

用于阿尔茨海默症分类的模糊逻辑特征选择和异质集成学习方法

韩亮^{*①②} 杨婷^① 蒲秀娟^{①②} 黄谦^①

^①(重庆大学微电子与通信工程学院 重庆 400044)

^②(生物感知与智能信息处理重庆市重点实验室 重庆 400044)

摘要: 阿尔茨海默症(AD)分类有助于在AD早期阶段及时采取针对性的治疗和干预措施,对降低老年群体的AD发病率和延缓AD疾病进展具有重要意义。该文提出一种改进的高斯模糊逻辑特征选择方法,首先采用互信息量和方差齐性分析两种方法给出特征重要性评分并分别进行归一化,然后使用改进的高斯模糊逻辑方法对其加权得到最终的特征重要性评分,最后依据特征重要性评分选取特征。该文还使用逻辑回归、随机森林、LightGBM、支持向量机和深度前馈网络作为初级分类器,多项式朴素贝叶斯分类器作为次级分类器,构建异质集成分类器,利用选取的特征进行AD分类。在TADPOLE数据集上进行实验,实验结果证实了所提特征选择方法是有效的,且采用所提特征选择方法,基于多项式朴素贝叶斯的异质集成分类器在AD分类上的性能要优于传统分类器。

关键词: 阿尔茨海默症; 模糊逻辑; 特征选择; 多项式朴素贝叶斯; 异质集成分类器

中图分类号: TN911.7

文献标识码: A

文章编号: 1009-5896(2021)11-3319-08

DOI: [10.11999/JEIT200963](https://doi.org/10.11999/JEIT200963)

Method on Alzheimer's Disease Classification Utilizing Fuzzy Logic Feature Selection and Heterogeneous Ensemble Learning

HAN Liang^{①②} YANG Ting^① PU Xiujuan^{①②} HUANG Qian^①

^①(School of Microelectronics and Communication Engineering, Chongqing University, Chongqing 400044, China)

^②(Chongqing Key Laboratory of Bio-perception & Intelligent Information Processing, Chongqing 400044, China)

Abstract: Early diagnosis of dementia is critical for timely treatment and intervention. Alzheimer's Disease(AD) classification is an effective method on identifying AD at its early stage. In this paper, a feature selection method using improved Gauss fuzzy logic is proposed. Firstly, the normalized feature importance scores are calculated utilizing mutual information and variance analysis respectively. Then the final feature importance score is obtained by using improved Gauss fuzzy logic. At last, the features for AD classification are selected in accordance with the feature importance score. Furthermore, the heterogeneous ensemble classifier is constructed to classify AD patient utilizing selected features, which using logistic regression, random forest, LightGBM, support vector machine and depth feedforward network as primary classifier and multinomial naive Bayes classifier as secondary classifier. The proposed AD classification method is evaluated on the TADPOLE dataset. The experimental results show that the proposed feature selection method is effective and the integrated classifier based on Bayesian fusion is better than other conventional classification model on AD classification using the proposed feature selection method.

Key words: Alzheimer's Disease(AD); Fuzzy logic; Feature selection; Multinomial naive Bayes; Heterogeneous ensemble classifier

收稿日期: 2020-11-10; 改回日期: 2021-01-31; 网络出版: 2021-03-01

*通信作者: 韩亮 hanliangaa@cqu.edu.cn

基金项目: 重庆市自然科学基金(cstc2016jcyjA0376)

Foundation Item: The Natural Science Foundation of Chongqing (cstc2016jcyjA0376)

1 引言

阿尔茨海默症(Alzheimer's Disease, AD), 俗称老年痴呆症, 是一种慢性的进展性神经退行性疾病, 常发生于老年群体^[1]。迄今为止, 还没有药物能有效治愈AD。因此, AD分类的研究有助于推动

AD预防和治疗手段的进步,降低老年群体的AD发病率,延缓疾病进展。

特征选择能够提升分类模型的性能及鲁棒性,同时可以提供数据的特征重要性解释,已被广泛地应用于AD分类中^[2]。传统的特征选择方法往往采用单一的评价标准,存在较多局限性,为此,本文提出一种改进的高斯模糊逻辑特征选择方法,采用改进的高斯模糊逻辑算法对由互信息量(Mutual Information, MI)和方差齐性分析(ANalysis Of VAriance, ANOVA)两种方法计算得到的特征重要性评分进行加权,在此基础上进行特征选择,以提升AD分类模型性能并进行特征重要性分析。

目前AD分类的常用分类模型包括逻辑回归(Logistic Regression, LR)^[3]、随机森林(Random Forest, RF)^[4]、LightGBM(LGB)^[5]、支持向量机(Support Vector Machine, SVM)^[6]和深度学习(Deep Learning, DL)^[7]等。集成学习可结合使用单个分类器来提高其分类性能,特别适用于各个领域,包括数据挖掘、运输系统、天气预报、医学诊断、银行业务和模式识别。异质集成学习方法^[8]使用不同种类的分类器实现集成学习。本文采用LR, RF, LGB, SVM和深度前馈网络(Deep Feedforward Networks, DFN)作为初级分类器,使用多项式朴素贝叶斯(Multinomial Naive Bayes, MultinomialNB)分类器作为次级分类器,构建异质集成分类器,对经改进的高斯模糊逻辑特征选择方法处理后得到的数据进行AD分类,以提高AD分类的准确率。

2 模糊逻辑特征选择方法

2.1 常用特征选择方法

常用特征选择算法分为过滤法(Filter)、封装法(Wrapper)和嵌入法(Embedded)3类^[2]。其中, Wrapper和Embedded两种特征选择方法均与分类器直接相关,必须使用特定分类器分类后才能得到特征重要性评价结果,且该结果均是针对所使用的特定分类器而言的。Filter法与特定分类器无关,无需事先分类,因此具有更广泛的适应性,本文使用互信息(MI)和方差齐性分析(ANOVA)两种Filter法。

MI是两个变量之间相互依赖的度量,量化了通过观察一个随机变量而获得的关于另一个随机变量的信息量,当且仅当两个随机变量独立时等于0。ANOVA也被称为F检验,它是一种在0假设之下,统计值服从F分布的检验,一般用于检验两类样本在某个特征上是否存在显著性差异。

2.2 改进的高斯模糊逻辑特征选择方法

模糊逻辑提供了一种表示确定程度的方法,可以灵活地处理不确定的问题^[9]。本文提出一种改进的高斯模糊逻辑特征选择方法,具体步骤如下:

步骤1 对输入的数据,由MI与ANOVA两种方法分别计算特征重要性评分。

步骤2 对由MI与ANOVA两种方法计算得到的特征重要性评分结果分别进行归一化,如式(1)和式(2)所示

$$C_{MI}(j) = \frac{S_{MI}(j)}{\sum_{j=1}^M S_{MI}(j)} \quad (1)$$

$$C_F(j) = \frac{S_F(j)}{\sum_{j=1}^M S_F(j)} \quad (2)$$

其中, M 为特征总数;对于第 j 个特征, $S_{MI}(j)$ 为由MI得到的特征重要性评分, $S_F(j)$ 为由ANOVA得到的特征重要性评分, $C_{MI}(j)$ 和 $C_F(j)$ 为归一化后的特征重要性评分。

步骤3 采用模糊逻辑方法对每一特征的两种归一化后的特征重要性评分进行加权,得到最终的特征重要性评分 $C(j)$,如式(3)所示

$$C(j) = \eta_{MI}C_{MI}(j) + \eta_F C_F(j) \quad (3)$$

其中, η_{MI} 和 η_F 分别是MI评分和ANOVA评分对应的高斯隶属度。

根据MI评分的均值 μ_{MI} 和方差 σ_{MI} 计算出它的高斯隶属度 T_{MI}

$$T_{MI} = \exp\left(-\frac{(C_{MI}(j) - \mu_{MI})^2}{2\sigma_{MI}^2}\right) \quad (4)$$

根据ANOVA评分的均值 μ_F 和方差 σ_F 计算出它的高斯隶属度 T_F

$$T_F = \exp\left(-\frac{(C_F(j) - \mu_F)^2}{2\sigma_F^2}\right) \quad (5)$$

本文采用一种改进方法计算高斯隶属度,具体为

$$\eta_{MI} = \frac{1 - T_F + T_{MI}}{2} \quad (6)$$

$$\eta_F = \frac{1 + T_F - T_{MI}}{2} \quad (7)$$

η_{MI} 为最终得到MI评分的高斯隶属度, η_F 为最终得到的ANOVA评分的高斯隶属度。采用该改进方法计算高斯隶属度,充分考虑了两种高斯隶属度计算方法的重要性等同,实质上是对以MI评分为基础和以ANOVA评分为基础计算得到的高斯隶属度进行了平均加权。

步骤4 依据步骤3计算出的特征重要性评分选择特征。

3 基于多项式朴素贝叶斯融合的AD分类方法

3.1 AD分类常用分类器

目前AD分类常用分类器有逻辑回归(LR)、随机森林(RF)、LightGBM(LGB)、支持向量机(SVM)和深度前馈网络(Deep Feedforward Networks, DFN)等。LR能够评估输入特征与输出结果的关联程度,但是它通常假设输入特征是相互独立的,这在实际情况中难以完全满足。RF^[10]以决策树(Decision Tree, DT)为基学习器,并在DT的训练过程中引入了随机属性选择,具有简单、容易实现、计算开销小的优点,但是RF容易过拟合且不稳定。LGB采用基于梯度的单边采样和互斥特征捆绑在不损失分类精度的同时提升了计算效率。但也存在容易过拟合的问题。SVM^[11]具有较强的逼近能力和泛化能力,但需要大量的计算机资源,且存在数值不稳定的问题。DFN是典型的深度学习模型,与人工神经网络等浅层机器学习方法相比,它具有更好的非线性估计性能,但存在确定最佳架构和调整超参数困难等缺陷^[8]。

3.2 朴素贝叶斯分类器

朴素贝叶斯分类器假定样本每个特征与其他特征都不相关^[12],因此可以分别学习每个属性的参数,这极大地简化了学习。朴素贝叶斯分类器使用条件概率确定具有特定类别的实例的概率,以此确定实例所属类的概率,并将概率最大的类标记为该实例所属类。高斯朴素贝叶斯(Gaussian Naive Bayes, GaussianNB)和多项式朴素贝叶斯(MultinomialNB)是常用的两种朴素贝叶斯分类器。MultinomialNB适用于离散变量,假设各个特征在各个类别下服从多项式分布,因此每个特征值不能是负数,计算概率为

$$P(x_i | y_k) = \frac{N_{y_k x_i} + \alpha}{N_{y_k} + \alpha n} \quad (8)$$

其中, $N_{y_k x_i}$ 表示特征 x_i 在类别为 y_k 的样本中出现的次数; N_{y_k} 表示类别为 y_k 的样本中,所有特征出现的次数; α 表示平滑系数,取值为1时为拉普拉斯平滑(Laplace smoothing); n 表示特征数量。

3.3 基于多项式朴素贝叶斯融合的异质集成学习

集成学习将多个初级分类器的输出组合起来,以获得更好的预测或分类精度。异质集成学习^[8]的初级分类器使用不同的学习算法,它利用初级分类器的多样性来增加不同错误类型的概率,以提高整

体预测精度。堆叠法是一种用于异质集成学习的常用融合策略,具有较好的鲁棒性,它首先使用初始数据集训练初级分类器,然后“生成”一个新数据集用于训练次级分类器,在这个新数据集中,初级分类器的输出作为次级分类器的输入,而初始样本的标签仍作为样本标签^[13]。

多个分类器融合的方法能胜过单个分类器方法的原因在于其分类决策是基于分类器的组合^[13]。集成多样性是指分类器之间的差异,初级分类器的多样性越高,其集成学习的性能越好。由3.1节的分析可知,LR, RF, LGB, SVM和DFN分类器已成功地应用于AD分类,具有一定的精确性,但均存在各自不同的缺陷。LR基于回归模型,RF和LGB均基于决策树学习模型,SVM基于统计学习模型,DFN基于深度学习模型,本文选择LR, RF, LGB, SVM和DFN分类器作为初级分类器,具有较高的多样性,有利于克服单一分类器存在的缺陷,以提高分类精度。本文所提多项式朴素贝叶斯融合异质集成分类器如图1所示。

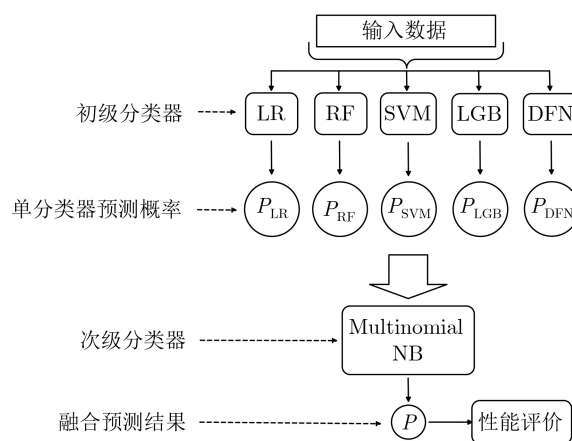


图1 多项式朴素贝叶斯融合异质集成分类器

具体步骤如下:

步骤1 首先将输入数据作为原始训练集数据,分别训练各个初级分类器,得到训练好的LR, RF, SVM, LGB, DFN分类器;

步骤2 再次将输入数据分别输入到训练好的LR, RF, SVM, LGB, DFN分类器,得到各个初级分类器输出的预测概率 $P_{LR}, P_{RF}, P_{SVM}, P_{LGB}, P_{DFN}$;

步骤3 将各个初级分类器输出的预测概率 $P_{LR}, P_{RF}, P_{SVM}, P_{LGB}, P_{DFN}$ 和个体对应的真实标签组合成新的训练集数据,采用该数据训练次级分类器,得到训练好的MultinomialNB分类器;

步骤4 将训练好的初级分类器LR, RF, SVM, LGB, DFN和次级分类器MultinomialNB按

图1的方式组合起来, 构建多项式朴素贝叶斯融合异质集成分类器。

本文所提基于多项式朴素贝叶斯融合的AD分类方法, 首先对AD数据进行颅内体积标准化和Z-score标准化^[1]; 然后使用2.2节提出的改进的高斯模糊逻辑特征选择方法对预处理后的AD数据集进行特征选择; 最后采用本节所述基于多项式朴素贝叶斯融合的AD分类器实现AD分类。

4 实验结果与分析

4.1 实验数据

TADPOLE^[14]挑战赛数据集隶属于ADNI, 旨在为阿尔茨海默症(AD)分类与预测研究提供标准数据集, 它包含119个大脑皮层与皮层下的感兴趣区域体积特征, 特征标签及描述见Cross-Sectional FreeSurfer (6.0)^[15]。由于AD患者在特定脑结构的体积上会发生明显变化, 因此本文采用TADPOLE挑战赛数据集中D1和D2数据集中的体积特征作为AD分类的特征。首先去掉D1与D2中个体相同的数据, 得到新的D1数据集(正常/AD:453/628)作为训练集; D2(正常/AD:563/52)作为测试集; 其中, 同一个体的不同时间点的数据视为不同样本。

4.2 实验结果与分析

本文实验所使用的计算机CPU为AMD Ryzen3 2200 G @3.5 GHz, 内存为16 GB, 操作系统为Windows10, 编程工具为Python, 机器学习库使用Scikit-learn和Lightgbm3.3.0。所有实验均使用如4.1节所述TADPOLE挑战赛数据集。所使用的DFN分类器4个隐藏层单元数分别为70, 80, 100和120。利用网格搜索法对LR的l1_ratio参数、RF的n_estimators和max_depth参数、SVM的C和gamma参数以及LGB的max_depth参数进行寻优。各分类器其余参数均使用默认值。

本文使用正确率(ACCuracy, ACC)、精确率(PREcision, PRE)、召回率(RECall, REC)、F1分数、AUC 5个指标对分类模型进行综合评价^[5,7]。ACC, PRE, REC, F1分数和AUC越高, 说明分类器性能越好。

4.2.1 特征选择实验

采用如2.2节所述改进的高斯模糊逻辑特征选择方法进行实验, 对应特征重要性评分排序前10的特征如表1所示。

实验结果表明与AD分类相关的皮层及皮层下体积特征主要集中于海马体、内嗅皮层、颞叶、杏仁核这几个区域, 左侧结构比右侧相应结构重要性更高, 这与前期的医学研究得到的结论是一致的。但是, 在左侧和右侧分别存在一个具有高特征重要性评分的未定义区域, 其医学意义有待医学专家进一步深入研究。

按特征重要性评分由高到低对特征进行排序, 分别选择特征重要性排序最高的前10%~100%数量的特征, 采用第3节所述基于多项式朴素贝叶斯融合的AD分类方法进行AD分类实验, 结果如图2所示。

由图2可知, AD分类的正确率(ACC)随特征数量占比增大整体呈先上升、后下降的趋势, 在特征数量占比为0.7时, 所选取特征的累计特征重要性评分高达0.96, 此时AD分类的ACC达到最高。这说明筛选部分特征重要性评分较低的特征后, 分类性能反而有所上升, 本文所提改进的高斯模糊逻辑特征选择方法是有效的。此外, 有很大比例的排序靠后的特征的重要性评分极低, 这一部分特征对AD分类价值不高。

4.2.2 融合策略实验

采用2.2节所述改进的高斯模糊逻辑特征选择方法进行特征选择, 采用第3节所述AD分类方法,

表1 特征重要性评分排序前10的特征

序号	特征标签	特征说明	特征重要性评分
1	Hippocampus	海马体(hippocampus)体积	0.0437339
2	ST29SV	左海马体(left hippocampus)体积	0.0423217
3	ST88SV	右海马体(right hippocampus)体积	0.0410883
4	Entorhinal	内嗅皮层(entorhinal)体积	0.0375120
5	MidTemp	中颞叶(Midtemp)体积	0.0304293
6	ST123CV	右侧未定义区域(皮层分割)体积	0.0302178
7	ST64CV	左侧未定义区域(皮层分割)体积	0.0300861
8	ST24CV	左内嗅皮层(left entorhinal)体积	0.0296456
9	ST12SV	左杏仁核(left amygdala)体积	0.0286703
10	ST40CV	左中颞叶(left middle temporal)体积	0.0281707




图 2 不同特征数量占比下累计特征重要性评分与分类精度

使用不同融合策略进行对比实验，对比的融合策略包括平均法、投票法、高斯朴素贝叶斯方法和本文提出的AD分类方法使用的多项式朴素贝叶斯(MultinomialNB)方法，实验结果如图3所示。

由图3可知，在不同特征数量占比的情况下，MultinomialNB融合策略在正确率(ACC)和召回率(REC)上均明显优于Average, Vote和GaussianNB策略。4种融合策略的精确率(PRE)在不同特征数量占比下的差异均小于1%，差距极小。尽管在PRE上MultinomialNB融合策略与其他3种方法相比略小，但它的ACC, REC, F1分数和AUC均上明显优于其他3种策略，这表明本文采用的MultinomialNB融合策略是有效的，且性能较好。

此外，随特征数量占比的增大，各融合策略下分类评价指标均有不同程度变化。在MultinomialNB融合策略下，ACC, REC和F1分数整体均是先

明显上升，在特征数量占比为0.7时达到最大值后开始逐渐下降；PRE和AUC虽在特征数量占比为0.5时出现震荡，但整体也是呈现先升后降的趋势，且在特征数量占比为0.6时达到最大值。

4.2.3 分类方法对比实验

采用第3节所述AD分类方法和传统的LR^[7], RF^[8], SVM^[9], LGB^[10], DFN^[11]进行AD分类实验，实验结果如图4所示。由图4可知：在不同特征数量占比的情况下，本文所提MultinomialNB融合异质集成分类器在正确率(ACC)和召回率(ACC)上均明显优于传统的LR, RF, SVM, LGB, DFN分类器。MultinomialNB融合异质集成分类器与其他5种分类器的精确率(PRE)在不同特征数量占比的情况下都表现十分良好且极为接近，它们之间的差异小于2%，且在F1分数和AUC上相对与其他5种传统分类器也有较大优势，这说明MultinomialNB融合异质集成分类器是有效的，其在不同特征数量占比下AD分类性能均明显优于传统的LR, RF, SVM, LGB, DFN分类器。

4.2.4 特征重要性分析方法对比实验

Wrapper法和Embedded法均与分类器相关，用于特征选择的分类器与最终使用的分类器相同时，理论上分类效果最好。采用2.2节所述改进的高斯模糊逻辑特征选择方法分别结合LR和LGB分类器，Wrapper-LR和Embedded-LR特征选择方法^[2]分别结合LR分类器，Wrapper-LGB和Embedded-LGB特征选择方法^[2]分别结合LGB分类器进行对比实验，实验结果如图5所示。

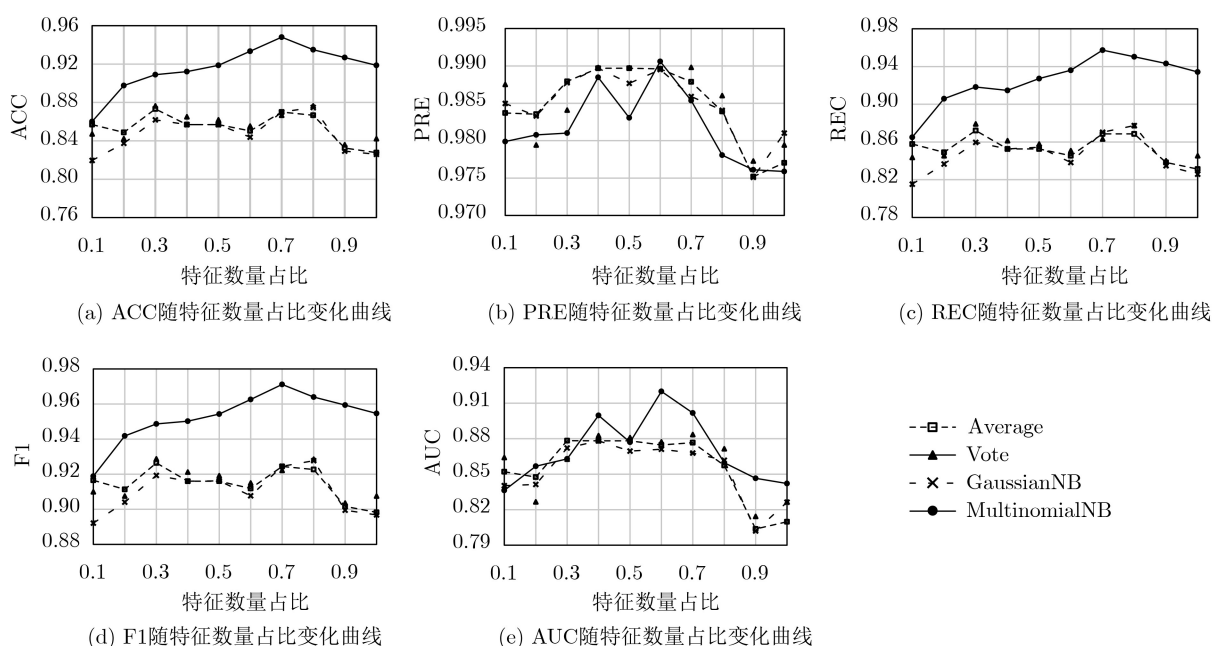
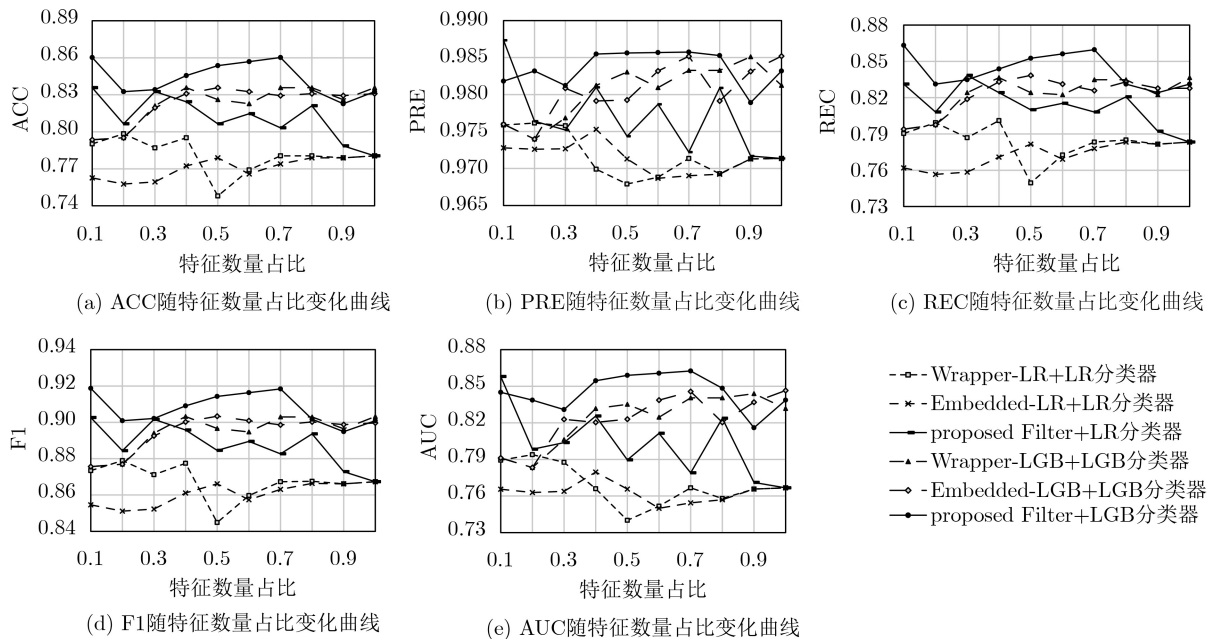
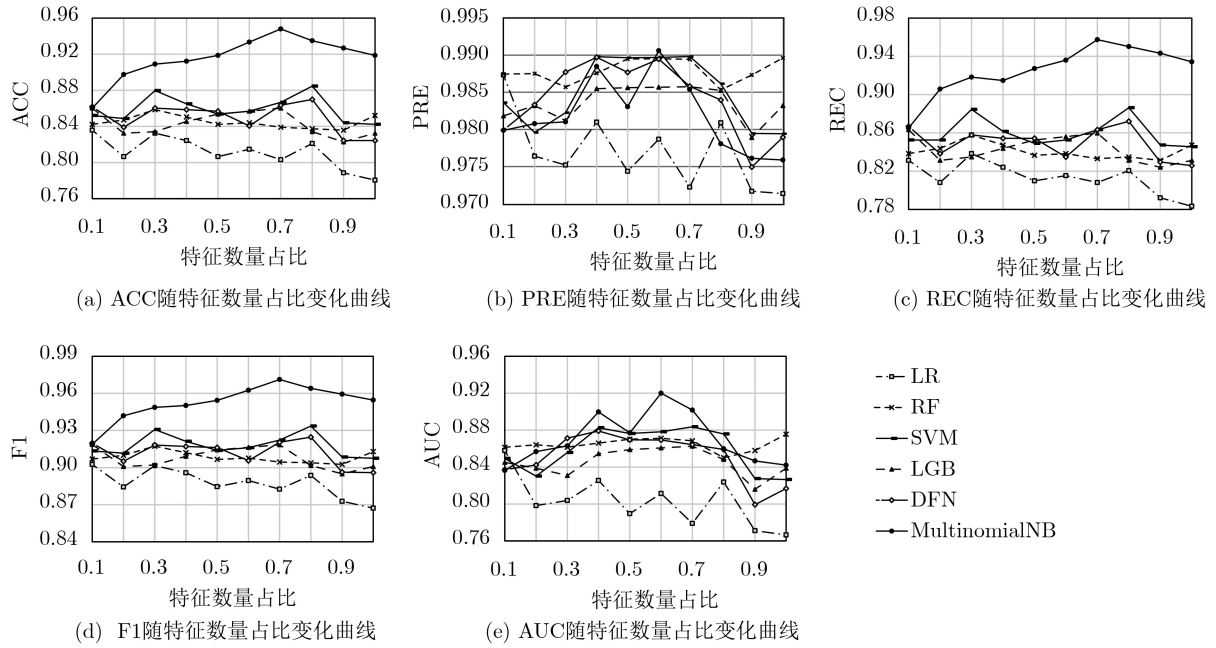


图 3 不同融合策略对比实验



由图5可知，在不同特征数量占比的情况下，本文所提改进的高斯模糊逻辑特征选择方法结合LGB分类器的AD分类性能最优；且本文提出的改进的高斯模糊逻辑特征选择方法结合LR分类器的AD分类性能均明显优于Wrapper-LR和Embedded-LR分别结合LR分类器。因此，本文所提改进的高斯模糊逻辑特征选择方法性能优于Wrapper和Embedded特征选择方法。

进一步采用本文所提改进的高斯模糊逻辑特征选择方法Wrapper-LR, Embedded-LR, Wrapper-

LGB, Embedded-LGB分别进行特征选择，再使用SVM分类器进行AD分类实验，实验结果如图6所示。

由图6可知，在不同特征数量占比的情况下，本文所提改进的高斯模糊逻辑特征选择方法使用SVM作为分类器用于AD分类的性能最优。这充分表明本文所提改进的高斯模糊逻辑特征选择方法能有效克服Wrapper法和Embedded法固有的与分类器紧密相关的缺陷，更适合应用于各种不同的分类器。

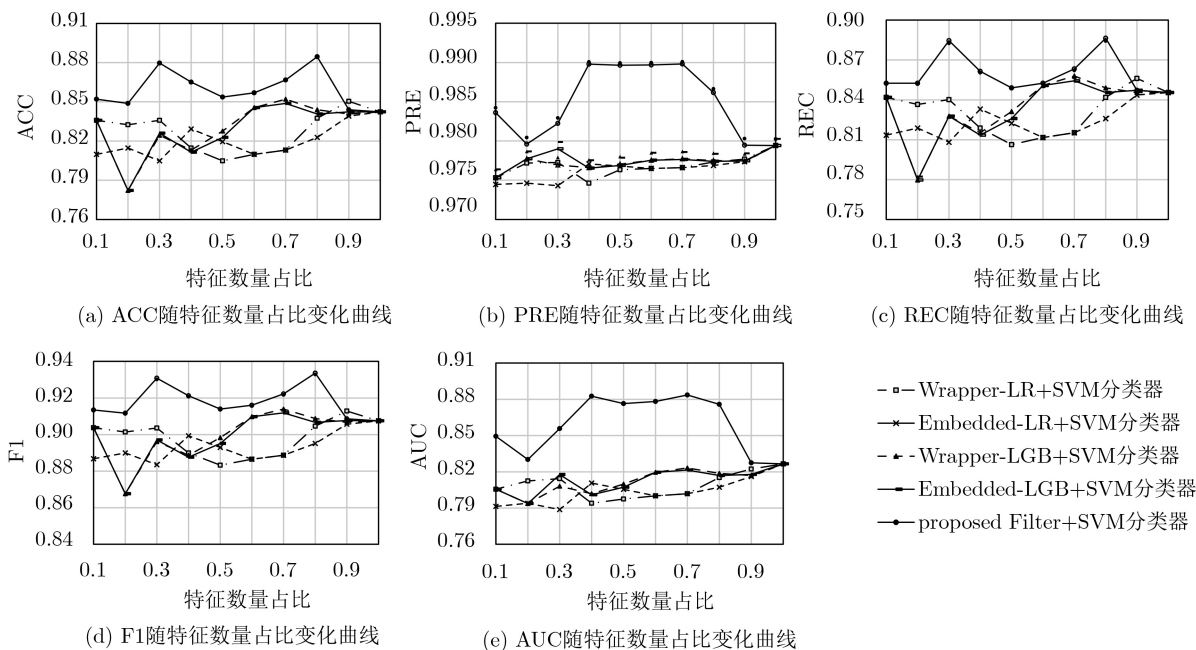


图 6 特征选择方法对比实验2

综上所述，本文所提改进的高斯模糊逻辑特征选择方法在各种分类器上均能够明显提升AD分类效果，其性能优于传统的Wrapper和Embedded特征选择方法。

4.2.5 时间复杂度分析

采用2.2节所述的高斯模糊逻辑特征选择方法确定AD分类所使用的特征后，初级分类器LR, RF, SVM, LGB和DFN、次级分类器MultinomialNB和本文所提多项式朴素贝叶斯融合异质集成分类器的训练时间如表2所示。

由表2可知，在初级分类器训练中，LR训练所用时间最短；SVM, RF和LGB训练所用时间比LR高1个数量级，且LGB比RF训练所用时间稍短；DFN训练所用时间最长。次级分类器MultinomialNB训练所用时间仅为0.0001 s。异质集成分类器时间复杂度依赖于初级分类器与次级分类器的时间复杂度，本文提出的多项式朴素贝叶斯融合异质集成分类器训练所用时间为各初级分类器与次级分类器训练所用时间之和，即2.9641 s。

表 2 分类器时间复杂度分析

分类器	训练所用时间(s)
LR	0.0468
RF	0.6396
SVM	0.3744
LGB	0.6084
DFN	1.2948
MultinomialNB	0.0001
多项式朴素贝叶斯融合异质集成分类器	2.9641

综上所述，本文所提以LR, RF, SVM, LGB和DFN作为初级分类器，MultinomialNB作为次级分类器的异质集成分类器训练所用时间主要集中在初级分类器上，MultinomialNB作为次级分类器训练所用时间极短，总体训练所用时间不超过3 s，其时间复杂度较低。

5 结论

本文提出一种结合改进的高斯模糊逻辑特征选择和多项式朴素贝叶斯融合异质集成分类器的分类方法，先采用改进的高斯模糊逻辑特征选择方法对AD数据集进行特征选择，再采用多项式朴素贝叶斯融合异质集成分类器进行AD分类。使用TAD-POLE数据集进行实验，实验结果表明，在AD分类上，本文所提改进的高斯模糊逻辑特征选择方法的性能优于Wrapper和Embedded法，且多项式朴素贝叶斯模型融合异质集成分类器的性能优于传统的LR, RF, SVM, LGB, DFN分类方法，本文所提方法更适用于AD分类。

参考文献

[1] LEANDROU S, PETROUDI S, KYRIACOU P A, et al. Quantitative MRI brain studies in mild cognitive impairment and Alzheimer's disease: A methodological review[J]. *IEEE Reviews in Biomedical Engineering*, 2018, 11: 97-111. doi: 10.1109/rbme.2018.2796598.

[2] BASKAR D, JAYANTHI V S, and JAYANTHI A N. An efficient classification approach for detection of Alzheimer's disease from biomedical imaging modalities[J]. *Multimedia*

- Tools and Applications*, 2019, 78(10): 12883–12915. doi: [10.1007/s11042-018-6287-8](https://doi.org/10.1007/s11042-018-6287-8).
- [3] ADANI G, FILIPPINI T, GARUTI C, *et al.* Environmental risk factors for early-onset Alzheimer’s dementia and frontotemporal dementia: A case-control study in northern Italy[J]. *International Journal of Environmental Research*, 2020, 17(21): 7941. doi: [10.3390/ijerph17217941](https://doi.org/10.3390/ijerph17217941).
- [4] BYEON H. A prediction model for mild cognitive impairment using random forests[J]. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 2015, 6(12): 8–12. doi: [10.14569/IJACSA.2015.061202](https://doi.org/10.14569/IJACSA.2015.061202).
- [5] NORI V S, HANE C A, CROWN W H, *et al.* Machine learning models to predict onset of dementia: A label learning approach[J]. *Alzheimer’s & Dementia: Translational Research & Clinical Interventions*, 2019, 5(1): 918–925. doi: [10.1016/j.trci.2019.10.006](https://doi.org/10.1016/j.trci.2019.10.006).
- [6] DYRBA M, BARKHOF F, FELLGIEBEL A, *et al.* Predicting prodromal Alzheimer’s disease in subjects with mild cognitive impairment using machine learning classification of multimodal multicenter diffusion-tensor and magnetic resonance imaging data[J]. *Journal of Neuroimaging*, 2015, 25(5): 738–747. doi: [10.1111/jon.12214](https://doi.org/10.1111/jon.12214).
- [7] IERACITANO C, MAMMONE N, HUSSAIN A, *et al.* A novel multi-modal machine learning based approach for automatic classification of EEG recordings in dementia[J]. *Neural Networks*, 2020, 123: 176–190. doi: [10.1016/j.neumet.2019.12.006](https://doi.org/10.1016/j.neumet.2019.12.006).
- [8] PHAM K, KIM D, PARK S, *et al.* Ensemble learning-based classification models for slope stability analysis[J]. *CATENA*, 2021, 196: 104886. doi: [10.1016/j.catena.2020.104886](https://doi.org/10.1016/j.catena.2020.104886).
- [9] MA J, CHEN S, and XU Y. Fuzzy logic from the viewpoint of machine intelligence[J]. *Fuzzy Sets and Systems*, 2006, 157(5): 628–634. doi: [10.1016/j.fss.2005.10.008](https://doi.org/10.1016/j.fss.2005.10.008).
- [10] 褚征, 于炯. 基于随机森林的流处理检查点性能预测[J]. 电子与信息学报, 2020, 42(6): 1452–1459. doi: [10.11999/JEIT190552](https://doi.org/10.11999/JEIT190552).
- CHU Zheng and YU Jiong. Performance prediction based on random forest for the stream processing checkpoint[J]. *Journal of Electronics & Information Technology*, 2020, 42(6): 1452–1459. doi: [10.11999/JEIT190552](https://doi.org/10.11999/JEIT190552).
- [11] 钱亚冠, 卢红波, 纪守领, 等. 基于粒子群优化的对抗样本生成算法[J]. 电子与信息学报, 2019, 41(7): 1658–1665. doi: [10.11999/JEIT180777](https://doi.org/10.11999/JEIT180777).
- QIAN Yaguan, LU Hongbo, JI Shouling, *et al.* Adversarial example generation based on particle swarm optimization[J]. *Journal of Electronics & Information Technology*, 2019, 41(7): 1658–1665. doi: [10.11999/JEIT180777](https://doi.org/10.11999/JEIT180777).
- [12] BAGUI S, DEVULAPALLI K, and JOHN S. MapReduce implementation of a multinomial and mixed naive Bayes classifier[J]. *International Journal of Intelligent Information Technologies (IJIT)*, 2020, 16(2): 1–23. doi: [10.4018/ijit.2020040101](https://doi.org/10.4018/ijit.2020040101).
- [13] KHAIRALLA M A, NING X, AL-JALLAD N T, *et al.* Short-term forecasting for energy consumption through stacking heterogeneous ensemble learning model[J]. *Energies*, 2018, 11(6): 1605. doi: [10.3390/en11061605](https://doi.org/10.3390/en11061605).
- [14] MARINESCU R V, OXTOBY N P, YOUNG A L, *et al.* TADPOLE challenge: Prediction of longitudinal evolution in Alzheimer’s disease[J]. arXiv: 1805.03909v2, 2018.
- [15] ADNI. Cross-sectional FreeSurfer (6.0)[EB/OL]. <https://adni.bitbucket.io/reference/ucsf6.html>, 2020.
- 韩亮: 男, 1975年生, 副教授, 博士, 研究方向为信号处理和图像处理.
- 杨婷: 女, 1996年生, 硕士生, 研究方向为生物医学信号处理.
- 蒲秀娟: 女, 1979年生, 讲师, 博士, 研究方向为生物医学信号处理.
- 黄谦: 男, 1998年生, 硕士生, 研究方向为信号与信息处理.

责任编辑: 余蓉