

用核学习算法的意识任务特征提取与分类

薛建中, 闫相国, 郑崇勋

(西安交通大学生物医学信息工程教育部重点实验室, 陕西西安 710049)

摘 要: 介绍了核学习算法中核主分量分析 (KPCA) 和支持向量机 (SVM) 的基本原理, 给出一种推广误差上界估计判据, 实现了 SVM 核参数及惩罚因子的优化选取. 根据多变量自回归模型理论对 4 个受试对象、三种不同意识任务的脑电信号进行特征提取, 并利用 KPCA 方法进行降维预处理, 对 SVM 进行训练和分类测试. 结果表明, KPCA 算法在高维特征空间具有较强的特征选择能力, 优化核参数的 SVM 的分类正确率明显高于径向基函数网络, 三种意识任务的平均分类正确率达 78.6%.

关键词: 核主分量分析 (KPCA); 支持向量机 (SVM); 意识任务; 脑电 (EEG)

中图分类号: R318 **文献标识码:** A **文章编号:** 0372-2112 (2004) 10-1749-05

Classifications of EEG during Mental Tasks by Kernel Learning Algorithms

XUE Jian-zhong, YAN Xiang-guo, ZHENG Chong-xun

(Key Laboratory of Biomedical Information Engineering of Education Ministry, Xi'an Jiaotong University, Xi'an, Shaanxi 710049, China)

Abstract: The fundamentals of two kernel-based learning algorithms, which are kernel principal component analysis (KPCA) and support vector machines (SVM), are introduced. An estimation formula of upper bound of generalization error is given to estimate the optimal kernel parameters and penalization factor of the SVM. Six-channel EEG data were recorded from four subjects while they performed three different mental tasks. A multivariate autoregressive (MVAR) model is applied to extract the features of EEG. The dimensionality of the feature vectors formed by the coefficients of MVAR models is reduced by KPCA first. Then the feature vectors with lower size are used as inputs of SVM with optimal parameters to train and test classification accuracy for three mental tasks. The classification accuracies indicate that the KPCA technique is a powerful feature selector in high-dimensional feature space, and optimal SVM can get optimal results which are significantly better than that of Radial Basis Function (RBF) network. The average classification accuracy over three mental tasks of four subjects achieves 78.6%.

Key words: kernel principal component analysis (KPCA); support vector machines (SVM); mental task; EEG

1 引言

人的大脑是一个极其复杂的系统. 近年的研究表明, 不同意识任务状态下的脑电 (EEG) 信号存在差异, 可以通过对几种简单易分意识任务的 EEG 信号进行模式识别, 形成较为复杂的控制命令, 完成轮椅、假肢等辅助设备的控制, 为有严重行为障碍的患者提供帮助. 1990 年, Keim 等人^[1]采集了六通道的 EEG 信号, 采用经典的功率谱分析方法进行特征提取, 并利用 Bayes 分类器对 5 种类型的心理任务进行了两两对比分类, 正确率超过 80%. 1998 年, Anderson 等人^[2]利用多变量自回归模型 (MVAR) 方法提取不同意识任务 EEG 信号的特征向量, 并对两种意识任务进行了分类, 取得了较满意的效果. Millan 等学者^[3]提出了一种局部神经分类器用于三种意识任务的识别, 在线分类正确率为 70%. 在过去的几年中, 基于核函数的学习算法得到快速发展, 如支持向量机 (SVM)^[4,5], 核

主分量分析 (KPCA)^[6,7]等, 这些技术已广泛应用于模式识别^[8]和回归分析等^[9]领域.

本文采集了 4 个受试对象、三种不同意识任务的 EEG 信号, 首先利用 MVAR 模型提取 EEG 信号的特征信息, 并通过 KPCA 技术在高维空间将得到的特征向量进行降低维数的处理, 最后利用三分类的优化 SVM 分类器对三种不同的意识任务进行分类.

2 EEG 数据的采集与预处理

人的 EEG 频率主要分布在 0.5 ~ 30Hz 之间, 并分为若干频带. 对于不同的人 and 不同的意识任务, 脑电信号的成分也存在一定的差异. 本研究是针对同一个人进行不同的意识任务的分类.

根据文献[10]的研究结果: 人在进行与语言、算术运算有关的意识活动时, 左半球的波小于右半球; 在进行与空间想

象有关的意识任务时,情况恰恰相反.因此本文所选择的意识任务为^[1]:放松状态、数学运算任务和想象几何物体空间旋转任务.

数据记录的位置是左、右半球对称布置: C3、C4、P3、P4、O1和 O2.另外,增加 FP2 用于检测眨眼伪迹;记录电极为 8mm 盘状电极,电极位置按 10~20 国际标准进行.实验对象为 4 名在校学生,年龄在 25~35 岁之间,均为男性,无神经系统疾病史.实验过程中,实验对象与放大器在屏蔽室中,记录设备放置在正常工作环境中.屏蔽室灯光较暗,以减少由于视觉在 EEG 中产生的伪迹.对实验环境中的噪声未进行刻意控制,使得本研究逐步实用化.实验仪器为美国 CADWELL 公司 EASY . 采样频率 400Hz.

在进行放松任务测试时,要求受试者尽量放松,不进行任何思维活动;在进行数学运算任务时,受试者对预先给定的数字进行乘法运算,这种运算状态一直保持到测试结束;在进行想象几何物体空间旋转任务时,要求受试者集中注意力想象一不规则物体绕某一轴连续旋转.每次记录时间为 10~15s.

本研究共进行了两组实验,每组实验每种任务进行 5 次.两组试验的时间不在同一天.

对每个受试对象,首先将所得到的 3 种意识任务的共 30 组数据分别根据 FP2 信号去除眨眼伪迹,生成新的、不含眨眼信息的数据,3 种意识任务共 60 组 4 秒数据.然后,将 4 秒的数据分成 1 秒的数据段,各数据段间重叠 0.5 秒,因此每 4 秒的数据可得到 7 个数据段,3 种意识任务共计 420 个数据段.去除各导联的趋势分量,将得到的数据段用于意识任务的特征提取.

3 特征向量的提取

利用多变量自回归 (MVAR) 模型方法对不同意识任务下的 EEG 信号进行模型阶数估计,求得各数据段在最佳模型阶数下的自回归模型的系数,形成不同的特征向量,用于后续的处理与分类.本文根据 SBC 判据准则,选取的最佳模型阶数为 3,特征向量维数 108,详见参考文献[2].

4 特征向量的降维-核主分量分析 (KPCA)

基于核函数的主分量分析 (KPCA)^[7]是一种非线性信号处理方法,在分类前对输入数据进行预处理,可以有效提取输入数据集的非线性结构信息,不仅减少了输入向量的维数,而且提高分类精度和分类速度.该方法首先通过非线性映射函数将输入向量映射到一个高维的特征空间,然后在高维空间进行传统的主分量分析,即线性主分量分析 (LPCA).

4.1 线性主分量分析 (LPCA)

对于均值为零的输入向量 $\tilde{x}_k \in \mathbf{R}^m, k=1, 2, \dots, l$, 可以通过求解下述特征方程解决 LPCA 问题^[7]:

$$\tilde{\mathbf{E}} \mathbf{v} = \lambda \mathbf{v} \quad (1)$$

其中特征值 $\lambda \geq 0$, 特征向量 $\mathbf{v} \in \mathbf{R}^m \setminus \{0\}$, 协方差矩阵 $\tilde{\mathbf{E}}$ 由下式计算:

$$\tilde{\mathbf{E}} = \frac{1}{l} \sum_{k=1}^l \tilde{x}_k \tilde{x}_k^T \quad (2)$$

由式 (1)、(2) 可得:

$$\tilde{\mathbf{E}} = \left(\frac{1}{l} \sum_{k=1}^l \tilde{x}_k \tilde{x}_k^T \right) = \frac{1}{l} \sum_{k=1}^l \tilde{x}_k, \tilde{x}_k \quad (3)$$

这就意味着所有 0 所对应的特征向量一定在 $\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_l$ 所张成的子空间中.式 (1) 等价于:

$$\sum_{k=1}^l \tilde{x}_k \tilde{x}_k^T \mathbf{v} = \lambda \mathbf{v} \quad (4)$$

4.2 核主分量分析 (KPCA)

考虑非线性映射 $\phi: \tilde{x} \in \mathbf{R}^m \rightarrow \tilde{x} \in \mathbf{R}^F$ 为输入空间, $\tilde{x} \in \mathbf{R}^F$ 为高维特征空间.假设 $\phi(\tilde{x}_k)$ 的均值为 0, 即:

$$\sum_{k=1}^l \phi(\tilde{x}_k) = 0 \quad (5)$$

在特征空间 F 中,映射后数据的协方差矩阵 E 为:

$$E = \frac{1}{l} \sum_{k=1}^l \phi(\tilde{x}_k) \phi^T(\tilde{x}_k) \quad (6)$$

与 LPCA 相似, KPCA 可以通过求解下列特征方程^[7]:

$$E \mathbf{v} = \lambda \mathbf{v} \quad (7)$$

该方程的解 \mathbf{v} 在由 $\phi(\tilde{x}_1), \phi(\tilde{x}_2), \dots, \phi(\tilde{x}_l)$ 张成的空间内, 式 (7) 等价于:

$$\sum_{k=1}^l \phi(\tilde{x}_k) \phi^T(\tilde{x}_k) \mathbf{v} = \lambda \mathbf{v}, k=1, 2, \dots, l \quad (8)$$

并且存在一组常数 $\{c_i\}$, 满足

$$\mathbf{v} = \sum_{i=1}^l c_i \phi(\tilde{x}_i) \quad (9)$$

定义点积矩阵 $\tilde{K} \in \mathbf{R}^{l \times l}$:

$$[\tilde{K}]_{ij} = \tilde{K}(\tilde{x}_i, \tilde{x}_j) = \phi(\tilde{x}_i), \phi(\tilde{x}_j) \quad (10)$$

函数 $\tilde{K}(\tilde{x}_i, \tilde{x}_j)$ 为满足 Mercer 条件的核函数^[5]. 将式 (8)、(9) 与 (10) 代入式 (7) 可得:

$$l \mathbf{c} = \tilde{\mathbf{c}} \tilde{\mathbf{K}} \mathbf{c}, \mathbf{c} = [c_1, c_2, \dots, c_l]^T \quad (11)$$

以 (c_1, c_2, \dots, c_l) 表示上述方程的一组解, $c_1 \geq c_2 \geq \dots \geq c_l, q$ 为主分量的数量. 要保证 $\mathbf{v}, \mathbf{v} = 1$, 则:

$$c_k^2 = \frac{1}{\tilde{K}(\tilde{x}_k, \tilde{x}_k)}, k=1, 2, \dots, q \quad (12)$$

当 $\phi(\tilde{x}_k)$ 的均值不为 0 时, 首先对映射后数据进行 0 均值处理:

$$\tilde{\phi}(\tilde{x}_k) = \phi(\tilde{x}_k) - \frac{1}{l} \sum_{j=1}^l \phi(\tilde{x}_j) \quad (13)$$

根据前面的推导, 不难得出新的点积矩阵:

$$\bar{\mathbf{K}} = \tilde{\mathbf{K}} - \mathbf{1}_l \tilde{\mathbf{K}} - \tilde{\mathbf{K}} \mathbf{1}_l + \mathbf{1}_l \tilde{\mathbf{K}} \mathbf{1}_l \quad (14)$$

其中 $\mathbf{1}_{ij} = 1, (\mathbf{1}_l)_{ij} = 1/l$. 以 $\bar{\mathbf{K}}$ 代替式 (11) 中的 $\tilde{\mathbf{K}}$, 并求其解 (\bar{c}_k, \bar{c}^k) . 则新向量 \tilde{x} 在 \bar{c}^k 方向的投影:

$$\bar{c}_k, \bar{\phi}(\tilde{x}) = (\bar{c}_k)^{-1/2} \sum_{i=1}^l \bar{c}_i \bar{K}(\tilde{x}_i, \tilde{x}), k=1, 2, \dots, q \quad (15)$$

从而获得高维特征空间中的 q 个主要分量.

KPCA 算法总结如下:

(1) 对于给定的维训练数据集 $\{\tilde{x}_k\}, k=1, 2, \dots, l$, 首先计算其核矩阵 $[\tilde{K}]_{ij} = \phi(\tilde{x}_i), \phi(\tilde{x}_j)$.

(2) 计算在特征空间对映射数据进行零均值处理后的核矩阵: $\bar{\mathbf{K}} = \tilde{\mathbf{K}} - \mathbf{1}_l \tilde{\mathbf{K}} - \tilde{\mathbf{K}} \mathbf{1}_l + \mathbf{1}_l \tilde{\mathbf{K}} \mathbf{1}_l$.

(3) 求解特征方程: $\bar{\mathbf{c}} = \bar{\mathbf{K}} \bar{\mathbf{c}}$, 解为 (\bar{c}_k, \bar{c}^k) .

(4) 对于一个新的向量 \tilde{x} , 利用式 (15) 提取 q 个主要分

量.

KPCA 中,由于利用了满足 Mercer 条件的核函数代替特征空间的内积运算,从而不必准确知道非线性变换的具体形式;由于映射函数可以是非线性的,特征空间的维数可以很高,因此选择合适的核函数及核参数,可以获得有效的主要特征分量.

5 优化支持向量机(SVM)

支持向量机(SVM)是基于结构风险最小化原则,它不仅要求最优分类面使各类准确地分开,而且要使类间间隔最大,从而保证真实风险最小,较好地解决了小样本的二分类问题.但是,SVM的性能与核参数的选取密切相关,通常调整参数的方法是采用穷举搜索法.该方法不仅计算量大,推广性差,而且当核参数的个数超过 2 时,该方法是难以奏效的.本文将利用一种最小误差上界函数优化 SVM 的参数^[11],设计优化的 SVM 分类器.

5.1 SVM 的基本原理

设包含 l 个样本的训练集 $\{x_k, y_k\}_{k=1}^l, x_k \in R^q$, 为输入向量, $y_k \in \{-1, +1\}$ 为类别标识. SVM 就是通过映射 $x \rightarrow z$ 将输入向量 $x \in R^q$ 变换到一个高维特征空间 $z \in F$, 在特征空间寻找最优的线性分类面.

对于线性可分 SVM(无训练误差),最优分类面可以通过求解下述优化问题获得^[5]:

$$\min_{w,b} \frac{1}{2} w^T w \quad (16)$$

$$\text{约束条件: } y_k (w^T (x_k) + b) \geq 1, k = 1, 2, \dots, l$$

根据最优理论, SVM 决策函数如下:

$$f(x) = \text{sign}(\sum_{i=1}^l y_i K(x, x_i) + b_0) \quad (17)$$

其中, b_0 为下列优化问题的最优解:

$$W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (18)$$

$$\text{约束条件: } \sum_{i=1}^l \alpha_i y_i = 0, \text{ 且 } \alpha_i \geq 0, i = 1, 2, \dots, l$$

函数 $[K]_{ij} = K(x_i, x_j) = (x_i, x_j)$ 为满足 Mercer 条件的核函数. 如果训练样本 x_i 对应的 $\alpha_i > 0$, 那么它就是支持向量.

Vapnik^[5]给出了线性可分 SVM 的误差上界函数:

$$T = \frac{1}{l} R^2 = \frac{1}{l} R^2 w^2 \quad (19)$$

R 和 w 为包含所有 (x_k) 的最小球半径和分类间隔.

对于线性可分 SVM,由于训练误差为零,因此易于产生分类器过训练的情况,推广性能较差. 因此在实际应用中,为保证分类器具有良好的推广性,允许一定的训练误差存在.

5.2 优化 SVM^[11]

对于线性不可分的 SVM,允许存在一定的训练误差,需在式(16)中增加一个松弛项.当松弛项为训练误差的平方时,式(16)变为:

$$\min_{w,b} \frac{1}{2} w^T w + \frac{C}{2} \sum_{i=1}^l \xi_i^2 \quad (20)$$

其中 ξ_i 为训练误差, C 为惩罚因子,起调节误差与正则项 $w^T w/2$ 间比例的作用. 该问题的对偶问题为:

$$W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \frac{1}{2C} \sum_{i=1}^l \alpha_i^2 \quad (21)$$

$$\text{约束条件: } \sum_{i=1}^l \alpha_i y_i = 0, \text{ 且 } \alpha_i \geq 0, i = 1, 2, \dots, l$$

公式(21)中,

$$[K_C]_{ij} = K_C(x_i, x_j) = [K + \frac{1}{C} I]_{ij} \quad (22)$$

I 为单位矩阵. 根据式(22)修改核矩阵,式(20)所表示的问题转化为了线性可分情况,惩罚因子 C 看作是核函数的一个参数. 因此,可以根据式(19)调整 SVM 的参数,改善分类效果.

根据 Vapnik^[5]的理论,分类间隔可以表示为:

$$w^2 = 2W(\alpha) = 2 \sum_{i=1}^l \alpha_i - \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K_C(x_i, x_j) \quad (23)$$

最小球半径 R 可以由下列优化问题获得:

$$R^2 = \max_{i=1}^l \sum_{i=1}^l \alpha_i K_C(x_i, x_i) - \sum_{i,j=1}^l \alpha_i \alpha_j K_C(x_i, x_j) \quad (24)$$

$$\text{约束条件: } \sum_{i=1}^l \alpha_i = 1, \text{ 且 } \alpha_i \geq 0, i = 1, 2, \dots, l$$

将式(23)和(24)两式分别对核参数 p 求偏导数:

$$\frac{\partial w^2}{\partial p} = - \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \frac{\partial K_C(x_i, x_j)}{\partial p} \quad (25)$$

$$\frac{\partial R^2}{\partial p} = \sum_{i=1}^l \alpha_i \frac{\partial K_C(x_i, x_i)}{\partial p} - \sum_{i,j=1}^l \alpha_i \alpha_j \frac{\partial K_C(x_i, x_j)}{\partial p} \quad (26)$$

其中 α 为式(24)的解.

当选择 Gaussian 函数作为核函数时,

$$K(x, z) = \exp\{-\frac{x-z}{2}\}$$

w^2 和 R^2 对 α 和惩罚因子 C 的偏导数如下:

$$\frac{\partial w^2}{\partial \alpha} = - \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \frac{x_i - x_j}{2^4} \quad (27)$$

$$\frac{\partial w^2}{\partial C} = \sum_{i=1}^l (\alpha_i)^2 \frac{1}{C^2} \quad (28)$$

$$\frac{\partial R^2}{\partial \alpha} = - \sum_{i,j=1}^l \alpha_i \alpha_j K(x_i, x_j) \frac{x_i - x_j}{2^4} \quad (29)$$

$$\frac{\partial R^2}{\partial C} = - \frac{1}{C^2} + \sum_{i=1}^l (\alpha_i)^2 \frac{1}{C^2} \quad (30)$$

将误差上界函数 T 作为目标函数,利用梯度下降法^[11],可以得到优化的核参数及惩罚因子.

对于 Gaussian 核函数,优化 SVM 设计过程总结如下:

(1) 给定 Gaussian 函数的参数 α 和惩罚因子 C 的初始值.

(2) 根据式(22)计算修改的核矩阵 K_C .

(3) 利用标准的 SVM 算法,求解优化问题(21),

$$\alpha = \arg \min W(\alpha, \alpha^2, C), \quad w^2 = 2W(\alpha)$$

(4) 求解优化问题(24),计算最小球半径 R .

(5) 根据式(27)、式(32)估计误差上界函数的梯度.

(6) 利用梯度下降法更新参数 γ 和 C 的值.

(7) 当 T 达到最小时, 参数 γ 和 C 为最佳值; 否则, 回到 (2), 继续寻找优化参数.

5.3 多分类支持向量机

SVM 是从二分类问题发展而来的, 如何将 SVM 有效地应用于多分类问题, 是目前正在研究的一项热点课题. Hsu 和 Lin^[12] 研究了几种多分类的 SVM, 结果表明, 一对一 (one-against-one) 方法在实际应用中效果较好, 而且性能稳定. 所以本文将采用一对方方法设计三分类优化 SVM 分类器.

对于 k 类的模式识别问题, 一对一方法需要构建 $k(k-1)/2$ 个分类器, 每个分类器完成其中两类问题的训练. 对于给定的测试向量, 各分类器均给出分类结果, 即“投票”, “得票”最多的一类为最终的分类结果. 如果存在两类或多类的得“票”数相同时, 将根据各类得票权重最大者决定分类结果. 本研究共三种意识任务, 因此设计了三个优化 SVM 完成三种意识任务的分类, 决策函数中 (参见式 (17)), 符号运算前的数值作为分类的权重.

6 试验结果

本节将给出采用不同的预处理方法及不同的分类器对三种意识任务的分类结果. 首先做几点说明:

(1) 本文中的 RBF 网络, 隐元数等于训练样本数, 输出节点数为 3. 调整网络参数, 以获得的最佳分类效果为本网络的分类正确率.

(2) 对于 KPCA, 使用的核函数为 Gaussian 函数, 即:

$$\tilde{K}(x, z) = \phi(x) \cdot \phi(z) = \exp\left(-\frac{x-z}{2}\right)$$

当降低的维数一定时, 核参数的取值范围为 0.8 ~ 3, 间隔为 0.4, 取分类效果最佳者为该维数下的最佳分类正确率.

(3) 在 4 个实验对象、三种意识任务的数据中, 选取 80% 作为训练部分, 剩余的 20% 用于分类器测试. 使用不同的训练数据与测试数据共进行 125 次分类得到三种任务的平均分类结果.

(4) 本研究共进行了以下 4 方面的测试:

Exp1: 利用 3 阶 MVAR 模型获得的 108 维特征向量直接作为 RBF 神经网络的输入, 分别对 4 个受试对象的三种意识任务进行训练与分类测试. 结果在图 1 中用直线表示.

Exp2: 将 3 阶 MVAR 模型获得的 108 维特征向量首先进行线性主分量分析, 降维后的特征向量作为 RBF 神经网络的输入进行训练与分类测试. 图 1 中用标记“ \square ”的曲线表示分类结果.

Exp3: 将 3 阶 MVAR 模型获得的 108 维特征向量首先进行核主分量分析, 降维后的特征向量作为 RBF 神经网络的输入进行训练与分类测试. 分类结果在图 1 中用标记“ ∇ ”的曲线表示.

Exp4: 将 3 阶 MVAR 模型获得的 108 维特征向量首先进行核主分量分析, 降维后的特征向量作为优化支持向量机的输入, 进行训练与分类测试. 分类结果在图 1 中用标记“ \circ ”的

曲线表示.

4 个实验对象的分类结果如图 1 所示.

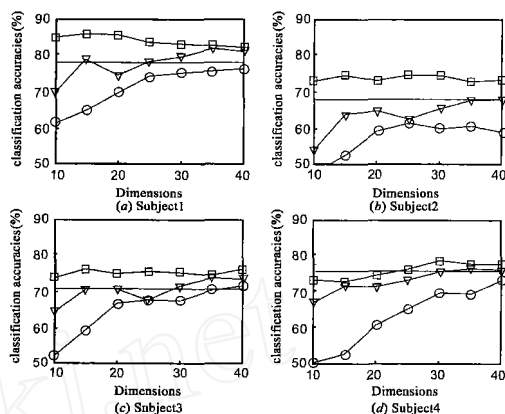


图 1 4 个受试对象的分类结果

7 讨论与结论

从图 1 的分类结果中可以看出, 将 3 阶 MVAR 模型特征提取方法获得的 108 维特征向量直接对 RBF 神经网络进行训练与分类测试, 四个对象三种意识任务的三分类正确率分别为 78.0%、67.7%、70.6% 和 75.1%, 平均正确率为 72.8%.

由于 EEG 信号的复杂性, 有效的意识特征分散于大量的特征数据之中, 且具有较强的非线性. 传统的 LPCA 算法是一种线性映射算法, 在处理非线性问题时往往不能取得好的效果. 在图 1 所示的分类结果中, 利用 LPCA 方法预处理不能有效改善分类效果, 分类正确率最低.

KPCA 算法引入了非线性变换, 因此比 LPCA 算法提取输入数据中的非线性特征信息能力更强. 图 1 的分类结果中, 当特征维数在 25 ~ 35 时, 分类的正确率就达到或超过 108 维特征向量直接分类的正确率. KPCA 方法在 EEG 信号的进一步特征提取中取得了较好的效果. 但是, 核函数的选取、优化参数的选择以及主分量数目的确定, 目前尚缺乏理论指导, 是需要进一步研究与探索的问题, 应用中主要靠试验的方法确定.

SVM 是基于结构风险最小化原则的, 目前是小样本统计估计和预测学习的最佳理论, 具有良好的推广能力. 本文根据一种误差上界估计函数, 实现了 SVM 核参数及惩罚因子的优化选取, 设计了三分类的优化 SVM, 在意识任务分类应用中取得了较好的分类效果, 分类正确率明显高于 RBF 网络. 经 KPCA 降维预处理后, 采用优化 SVM 对三种意识任务进行分类, 4 个对象的最佳分类正确率分别为 85.6%、74.5%、75.9% 和 78.3%, 平均正确率为 78.6%, 明显高于 RBF 网络对 108 维特征向量直接分类的正确率.

文献 [1] 与 [2] 实现了不同意识任务间的二分类, 本文则主要针对三种意识任务间的三分类问题, 分类正确率明显优于文献 [3] 的分类结果, 使任务分类更接近实用化. 与文献 [1] 和 [2] 实现的二分类问题相比, 在实际应用中具有更重要的意义.

综上所述, KPCA 具有较强的提取特征向量的主要成分的能力, SVM 具有较好的分类能力. 综合两种基于核函数的学习

算法,在较低的维数下,对三种意识任务获得了较高的分类正确率.基于核函数的学习算法在模式识别领域具有广阔的应用前景.

参考文献:

- [1] Keirn ZA ,Aunon JJ. A new mode of communication between man and his surroundings [J]. IEEE Trans Biomed Eng ,1990 ,37(12) :1209 - 1214.
- [2] Anderson CW ,Stolz EA ,Shamsunder S. Multivariate autoregressive models for classification of spontaneous electroencephalographic signals during mental tasks[J]. IEEE Trans Biomed Eng ,1998 ,45(3) :277 - 286.
- [3] Millan del RJ ,Mburino J ,Franze M ,et al. A local neural classifier for the recognition of EEG patterns associated to mental tasks[J]. IEEE Trans Neural Networks ,2002 ,13(3) :678 - 686.
- [4] Muller K-R ,Mika S ,Ratsch G ,et al. An introduction to kernel-based learning algorithms[J]. IEEE Trans Neural Networks ,2001 ,12(1045-9227) :181 - 201.
- [5] Vapnik VN. Statistical Learning Theory[M]. New York :John Wiley and Sons Inc. 1998.
- [6] Scholkopf B ,Mika S ,Burges CJC ,et al. Input space versus feature space in kernel-based methods [J]. IEEE Trans Neural Networks , 1999 ,10(5) :1000 - 1017.
- [7] Scholkopf B ,Smola AJ ,Muller K-R. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computation ,1998 ,10:1299 - 1319.
- [8] Lu J ,Platanotis KN ,Venetsanopoulos AN. Face recognition using kernel direct discriminant analysis algorithms [J]. IEEE Trans Biomed Eng ,2003 ,14(1) :117 - 126.
- [9] Muller K-R ,Smola AJ ,Ratsch G ,et al. Predicting time series with support vector machines[A]. in Artificial Neural Networks- ICANN97[C]. Berlin , Germany :Springer-Verlag ,1997. 999 - 1004.
- [10] Galin D ,Ornstein RE. Hemispheric specialization and the duality of consciousness[A]. in Human Behavior and Brain Function[C]. USA : Springfield ,IL ,1973.
- [11] Chapelle O ,Vapnik V ,Bousquet O ,et al. Choosing multiple parameters for support vector machines[J]. Machine Learning ,2002 ,46(1-3) :131 - 159.
- [12] Hsu C-W ,Lin C-J . A comparison of methods for multiclass support vector machines[J]. IEEE Trans Neural Networks ,2002 ,13(2) :415 - 425.

作者简介:



薛建中 男,1966年3月出生于辽宁朝阳,西安交通大学在读博士研究生,主要研究方向为生物医学信号处理. Email :xue2873808@sina.com.cn



闫相国 男,1963年12月出生于河南周口,西安交通大学生物医学研究所,副教授,主要研究方向为生物医学信号处理、医学图像处理等.