

DOI: 10.11992/tis.201808005

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.tp.20190527.1715.012.html>

面向自闭症辅助诊断的无监督模糊特征学习新方法

张英, 王骏, 鲍国强, 张春香, 王士同

(江南大学数字媒体学院, 江苏 无锡 214122)

摘 要: 自闭症患者的行为和认知缺陷与潜在的脑功能异常有关。对于静息态功能磁共振图像 (functional magnetic resonance imaging, fMRI) 高维特征, 传统的线性特征提取方法不能充分提取其中的有效信息用于分类。为此, 本文面向 fMRI 数据提出一种新型的无监督模糊特征映射方法, 并将其与多视角支持向量机相结合, 构建分类模型应用于自闭症的计算机辅助诊断。该方法首先采用多输出 TSK 模糊系统的规则前件学习方法, 将原始特征数据映射到线性可分的高维空间; 然后引入流形正则化学习框架, 提出新型的无监督模糊特征学习方法, 从而得到原输出特征向量的非线性低维嵌入表示; 最后使用多视角 SVM 算法进行分类。实验结果表明: 本文方法能够有效提取静息态 fMRI 数据中的重要特征, 在保证模型具有优越且稳定的分类性能的前提下, 还可以提高模型的可解释性。

关键词: 自闭症; 功能磁共振成像; 功能连接; 皮尔森相关性; 特征选择; 无监督模糊特征映射; 流形正则化框架; 支持向量机

中图分类号: TP391 文献标志码: A 文章编号: 1673-4785(2019)05-0882-07

中文引用格式: 张英, 王骏, 鲍国强, 等. 面向自闭症辅助诊断的无监督模糊特征学习新方法 [J]. 智能系统学报, 2019, 14(5): 882-888.

英文引用格式: ZHANG Ying, WANG Jun, BAO Guoqiang, et al. A novel unsupervised fuzzy feature learning method for computer-aided diagnosis of autism[J]. CAAI transactions on intelligent systems, 2019, 14(5): 882-888.

A novel unsupervised fuzzy feature learning method for computer-aided diagnosis of autism

ZHANG Ying, WANG Jun, BAO Guoqiang, ZHANG Chunxiang, WANG Shitong

(School of Digital Media, Jiangnan University, Wuxi 214122, China)

Abstract: Studies have shown that the behavioral and cognitive defect of patients with autism have a close relationship with potential brain dysfunction. For the high-dimensional rs-fMRI features, traditional linear feature extraction method cannot always discriminatively extract the important information for classification. To this end, a novel method for fMRI data based on both unsupervised fuzzy feature mapping and multi-view support vector machine is proposed in this study, which aims to build a classification model for computer aided diagnosis of autism. In this method, the original features are first mapped to a linear separable high-dimensional space using the rule precursor learning method of multi-output Takagi-Sugeno-Kang (TSK) fuzzy system; then the manifold regularization learning framework is introduced. On the basis of this, a novel unsupervised fuzzy feature learning method is used to obtain the nonlinear low-dimensional embedding representation of the original output eigenvector. Finally, a multi-view support vector machine (SVM) algorithm is used for classification. The experimental results show that the proposed method can effectively extract important features from the rs-fMRI data and improve the interpretability of the model on the premise of ensuring a superior and stable classification performance of the model.

Keywords: autism; functional magnetic resonance imaging; functional connectivity; Pearson's correlation; feature selection; unsupervised fuzzy feature mapping; manifold regularization framework; support vector machine

收稿日期: 2018-08-08. 网络出版日期: 2019-05-29.

基金项目: 江苏省自然科学基金项目 (BK20181339).

通信作者: 王骏. E-mail: wangjun_syty@hotmail.com.

自闭症又叫孤独症, 是一种广泛性神经失调的发展障碍疾病, 其临床表现主要为社会交往障

碍、言语交流障碍和动作刻板重复等^[1-3]。自1943年利奥·坎纳医生首次对自闭症做出经典性描述以来,该疾病因其病因不明确,又集多种障碍于一身,已经得到了广泛的关注。目前,在美国平均每68名儿童中就有1名自闭症儿童;在世界范围内,自闭症患者超过1%。据统计,约2/3孤独症患儿成年后无法独立生活,需要终生照顾和看护。为此,人们迫切希望寻找科学而高效的手段对自闭症进行准确诊断以达到早发现早治疗的目的。

已有研究表明,自闭症患者行为和认知缺陷与潜在的脑功能异常有关。静息态fMRI技术^[4-9]通过使用血氧水平依赖(blood oxygenation level dependent, BOLD)信号可以有效地反映患者在静息状态下脑部血流和代谢活动等功能性变化,因此在自闭症的辅助诊断中起着重要的作用。基于静息态的医学影像诊断大致可分为特征提取和分类器设计这两个阶段。在特征提取阶段,通过使用相关性特征选择等方法从高维医学影像特征中得到有鉴别意义的特征;在分类器设计阶段,通过使用线性或非线性分类器进行分类。但是目前多采用线性特征学习方法,虽然具有简单高效等优点,但是尚不能有效挖掘出医学影像数据中的复杂信息。

本文基于静息态fMRI提出了一种新型的无监督模糊特征学习方法,并在此基础上构造多视角分类器从而实现自闭症的辅助诊断。其技术路线可概括为:首先,将静息态fMRI经过预处理后,基于Pearson相关系数构造低阶功能连接矩阵,并使用文献[7]的方法构造高阶功能连接矩阵;然后,提出新型的无监督模糊特征学习方法,将2种功能连接矩阵分别映射到不同的低维嵌入空间中;最后,以低阶和高阶功能连接在脑疾病诊断中的互补性为出发点,设计多视角SVM^[10]分类器进行分类。

1 实验数据集及处理

本文使用的数据集来自ABIDE(autism brain imaging datae xchange)数据库(<http://preprocessed-connectomes-project.org/abide/download.html>)的NYU子集和USM子集,采集对象的FIQ(full-scale intelligence quotient)范围为65~150。实验所处理对象的相关信息如表1和表2所示。

表1 NYU实验对象信息

Table 1 The information of NYU experimental object

实验对象信息	自闭症患者数	正常对照组
人数(男/女)	68/11	77/26
年龄	7.13~39.1	6.47~31.78

表2 USM实验对象信息

Table 2 The information of USM experimental object

实验对象信息	自闭症患者数	正常对照组
人数(男/女)	56/0	43/0
年龄	11.4~42.3	8.8~39.4

每个对象的fMRI数据使用DPARSF(data processing assistant for resting-state fMRI)^[11]工具进行处理。处理步骤主要包括:1)去除功能磁共振图像序列前10个时间点的数据;2)时间层校正和头部运动校正;3)数据通过统一使用T1加权图像分割并将其归一化到MNI152(montreal neurologic-al institute 152)标准空间中;4)使用AAL(anatomical automatic labeling)模板将大脑划分成116个脑区,每个区域重新采样 $3 \times 3 \times 3 \text{ mm}^3$ 的体素;5)使用半高全宽高斯核进行空间平滑处理;6)应用带通滤波(0.01~0.1 Hz)去除噪声;7)去线性漂移并进行全局信号校正去干扰变量;8)计算每个脑区的平均时间序列。

2 基于fMRI数据的无监督模糊特征学习方法

2.1 方法流程

基于静息态fMRI进行自闭症辅助诊断包括训练和测试两个阶段。本文所采用的训练过程如图1所示,各步骤包括:

1)根据预处理后的静息态功能磁共振成像数据,提取出各脑区的平均时间序列信号,计算脑区之间的Pearson系数,得到低阶功能连接矩阵 M_{tr}^l 。

2)将低阶功能连接矩阵的每一行作为各脑区的特征描述,再次计算脑区之间的Pearson系数,得到高阶功能连接矩阵 M_{tr}^h 。

3)分别取低阶和高阶功能连接矩阵 M_{tr}^l 和 M_{tr}^h 的上三角阵,按行串联形成新的特征向量,然后将所有对象的特征向量进行排列,生成基于低阶和高阶功能连接的所有对象的特征矩阵;对两种不同的特征矩阵计算各特征与类标的相关性,选择与类标相关性最高的 D 个特征,构成矩阵 $X_{\text{tr}}^l = \left((x_1^{\text{tr},l})^T; (x_2^{\text{tr},l})^T; \dots; (x_N^{\text{tr},l})^T \right) \in \mathbf{R}^{N \times D}$ 和 $X_{\text{tr}}^h = \left((x_1^{\text{tr},h})^T; \dots; (x_N^{\text{tr},h})^T \right) \in \mathbf{R}^{N \times D}$ 。

$(x_2^{\text{tr},h})^T; \dots; (x_N^{\text{tr},h})^T) \in \mathbf{R}^{N \times D}$, 其中 $x_i^{\text{tr},l} \in \mathbf{R}^D$, $x_i^{\text{tr},h} \in \mathbf{R}^D$, $i = 1, 2, \dots, N$ 。

4) 使用无监督模糊特征映射方法对低阶和高阶功能连接的特征矩阵进行特征学习, 得到相应的变换矩阵 β_g , 并将 X_{tr}^l 和 X_{tr}^h 变换到低维空间中

得到相应的嵌入矩阵 E_{tr}^l 和 E_{tr}^h 。

5) 基于4)得到的嵌入矩阵 E_{tr}^l 和 E_{tr}^h , 分别计算相应的核矩阵。

6) 将2种不同的核矩阵进行线性组合得到复合核矩阵。

7) 构造相应的SVM分类器。

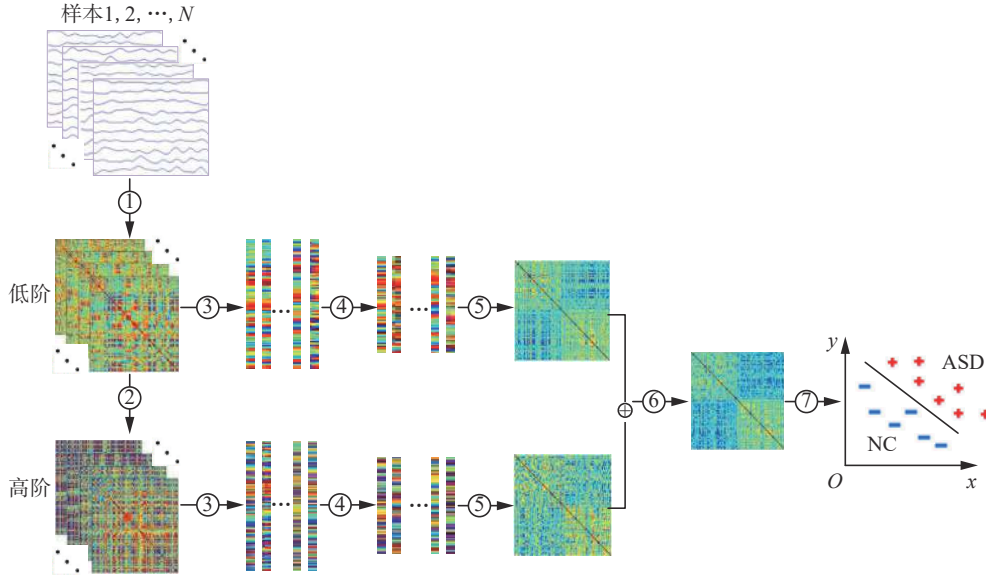


图1 无监督模糊特征学习方法的框架流程图

Fig. 1 The framework of an unsupervised fuzzy feature learning method

2.2 低阶和高阶功能连接矩阵的生成

虽然大脑各脑区在空间上相互隔离, 但它们之间的神经活动相互影响, 通常使用功能连接矩阵来表示脑区之间的时间相关性^[12]。本文使用文献[8]中的方法, 基于每个脑区fMRI时间序列来计算每个对象各脑区之间的Pearson相关系数, 得到低阶功能连接矩阵 M_{tr}^l 。将低阶功能连接矩阵的每一行作为一个脑区的特征描述, 使用同样的方法再次计算脑区之间的Pearson相关系数, 从而得到高阶功能连接矩阵 M_{tr}^h 。

2.3 基于流形正则化约束的模糊特征学习

为了在无监督环境中将高维空间中的样本点映射到 S 维的低维空间, 本文引入多输出TSK模糊建模方法。TSK模糊系统是由形式为“IF-THEN”的模糊规则组成的, 对于多输出TSK模糊系统, 给定任意一个 D 维输入向量 $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_D]^T$, 第 k 条模糊规则可以表示为:

if x_1 is $A_1^k \wedge x_2$ is $A_2^k \wedge \dots \wedge x_D$ is A_D^k , then

$$\begin{cases} f_1^k(\mathbf{x}) = \beta_0^{k,1} + \beta_1^{k,1} x_1 + \dots + \beta_D^{k,1} x_D \\ f_2^k(\mathbf{x}) = \beta_0^{k,2} + \beta_1^{k,2} x_1 + \dots + \beta_D^{k,2} x_D \\ \vdots \\ f_S^k(\mathbf{x}) = \beta_0^{k,S} + \beta_1^{k,S} x_1 + \dots + \beta_D^{k,S} x_D \end{cases}$$

式中: A_d^k 表示输入特征向量 \mathbf{x} 第 d 维特征所对应的第 k 条模糊规则的模糊子集; \wedge 表示模糊合取操作; $k = 1, 2, \dots, K$; $d = 1, 2, \dots, D$, d 表示统称; $s = 1, 2, \dots, S$; K 表示模糊规则数; S 表示模型输出的个数。

本文采用高斯函数表示模糊规则的模糊集, 即

$$\mu_{A_d^k}(x_d) = \exp\left(\frac{-(x_d - c_d^k)^2}{2\delta_d^k}\right) \quad (1)$$

并使用式(2)、式(3)来计算每个样本相对于每条模糊规则的点火强度:

$$\mu^k(x) = \prod_{d=1}^D \mu_{A_d^k}(x_d) \quad (2)$$

$$\tilde{\mu}^k(x) = \frac{\mu^k(x)}{\sum_{k=1}^K \mu^k(x)} \quad (3)$$

参数 c_d^k 和 δ_d^k 的值可以使用聚类技术或其他划分方法^[13-14]计算得出。本文使用FCM聚类算法进行数据集的模糊划分, 其中 c_d^k 和 δ_d^k 可通过式(4)、式(5)计算得到:

$$c_d^k = \sum_{i=1}^N u_{ik} x_{id} / \sum_{i=1}^N u_{ik} \quad (4)$$

$$\delta_d^k = h \cdot \sum_{i=1}^N u_{ik} (x_{id} - c_d^k)^2 / \sum_{i=1}^N u_{ik} \quad (5)$$

式中: u_{ik} 表示每个样本 x_i 属于第 k 类的模糊隶属度; h 是隶属度函数的可调尺度参数。多输出 TSK 模糊系统的输出可以表示为

$$y_s = \sum_{k=1}^K \tilde{\mu}^k(x) \cdot f_s^k(x) \quad (6)$$

式中 $s = 1, 2, \dots, S$ 。

令 $X = (x_1^T, x_2^T, \dots, x_N^T)$, $\mathbf{1}$ 为全 1 列向量, 多输出 TSK 模糊系统的建模过程可用式 (7)~(13) 的计算方法表述^[15]:

$$X_e = (\mathbf{1}, X) \quad (7)$$

$$\tilde{X}^k = \text{diag}(\tilde{\mu}^k(x_1), \tilde{\mu}^k(x_2), \dots, \tilde{\mu}^k(x_N)) X_e \quad (8)$$

$$X_g = ((\tilde{X}^1)^T (\tilde{X}^2)^T \dots (\tilde{X}^K)^T)^T \quad (9)$$

$$\beta^{s,k} = (\beta_0^{s,k}, \beta_1^{s,k}, \dots, \beta_D^{s,k})^T \quad (10)$$

$$\beta^s = ((\beta^{s,1})^T, (\beta^{s,2})^T, \dots, (\beta^{s,K})^T)^T \quad (11)$$

$$\beta_g = [\beta^1 \ \beta^2 \ \dots \ \beta^S] \quad (12)$$

$$f(X) = X_g \beta_g \quad (13)$$

式 (7)~(13) 表述的多输出 TSK 模糊系统建模过程可以看作将 $K(D+1)$ 维空间中的数据通过变换矩阵 β_g 降维到 S 维数据空间的过程, 通常 $S < K(D+1)$ 。为了学习得到适合的 β_g , 本文构造的目标学习准则为

$$\begin{aligned} \min_{\beta_g \in \mathbb{R}^{(D+1)K \times S}} & \|\beta_g\|_F + \lambda \text{tr}(\beta_g^T X_g^T L X_g \beta_g) \\ \text{s.t.} & (X_g \beta_g)^T X_g \beta_g = I_S \end{aligned} \quad (14)$$

式中: λ 为惩罚项系数; 单位矩阵 $I_S \in \mathbb{R}^{S \times S}$; L 为定义在功能连接矩阵 X 上的拉普拉斯矩阵。式 (14) 在 β_g 全为零时取得最小值。为了避免平凡解, 引入约束条件 $(X_g \beta_g)^T X_g \beta_g = I_S$ 。本文引入流形正则化项 $\text{tr}(\beta_g^T X_g^T L X_g \beta_g)$, 将处于流形上的特征数据映射到低维空间中, 并尽可能保留特征数据间相似度。

本文中所涉及的场景是典型的高维小样本问题, 故满足 $(D+1)K > N$ 。式 (14) 可以转化为式 (15) 所描述的广义特征值问题:

$$(I_N + \lambda L X_g X_g^T) u = \gamma X_g X_g^T u \quad (15)$$

在得到最小 S 个特征值 $\gamma_1, \gamma_2, \dots, \gamma_S (\gamma_1 \leq \gamma_2 \leq \dots \leq \gamma_S)$ 及其对应的广义特征向量 u_1, u_2, \dots, u_S (因 $u_1 = 0$, 故不用) 后, 可以求得最优解为:

$$\beta_g = X_g^T (\tilde{u}_2, \tilde{u}_3, \dots, \tilde{u}_{S+1}) \quad (16)$$

式中: $\tilde{u}_d = u_d / \|X_g X_g^T u_d\|$ 表示归一化特征向量, $d = 2, 3, \dots, S+1$ 。

无监督模型模糊特征学习的过程如图 2 所示。

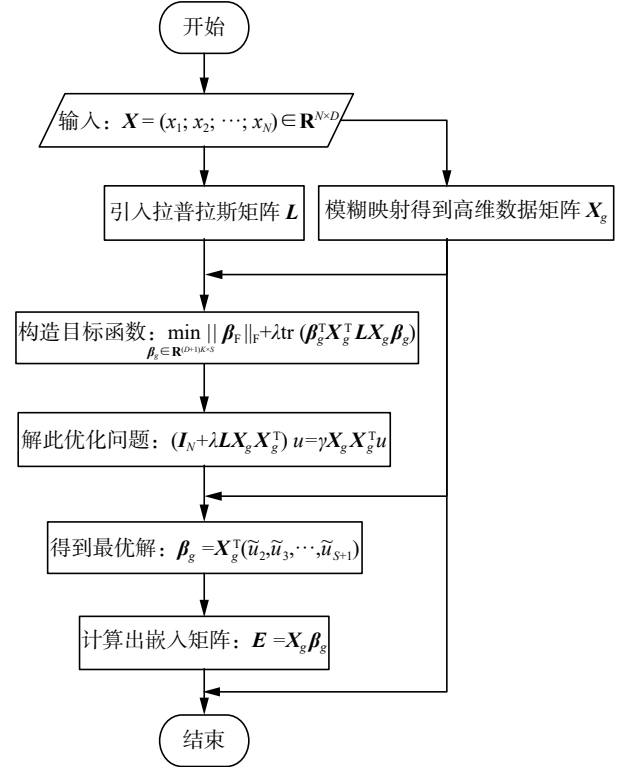


图 2 无监督模糊特征学习流程图

Fig. 2 Flowchart of unsupervised fuzzy feature learning

在模型训练过程中, 本文分别对低阶功能连接数据 $X_{tr}^l = (x_1^{tr,l}, x_2^{tr,l}, \dots, x_N^{tr,l}) \in \mathbb{R}^{N \times D}$ 和高阶功能连接数据 $X_{tr}^h = (x_1^{tr,h}, x_2^{tr,h}, \dots, x_N^{tr,h}) \in \mathbb{R}^{N \times D}$ 采用上述过程进行处理, 分别将它们映射到 S 维的低维空间中去, 记相应的变换矩阵分别为 β_g^l 和 β_g^h , 则低维空间中的嵌入矩阵由式 (17) 和式 (18) 计算而得:

$$E_{tr}^l = (X_{tr}^l)_g \beta_g^l \quad (17)$$

$$E_{tr}^h = (X_{tr}^h)_g \beta_g^h \quad (18)$$

2.4 基于功能连接矩阵的多视角 SVM

基于上述模糊特征学习过程得到低阶和高阶嵌入矩阵 E_{tr}^l 和 E_{tr}^h , 本文采用文献 [16] 中的方法构造 SVM 分类器。对于拟构造的 SVM 分类器, 采用线性核计算其核矩阵 K_{tr}^l 和 K_{tr}^h :

$$K_{tr}^l = E_{tr}^l (E_{tr}^l)^T \quad (19)$$

$$K_{tr}^h = E_{tr}^h (E_{tr}^h)^T \quad (20)$$

使用式 (21) 对核矩阵进行线性组合, 得到最终的复合核矩阵 K_{tr} :

$$K_{tr} = \theta_1 K_{tr}^l + \theta_2 K_{tr}^h \quad (21)$$

式中: θ_1 和 θ_2 是复合核矩阵的组合系数, 满足 $\theta_1 + \theta_2 = 1$ 。

3 实验结果与分析

3.1 性能指标及参数设置

本节通过实验验证本文方法的有效性并与已有方法进行比较。本文选取精确度 (ACC)、AUC

值、敏感度 (SEN)、特异性 (SPE) 作为实验的评价指标, 实验的参数设置使用嵌套五折交叉验证来

进行寻优。相关方法的表述及各参数的详细设置等信息如表 3 所示。

表 3 各算法说明及参数详细设置
Table 3 Details and parameter settings of algorithms

算法名称	算法说明	特征选择	相关参数设置
LOFCC	仅使用低阶功能连接数据进行SVM分类	通过简单特征选择, 得到200维特征	惩罚项系数 $c=\{10^{-6}, 10^{-5}, \dots, 10^5, 10^6\}$ 高斯核带宽 $g=\{10^{-6}, 10^{-5}, \dots, 10^5, 10^6\}$
HOFCC	仅使用低阶功能连接数据进行SVM分类	通过简单特征选择, 得到200维特征	惩罚项系数 $c=\{10^{-6}, 10^{-5}, \dots, 10^5, 10^6\}$ 高斯核带宽 $g=\{10^{-6}, 10^{-5}, \dots, 10^5, 10^6\}$
M2SVC ^[16]	同时使用低阶功能连接数据和高阶功能连接数据进行SVM分类	对每一个视角分别采用简单特征选择, 提取得到200维特征	惩罚项系数 $c=\{10^{-6}, 10^{-5}, \dots, 10^5, 10^6\}$ 高斯核带宽 $g=\{10^{-6}, 10^{-5}, \dots, 10^5, 10^6\}$ 组合系数 $\theta_1=\{0, 0.1, 0.2, \dots, 0.9, 1\}$, $\theta_2=\{1, 0.9, \dots, 0.2, 0.1, 0\}$
UFFM-M2SVC	本文方法	对每一个视角分别采用简单特征选择, 提取得到200维特征	惩罚项系数 $c=\{10^{-6}, 10^{-5}, \dots, 10^5, 10^6\}$ 高斯核带宽 $g=\{10^{-6}, 10^{-5}, \dots, 10^5, 10^6\}$ 尺度参数 $h=\{10^{-6}, 10^{-5}, \dots, 10^5, 10^6\}$ 组合系数 $\theta_1=\{0, 0.1, 0.2, \dots, 0.9, 1\}$, $\theta_2=\{1, 0.9, \dots, 0.2, 0.1, 0\}$ 模糊指数 $k=\{1.2, 1.4, \dots, 2.8, 3.0\}$

本文采用式 (22)~(24) 计算性能指标, 以此进行算法性能评估:

$$ACC = \frac{TP + TN}{TP + FN + TN + FP} \quad (22)$$

$$SEN = \frac{TP}{TP + FN} \quad (23)$$

$$SPE = \frac{TN}{TN + FP} \quad (24)$$

式中: TP 和 TN 分别代表正确分类为自闭症患者的人数和正确分类为正常对照组的人数; FP 和 FN 分别代表正常个体被分类为自闭症患者的人数以及自闭症患者被分类为正常对照组的人数^[17]; 灵敏度 SEN 作为衡量该方法准确预测出自闭症患者的能力的指标; 特异性 SPE 是衡量该方法准确预测出健康个体的能力指标。本文实验使用 LIBSVM^[18] 工具包中的高斯核 SVM。

3.2 分类结果及分析

从表 4 和表 5 中可以看到, UFFM-M2SVC 使用无监督模糊特征映射算法 UFFM 进行特征学习, 在此基础上构造分类器 M2SVC, 可以取得比 LOFCC、HOFCC 及 M2SVC 等传统分类器更好的性能。

M2SVC 算法联合使用两个视角的数据进行分类, 其分类结果要明显优于基于单视角的分类器 LOFCC 和 HOFCC; 而本文方法采用新型的模糊特征学习技术进行特征学习, 在此基础上使用

M2SVC 进行分类, 从而取得了比仅使用 M2SVC 更好的效果, 这表明本文所使用的模糊特征学习技术能够得到更有鉴别能力的特征, 这对自闭症的诊断具有更优的判别能力。

表 4 各算法在自闭症分类中的性能比较 (NYU)
Table 4 The performance comparison of each algorithm in the classification of autism(NYU)

算法	ACC	AUC	SEN	SPE
LOFCC	0.675 7	0.761 9	0.437 5	0.857 1
HOFCC	0.702 7	0.729 2	0.687 5	0.714 3
M2SVC	0.732 2	0.757 7	0.663 2	0.886 2
UFFM-M2SVC	0.783 8	0.824 4	0.660 7	0.823 1

表 5 各算法在自闭症分类中的性能比较 (USM)
Table 5 The performance comparison of each algorithm in the classification of autism(USM)

算法	ACC	AUC	SEN	SPE
LOFCC	0.690 8	0.725 5	0.585 5	0.769 9
HOFCC	0.718 4	0.735 7	0.536 1	0.835 3
M2SVC	0.736 8	0.738 6	0.375 0	0.363 6
UFFM-M2SVC	0.789 5	0.818 2	0.362 5	0.936 4

3.3 特征数目对实验结果的影响

本节研究 UFFM 所提取的特征数目 S 对 M2SVC 性能的影响, 图 3 和图 4 中给出了算法在

数据集 NYU 和 USM 上 S 取不同值时 M2SVC 的分类结果。从图 3 和图 4 可以看出,UFFM-M2SVC 算法的分类准确率随着 S 取值的不同而发生变化,图 3 中最高达到 78.38%,图 4 中最高达到 78.95%,均比 M2SVC 算法提高了约 5%。可知,在特征提取数 S 合理取值的情况下,本文使用 UFFM 进行无监督模糊特征学习,不仅可以有效保留原始有效的特征信息,而且去除了其中包含的冗余信息,使得自闭症患者和正常对照组之间的特征差异更有区分性。




图 3 特征数目对分类结果的影响 (NYU)

Fig. 3 The influence of the number of feature learning on the classification results (NYU)




图 4 特征数目对分类结果的影响 (USM)

Fig. 4 The influence of the number of feature learning on the classification results (USM)

4 结束语

自闭症患者的脑区神经活动异于常人。以此为出发点,本文基于静息态 fMRI 提出了一种面向自闭症辅助诊断的无监督模糊特征学习方法 UFFM,并与 M2SVC 相结合,从而实现了自闭症的辅助诊断。相对于目前传统的分类算法,UFFM-M2SVC 算法训练出的分类模型具有优越且稳定的分类性能。实验结果表明,本文所使用的无监督模糊特征学习方法能够有效地提取出 fMRI 数据中的重要特征,从而有助于自闭症的临床辅助诊断。但是,本文仅基于静息态 fMRI 数据进行实验,针对任务态 fMRI 数据的分类效果还未可知,有待进一步的研究。

参考文献:

[1] DUAN Xujun, CHEN Heng, HE Changchun, et al. Resting-state functional under-connectivity within and between large-scale cortical networks across three low-frequency bands in adolescents with autism[J]. *Progress in neuro-psy-*

chopharmacology and biological psychiatry, 2017, 79: 434–441.

[2] DICKIE E W, AMEIS S H, SHAHAB S, et al. Personalized intrinsic network topography mapping and functional connectivity deficits in autism spectrum disorder[J]. *Biological psychiatry*, 2018, 84(4): 278–286.

[3] 徐云, 杨健. 自闭症早期发现研究进展 [J]. 中国临床心理学杂志, 2014, 22(6): 1023–1027.

XU Yun, YANG Jian. The research progress of the early recognition of autism[J]. *Chinese journal of clinical psychology*, 2014, 22(6): 1023–1027.

[4] BULLMORE E, SPORNS O. Complex brain networks: graph theoretical analysis of structural and functional systems[J]. *Nature reviews neuroscience*, 2009, 10(3): 186–198.

[5] BULLMORE E, SPORNS O. The economy of brain network organization[J]. *Nature reviews neuroscience*, 2012, 13(5): 336–349.

[6] PLIS S M, SUI Jing, LANE T, et al. High-order interactions observed in multi-task intrinsic networks are dominant indicators of aberrant brain function in schizophrenia[J]. *NeuroImage*, 2014, 102: 35–48.

[7] CHEN Xiaobo, ZHANG Han, GAO Yue, et al. High-order resting-state functional connectivity network for MCI classification[J]. *Human brain mapping*, 2016, 37(9): 3282–3296.

[8] MEUNIER D, ACHARD S, MORCOM A, et al. Age-related changes in modular organization of human brain functional networks[J]. *NeuroImage*, 2009, 44(3): 715–723.

[9] DSOUZA A M, ABIDIN A Z, CHOCKANATHAN U, et al. Mutual connectivity analysis of resting-state functional MRI data with local models[J]. *NeuroImage*, 2018, 178: 210–223.

[10] CORTES C, VAPNIK V. Support-vector networks[J]. *Machine learning*, 1995, 20(3): 273–297.

[11] YAN Chaogan, ZANG Yufeng. DPARSF: a MATLAB toolbox for “pipeline” data analysis of resting-state fMRI[J]. *Frontiers in systems neuroscience*, 2010, 4(13): 13.

[12] LAUFS H, DUNCAN J S. Electroencephalography/functional MRI in human epilepsy: what it currently can and cannot do[J]. *Current opinion in neurology*, 2007, 20(4): 417–423.

[13] KESHAVARZI A, SARMADIAN F, SHIRI J, et al. Application of ANFIS-based subtractive clustering algorithm in soil Cation Exchange Capacity estimation using soil and remotely sensed data[J]. *Measurement*, 2017, 95: 173–180.

- [14] DAMAYANTI A. Fuzzy learning vector quantization, neural network and fuzzy systems for classification fundus eye images with wavelet transformation[C]//Proceedings of the 2nd International Conferences on Information Technology, Information Systems and Electrical Engineering (ICITISEE). Wuhan, China, 2017: 331–336.
- [15] DENG Zhaohong, JIANG Yizhang, CHOI K S, et al. Knowledge-leverage-based TSK Fuzzy System modeling[J]. *IEEE transactions on neural networks and learning systems*, 2013, 24(8): 1200–1212.
- [16] ZHANG Daoqiang, WANG Yaping, ZHOU Luping, et al. Multimodal classification of Alzheimer's disease and mild cognitive impairment[J]. *NeuroImage*, 2011, 55(3): 856–867.
- [17] POWERS D M W. Evaluation: from precision, recall and F-factor to ROC, informedness, markedness and correlation[J]. *Journal of machine learning technologies*, 2011, 2(1): 37–83.
- [18] CHANG C C, LIN C J. LIBSVM: a library for support vector machines[J]. *ACM transactions on intelligent systems and technology*, 2011, 2(3): 27.

作者简介:



张英, 女, 1992 年生, 硕士研究生, 主要研究方向为模式识别与数据挖掘。



王骏, 男, 1978 年生, 副教授, 博士, 主要研究方向为智能计算与数据挖掘。主持国家自然科学基金项目 1 项, 江苏省自然科学基金项目 1 项, 申请并获得国家发明专利 5 项。于 2016 年获江苏省高校科研成果自然科学一等奖。发表学术论文 50 余篇。



鲍国强, 男, 1992 年生, 硕士研究生, 主要研究方向为智能计算与模式识别。