别作用,影响了分类的准确性。所以对于BP神经网络分类器以及SVM分类器采用最大最小化法对分类数据进行归一化处理,有:

$$x_k = (x_k - x_{\min}) / (x_{\max} - x_{\min}) \quad (1)$$

式中, x_k 为样本 x 的第 k 个元素; x_{\min} 和 x_{\max} 分别为样本 x 中的最小值和最大值。测试数据的分布权值 $D_i(i) = 1/m$ 。

1.3 弱分类器构建

根据BP神经网络、SVM以及LDA的相关理论分别构造了BP神经网络、SVM弱分类器以及LDA弱分类器。其中BP神经网络的输入层节点数为6、隐含层节点数取为7、输出层节点数1,训练迭代次数为20次,学习速率为0.01;由LDA分类器的最优解方程为:

$$\max = \frac{|\varphi_i^T S_b \varphi_i|}{|\varphi_i^T S_w \varphi_i|} = \frac{\lambda_i |\varphi_i^T S_b \varphi_i|}{|\varphi_i^T S_w \varphi_i|} = \lambda_i \quad (2)$$

式中, S_b 和 S_w 分别为类间离散度和类内离散度矩阵;在构造SVM分类器时选择的核函数为如下形式的径向基函数:

$$K_{rbf}(x, x_i) = \exp(-\gamma |x - x_i|^2) \quad (3)$$

并选择了交叉验证模式对SVM的参数进行设置,具体SVM的参数设置可以参考LIBSVM(a library for support vector machines)。

1.4 弱分类器训练及预测

弱分类器训练步骤如下:

1) 训练第 i 个弱分类器时,用训练数据分别训练BP神经网络、LAD及SVM,并且预测训练数据的输出,得到其预测序列 $g(t)$ 的预测误差之和为:

$$e_i = \sum_j D_j(i) \quad (4)$$

式中, $i = 1, 2, \dots, m (g(t) \neq y)$, $g(t)$ 为预测分类结果; y 为期望分类结果。

2) 计算预测序列权重 $g(t)$ 的预测误差 e_i 计算分类序列的权重为:

$$\alpha_i = \frac{1}{2} \ln \left(\frac{1 - e_i}{e_i} \right) \quad (5)$$

3) 测试数据权重 a_i 调整下一轮训练样本的权重,调整公式为:

$$D_{i+1}(i) = \frac{D_i(i) \exp[-a_i y_i g_i(x)]}{B_i} \quad (6)$$

式中, $i = 1, 2, \dots, m$; B_i 为归一化因子。

1.5 形成强分类器

经过 N 轮训练后即可得到 N 组弱分类函数 $f(g_i, a_i)$, 通过将它们进行组合,可得到最终的强分类器 $h(x)$, 且有:

$$h(x) = \text{sign} \left[\sum_{i=1}^N \alpha_i f(g_i, a_i) \right] \quad (7)$$

实现过程如图1所示。

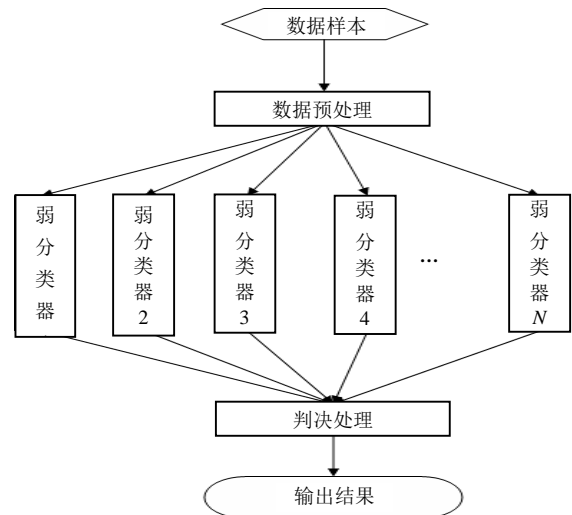


图1 Adaboost网络构建流程图

2 结果

测试集的数据可用于评估训练好的分类器的实际分类效果, 利用构造好的分类器对测试集数据进行预测, 并计算分类准确率, 得到表1和表2的结果。

表1 传统分类器的分类效果

分类器名	误分类个数	测试样本空间	分类准确率/(%)
SVM	13	280	95.36
LDA	16	280	94.29
单层BP神经网络	141	280	51.79

表2 强分类器的分类效果

分类器名	误分类个数	测试样本空间	分类准确率/(%)
SVM_AdaBoost	9	280	96.79
LDA_AdaBoost	15	280	94.64
BP_AdaBoost	1	280	99.64

3 讨论

通过对比表1和表2, 发现采用AdaBoost思想对BP神经网络、SVM网络和LDA网络进行强化训练后, 强分类器的分类效果比单一使用这些网络进行分类时的分类效果都有不同程度的提高。性能的提高归结于算法中每次运算后都按照分类结果更新了训练数据集, 使权重分布发生改变和分类失败的个体在下一次的迭代过程中得到了较大的权重, 也使迭代运算时受到更大的关注。

采用这一方式在一定程度上改善了SVM分类器在训练时, 因为追求最小风险度而忽略关键信息的缺陷。对于神经网络类分类器, 在训练时采用归一化策略, 在一定程度上消除了数据间数量级的差别, 避免了因为输入输出数据数量级差别较大而产生的较大网络预测误差; 而对于判别式分类器没有进行归一化处理, 避免了训练集数据由于归一化变得过分靠近而弱化线性分类的效果。由于针对不同类型的分类器采用了不同的预处理方法, 从而进一步提高了Adaboost对于弱分类器的训练效果。

在本文的3种强分类器中发现使用BP神经网络做弱分类器时, 虽然每个子分类器的分类效果都没有用LDA以及SVM训练时的效果好, 但是BP神经网络弱分类器形成的强分类器的分类效果却是最好的, 说明在强分类器的构造中, 较弱的多个分类器也可以通过学习, 形成一个有较好性能的强分类器。

4 结束语

通过上述分析应用发现, 基于AdaBoost思想训练成的强分类器能不同程度地提高传统分类器的分类效果。本文提出的算法依据AdaBoost思想对不同的分类器进行强化训练时, 能根据分类器的映射特

点调整权值分布函数, 在一定程度上降低了原有Adaboost方法训练弱分类器时对数据结构的依赖性, 从而进一步提高强分类器的分类效果, 具有一定的推广意义。由于该算法在训练分类器时能在一定程度上减少数据信息的丢失, 对脑电随机性较强的信号具有较好的识别能力, 从真实运动想象实验数据分类结果可知, 本文提出的方法在脑机接口技术的开发中具有较好的应用价值和潜力。在将来的工作中, 将进一步将发展的方法应用到实验室发展的脑机在线系统上, 检测该方法的在线学习能力。

参 考 文 献

- [1] 尧德中, 刘铁军, 徐鹏. 基于脑电的脑—机接口: 关键技术和应用前景[J]. 电子科技大学学报, 2009, 38(5): 550-553.
- [2] YAO De-zhong, LIU Tie-jun, XU Peng. Electroencephalogram based brain-computer interface: Key techniques and application prospect[J]. Journal of University of Electronic Science and Technology of China, 2009, 38(5): 550-553.
- [3] WPLPAW J R, BIRBAUMER N, MCFARLAND D J. Brain-computer interfaces for communication and control[J]. Clinical Neurophysiology, 2002, 113(6): 767-791.
- [4] JING G L, DU W T, GUO Y Y. Studies on prediction of separation percent in electro dialysis process via BP neural networks and improved BP algorithms[J]. Desalination, 2012, 291(2): 78-93.
- [5] WU W, WANG J A, CHENG M S. Convergence analysis of online gradient method for BP neural networks[J]. Neural Networks, 2011, 24(1): 91-98.
- [6] WANG H Q. Improvement of the recognition probability about camouflage target based on BP neural network[J]. Spectroscopy and Spectral Analysis, 2010, 30(12): 3316-3319.
- [7] CAO A L, ZHU Q J, ZHANG S T. BP neural network predictive model for stray current density of a buried metallic pipeline[J]. Anti-Corrosion Methods and Materials, 2010, 57(5): 234-237.
- [8] KIM T, STENGER B, KITTLER J, et al. Incremental linear discriminant analysis using sufficient spanning sets and its applications[J]. International Journal of Computer Vision, 2011, 91(2): 216-232.
- [9] MOURAO-MIRANDA J, ECKER C, SATO JOAO R. Evaluating SVM and MLDA in the extraction of discriminant regions for mental state prediction[J]. Neuroimage, 2009, 46(1): 105-114.
- [10] OHKAWA Y, SURYANTO C H, FUKUI K. Image set-based hand shape recognition using camera selection driven by multi-class AdaBoosting[J]. Advances in Visual Computing, 2011(6939): 555-566.

编辑 黄 莘