基于面孔加工异常的孤独症儿童识别

崔冬^{1,2}, 韩晓雅^{1,2}, 陈贺³, 韩俊霞⁴, 李小俚³, 康健楠^{5*}

1. 燕山大学信息科学与工程学院, 秦皇岛 066004;
2. 河北省信息传输与信号处理重点实验室, 秦皇岛 066004;
3. 北京师范大学认知神经科学与学习国家重点实验室, 北京 100875;
4. 首都师范大学心理学院, 北京市“学习与认知”重点实验室, 北京 100048;
5. 河北大学电子信息工程学院, 保定 071000

* 联系人, E-mail: kangjiannan81@163.com

2019-11-25 收稿, 2019-12-27 修回, 2019-12-27 接受, 2019-12-30 网络版发表
国家自然科学基金(61761166003)和河北省自然科学基金(F2018203239)资助

摘要 眼动追踪技术在孤独症谱系障碍的早期诊断中具有潜在的应用价值. 为研究孤独症儿童对不同面孔加工的特点, 应用机器学习算法对其进行自动识别, 本研究选取3~6岁孤独症儿童40名和性别、年龄相匹配的正常儿童41名观看异国陌生面孔、本国陌生面孔和本国熟悉面孔, 根据两组儿童眼动坐标数据, 使用机器学习算法进行自动划分兴趣区、特征选择和分类, 来判断不同面孔的扫描模式是否可以用于识别孤独症儿童, 并从准确率、特异性、敏感性和可靠性4个方面对分类模型进行评估. 结果显示, 基于不同面孔扫描模式的机器学习算法可以提取足够的信息来区分孤独症和正常儿童, 最大分类准确率为90.28%, 对应AUC(area under the ROC curve)为0.9317. 因此, 眼动追踪技术结合机器学习能够为临床诊断提供辅助的评价指标.

关键词 孤独症, 眼动追踪, 机器学习, 面孔加工

孤独症谱系障碍(autism spectrum disorder, ASD)是一种先天的神经发育障碍, 具有复杂的病因和过程, 其核心症状包括社会交往障碍、兴趣狭窄和重复刻板行为^[1]. ASD的发病率在过去几年里急剧上升, 美国疾病控制与预防中心报告指出, 孤独症发病率已经达到1/59^[2]. 社会交往障碍是ASD的核心特异性障碍, 而面孔加工异常被认为是孤独症社会交往障碍的一个主要特征^[3,4]. 在人际交往过程中, 面孔提供大量的社交信息. 正常儿童可以通过面孔来获取和传递信息, 而大量的研究表明, 与正常发育(typical development, TD)儿童相比, ASD患者表现出非典型的面孔扫描模式, 即对面孔及其主要特征的注视减少, 尤其是眼睛区域^[5~7]. Langdell^[8]研究显示, ASD在面孔识别方面正确率比正

常人低, 并且反应时间更长. Pelphrey等人^[5]发现, ASD患者对基本情绪的扫描路径与正常者不同, 相比正常人, 他们更少地注视眼睛区域, 更多地注视非特征区域. Spezio等人^[9]发现, 自闭症患者处理面部情绪信息时, 更多依赖于嘴巴等面部的下半部分所包含的信息, 未能利用眼睛区域的信息.

机器学习(machine learning, ML)是通过分析大量数据, 从中进行学习, 进而对某件事情做出决定或预测. 机器学习在各领域都有着广泛的应用, 例如人脸识别^[10]、语音识别^[11]、图像检索^[12]和人脸表情全自动识别^[13]. 近年来, 有研究将机器学习应用于区分正常发育个体和ASD患者, 并显示出巨大的潜力. Crippa等人^[14]提出一个机器学习框架, 通过一个简单的触摸到放下

引用格式: 崔冬, 韩晓雅, 陈贺, 等. 基于面孔加工异常的孤独症儿童识别. 科学通报, 2020, 65: 2128–2135

Cui D, Han X Y, Chen H, et al. Recognition of autism spectrum disorder based on face processing abnormality (in Chinese). Chin Sci Bull, 2020, 65: 2128–2135, doi: 10.1360/TB-2019-0024

任务的运动学分析将TD儿童和ASD儿童进行区分,最大分类准确率为96.7%。Deshpande等人^[15]把大脑因果连通性权重和功能连通性值等作为分类特征,使用机器学习算法对ASD和TD儿童进行分类,分类准确率为95.9%。Liu等人^[16,17]提出了一种基于人脸扫描模式识别ASD儿童的机器学习框架。他们采用数据驱动方法进行特征提取,使用SVM进行分类并且他们的模型具有较好的性能,分类准确率为88.51%。他们的研究结果证明了基于人脸扫描模式的机器学习算法在ASD分类和预测中的有效性和可行性^[16,17]。Wan等人^[18]通过10 s女性演讲视频的注视时间区分ASD和TD儿童,分类准确率为85.1%。

以往ASD儿童的非典型面孔处理结果大多基于同一种族的面孔或同一熟悉度的面孔,并且是在统计意义上显著的非典型面孔扫描模式,较少地利用机器学习算法对特征进行选择,并进行预测任务。相比传统的统计分析,机器学习能够进行预测。本研究使用异国陌生面孔、本国陌生面孔和熟悉面孔作为刺激材料,探究与TD儿童相比,ASD儿童对不同种族和不同熟悉度的面孔刺激是否具有不同的面孔扫描模式。我们根据三类面孔的眼动扫描数据提取特征,并进行特征选择和支持向量机对其进行分类,从准确率、特异性、敏感性和可靠性4个方面对分类模型进行评估。尽早诊断孤独症,可以通过早期干预ASD症状的发展,有可能最大限度地提高对ASD患者的治疗效果^[19-21]。

1 材料和方法

1.1 材料

(i) 被试。本研究共招募了81名儿童参与眼动数据采集。其中孤独症儿童40名,男生31名,女生9名,年龄3~6周岁($M=4.9$, $SD=1.1$),全部儿童的视力或矫正视力正常。孤独症儿童符合DSM-IV相关诊断标准,并排除Rett综合征、发育迟缓和癫痫等其他精神发育疾病。从河北省某幼儿园随机选取41名儿童作为对照组,其中男生26名,女生15名,年龄3~6周岁($M=4.5$, $SD=0.8$),全部儿童的视力或矫正视力正常。排除神经疾病和精神发育障碍疾病,无孤独症相关家族遗传史。两组在年龄、性别上无统计学差异($P>0.05$)。由于本实验中多数为低功能自闭症儿童,无法对ASD组儿童的智商进行标准化评估,故未能将两组儿童的智商进行匹配。

(ii) 实验仪器。使用Tobii TX300眼动仪及其软件

包记录每位被试的注视过程。该眼动仪为完全非接触式,采用双眼追踪,采样频率为300 Hz。

(iii) 实验材料。实验材料包括本国熟悉面孔图片、本国陌生面孔图片和异国陌生面孔图片,每张面孔图片的背景统一,并且人的脸部、身体和背景的占比一致。每类面孔有4张刺激材料,每类照片的亮度等物理因素均有控制。所有实验素材均由实验主试拍摄,异国面孔中的4张面孔特征位置相似,陌生面孔和熟悉面孔中的8张面孔特征位置相似。ASD儿童的熟悉面孔拍摄对象为儿童的家长,TD儿童的熟悉面孔拍摄对象为幼儿园班级老师。图片的大小均为600 px×799 px。

(iv) 实验程序。被试坐在距离眼动仪60 cm左右的位置。正式实验前先对每位被试儿童进行5点校正,屏幕呈现动态的小猫并且配合声音使用婴儿校正模式吸引儿童对校正点进行注视,从而进行5点校正。如果被试儿童的左右眼均看到两个及两个以上的校正点,则认为眼动校准成功,可以进行正式实验。面孔图片刺激以随机顺序呈现,每次呈现一张面孔,每张面孔图片出现10 s。试次间间隔是3 s,间隔时呈现一只配有声音的动态小猫用来吸引被试注意。实验期间,被试不需要做出反应。

(v) 实验设计。实验采用2(被试类型:孤独症儿童、正常儿童)×3(面孔类型:熟悉面孔、陌生面孔、异国面孔)设计。本研究探讨ASD儿童注视不同类别的面孔是否与TD儿童都有不同的注视模式,并且基于面孔扫描使用机器学习算法进行分类。

1.2 方法

(i) 方法框架。传统的兴趣区方法(area of interest, AOI)被广泛应用于人脸扫描分析中,它是一个自上而下的过程,通过测量预定义兴趣区内的注视,统计所划AOI的固定数量和持续时间^[22],常用的AOI包括脸、眼睛、嘴巴和鼻子。但是AOI存在的常见问题包括:它固定的区域较大,无法将所划分的区域进行更详细地划分,往往会遗漏掉一些细小但是具有重要作用的注视;AOI的边界往往由人的经验所确定,在统计上缺少一定的合理性^[16]。本研究计算中,将坐标点的注视时间进行归一化作为坐标的权重,计算坐标的频率分布,通过对坐标的统计分布自动对图片刺激进行兴趣区域分割。考虑到扫描面部坐标频率分布与ASD之间关系的现有证据,面部扫描的非典型性直接反映在ASD固定坐标分布上的异常^[6,22],我们使用坐标频率分布作为ASD分

类的判别特征,并对特征进行选择 and 分类. 研究流程框图如图1所示.

(ii) 注视点计算方法及相关参数. 注视点的计算使用Tobii数据过滤器(Tobii fixation filter)方法. 选择采集眼睛的方式为双眼(average). 速度基准值(velocity threshold)设置为35像素, 距离基准值(distance threshold)设置为35像素.

(iii) 基于K-means聚类算法的兴趣区划分. K-means算法属于非监督机器学习算法, 本研究使用K-means算法对所需要分析的图片进行区域分割. 具体处理流程如下: (1) 从 n 个固定坐标数据中, 随机选择 K 个坐标作为簇的初始聚类中心; (2) 将固定坐标的注视时间进行线性变换, 使得结果映射到 $[0, 1]$ 范围, 归一化后作为坐标的权重, 计算每个固定坐标与 K 个聚类中心之间的距离, 把每个坐标分配给距离最近的聚类中心; (3) 使用每个聚类中的样本均值作为新的聚类中心; (4) 重复(2)、(3)直至平方和误差准则函数值小于阈值1个像素点时, 则终止迭代. (5) 最终将整幅图像分割成 K 个不同的细胞样区域, 如图2($K=64$, 不同颜色代表不同的兴趣区).

(iv) 基于最大相关最小冗余算法的特征选择. 本研究借鉴了Liu等人^[17]研究选取 $K=64$, 也就是刺激图片被自动划分成64个兴趣区, 有64个特征. 一种简单的特征选择方法是 T 检验, 通过比较两组平均值选择出有显著性差异的特征. 但 T 检验存在两个问题: (1) 不能确保选择出来具有显著差异的特征有很好的可分性, 因为可能两组间的均值存在差异, 但是方差较大, 两类的分布存在较多的重叠; (2) 选择的特征之间可能相关性过大, 会包含很多冗余信息. 为了避免这种情况, 本研究

采用最大相关最小冗余(minimal redundancy and maximal relevance, mRMR)的方法对64个特征进行排序选择, 使分类精度达到最高.

mRMR选择互信息进行度量. X 和 Y 为两个随机变量, 则互信息计算方法为

$$I(X, Y) = \sum_{i,j} p(x_i, y_j) \log \frac{p(x_i, y_j)}{p(x_i)p(y_j)}, \quad (1)$$

其中, $p(x)$ 和 $p(y)$ 分别为 x 和 y 的概率分布函数, $p(x, y)$ 为联合分布函数.

mRMR算法的核心思想是最大化特征与分类变量之间的相关性, 而最小化特征与特征之间的相关性^[23]. 首先特征与类别的最大相关准则为

$$\max V(S, h), V = \frac{1}{|S|} \sum_{j \in S} I(h, j), \quad (2)$$

其中, h 为类别向量, S 为特征子集, j 为个体特征. 最大相关准则能使特征和类别的相关性最大, 相比 T 检验, 能保证选择的数据具有很好的可分性. 然而只保证特征与类别之间的最大相关性还是不够的. 根据最大相关准则选择的特征可能具有丰富的冗余, 即这些特征之间的依赖性可能很大. 当两个特征高度依赖时, 则认为其中的一个特征是多余的, 对最终分类结果不会有太大贡献, 留下与类别相关性相比较而言更大的一个特征^[23]. 因此, 还需要满足以下特征与特征的最小冗余准则:

$$\min W(S, h), W = \frac{1}{|S|^2} \sum_{i,j \in S} I(i, j). \quad (3)$$

综上, 如果使 $(V-W)$ 最大, 则同时满足最大相关和最小冗余:

图1 研究流程框图

Figure 1 The flow chart of this study

图2 (网络版彩色)K=64异国面孔的图像分割
Figure 2 (Color online) K=64 Image segmentation of foreign face

$$\max(V-W), V-W = \frac{1}{|S|} \sum_{j \in S} I(h, j) - \frac{1}{|S|^2} \sum_{i, j \in S} I(i, j), \quad (4)$$

使用mRMR算法可以求得N个特征子集进行分类,并选择出使分类正确率最大的特征数m.

(v) 支持向量机分类. 本研究中使用支持向量机(support vector machine, SVM)对所构建的模型进行评估. SVM以其优异的分类性能而被广泛使用. 其主要原理是寻找一个满足分类要求的最优分类超平面,即该平面不仅要有好的分类精度而且也要使两类样本到该超平面的距离最大^[24,25]. 本研究使用线性支持向量机(linear SVM). 为了评估分类器的分类效果,需要对数据进行交叉验证.

K折交叉验证(K-fold cross-validation),即将所有样本数据随机分割成K个子样本数据,其中一组子样本数据作为测试集,其余K-1组子样本数据当作训练集,重复K次取平均得到最终的分类精度. 本研究使用10折交叉验证.

(vi) 评价指标. 本研究中,使用以下5个指标对预测性能进行了评估. (1) AUC(area under the ROC curve). ROC曲线下面积,取值范围在0~1之间. AUC越接近于1,准确度越高. AUC具有一个重要的统计特性:分类器的AUC等价于分类器将随机选择的正样本排序高于随

机选择的负样本的概率^[26]. 目前AUC作为一种分类器的评价指标已经广泛被应用^[27]. (2) 正确率. 正确预测的受试者数量与受试者总数之间的关系. (3) 特异性. 正确预测TD儿童数量与TD儿童总数之间的关系. (4) 敏感性. 正确预测ASD儿童数量与ASD儿童总数之间的关系. (5) 置换检验. 当基于特定特征训练模型A时,另一个模型B也由相同的样本训练,但具有随机改组的标签,通过测试A和B之间差异的显著性来评估模型A的性能. 如果原始数据包含数据和标签之间的真实依赖性,则该测试将导致小的P值并且拒绝该特征的零假设,假设特征和标签是独立的. 在该研究中,在模型B上进行相同的交叉检验过程,但是使用改组标签,并且记录每个SVM分类器的正确率. 然后应用显著性水平为5%的单一样本t检验($n=1000$)来验证模型的有效性. 如果测试失败,分类器模型并没有明显优于使用随机标签,因此任何分类准确率都是偶然的,并且这些特征被认为不符合此分类任务^[28].

(vii) 统计处理. 使用SPSS 23.0软件进行统计学分析.

2 结果

根据每个参与者所观察每幅图片的注视坐标顺序,将每个坐标分配给K-means得到的最近端的聚类质心,计算每个簇的分配数量,并通过除以总坐标数来对分配计数进行归一化. 因此,我们得到了每个参与者注视不同面孔的64个兴趣区的视觉注意的频率分布,即每个参与者对于每类面孔图片都具有64个特征. 我们使用mRMR算法对64个特征进行选择,选择出使SVM分类精度最大的m个特征. 结果显示,注视异国面孔的64个特征(mRMR选择排序后的特征)中前12个特征在组间具有最高的识别能力,分类精度达到最大78.89%,特异性为74.00%,敏感性为81.67%. 并且AUC=0.8065,如图3(a). 陌生面孔中前21个特征能使分类精度达到最大73.89%,特异性为76.38%,敏感性为70.88%,AUC=0.8217,如图3(b). 熟悉面孔中前31个特征能使分类精度达到最大79.44%,特异性为79.71%,敏感性为82.67%,AUC=0.8387,如图3(c). 我们将三类面孔所对应特征放在一起共192个特征,再进行特征选择和SVM分类,结果显示选择前27个特征分类精度达到最大90.28%,特异性为86.83%,敏感性为91.33%,AUC=0.9317,如图3(d). 置换检验结果显示异国面孔、陌生面孔、熟悉面孔和三类面孔混合模型的P值均小

图3 不同面孔对应特征数量的分类准确度和AUC. (a) 异国面孔的分类准确度和AUC; (b) 陌生面孔的分类准确度和AUC; (c) 熟悉面孔的分类准确度和AUC; (d) 三类面孔的分类准确度和AUC

Figure 3 The classification accuracy and AUC of the number of features corresponding to different faces. (a) Classification accuracy and AUC of foreign face; (b) classification accuracy and AUC of strange face; (c) classification accuracy and AUC of familiar face; (d) classification accuracy and AUC of three types of faces

于0.05, 通过了置换检验, 说明4种模型的分类结果均大于随机水平. 具体不同面孔最大分类精度、AUC和置换检验的 P 值如表1所示.

为了探讨ASD儿童对不同面孔的非典型面孔扫描模式, 分别对异国面孔和陌生面孔的64个特征进行独立样本 t 检验, 选择出具有显著性差异的区域, 并将其标注出来. 对异国面孔特征进行独立样本 t 检验结果: 兴趣区域1 $t(75)=-3.084$, $P=0.003$, 兴趣区域2 $t(75)=-3.358$, $P=0.001$, 兴趣区域3 $t(75)=-2.140$, $P=0.036$, 兴趣区域4 $t(75)=-2.477$, $P=0.015$, 兴趣区域5 $t(75)=-2.392$, $P=0.019$. 结果显示相比TD儿童, ASD儿童在注视异国面孔时更少注视左眼的眼睑周围、右眼的左半部分和眼睑周围部分(读者的角度), 如图4(a). 对陌生面孔特征进行独立样本 t 检验结果: 兴趣区域1 $t(75)=2.843$, $P=0.006$, 兴趣区域2 $t(75)=2.106$, $P=0.041$, 兴趣

区域3 $t(75)=2.146$, $P=0.036$, 兴趣区域4 $t(75)=2.200$, $P=0.031$, 兴趣区域5 $t(75)=2.792$, $P=0.007$, 兴趣区域6 $t(75)=2.038$, $P=0.045$. 注视本国陌生面孔ASD儿童更多的注视右眼下方部分、背景的右半部分和身体下方中间部分(读者的角度), 如图4(b).

3 讨论

本研究基于面孔扫描模式利用机器学习算法提出识别ASD儿童的框架. 计算中使用了 K -means聚类, mRMR特征选择和SVM分类. 结果表明, 我们的框架基于面孔扫描模式有一个好的分类结果(正确率最大90.28%, $AUC=0.9317$). 相比Liu等人^[17]的研究, 本研究采用熟悉、陌生和异国三类面孔分别进行分类, 并且结果显示, 当三类面孔结合在一起的时候分类准确率最高为90.28%, 模型具有较好的性能, 同时探讨了ASD

表1 不同面孔最大分类精度、AUC和置换检验 P 值

Table 1 Maximum classification accuracy, AUC and P -value of permutation testing for different faces

面孔类别	达到最大分类度的特征数量	准确率(%)	AUC	置换检验 P 值
异国面孔	12	78.89	0.8065	<0.001
陌生面孔	21	73.89	0.8217	0.004
熟悉面孔	31	79.44	0.8387	0.027
三类面孔	27	90.28	0.9317	<0.001

图4 (网络版彩色)异国面孔和陌生面孔显著差异区域。(a) 异国面孔; (b) 陌生面孔

Figure 4 (Color online) Regions of significant difference in foreign and strange face. (a) Foreign face; (b) strange face

儿童和TD儿童对不同种族面孔的注视差异。与之前的研究一致，我们的研究也验证了应用机器学习在眼动中对ASD儿童和TD儿童进行分类和预测是可行的^[15]。我们还进一步对异国面孔和陌生面孔确定了最具有显著性差异的区域，结果发现ASD儿童和TD儿童在注视异国陌生面孔和本国陌生面孔有不同的处理模式^[29]。以往的一些研究结果大多是基于本国面孔的非典型面孔扫描模式，即ASD儿童对眼睛区域的注视减少，但对嘴巴的注视并没有显示出异常^[30-32]。本研究发现注视异国陌生面孔ASD儿童也表现出典型的目光回避现象，对眼睛及眼睛周围的注视减少，其他部分的注视与TD儿童没有显著的差异。根据眼睛威胁假说，这可能是由于ASD儿童将眼睛视为威胁刺激，会避免与另一个人直接目光接触，导致对眼睛区域的注视减少。而对于本国陌生面孔，ASD儿童在右眼下部分有较多的注视，面部的其他部分并没有显著性的差异，反而在身体和背景的部分区域有显著性差异。我们认为，注视本国陌生面孔并没有出非典型面孔扫描模式是因为我们的ASD儿童数据采集于特殊教育机构，机构会对ASD儿童进行有针对性的训练，ASD儿童经过一段时间的训练注视本国陌生面孔和TD儿童在面部主要特征区域

并没有显著的差异，但是由于在平时训练中ASD儿童接触不到异国面孔，所以在异国面孔的注视上还会有非典型面孔扫描模式。

虽然本研究探讨了ASD儿童和TD儿童眼动注视差异，但仍存在一些局限。第一，本研究入组的ASD儿童和TD儿童未能进行智商匹配，不同的智力水平应作为考虑的因素。第二，在校准中，我们选取基于2个校准点构建的校准模型会产生一定的误差，未能获得校准的误差，只能够根据输出的图像判断偏移误差。

4 结论

本研究结合眼动技术，致力于研究孤独症儿童对不同面孔的扫描模式，并且利用机器学习对ASD儿童进行预测和识别。结果发现，与TD儿童相比，ASD儿童在异国面孔注视上出现了对眼睛及周边的一些区域注视减少的非典型面孔扫描模式，而对本国陌生面孔的注视更多在背景和身体部分。基于面孔的注视情况，利用机器学习对ASD儿童和TD儿童进行分类的正确率可达到90.28%，对应AUC为0.9317。结果表明，机器学习算法在预测ASD儿童中具有可行性，并且本研究为国内孤独症儿童的康复训练提供一些证据和支持。

参考文献

- 1 Amaral D G, Schumann C M, Nordahl C W. Neuroanatomy of autism. *Trends Neurosci*, 2008, 31: 137-145
- 2 Baio J, Wiggins L, Christensen D L, et al. Prevalence of autism spectrum disorder among children aged 8 years—Autism and developmental

- disabilities monitoring network, 11 sites, United States, 2014. *MMWR Surveillance Summaries*, 2018, 67: 1–23
- 3 Dawson G, Webb S J, McPartland J. Understanding the nature of face processing impairment in autism: Insights from behavioral and electrophysiological studies. *Dev Neuropsychol*, 2005, 27: 403–424
- 4 Schultz R T. Developmental deficits in social perception in autism: The role of the amygdala and fusiform face area. *Int J Dev Neurosci*, 2005, 23: 125–141
- 5 Pelphrey K A, Sasson N J, Reznick J S, et al. Visual scanning of faces in autism. *J Autism Dev Disorders*, 2002, 32: 249–261
- 6 Yi L, Fan Y B, Quinn P C, et al. Abnormality in face scanning by children with autism spectrum disorder is limited to the eye region: Evidence from multi-method analyses of eye tracking data. *J Vision*, 2013, 13: 5
- 7 Falck-Ytter T. Face inversion effects in autism: A combined looking time and pupillometric study. *Autism Res*, 2008, 1: 297–306
- 8 Langdell T. Recognition of faces: An approach to the study of autism. *J Child Psychol Psych*, 2010, 19: 255–268
- 9 Spezio M L, Adolphs R, Hurley R S E, et al. Abnormal use of facial information in high-functioning autism. *J Autism Dev Disord*, 2007, 37: 929–939
- 10 Li S Z, Zhang S Z. FloatBoost learning and statistical face detection. *IEEE Trans Pattern Anal Mach Intell*, 2004, 26: 1112–1123
- 11 Rabiner L R. A tutorial on hidden Markov models and selected applications in speech recognition. *Proc IEEE*, 1989, 77: 257–286
- 12 Qi Y, Zhang G. Strategy of active learning support vector machine for image retrieval. *IET Comput Vision*, 2016, 10: 87–94
- 13 Bartlett M S, Littlewort G, Lainscek C, et al. Machine learning methods for fully automatic recognition of facial expressions and facial actions. In: *IEEE International Conference on Systems, Man and Cybernetics (IEEE Cat. No. 04CH37583)*, 2004. 8292597
- 14 Crippa A, Salvatore C, Perego P, et al. Use of machine learning to identify children with autism and their motor abnormalities. *J Autism Dev Disord*, 2015, 45: 2146–2156
- 15 Deshpande G, Libero L E, Sreenivasan K R, et al. Identification of neural connectivity signatures of autism using machine learning. *Front Hum Neurosci*, 2013, 7: 670
- 16 Liu W B, Yu Z D, Raj B, et al. Efficient autism spectrum disorder prediction with eye movement: A machine learning framework. In: *2015 International Conference on Affective Computing and Intelligent Interaction (ACII)*, 2015. 649–655
- 17 Liu W, Li M, Yi L. Identifying children with autism spectrum disorder based on their face processing abnormality: A machine learning framework. *Autism Res*, 2016, 9: 888–898
- 18 Wan G, Kong X, Sun B, et al. Applying eye tracking to identify autism spectrum disorder in children. *J Autism Dev Disord*, 2019, 49: 209–215
- 19 Anderson D K, Liang J W, Lord C. Predicting young adult outcome among more and less cognitively able individuals with autism spectrum disorders. *J Child Psychol Psychiatr*, 2014, 55: 485–494
- 20 Dawson G, Rogers S, Munson J, et al. Randomized, controlled trial of an intervention for Toddlers with autism: The early start denver model. *Pediatrics*, 2010, 125: E17–E23
- 21 Dawson G, Jones E J H, Merkle K, et al. Early behavioral intervention is associated with normalized brain activity in young children with autism. *J Am Acad Child Adolesc Psychiatr*, 2012, 51: 1150–1159
- 22 Yi L, Feng C, Quinn P C, et al. Do individuals with and without autism spectrum disorder scan faces differently? A new multi-method look at an existing controversy. *Autism Res*, 2014, 7: 72–83
- 23 Peng H C, Long F H, Ding C. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Trans Pattern Anal Mach Intell*, 2005, 27: 1226–1238
- 24 Vapnik V N. *The Nature of Statistical Learning Theory*. New York: Springer, 1995
- 25 Burges C J C. A tutorial on Support Vector Machines for pattern recognition. *Data Min Knowl Discov*, 1998, 2: 121–167
- 26 Fawcett T. An introduction to ROC analysis. *Pattern Recognit Lett*, 2006, 27: 861–874
- 27 Bradley A P. The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognit*, 1997, 30: 1145–1159
- 28 Chen H, Chen W, Song Y, et al. EEG characteristics of children with attention-deficit/hyperactivity disorder. *Neuroscience*, 2019, 406: 444–456
- 29 Yi L, Quinn P C, Fan Y, et al. Children with autism spectrum disorder scan own-race faces differently from other-race faces. *J Exp Child Psychol*, 2016, 141: 177–186
- 30 Rutherford M D, Clements K A, Sekuler A B. Differences in discrimination of eye and mouth displacement in autism spectrum disorders. *Vision Res*, 2007, 47: 2099–2110
- 31 Corden B, Chilvers R, Skuse D. Avoidance of emotionally arousing stimuli predicts social-perceptual impairment in Asperger's syndrome. *Neuropsychologia*, 2008, 46: 137–147
- 32 Dalton K M, Nacewicz B M, Johnstone T, et al. Gaze fixation and the neural circuitry of face processing in autism. *Nat Neurosci*, 2005, 8: 519–526

Summary for “基于面孔加工异常的孤独症儿童识别”

Recognition of autism spectrum disorder based on face processing abnormality

Dong Cui^{1,2}, Xiaoya Han^{1,2}, He Chen³, Junxia Han⁴, Xiaoli Li³ & Jiannan Kang^{5*}

¹ School of Information Science & Engineering, Yanshan University, Qinhuangdao 066004, China;

² Hebei Province Key Laboratory of Information Transmission and Signal Processing, Qinhuangdao 066004, China;

³ State Key Laboratory of Cognitive Neuroscience and Learning, Beijing Normal University, Beijing 100875, China;

⁴ Beijing Key Laboratory of Learning and Cognition, School of Psychology, Capital Normal University, Beijing 100048, China;

⁵ Institute of Electronic Information Engineering, Hebei University, Baoding 071000, China

* Corresponding author, E-mail: kangjiannan81@163.com

Autism spectrum disorder (ASD), a highly complex neurodevelopmental disorder with complicated causes and processes, has core symptoms including impairment of social interaction, narrow interests, and repetitive stereotypical behaviors. Many methods have been applied to the early diagnosis of ASD, one of which is eye-tracking technology. Faces are important social stimuli, and face processing is very important for social interaction. Eye movements during face processing are a source of information which can reveal characteristics of neural development. We here study eye movements during the processing of different types of faces in autistic children. We use machine learning on eye movement information to automatically identify ASD. We recruited a total of 81 children aged 3 to 6 years (40 ASD, 41 age- and gender-matched typically-developing controls) to look at faces of strangers from foreign races, faces of strangers from the children's own race, and faces of familiar people from the children's own race. We quantized eye-fixation coordinates using K-means, partitioning face images into $K=64$ different cell-like regions (areas of interest). We then used the fixation coordinate frequency distribution as features, along with the minimal redundancy and maximal relevance (mRMR) method for feature selection and support vector machines (SVM) for classification of ASD versus control. Results showed that maximum classification accuracies based on foreign face, own-race stranger face, and familiar face respectively reached 78.89% (sensitivity 81.67%, specificity 74.00%), 73.89% (sensitivity 70.88%, specificity 76.38%), and 79.44% (sensitivity 82.67%, specificity 79.71%). The areas under the receiver operating characteristic curves (AUC) were 0.8065, 0.8217, and 0.8387, respectively. Then, we combined features from the three types of faces to obtain a total of 192 features and used the mRMR method, selecting 27 features. With these features, the maximum classification accuracy reached 90.28% (sensitivity 91.33%, specificity 86.83%), and the AUC was 0.9317. Independent sample t -tests showed that, compared with controls, ASD children had atypical facial scanning. In particular, ASD children paid less attention to some areas around the eyes of foreign faces, while gazes on unfamiliar faces focused more on the body and background. In summary, our results show that face scanning characteristics are feasible for classifying ASD versus typically developing children, implying that eye-tracking technology combined with machine learning can provide auxiliary evaluation indices for clinical diagnosis of ASD.

autism, eye tracking, machine learning, face processing

doi: [10.1360/TB-2019-0024](https://doi.org/10.1360/TB-2019-0024)