

基于结构磁共振影像的自闭症分类中的数据增强研究

马瑞民^{1#}, 谢锐涛^{1#}, 黄莹¹, 郗文辉¹, 魏彦杰^{1*}, 潘毅^{1*}

¹ (中国科学院深圳先进技术研究院 深圳 518055)

摘要: 基于结构磁共振影像的自闭症分类对于疾病早期筛查和精准诊断具有重要意义, 但受到数据噪声及样本不足的影响, 基于结构磁共振影像的机器学习分类模型准确率并不理想。本文提出了一种新型的数据增强模型, 我们采用 ABIDE-I 中的 UM1 数据集进行模型测试, 随机选取了 UM1 数据集中 78 个样本进行实验, 对自闭症分类准确率进行评估。实验结果显示本方法在 500 次实验的 494 次中 (98% 以上的实验中) 能够将分类准确率提升 10%~20%, 在不增加数据量的情况下显著提升了自闭症的分类准确率, 通过分析准确率提升和标注变化比例之间的关系, 文中进一步对数据标注噪音的问题进行了探讨。

关键词 自闭症; 结构磁共振影像; 数据增强; 分类准确率

中图分类号: doi: 10.12146/j.issn.2095-3135.20230413001

Data Augmentation Study in Structural MRI Based Autism Spectrum Disorder Classification

MA Ruimin^{1#}, XIE Ruitao^{1#}, HUANG Ying¹, XI Wenhui¹, WEI Yanjie^{1*}, PAN Yi^{1*}

¹ (Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)

1# Equal Contribution

1* Corresponding Author: PAN Yi, WEI Yanjie Email: yi.pan@siat.ac.cn, yj.wei@siat.ac.cn

Abstract: Structural-MRI based autism spectrum disorder classification is important nowadays for early-stage screening and accurate diagnosis of autism spectrum disorder. However, due to the limitation of large data noise and small data volume, the predictive accuracy of structural-MRI based autism classification is not ideal. In this study, a new data augmentation model is proposed to improve classification accuracy without increasing training data volume. The UM1 dataset of ABIDE I for autism study was used for training and evaluating the proposed model. 78 samples of the UM1 dataset was selected randomly for performing the experiment, and the performance improved using proposed data augmentation algorithm for ASD classification task was calculated. Such a procedure was repeated for 500 times to collect results that are statistically significant. Based on the results, this method can stably improve classification accuracy between 10% and 20% in 494 out of 500 experiments (over 98% of the experiments). Through a comparative study of accuracy improvement and label change ratio, the problem of data label noise was explored.

来稿日期: yyyy-mm-dd 修回日期: yyyy-mm-dd

基金项目: 国家重点研发计划 (No.2021yff1200100), 国家自然科学基金 (No. 2021yff1200100), 深圳市科技计划 (No. KQTD20200820113106007), 广东省重点研发项目 (No.2021B0101310002)。

作者简介: 马瑞民, 博士, 研究方向为生物信息学; 谢锐涛, 博士, 研究方向为生物信息学; 黄莹, 硕士, 研究方向为计算生物、深度学习; 郗文辉, 副研究员, 研究方向为计算生物、分子动力学模拟; 魏彦杰 (通讯作者), 研究员, 研究方向为计算生物学、高性能计算, E-mail: yj.wei@siat.ac.cn; 潘毅 (通讯作者), 教授, 研究方向为生物信息学、深度学习, E-mail: yi.pan@siat.ac.cn。

Key words: autism spectrum disorder; structural MRI; data augmentation; classification accuracy

Funding: This project is supported by the National Key Research and Development Program of China grant No.2021YFF1200100, National Natural Science Foundation of China under grant No. U22A2041, the Shenzhen Science and Technology Program Nos. KQTD20200820113106007, the Key Research and Development Project of Guangdong Province under grant No.2021B0101310002.

Ethical Statement: The study was approved by the ABIDE-I organization and informed consent for this study was waived due to data widely open-sourced.

1 引言

孤独症谱系障碍（简称孤独症，也称自闭症，英文名称 Autism Spectrum Disorder，缩写为 ASD）是一种复杂的神经发育障碍，其特点包括社交障碍、刻板行为和兴趣狭隘等^[1]。患儿在幼儿时期便开始出现单一或多种特征，影响社交、沟通、学习、适应性发展等功能^[2]。ASD 的确切病因尚不清楚，目前研究认为是由遗传、大脑发育、免疫、家庭及生活习惯等多种因素所导致的复杂疾病，ASD 个体间的连续性变异可能反映了这些因素和相关机制不同程度的表达^[3, 4]。ASD 是患病率攀升速度最快的儿童精神疾病，据美国疾病控制与预防中心 2020 年的统计数据显示，美国儿童患 ASD 的人数比例为 2.76%，即每 36 个儿童中就有一位确诊^[5]；在中国，ASD 患病率约在 0.7%到 1%之间，保守估计每年将有约十万的新生潜在患儿^[6, 7]。ASD 造成世界范围内的巨大经济损失和社会负担，然而目前 ASD 的临床诊断缺乏高效灵敏的生物标记物，多数情况下依赖于医生的临床症状评估量表，一般依照《精神疾病诊断与统计手册第五版》（DSM-5）诊断标准，结合数种常用的 ASD 评定量表，如 ASD 诊断观察量表（ADOS）、孤独症诊断访谈量表修订版（ADI-R）等^[8-10]。由于 ASD 诊断没有相关的病理生理标志物来帮助诊断，其症状常与其他精神疾病如智力残疾、精神分裂等多有重合，导致基于行为量表的 ASD 诊断存在一定的误诊率^[11]。基于自闭症检测的当前困境，需要发展行为量表之外的生物特征来提高自闭症检测精度，降低误诊率。

随着神经影像学的发展，研究者开始探索使用神经影像数据来对 ASD 进行诊断。早期基于神经影像的 ASD 诊断通过分析大脑区域的结构连接、活动性能、以及功能连接来进行^[12, 13]。临床医生基于神经影像的常规 ASD 诊断方法存在一系列的问题，如图片分辨率低、对运动伪影敏感等，归根结底在于人眼对影像的处理能力有限，图像信息的特征提取精度低，严重依赖经验判断。随着人工智能方法的快速发展，许多研究开始采用机器学习的方法提升影像特征提取精度，已发展出多种类型的机器学习方法来提升医学影像的自动分析能力，辅助医生进行诊断^[14-16]。影像学数据中存在空间依赖性，可以使用二维卷积网络来进行特征提取，实现数据降维的同时保留部分空间依赖信息^[17]。对于功能磁共振影像（fMRI）

这类同时拥有空间依赖性和时间依赖性的影像数据，可采用三维卷积网络来进行特征提取，保留特征中的空间和时间依赖性信息^[18]。对于大量没有标注的影像学数据，可以利用自动编码器等无监督学习方法进行特征提取，进而用于 ASD 诊断^[19]。

基于机器学习的 ASD 诊断研究大量集中在提升特征提取精度上，但是作为一种数据驱动方法，机器学习很难在训练数据外的区域进行外推；当训练数据过少时，高精度特征提取效果并不显著。加之神经影像数据的收集较为昂贵，通过收集更多数据的方式来提高 ASD 检测准确率的研究思路在许多场景中不具备客观条件。因此，提升已有数据的质量从而提升模型训练精度是一种有效的改进方法。数据增强方法是通过添加已存在数据的略微修改副本或从现有数据中新创建合成数据来增加数据量的技术，发挥了类似正则器的作用，有助于在训练机器学习模型时减少过度拟合问题^[20]。基于磁共振影像数据驱动的 ASD 诊断领域时常面临数据量不足的问题，数据增强技术有助于提升机器学习模型的泛化性能，改进测试集上的预测准确率。Jönemo 等人利用三维卷积神经网络对 ASD 患者的 fMRI 影像进行分类，通过图片的反转、旋转、缩放、亮度调控、弹性形变等数据增强技术提升可用于训练的 fMRI 影像数据量，不过分类准确率的提升效果并不明显^[21]。Eslami 等人利用特征间线性插值的方式生成新的 fMRI 特征并且进行伪标注的数据增强方式提升 ASD 的分类准确率，改进效果从 28%到 82%不等^[22]。另有研究者对 fMRI 影像使用合成少数过采样(Synthetic Minority Oversampling Technique, SMOTE)方法进行数据增强，从而提升了 ASD 分类准确率^[23, 24]。

数据增强方法通过增加合成数据来提升分类准确率，提升的效果各不相同，并不总能获得显著提升。关键点在于所增添的数据中既会提供任务相关信息，也会引入无关噪音，信噪比决定了分类准确率的提升效果，引入信噪比小的合成数据并无益处。基于大脑磁共振影像的 ASD 诊断，通常面临数据集小、合成数据信噪比小等问题，因此需要发展有效的数据增强方法。同时，传统的 ASD 脑影像标注通常基于专家对患者的行为观察，存在一定的误诊情况，引入了原始标注的噪声^[25]；如果能够自动地纠正这些错误的标注，将有助于提升数据质量，提升分类准确率。本文提出一种新型的数据增强模型，自动对原始磁共振影像特征生成一组新的标注，在不增加新合成数据的前提下，提升数据质量从而改进分类准确率。相较于原始磁共振影像特征和原始标注的预测结果，本文发展的数据增强方法引入的新标注显著的改进了 ASD 分类预测准确率，对比其他同类机器学习模型获得了 10%~20%准确率提升。

2 方法

2.1 磁共振影像数据集

本研究使用了 ABIDE I (Autism Brain Imaging Data Exchange I) 数据库^[26]中的密

西根大学样本库 1 (University of Michigan: Sample 1, UM1) ^[27] 作为研究数据集。UM1 数据集共包含 109 个样本，其中 54 个为 ASD 患者，年龄范围为 8.5-18.6 岁；55 个为对照组，年龄范围为 8.2-19.2 岁，无论是 ASD 患者还是对照组均要求智商大于 85。患者的诊断结果是密西根大学自闭症和沟通障碍中心的医生基于 ADI-R (Autism Diagnostic Interview Revised) 和 ADOS (Autism Diagnostic Observation Schedule) 量表的结果进行判定的。采集 MRI 影像的仪器型号为 3 Tesla GE Signa 扫描仪，109 个样本的数据包括 fMRI 和 sMRI，本工作中所有的数据分析是基于 UM1 的 sMRI 数据集。

2.2 数据训练的流程和目标

本研究中提出的数据增强模型的流程和提升目标如图 1 所示。首先，将数据/影像特征输入到数据增强模型中，产生新的标注，接着将数据特征和新标注输入到随机森林模型中，采用十折交叉验证（十次切分数据进行训练和验证，每次的训练集占比都是 0.9，验证集占比均为 0.1），产生新的分类准确率 S2。将相同的数据特征及其原始标注输入到随机森林模型中，同样地采用十折交叉验证输出原始的分类准确率 S1。本研究的目标，是通过比较两组结果的分​​类准确率，寻到数据增强模型中可以使新的分类准确率有所提升的新标注，这里的提升阈值设置为 10%-20%。为了进行多轮实验获得具有统计意义的结果，该流程被执行 500 次，通过随机丢弃部分原始数据特征（78 个样本被留下），使得每轮实验过程中输入增强模型和随机森林模型的数据特征集都不一样，统计不同数据集输入产生的实验结果，增强实验的可靠性。

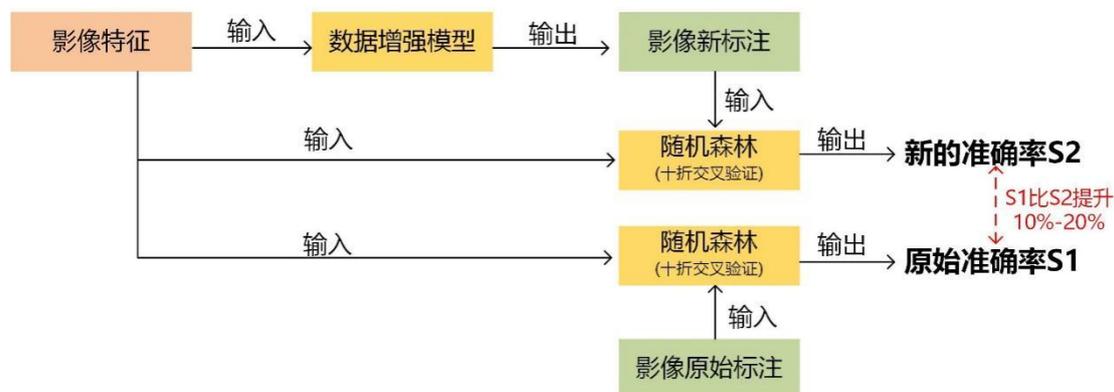


图 1 数据增强流程和提升目标

Fig.1 Data augmentation process and goals to optimize.

2.3 数据增强模型算法实现

整个数据增强模型的算法实现采用 PyTorch 语言^[28]，算法流程图如图 2 所示，包含两个阶段。第一阶段，使用监督学习方法来学习影像特征的分布，即 $P(y|X)$ ，其中 y 是标注（自闭症/非自闭症）， X 是原始磁共振影像特征。学习到的模型将作为后期强化学习的先验，用于防止强化学习过程中生成过度不合理的标注。为了更好地模仿专家的标注行为，使用了双向循环神经网络 (bi-RNN) 作为先验模型^[29]，即使用递归任务标记一批医学图像，

专家对每个图像依次标记，但标注行为不会只进行一次，专家可能会在一轮标注后，回溯结果以确保诊断足够准确。在一批图像的标注过程中，使用 bi-RNN 模型能够有效地实现其中的任何一个图像均可使用之前和/或之后观察到的图像作为参考（即双向）。这里选用门控循环单元（gated recurrent unit, GRU）作为 bi-RNN 的基本单元，使用单层隐藏层，其大小为 3。Adam 优化器^[30]对 bi-RNN 网络优化 1000 步，尽可能地捕获影像特征的数据分布，学习率为 0.005，每次输入模型训练的数据批次大小为原始数据的大小，超参数通过网格搜索选择。

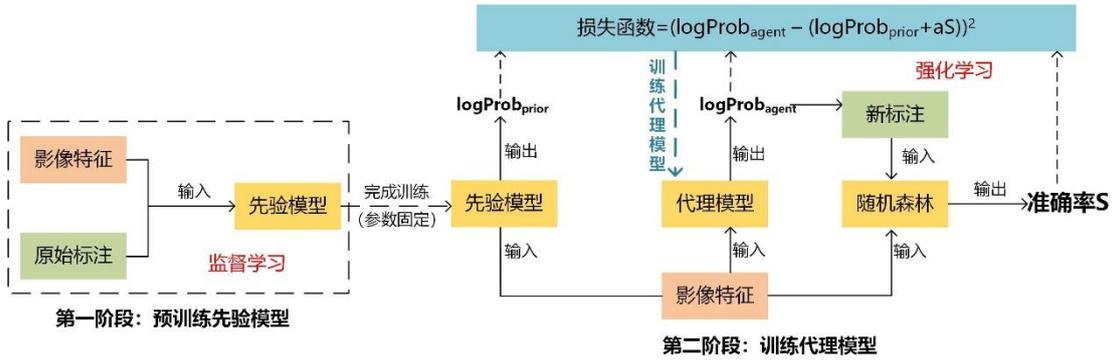


图 2 数据增强模型用来找到能够提升下游分类任务准确率的新标注

Fig. 2 Data augmentation model is used to find new annotations that can improve the accuracy of downstream classification tasks.

数据增强算法的第二个阶段是对代理模型进行训练，该代理模型具备与先验模型同样的架构，是寻找提升分类准确率的新标注的代理人（agent）。在训练该代理模型的每一步中，输入原始磁共振影像特征到代理模型中，由代理模型输出新标注，使用随机森林^[31]模型来量化原始磁共振影像和新标注之间的关系，并且计算 10 折交叉验证准确率（S）。随后，S 会被用作强化学习的激励或者反馈。bi-RNN 的输出是 logits，其值在 0 和 1 之间，表示预测为自闭症（标为 1）的可能性。将原始磁共振影像特征分别输入到代理模型和训练好的先验模型中，计算它们预测自闭症的对数概率，表示为 $\log\text{Prob}_{\text{prior}}$ 和 $\log\text{Prob}_{\text{agent}}$ 。强化学习的损失函数定义为

$$J = (\log\text{Prob}_{\text{agent}} - (\log\text{Prob}_{\text{prior}} + \alpha S))^2 \quad (1)$$

其中 α 是可以调整的超参数，本研究通过多组实验对比，将该值设置为 200。训练代理模型所采用的优化器和学习率跟训练先验模型时的一致，训练的迭代轮次 (epoch) 设置为 100，每轮 (epoch) 训练过程中，被输入网络的数据批次大小 (batch size) 为原始样本数据的大小。为了防止代理模型生成无意义的标注分布，这里将代理模型产生的新标注分布锚定到训练好的先验模型产生的标注分布。

为了更好地呈现整个算法的流程，表 1 展示了数据增强算法实现的伪代码：

表 1. 数据增强算法的伪代码

Table 1. Pseudocode of data augmentation algorithm

数据增强算法

输入：影像特征 X ，原始标注 Y

输出：新的准确率集合 $S' = \emptyset$ ，新的标注集合 $Y' = \emptyset$

先验模型：Prior；代理模型：Agent；随机森林：RF；训练代理模型目标函数： J

for $i=1$ to 500 do

 在 X 上随机采样获得 X_i ，对应的标注组成 Y_i

 for $j=1$ to 1000 do

$Z_1 = \text{Prior}(X_i)$;

 更新 Prior 模型参数，减小 Z_1 与 Y_i 的距离；

 end

 原始分类准确率 $S_{ori} = \text{RF}_{i,0}(X_i, Y_i)$

 初始化新分类准确率 $S_{new} = 0$

 初始化新标注 $Y_{new} = \emptyset$

 for $k=1$ to 100 do

$Z_2 = \text{Agent}(X_i)$;

 由预测概率结果 Z_2 获得新的标注 Y^* ;

$S = \text{RF}_{i,k}(X_i, Y^*)$;

 损失值 $\text{Loss} = J(Z_1, Z_2, S)$;

 更新 Agent 参数，减小损失值 Loss;

 if $0.1 \leq S - S_{ori} \leq 0.2$ & $S_{new} < S$ then

$S_{new} = S$;

$Y_{new} = Y^*$;

 end

$S' = S' \cup S_{new}$

$Y' = Y' \cup Y_{new}$

end

3 实验结果

本研究使用随机挑选的磁共振影像样本特征作为输入。图 1 所示的数据增强流程经过 500 次重复，每次随机挑选样本产生不同的数据集，使得结果更具统计意义。在每一次重复数据增强的流程中，分别记录原始分类准确率和新的分类准确率，并对两者进行比较。图 3a 展示了 500 次重复实验过程中原始分类准确率的分布（灰色），图 3b 则记录了在 500

次重复实验过程中新的分类准确率的分布（绿色）。如图所见，原始分类准确率分布在 0.6 左右，而新的分类准确率分布在 0.8 左右。为了更精准地量化新分类的准确率提升，计算了新的分类准确率和原始分类准确率之差，并按照降序重新排列，如图 3c 所示（红色）。为了便于对照，图 3a 和 3b 的横坐标排列顺序与图 3c 遵循相同的规则。假设医生在标注过程中不会出现过多的失误，不能无限度提升准确率，因此在算法中设定限制，将新的分类准确率的提升约束在 10%~20%之间，即在 500 次试验中，如果找到提升分类准确率介于 10%~20%的新标注，则输出新的分类准确率，反之则输出 0。在实验中存在少数没有找到提升分类准确率介于 10%~20%之间的新标注的情况，因此图 3c 中的末尾部分存在少量的负数例子。除此之外的其他新标注的分类准确率提升在 0.102 到 0.200 之间不等。在所有试验中，共有 494 次（98.8%）找到可以提升分类准确率 10%~20%的新标注，即对于不同的数据集，本方法都能够比较稳定地通过数据增强的方式提升其分类准确率。为了更加直观地说明本研究提出算法的有效性，500 次实验的量化比较结果也被展示在表格 2 中，从表格 2 中可以看出，500 次实验中，数据增强算法产生的平均准确率为 0.838，而不进行数据增强产生的平均准确率为 0.665，比引入数据增强算法的实验结果低 0.173 的准确率。

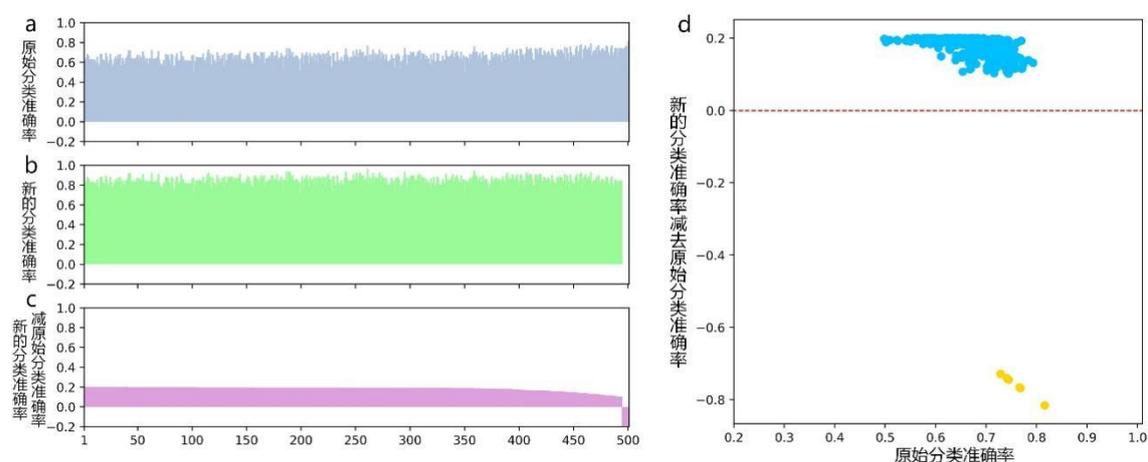


图 3 500 次试验中 a) 原始分类准确率、b) 新的分类准确率及 c) 二者之差（新的分类准确率-原始分类准确率，按降序排列）的分布；d) 原始分类准确率和（新的分类准确率-原始分类准确率）的配对图。

Fig. 3 a) Distribution of a) original classification accuracy, b) new classification accuracy and c) the difference between them (new classification accuracy - original classification accuracy, sorted in descending order) in 500 trials; d) Pair plot of original classification accuracy and (new classification accuracy - original classification accuracy).

表 2. 500 次实验数据增强得到的平均准确率与不进行数据增强（原始）得到的平均准确率结果

Table 2. Mean accuracies obtained from methods with/without data augmentation in 500 experiments.

数据增强产生的平均准确率	原始平均准确率	数据增强提升的平均准确率
--------------	---------	--------------

0.838	0.665	0.173
-------	-------	-------

为了进一步阐明准确率提升与标注之间的关系，图 3d 展示了原始分类准确率和新旧二者之差(新的分类准确率-原始分类准确率)的配对关系。对于原始准确率较低的区域 (<0.6)，提升准确率的效果较为显著，集中于 0.2 左右(蓝色区域左部)。而对于原始准确率较高的区域 (>0.6)，准确率的提升效果开始下降，具体表现为准确率提升的变化幅度变大(蓝色区域右部)。一种可能的解释是，对于原始准确率较高的数据集，特征和标注间的关系简单，决策边界清晰，可能归因于标注中的噪声比较小、准确率的提升空间较小；反之，对于原始准确率较低的数据集，标注中的噪声比较大，准确率的提升空间较大。

在证实了模型可以稳定提升准确率之后，在固定数据集的基础上，本研究着眼于从可以提升准确率的标注分布候选中，寻找最合理的标注分布并进行可解释分析。对于生成的新的标注分布，不同的标注分布可以提升相似的准确率，但不是所有能够提升分类准确率的标注分布都是合理的，即统计意义上的准确率提升并不能保证模型能够纠正医学上的错误标签，因而需要对生成的标注分布进行后筛选，并尝试进行解释。用上述的数据增强模型进行新的标注生成，并计算随机森林模型在(原始磁共振影像特征/原始标注)以及(原始磁共振影像特征/新的标注)上的 10 折交叉验证准确率。通过比较新的分类准确率和原始分类准确率，保留能提升分类准确率 0%~10%范围内的新的标注分布，选择该范围的原因是为了在初期尽可能减少新的标注和原始标注之间的差异，从而便于追踪造成差异的原因。上述过程重复了 50000 次，以确保找到尽可能多的满足指定条件的新的标注分布。

在 50000 次的试验当中，共找到了 70 个满足指定条件的新标注分布。将这 70 个标注分布与原始标注进行比较，并计算新的标注分布较之原始标注分布的改变比例，标注改变比例和准确率提升的配对图如图 4 所示。通过生成新的标注分布来提升分类准确率至 0%~10%，标注改变比例可以从 40.37%变化到 57.80%，有着比较大的改变。同时，当标注改变比例较小时(40.37%-45.00%)，准确率提升变化幅度较小，在 7%~10%之间；而当标注改变比例较大时(45.00%-57.80%)，准确率提升变化幅度较大，约为 2%~10%。可以看出当生成的新的标注分布和原始标注分布之间的差异较大时，即过多地改动原始的标注分布时，不一定能稳定且显著地提升分类准确率。另一个问题在于，新的标注分布较原始标注分布的改变比例较大，最小的也有 40.37%，使得追踪和验证生成的新标注是否合理具有一定的挑战性。

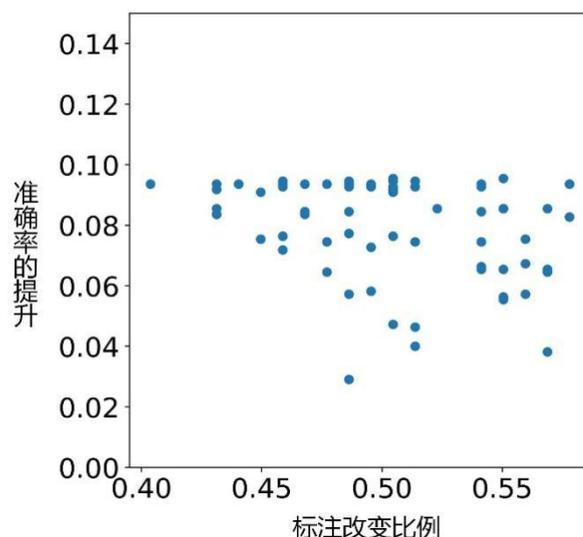


图 4 标注改变比例和准确率提升的配对图

Fig. 4 Pair plot between label-change-ratio and classification-accuracy-improvement.

增强 ABIDE 结构磁共振影像数据进行自闭症分类的研究较少，现有的数据增强方法主要有两种，一种是对原始影像进行编辑转换，扩增影像的数量。有研究者提出了动态数据增强的方法，每次训练网络前，将 ABIDE-I 训练集中的结构磁共振影像进行随机 0 到 15° 范围内的旋转、随机水平或垂直方向偏移 20%、随机 0 至 15% 的放大或缩小、随机 0.1 至 1（1 代表原始亮度）的亮度变化，使得每次训练网络时输入的影像数据都不一致，扩增了训练影像的数量，提出的模型和数据增强方法在 ABIDE I 影像上达到约 80% 的自闭症检测准确率^[32]。相似地，Nogay 等人将 ABIDE 数据集上的结构磁共振影像分别进行水平翻转、右旋转 90° 和 180°、加入噪声，使得增强后的训练数据量是原先的 5 倍，在自闭症检测上取得不错的结果^[33]。另一种数据增强方法是基于生成对抗网络产生新的影像，Liu 等人提出了一个多输出的条件对抗生成网络用于生成新的功能和结构磁共振影像特征，该生成网络采用底部全连接层共享的策略，学习不同模态数据的联合表征，接着使用两个独立的全连接网络模块分别生成新的功能和结构磁共振影像特征，原始和新生成的特征被输入到分类网络中，实验结果表明，采用多输出条件生成对抗网络产生新特征的数据增强方式，在 ABIDE-I 上能够提升 4% 的自闭症检测准确率（达到 72.9%）^[34]。虽然这些数据增强方法能够给模型带来一定程度的性能提升，但提升效果并不是很明显，而且这些方法都是基于原始影像和特征进行数据扩充，增加训练数据量的同时也使得训练过程变慢，训练难度增强，且盲目地扩增数据也容易引入一些不必要甚至是干扰的信息。与这些方法不同的是，本文提出的数据增强新范式是基于修正数据标签进行的，能够在不增加数据量的情况下明显地提升自闭症检测的准确率（10%-20%），且由于本文提出的方法并无引入其他数据信息，不容易受干扰，使得数据增强带来的模型性能提升效果更加稳定，在 500 次试验中模型性能提升 10%-20% 的次数达到了 494 次，进一步说明基于修正数据标签的数据增强算法的稳定性和可靠性。

为了进一步验证所提出的算法的优越性，本研究采用现有数据增强方法进行实验，分别对影像特征进行水平翻转和添加随机噪声的操作，实验结果表明，水平翻转的数据增强方式在 500 次实验过程中提升 10%以上准确率的次数为 8，而随机添加噪声的数据增强方式在 500 次实验过程中提升 10%以上准确率的次数为 50，验证了本研究提出的增强算法在自闭症分类方面的优越性（500 次实验提升准确率在 10%-20%的次数为 494）。为了进一步验证所提出算法的普适性，本文在 ABIDE I 另一个中心(CMU)数据集进行实验，在 500 次实验中能有效提升准确率在 10%-20%的次数达到 500；除此之外，不同的分类算法也被应用到本研究提出的数据增强算法中，具体地，原始的影像特征和数据增强模型产生的新标注也被输进 SVM, XGBoost 和 GBDT 分类器中，实验结果表明，提出的数据增强算法在其他的分类器上也能产生较好的结果，500 次实验提升准确率在 10%-20%的次数分别为 499(SVM), 492 (XGBoost), 486(GBDT)，这说明了本研究提出的算法具备较好的普适性。

4 结论

本研究聚焦于利用大脑结构磁共振影像进行自闭症分类的人工智能算法改进，提出了一种新的数据增强模型，与现有的通过扩增结构磁共振影像或特征进行数据增强的算法不同，该模型采用修正数据标签的思想，能够在不增加数据量的情况下提升数据质量，明显提升了自闭症分类的准确率，且由于本文提出的增强算法没有盲目引入其他数据信息，不易于受干扰，因此效果更加稳定。ASD 的传统诊断依赖临床行为量表，存在误诊的情况，即原始标注之中可能会有噪声，本文通过为原始特征生成新的标注提升数据的质量，并基于 ABIDE I 中的 UM1 数据集进行训练并进行模型测试，结果证实新的标注分布确实能够带来分类准确率上的提升。同时，对于提升相似的分类准确率，可以有不同的新的标注分布。在临床医学的诊断上，并不是所有的标注分布都是合理的，即分类准确率的提升不等价于对原始标注的成功纠错。例如，将标注中的 0 和 1 颠倒，并不会损失分类准确率，但是却是完全错误的标注。本文的研究结果表明，新标注分布与原始标注分布之间的差异较大，这为标注的验证带来了极大的挑战，拟在未来工作中，与临床医生建立进一步的联合分析，借助于临床医生的诊断经验，进一步分析和验证标注的数据增强方法的可靠性和可解释性。

参考文献

- [1] Ziats CA, Patterson WG and Friez M. Syndromic Autism Revisited: Review of the Literature and Lessons Learned [J]. *Pediatr Neurol*, 2021, 114: 21-25.
- [2] Lai M C, Kassee C, Besney R, et al. Prevalence of co-occurring mental health diagnoses in the

-
- autism population: a systematic review and meta-analysis[J]. *The Lancet Psychiatry*, 2019, 6(10): 819-829.
- [3] Chaste P and Leboyer M. Autism risk factors: genes, environment, and gene-environment interactions [J]. *Dialogues Clin Neurosci*, 2012, 14(3): 281-292.
- [4] Masi A, DeMayo MM, Glozier N, et al. An Overview of Autism Spectrum Disorder, Heterogeneity and Treatment Options [J]. *Neurosci Bull*, 2017, 33(2): 183-193.
- [5] Maenner MJ, Warren Z, Williams AR, et al. Prevalence and Characteristics of Autism Spectrum Disorder Among Children Aged 8 Years - Autism and Developmental Disabilities Monitoring Network, 11 Sites, United States, 2020 [J]. *MMWR Surveill Summ*, 2023, 72(2): 1-14.
- [6] Zhou H, Xu X, Yan W, et al. Prevalence of Autism Spectrum Disorder in China: A Nationwide Multi-center Population-based Study Among Children Aged 6 to 12 Years [J]. *Neurosci Bull*, 2020, 36(9): 961-971.
- [7] Sun X, Allison C, Wei L, et al. Autism prevalence in China is comparable to Western prevalence[J]. *Molecular autism*, 2019, 10: 1-19.
- [8] Sharma S R, Gonda X, Tarazi F I. Autism spectrum disorder: classification, diagnosis and therapy[J]. *Pharmacology & therapeutics*, 2018, 190: 91-104.
- [9] Rosen NE, Lord C and Volkmar FR. The Diagnosis of Autism: From Kanner to DSM-III to DSM-5 and Beyond [J]. *J Autism Dev Disord*, 2021, 51(12): 4253-4270.
- [10] Frigaux A, Evrard R, Lighezzolo-Alnot J. ADI-R and ADOS and the differential diagnosis of autism spectrum disorders: Interests, limits and openings[J]. *L'encephale*, 2019, 45(5): 441-448.
- [11] Yazdani S, Capuano A, Ghaziuddin M, et al. Exclusion criteria used in early behavioral intervention studies for young children with autism spectrum disorder[J]. *Brain sciences*, 2020, 10(2): 99.
- [12] Khodatars M, Shoeibi A, Sadeghi D, et al. Deep learning for neuroimaging-based diagnosis and rehabilitation of autism spectrum disorder: a review[J]. *Computers in Biology and Medicine*, 2021, 139: 104949.
- [13] Kaur P and Kaur A. Review of Progress in Diagnostic Studies of Autism Spectrum Disorder Using Neuroimaging [J]. *Interdiscip Sci*, 2023, 15(1): 111-130.
- [14] 杨兆凯, 王龙, 陈金栋. 人工智能与深度学习在医学影像辅助诊断中的应用 [J]. *电脑知识与技术*, 2021, 17(35): 91-93.
Yang ZK, Wang L, Chen JD. Application of artificial intelligence and deep learning in computer aided diagnosis of medical images [J]. *Computer knowledge and technology*, 2021, 17(35): 91-93. (Translated from Chinese)
- [15] Bento M, Fantini I, Park J, et al. Deep learning in large and multi-site structural brain MR imaging datasets[J]. *Frontiers in Neuroinformatics*, 2022, 15: 805669.
- [16] Celard P, Iglesias EL, Sorribes-Fdez JM, et al. A survey on deep learning applied to medical images: from simple artificial neural networks to generative models [J]. *Neural Comput Appl*, 2023, 35(3): 2291-2323.
- [17] Soleimani M, Vahidi A, Vaseghi B. Two-dimensional stockwell transform and deep convolutional neural network for multi-class diagnosis of pathological brain[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 29: 163-172.
- [18] Zou L, Zheng J, Miao C, et al. 3D CNN based automatic diagnosis of attention deficit

-
- hyperactivity disorder using functional and structural MRI[J]. *Ieee Access*, 2017, 5: 23626-23636.
- [19] Baur C, Denner S, Wiestler B, et al. Autoencoders for unsupervised anomaly segmentation in brain MR images: a comparative study[J]. *Medical Image Analysis*, 2021, 69: 101952.
- [20] Shorten C, Khoshgoftaar T M. A survey on image data augmentation for deep learning [J]. *Journal of big data*, 2019, 6(1): 1-48.
- [21] Jönemo J, Abramian D, Eklund A. Evaluation of augmentation methods in classifying autism spectrum disorders from fMRI data with 3D convolutional neural networks[J]. *arXiv preprint arXiv:2110.10489*, 2021.
- [22] Eslami T, Mirjalili V, Fong A, et al. ASD-DiagNet: A Hybrid Learning Approach for Detection of Autism Spectrum Disorder Using fMRI Data [J]. *Front Neuroinform*, 2019, 13: 70.
- [23] Eslami T, Saeed F. Auto-ASD-network: a technique based on deep learning and support vector machines for diagnosing autism spectrum disorder using fMRI data [C] // *In Proceedings of the 10th ACM International Conference on Bioinformatics, Computational Biology and Health Informatics*, 2019: 646-651.
- [24] Huang Z A, Zhu Z, Yau C H, et al. Identifying autism spectrum disorder from resting-state fMRI using deep belief network [J]. *IEEE Transactions on neural networks and learning systems*, 2020, 32(7): 2847-2861.
- [25] Eslami T, Mirjalili V, Fong A, et al. ASD-DiagNet: a hybrid learning approach for detection of autism spectrum disorder using fMRI data[J]. *Frontiers in neuroinformatics*, 2019, 13: 70.
- [26] Di Martino A, Yan CG, Li Q, et al. The autism brain imaging data exchange: towards a large-scale evaluation of the intrinsic brain architecture in autism [J]. *Mol Psychiatry*, 2014, 19(6): 659-667.
- [27] Monk CS, Peltier SJ, Wiggins JL, et al. Abnormalities of intrinsic functional connectivity in autism spectrum disorders [J]. *Neuroimage*, 2009, 47(2): 764-772.
- [28] Paszke A, Gross S, Massa F, et al. Pytorch: An imperative style, high-performance deep learning library[C] // *Advances in neural information processing systems*, 2019: 32.
- [29] Schuster M, Paliwal K K. Bidirectional recurrent neural networks [J]. *IEEE transactions on Signal Processing*, 1997, 45(11): 2673-2681.
- [30] Kingma D P, Ba J. Adam: A method for stochastic optimization[J]. *arXiv preprint arXiv:1412.6980*, 2014.
- [31] Breiman L. Random forests [J]. *Machine Learning*, 2001, 45(1): 5-32.
- [32] Mishra M, Pati U C. A classification framework for Autism Spectrum Disorder detection using sMRI: Optimizer based ensemble of deep convolution neural network with on-the-fly data augmentation[J]. *Biomedical Signal Processing and Control*, 2023, 84: 104686.
- [33] Nogay H S, Adeli H. Diagnostic of autism spectrum disorder based on structural brain MRI images using, grid search optimization, and convolutional neural networks[J]. *Biomedical Signal Processing and Control*, 2023, 79: 104234.
- [34] Liu R, Huang Z A, Hu Y, et al. Attention-Like Multimodality Fusion With Data Augmentation for Diagnosis of Mental Disorders Using MRI[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022.