

DOI:10.19651/j.cnki.emt.2211787

基于融合特征与优化随机森林的眼动模式识别

沈胤宏^{1,2} 郑秀娟^{1,2} 张畅^{1,2}

(1. 四川大学电气工程学院 成都 610065; 2. 信息与自动化技术四川省高校重点实验室 成都 610065)

摘要:为充分挖掘眼动模式信息,最大限度优化模型效果,提高眼动模式识别准确率,本文提出了一种基于融合特征与优化随机森林的眼动模式识别方法。首先提取常规眼动特征、眼动序列子模式特征、视线点高斯分布特征3组特征参数,结合ReliefF选择重要的特征,建立融合特征矩阵,然后以随机森林为基础,使用粒子群算法对模型参数全局寻优,建立优化随机森林眼动模式识别模型。通过自闭症患者眼动实验公开数据集验证本文所提方法的有效性,实验结果表明所提方法能较好区分正常人和自闭症患者之间的眼动模式差异,相较于常规眼动特征随机森林的分类准确率提升了9.57%。因此,融合特征能更好的挖掘眼动模式包含的信息,粒子群算法能有效优化模式识别模型效果,为眼动模式识别提供了新思路与方法。

关键词:融合特征;眼动模式;粒子群算法;随机森林

中图分类号:TP181;R318 文献标识码:A 国家标准学科分类代码:310.61

Eye movement pattern recognition based on fused features and optimized random forest

Shen Yinzhong^{1,2} Zheng Xiujuan^{1,2} Zhang Chang^{1,2}

(1. College of Electrical Engineering, Sichuan University, Chengdu 610065, China;

2. Key Laboratory of Information and Automation Technology of Sichuan Province, Chengdu 610065, China)

Abstract: To fully exploit the eye movement pattern information, maximize the optimization model effect and improve the eye movement pattern recognition accuracy, this paper proposes an eye movement pattern recognition method based on fused features and optimized random forest. First, we extract three groups of feature parameters: Conventional eye movement features, eye movement sequence sub-pattern features, and gaze points gaussian distribution features, combine them with ReliefF to select important features and build a fused features matrix. Then we use the particle swarm algorithm to globally seek the model parameters based on random forest to build the optimized random forest eye movement pattern recognition model. We verify the effectiveness of the proposed method by using the open dataset of eye movement experiments of autistic patients, and the experimental results show that the proposed method can better distinguish the difference of eye movement patterns between normal and autistic patients, and the classification accuracy is improved by 9.57% compared with the random forest of Conventional eye movement features. Therefore, the fused features can better exploit the information contained in the eye movement patterns, and the particle swarm algorithm can effectively optimize the effect of the pattern recognition model, which provides a new idea and method for eye movement pattern recognition.

Keywords: fused features; eye movement pattern; particle swarm optimization algorithm; random forest

0 引言

人类通过视觉与世界互动,但无法处理周围环境提供的所有视觉信息,而是将注意力依次分配到环境中最相关的部分或最感兴趣的部分,这个过程发生的一连串眼球运

动行为称为眼动,眼动受到自下而上(观察内容特征,如颜色、亮度、大小等)、和自上而下的影响(观察者年龄、兴趣爱好、认知和思维方式、健康状态等)^[1]。因此可以利用眼动模式差异分析驾驶^[2]、阅读^[3]等不同任务下的认知差异;也可以利用眼动模式差异量化精神负荷、进行疾病筛查^[4-5]。

目前,已经可以利用眼动仪来观察和采集眼动模式信息^[6]。眼动模式表现为序列的形式,由具有时间先后顺序的视线点(x, y)坐标组成。近年来,许多学者相继提出了不同的眼动模式特征提取方案,其中最常用的眼动特征提取方法是提取注视和眼跳等相关信息,如文献[7]设计了VR场景中的眼动追踪实验,该研究通过注视点的个数、时间占比以及景观之间的转移等特征构建了自闭症检测系统模型,提出了一种快速客观的自闭症早期筛查方法;文献[8]将眨眼次数,注视方向和时间等特征用于疲劳驾驶的检测。注视内容和眼跳过程在一定程度上可以反映观察者的注意力分布以及观察时间等,但是无法描述观察者注意力转移的过程。有相关研究提出将眼动序列量化为字符串的形式,通过序列比对算法分析眼动模式差异^[9 10],但这种方法需要对眼动序列进行两两比对,在样本数量庞大的情况下,时间复杂度过高。文献[11]在此基础上将字符串模式的频率作为特征值,使用支持向量机构建眼动模式识别模型。通过字符串模式的方法提取眼动特征可以同时挖掘眼动模式中的注意力位置信息和注意转移信息,但是无法反映人的注意力整体分布情况。因此,一些学者对人的注意力整体分布情况进行建模,使用模型参数来分析不同眼动模式的差异,如文献[12]使用混合高斯模型来描述注意力的整体分布情况;文献[13]使用混合高斯确定隐马可夫的隐状态数量,然后使用隐马可夫模型来描述观察者的注意力转移情况。建模的方式可以从整体刻画人的注意力分布情况,但无法细致刻画感兴趣区域的注视情况,眼动序列视线点使用数量较少的隐状态进行表示也只能大体描述观察者的注意力转移情况而无法细致刻画注意力转移情况。

眼动模式信息可以从多种角度进行分析,前人的研究大都从单一的角度进行特征提取,无法充分挖掘眼动模式包含的信息。因此在前人研究的基础上,本文提取眼动模式的常规眼动特征来细致刻画观察者的注意力分布情况,提取眼动序列子模式特征来描述观察者的注意力转移情况,通过对视线点分布进行混合高斯建模,使用模型参数描述观察者的注意力整体分布情况,本文提出将3组特征参数组成融合特征矩阵,通过融合特征最大限度挖掘眼动模式包含的信息,利用随机森林鲁棒性强,稳定性好的特性^[14-15],建立随机森林(random forests, RF)眼动模式识别模型。同时,使用ReliefF算法^[16]优化特征选取,去除无用特征。为解决RF模型效果受参数影响较大的问题,本文引入粒子群算法(particle swarm optimization, PSO)^[17]获取随机森林的全局最优参数,建立基于粒子群的优化随机森林(particle swarm optimization random forest, PSO-RF)模型^[18]进行眼动模式识别。在自闭症患者眼动实验公开数据集上的实验结果显示,融合特征的分类表现优于单组特征,PSO-RF模型的分类表现优于RF模型,证明了本文方法的有效性,为眼动模式识别提供了新的参考。

1 融合特征提取

1.1 常规眼动特征

注视的持续时间和位置是描述眼神经系统行为的两个基本注视特征(F01~F20,如表1所示)^[19],人在观察时的信息主要是在注视期间获得。在观察过程中,这些特征可用于检查由各个方面共同调节的认知功能,如注视时间被认为是字词识别中语义激活阶段的良好指标,反映了观察者对当前内容的加工程度;注视位置则反映了被试感兴趣区域的位置分布。

表1 眼动特征详细信息

特征标号	特征含义
F01~F02	注视点个数、注视总时长
F03~F07	首次注视的坐标与时长、与图像中心的距离、相对时长
F08~F12	最后一次注视的信息,与首次注视类似
F13~F17	最长注视时长注视点的信息,与首次注视类似
F18~F20	平均注视时长、注视总长度、平均视线点转移距离
F21~F24	眼跳个数、时间、总长、最大幅度
F25~F27	平均一次眼跳距离、眼跳距离分布方差、平均眼跳速度
F28~F29	感兴趣区域个数、回视次数
F30~F33	第1次回视的信息
F34~F37	最后一次回视的信息
F38~F43	最高次数回视的信息
F44~F46	回视时间信息

眼跳是指眼睛在两个注视点之间转移的过程(F21~F27,如表1所示)。眼跳时间与眼跳幅度相关,幅度越大眼跳时间越长。眼跳是非常快速的运动,将眼睛从一个注

视区域移动到另一个注视区域,眼跳特征反映了人注意转移的能力。

在观察时眼跳通常是从一个已知位置朝向一个新的

未知区域,但有时会出现相反的眼跳,即回视(F28~F46,如表 1 所示)。回视是观察过程中另一个重要的眼动组成部分,大多数回视是针对紧邻的前一个注视区域,然而当观察者对信息理解不充分或信息太难时,回视会指向较早注视的区域回视次数的多少反映了感兴趣程度或信息理解难易程度。

1.2 眼动序列子模式特征

眼动序列中视线点(x, y)之间的转移表征了观察者的注意力转移过程,因此本文提出对眼动序列提取子模式特征来描述眼动模式顺序上的差异。首先使用网格法对眼动序列进行量化,每个格子的视线点使用对应的字符进行替代。字符化过程是一个数据降维过程,可以消除眼动序列因被试头部移动等因素造成的影响,简化眼动序列的分析,同时保留了眼动序列原本的空间信息和时间信息。字符化过程如图 1 所示。

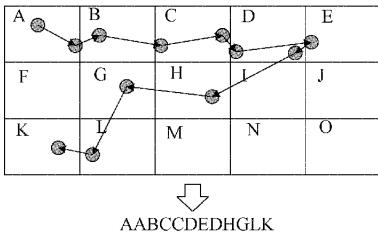


图 1 眼动路径字符化

不同时间尺度的眼动序列代表不同的眼动模式,当时尺度为 1 时表示包含当前视线点空间信息的子模式,当时尺度为 2 时的眼动模式为两个视线点之间的转移,当时尺度为 n 时,眼动模式表示 n 个视线点之间的转移。时间尺度越大,子模式特征包含的信息越充分,但是会导致特征数量呈指数增长,产生大量杂质稀疏特征^[20],本文按经验选取子模式的时间尺度为 3。

在计算眼动序列子模式特征之前,本文首先使用滑动窗口对眼动序列进行子模式特征的提取,构建大小为 w 的时间窗口,按步长为 3 的速度进行滑动,如图 2 所示。

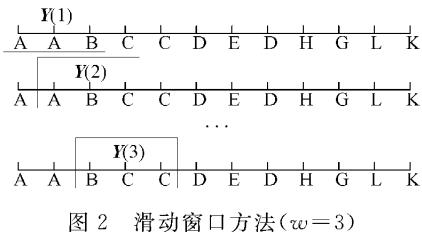


图 2 滑动窗口方法($w=3$)

假定长为 N 的字符序列为 \mathbf{X} , 使用大小为 w 的滑动窗口提取子模式,则子模式特征 $\mathbf{Y}(i)$ 为:

$$\mathbf{Y}(i) = [\mathbf{X}(i), \mathbf{X}(i+1), \dots, \mathbf{X}(i+w-1)] \quad (1)$$

式中: $i = 1, 2, \dots, N-w+1$ 。

为了反映不同眼动序列之间的差异,本文统计子模式出现的频率作为特征值,则眼动序列子模式特征 $\mathbf{Y}(i)$ 对应

的特征值为:

$$f(i) = \frac{\mathbf{Y}(i)}{\sum_{i=1}^{N-w+1} \mathbf{Y}(i)} \quad (2)$$

1.3 视线点高斯分布特征

对眼动序列视线点整体分布进行建模是分析眼动模式的有效方法。高斯混合模型^[21]属于数据驱动的概率模型,使用多个单高斯模型线性叠加来拟合数据分布,通过调整单个高斯模型的参数可以做到近似表达数据分布。本文使用高斯混合模型来拟合眼动序列视线点的分布情况,即受试者的整体观察情况,对于 K 个高斯模型组成的高斯混合模型定义如式(3)所示。

$$p(s | \theta) = \sum_{i=1}^K \alpha_i \phi(s | \theta_i) \quad (3)$$

$$\sum_{i=1}^K \alpha_i = 1 \quad (4)$$

式中: α_i 是系数且 $\alpha_i > 0$ 。 $\phi(s | \theta_i)$ 是第 i 个高斯模型的密度分布, $\theta_i = (\mu_i, \sigma_i^2)$ 。对于变量 s 在本文表达为视线点(x, y),即:

$$\phi(s | \theta_i) = \frac{1}{2\pi\sigma_i^2} e^{-\frac{(x-\mu_i)^2 + (y-\mu_i)^2}{2\sigma_i^2}} \quad (5)$$

高斯混合模型的参数使用期望最大化(expectation maximization, EM)算法进行估计,主要分为两个步骤,E 步求各分布的期望;M 步求期望最大化时的参数值。模型个数 K 是高斯混合模型的关键参数,一般来说, K 值越大模型越贴合实际数据,但同时容易导致过拟合,如图 3 所示。为了使高斯混合模型尽可能受参数驱动,且适应视线点分布情况,本文将 K 值设定为 3。对于具有 3 个高斯的混合模型,均值点参数 μ 的数量为 2×3 ,协方差矩阵 σ 的参数数量为 $2 \times 2 \times 3$,权重系数参数的数量为 3。本文将高斯混合模型的 21 个参数作为一组特征表达眼动序列的分布情况。

1.4 特征选择与融合

常规眼动特征、眼动序列子模式特征和视线点高斯分布特征均存在一定的无用特征,因此需要选取合适的特征构建分类模型。ReliefF 是一种轻量型的过滤式特征选择算法,在分类中具有良好的性能,因此本文使用 ReliefF 算法进行特征选择,去除杂质特征。设有特征集合 $\mathbf{A} = \{A_1, A_2, \dots, A_d\}$, ReliefF 的特征权重更新公式如式(6)所示。

$$W(A_a^{t-1}) = W(A_a^t) - \frac{\sum_{j=1}^k \text{diff}(A_a^t, x_t, H_j)}{t \times k} + \sum_{C \neq \text{class}(x_t)} \frac{P(C)}{1 - P(\text{class}(x_t))} \times \frac{\sum_{j=1}^k \text{diff}(A_a^t, x_t, M_j(C))}{t \times k} \quad (6)$$

式中: t 表示当前迭代次数, W 表示权重, x_t 当前迭代下选取的样本, k 表示样本 x_t 的最近邻个数, H_j 被称为 nearest hit, M_j 被称为 nearest miss, $P(C)$ 表示 C 类的先

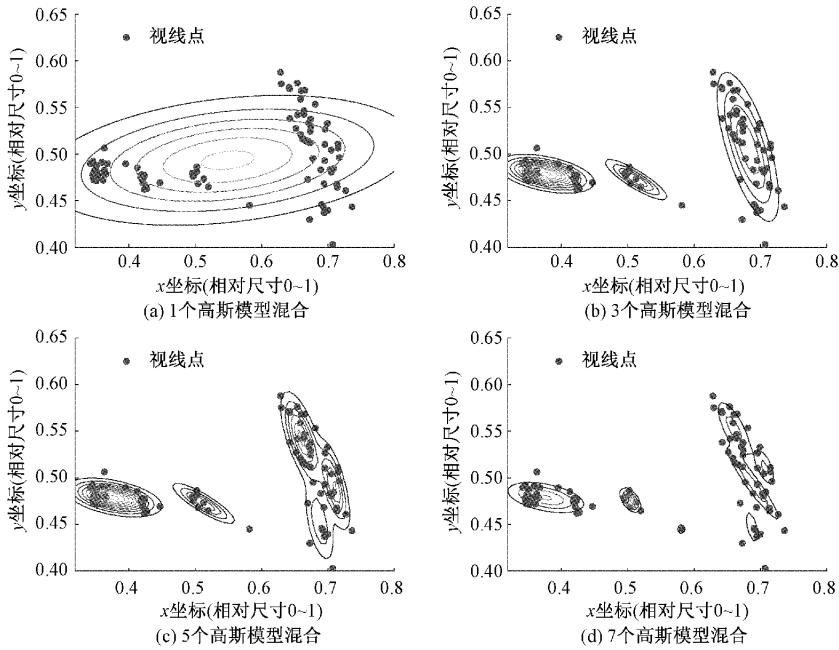


图 3 不同数量高斯混合模型对视线点分布拟合情况

验概率, $class(x_i)$ 表示 x_i 的类别, $diff(A_a, x_1, x_2)$ 表示不同样本 x_1, x_2 在同一特征 A_a 下的距离。 $diff(A_a, x_1, x_2)$ 的定义如式(7)所示。

$$diff(A_a, x_1, x_2) = \frac{|val(A_a, x_1) - val(A_a, x_2)|}{\max(A_a) - \min(A_a)} \quad (7)$$

式中: $val(A_a, x_1)$ 表示样本 x_1 的 A_a 特征值, $val(A_a, x_2)$ 表示样本 x_2 的 A_a 特征值, $\max(A_a)$ 表示 A_a 特征的最大值, $\min(A_a)$ 表示 A_a 特征的最小值。

ReliefF 算法对每个特征均返回一个特征权重。权重越大表示对分类作用越大,负权重表示该特征不是良好的分类特征。因此本文特征选择的标准是:选取特征权重为正值对应的特征用于分类。本文使用 ReliefF 算法分别去除 3 组特征的杂质特征,保留重要特征,然后将 3 组特征组合得到融合特征。

2 PSO-RF 分类模型

2.1 随机森林

RF 是一种通用性算法,既可以用于分类问题,也可以用于回归问题,RF 属于集成学习算法的一种,将决策树作为基学习器,对基决策树的每个结点,先从该结点的特征集合 D 中随机选择一个包含 m 个特征的子集,然后再从这个子集中选择一个最优特征用于划分,子决策树分裂达到预定的节点阈值后停止生长,通过训练好的子树的投票结果确定类别,如式(8)所示。

$$\hat{Y} = \frac{1}{p} \sum_{t=1}^p \hat{S}(X, T_{n/p}^t) \quad (8)$$

$$T_n = \{(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)\} \quad (9)$$

式中: T_n 表示包含 n 个样本的训练集, X 表示包含 m 个特征的特征矩阵, Y 表示训练样本类别, \hat{S} 表示模型估计函数, \hat{Y} 表示预测类别。

RF 算法原理如图 4 所示,主要步骤如下:

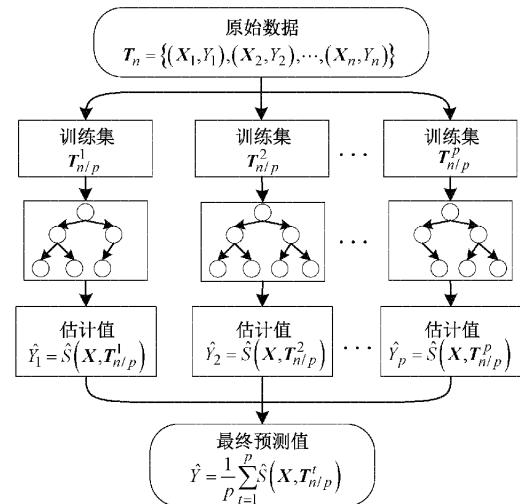


图 4 RF 模型算法原理

1) 使用 Bootstrap 方法从数据集中随机提取相同大小的样本,形成 p 个训练子集。

2) 从子树的每个节点的特征集合 D 中,随机选择 m 个特征变量组成特征子集,进行选择最佳分割特征。

3) 重复 1)~2),生成 p 个相应的子树构成 RF 模型。

4) 以 p 个子树的输出投票获得最终分类结果。

2.2 粒子群算法

PSO 是一种模拟鸟群捕食的进化算法, PSO 将鸟儿抽象成“粒子”, 鸟群寻找的食物则是最优解。粒子的坐标变化与上一次迭代时的坐标以及搜索速度有关, 搜索速度的计算与局部极值、全局极值、惯性权重、加速因子有关。粒子的坐标与速度迭代公式如式(10)、(11)所示。

$$\mathbf{s}_{i,d}^{k+1} = \mathbf{s}_{i,d}^k + \mathbf{v}_{i,d}^{k+1} \quad (10)$$

$$\mathbf{v}_{i,d}^{k+1} = w^{k+1} \mathbf{v}_{i,d}^k + c_1^{k+1} r_1 (\mathbf{P}_{i,d} - \mathbf{s}_{i,d}^k) + c_2^{k+1} r_2 (\mathbf{G}_{i,d} - \mathbf{s}_{i,d}^k) \quad (11)$$

式中: $\mathbf{s}_{i,d}^k$ 表示第 i 个粒子的第 d 个分量在第 k 次迭代时粒子的位置, $\mathbf{v}_{i,d}^k$ 表示第 i 个粒子的第 d 个分量在第 k 次迭代时粒子的速度, w 表示惯性权重, c_1, c_2 表示加速因子, \mathbf{P} 表示局部极值, \mathbf{G} 表示全局极值。

每次迭代后根据粒子位置计算局部极值和全局极值, 保证全局极值不断向最优解靠近, 实现参数寻优的功能。

2.3 构建 PSO-RF 分类模型

RF 的分类性能受到子树个数 p 以及特征子集大小 m 的影响。当决策树数量越大, 特征子集越大时, 模型容易过拟合; 当决策树数量越小, 特征子集越小时, 虽然模型泛化能力较好, 但是存在学习不充分, 分类精度低的缺点。本文使用 PSO 对 RF 进行超参数优化, 构建 PSO-RF 分类模型如图 5 所示。具体步骤描述如下:

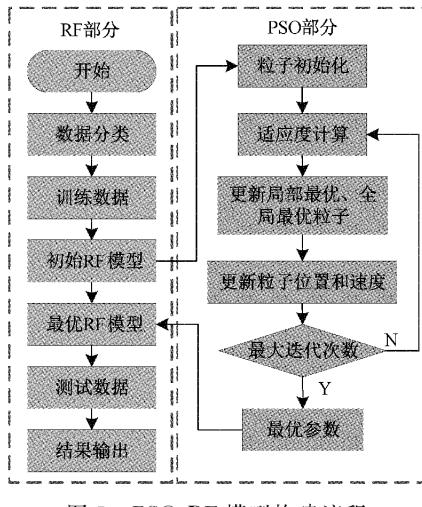


图 5 PSO-RF 模型构建流程

1) 对眼动数据分别提取常规眼动特征、眼动序列子模式特征、视线点高斯分布特征, 使用 ReliefF 算法进行特征选择, 将 3 组特征组成融合特征矩阵。

2) 将融合特征集进行随机划分, 训练数据与测试数据的比例为 7 : 3。

3) 初始化 RF 模型, 随机选择参数 m 和参数 p 。

4) 使用 PSO 在训练集基础上对 RF 模型的 m 和 p 参数进行寻优, 输出最佳参数。

5) 训练最优参数 m, p 下的 RF 模型, 对测试集进行分类识别。

3 实验分析

3.1 眼动数据

本文采用的数据集为 Hedger 等^[5]在 2021 年公开的自闭症眼动数据集, 目前收录于 figshare 开源数据库 (https://figshare.com/articles/dataset/EYETRACK_CHOICE_2020/11799030)。该数据集包含 53 名受试者眼动实验数据, 其中 30 名是从大学招募的学生和教职工, 为非自闭症患者 (neurotypical, NT) 组, 另外从 23 名成年人来自公立的医院, 均通过了基于《精神障碍诊断与统计手册》第四版文本修订版 (DSM-IV TR) 的自闭症障碍诊断, 为自闭症患者 (autistic spectrum disorder, ASD) 组, 每位受试者均完成了韦氏智力量表测量, 表明两组受试者的智力能力和认知能力相当。实验总共包含 60 组图像刺激, 每组图像刺激包含一左一右两个子图, 内容分别涉及社会场景 (幸福的夫妻、人群、婴儿等) 和非社会场景 (自然风光、金钱等), 实验要求受试者从每组图像中选取感兴趣的子图, 每组实验重复 4 次, 使用 Tobii T60 对眼动序列信息进行收集。因此每组图像对应 212 条眼动序列, 其中 120 条来自 NT 组, 92 条来自 ASD 组, 眼动数据集总共包含 12 720 条眼动序列。本文对每组图像的眼动序列提取融合特征, 使用 PSO-RF 模型进行眼动模式识别。

3.2 评价指标

为评估测试集眼动模式分类的准确性, 本文采用准确率 (accuracy, Acc)、查准率 (precision, Pre)、召回率 (recall, Rec) 和 F1 分数 (F1 score, F1) 作为评价指标。4 种指标的计算公式如下:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (12)$$

$$Pre = \frac{TP}{TP + FP} \times 100\% \quad (13)$$

$$Rec = \frac{TP}{TP + FN} \times 100\% \quad (14)$$

$$F1 = 2 \times \frac{(Pre \times Rec)}{(Pre + Rec)} \quad (15)$$

式中: 真阳性 (true positive, TP) 表示实际为正预测为正样本的数量; 真阴性 (true negative, TN) 表示实际为负预测为负样本的数量; 假阳性 (false positive, FP) 表示实际为负预测为正样本的数量; 假阴性 (false negative, FN) 是实际为正预测为负样本的数量。

3.3 特征选择分析

为了验证 ReliefF 特征选择的有效性, 本文将提取的常规眼动特征 (conventional eye movement features, EF)、眼动序列子模式特征 (eye movement sequence sub-pattern features, SF) 和视线点高斯分布特征 (gaze points Gaussian distribution features, GF) 输入 RF 分类模型, 比较特征选择前后 60 组图像上的平均分类 (Acc), 以及模型

平均训练时长(Time)如表 2 所示。

表 2 特征选择前后对比

特征	特征选择前		特征选择后	
	Acc / %	Time / s	Acc / %	Time / s
EF	74.64	2.41	75.23	1.74
SF	68.37	7.24	69.69	1.77
GF	63.95	1.96	63.53	1.53

由表 2 可以看出,特征选择前后平均分类 Acc 变化不大,这是因为 RF 模型在构建时选用最优特征进行节点分裂,RF 模型本身具备了对特征优劣的识别能力。本文使用 ReliefF 算法进行特征选择,目的在于去除冗余特征,加快 RF 模型训练。眼动特征和分布特征本身数量较小,因此特征选择前后平均耗时减少的不多,分别减少了 0.67、0.43 s,但子模式特征的维数很高,其中包含大量稀疏且无用的特征,使用 ReliefF 特征选择去除冗余特征,保留有效特征进行训练,在保证 Acc 的情况下变化不大的情况下,训练耗时比特征选择前大大减少,训练耗时变为原来的 0.24 倍。

3.4 融合特征分析

为了比较融合特征的有效性,本文将 EF、SF、GF、融合特征以及两两组合特征输入 RF 分类模型,在 60 组图像上的分类 Acc 散点箱线图如图 6 所示。

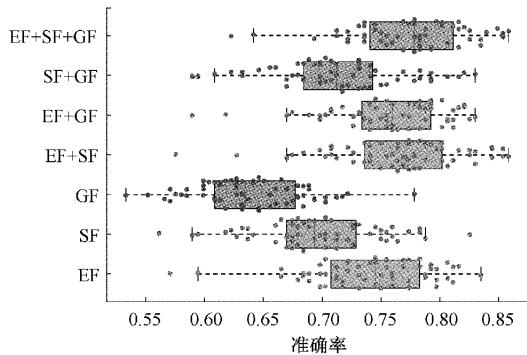


图 6 不同特征的 RF 分类准确率散点箱线图

其中,EF 的分类中位数 Acc 为 74.53%,SF 的分类 Acc 中位数为 69.34%,GF 的分类 Acc 中位数为 63.44%,说明 EF 在分类中效果最好。

另外两两组合特征中,EF+SF 的分类 Acc 中位数为 77.02%,EF+GF 的分类 Acc 中位数为 75.94%,SF+GF 的分类 Acc 的中位数为 71.23%;融合特征 EF+SF+GF 的分类 Acc 中位数为 77.83%,融合特征 EF+SF+GF 的分类表现均优于单组特征,融合特征 EF+SF+GF 分类效果优于其他两种特征的组合,说明 3 组特征对分类均起作用,特征之间互相补充能最大限度挖掘眼动序列中的信息,提升分类 Acc。

3.5 PSO-RF 模型有效性分析

PSO 对 RF 模型优化过程中,设置子决策树数量 p 的寻优范围为 [1,50],特征子集大小 m 的寻优范围为 [1, size(\mathbf{D})] (size(\mathbf{D}) 表示特征集合 \mathbf{D} 的特征数量),最大迭代次数为 100,粒子规模为 30,学习因子取经验值 $c_1 = c_2 = 1.5$,惯性权重取经验值 $\omega_{\min} = 0.4, \omega_{\max} = 0.9$,最大飞行速度取经验值 $V_{\max} = 0.002$ 。在满足上述条件下,基于 PSO 优化 RF 的个体适应度变化情况如图 7 所示,随着迭代次数的增加,个体最佳适应度也逐渐增大并趋于收敛,最终误识率降到 13.2%,并趋于稳定,表明优化模型参数设置得当,训练效果较好。

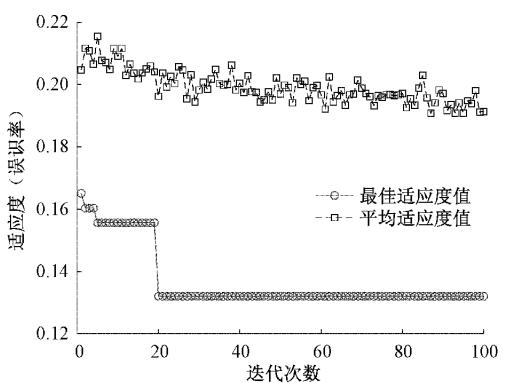


图 7 优化过程的适应度曲线

为了验证训练得到的 PSO-RF 模型分类的有效性,本文选用了常用的机器学习模型,逻辑回归(LR)、支持向量机(SVM)以及本文提到的 RF、PSO-RF 四种模型,使用 EF+SF+GF 融合特征在测试集上进行眼动模式识别,结果如表 3 所示。

由表 3 可以看出,4 种模型在 60 组图像上的平均分类 Acc 分别为 69.42%、76.25%、77.48%、84.21%,其中本文提出的 PSO-RF 分类 Acc 最高,PSO-RF 在 Pre、Rec、F1 这 3 个指标也达到了最佳,说明了 PSO-RF 模型的有效性。PSO-RF 相比 RF 的分类 Acc 提高了 6.73%,说明 PSO 能对 RF 模型进行有效寻优,避免了 RF 模型参数选取的盲目性。

另外注意到 4 种模型的 Rec 均高于 Pre,这是因为 ASD 组的共性高于 NT 组,ASD 组受试者在观察图像时会倾向于回避社交内容,更多的观看自然风光等,这与 ASD 患者症状相关^[22-23];NT 组受试者则会根据自身感兴趣的内容进行观看,组内共性低于 ASD 组,这在表 3 的混淆矩阵中也有所体现,4 种模型下 ASD 组的识别准确率均优于 NT 组。PSO-RF 模型分类混淆矩阵的结果在 4 种模型中表现最优,进一步说明了 PSO-RF 的有效性。

表 3 4 种模型分类表现对比

%

模型	实际类别	预测类别		Acc	Pre	Rec	F1
		ASD	NT				
LR	ASD	74.06	25.94	69.42	72.78	74.06	73.17
	NT	36.63	63.37				
SVM	ASD	82.99	17.01	76.25	77.17	82.99	79.89
	NT	32.54	67.46				
RF	ASD	82.89	17.11	77.48	78.58	82.89	80.65
	NT	29.58	70.42				
PSO-RF	ASD	89.12	10.87	84.21	84.00	89.12	86.44
	NT	22.21	77.79				

4 结 论

通过对 ReliefF 特征筛选前后 EF、SF、GF 的分类准确率和模型训练耗时进行分析,说明 ReliefF 算法能有效去除冗余的特征,少量的特征在保证分类准确率变化不大的情况下,大大降低了模型训练时间复杂度。

EF 表达了人在观察时注意力的空间和时间信息,SF 表达了注意力的转移信息,GF 表达了人的注意力整体分布情况。实验结果表明,融合特征的检测表现优于单组特征及其他组合特征,说明融合特征可以充分整合 3 种不同类别的信息表达。

通过对比融合特征在不同机器模型下的分类准确率可知,RF 模型结合 PSO 参数寻优的 PSO-RF 模型分类表现最好,相比 RF 模型识别准确率提升了,说明通过 PSO 可以克服 RF 参数选取的盲目性,提升分类的准确率。

参考文献

- [1] COUTROT A, HSIAO J H, CHAN A B. Scanpath modeling and classification with hidden Markov models[J]. Behavior Research Methods, 2018, 50(1): 362-379.
- [2] XU Q, CHONG H Y, LIAO P. Exploring eye-tracking searching strategies for construction hazard recognition in a laboratory scene[J]. Safety Science, 2019, DOI: 10.1016/j.ssci.2019.08.012.
- [3] FATEMEH J, MOHSEN A, FARNOUSH J. Eye movement patterns in Iranian dyslexic children compared to non-dyslexic children[J]. Auris Nasus Larynx, 2021, 48(4):594-600.
- [4] CRABB D P, SMITH N D, ZHU H. What's on TV? Detecting age-related neurodegenerative eye disease using eye movement scanpaths[J]. Frontiers in Aging Neuroscience, 2014, DOI: 10.3389/fnagi.2014.00312.
- [5] HEDGER N, CHAKRABARTI B. To covet what we see: Autistic traits modulate the relationship between looking and choosing [J]. Autism Research, 2021, 14(2): 289-300.
- [6] CARTER B T, LUKE S G. Best practices in eye tracking research [J]. International Journal of Psychophysiology, 2020, DOI: 10.1016/j.ijpsycho.2020.05.010.
- [7] LIN Y, GU Y, XU Y, et al. Autistic spectrum traits detection and early screening: A machine learning based eye movement study[J]. Journal of Child and Adolescent Psychiatric Nursing, 2022, 35(1): 83-92.
- [8] 牛清宁, 周志强, 金立生, 等. 基于眼动特征的疲劳驾驶检测方法[J]. 哈尔滨工程大学学报, 2015, 36(3):394-398.
- [9] KUMAR A, TIMMERMANS N, BURCH M, et al. Clustered eye movement similarity matrices [C]. Proceedings of the 11th ACM Symposium on Eye Tracking Research & Applications, 2019, DOI: 10.1145/3317958.3319811.
- [10] HUANG L, XU F, HU X. Scanmatch: A new method for studying decision-making process [J]. Advances in Psychological Science, 2020, 28 (9): 1454-1461.
- [11] KUBLER T C, ROTHE C, SCHIEFER U, et al. SubsMatch 2.0: Scanpath comparison and classification based on subsequence frequencies [J]. Behavior Research Methods, 2017, 49 (3): 1048-1064.
- [12] LAO J, MIELLET S, PERNET C, et al. iMap4: An open source toolbox for the statistical fixation mapping of eye movement data with linear mixed modeling[J]. Behavior Research Methods, 2017, 49(2): 559-575.
- [13] 刘华茜, 郑秀娟, 王艳, 等. 人类视觉行为的混合高斯-隐马尔可夫模型[J]. 生物医学工程学杂志, 2021, 38(3):512-519.
- [14] 王毅, 陈进, 李松浓, 等. 基于时频域分析和随机森林的故障电弧检测[J]. 电子测量与仪器学报, 2021, 35(5):62-68.
- [15] 刘成龙, 高旭, 曹明. 基于 VMD 和 BA 优化随机森林

- 的短期负荷预测[J]. 中国测试, 2022, 48(4):159-165.
- [16] ANGADI S, REDDY V S. Multimodal sentiment analysis using reliefF feature selection and random forest classifier [J]. International Journal of Computers and Applications, 2021, 43(9): 931-939.
- [17] 吴阳, 刘凯, 陈柏, 等. 自适应粒子群优化算法优化径向基函数神经网络用于电阻抗成像图像重建[J]. 仪器仪表学报, 2020, 41(6):240-249.
- [18] 杨毅, 徐晓冉, 刘雅琳, 等. 基于离散二进制粒子群优化随机森林的平面变压器寄生参数预测模型[J]. 国外电子测量技术, 2021, 40(4):37-41.
- [19] RIGAS I, FRIEDMAN L, KOMOGORTSEY O. Study of an extensive set of eye movement features: Extraction methods and statistical analysis[J]. Journal of Eye Movement Research, 2018, 11(1):1-28.
- [20] REANI M, PEEK N, JAY C. An investigation of the effects of n-gram length in scanpath analysis for eye-tracking research[C]. Proceedings of the 2018 ACM Symposium on Eye Tracking Research & Applications, 2018, DOI: 10.1145/3204493.3204527.
- [21] 舒珏淋, 张力, 胡建. 基于高斯混合模型的智能电表误差数据挖掘与分析方法[J]. 电子测量技术, 2021, 44(15):56-61.
- [22] TRAYNOR J M, GOUGH A, DUKU E, et al. Eye tracking effort expenditure and autonomic arousal to social and circumscribed interest stimuli in autism spectrum disorder [J]. Journal of Autism and Developmental Disorders, 2019, 49(5): 1988-2002.
- [23] DUBEY I, ROPAR D, DE C HAMILTON A F. Brief report: A comparison of the preference for viewing social and non-social movies in typical and autistic adolescents[J]. Journal of Autism and Developmental Disorders, 2017, 47(2): 514-519.

作者简介

沈胤宏,硕士研究生,主要研究方向为眼动数据分析与研究。

E-mail: 13551400579@qq.com

郑秀娟(通信作者),博士,副教授,主要研究方向为人体多维信号协调感知与智能分析。

E-mail: xiujuanzheng@scu.edu.cn