

## 引文格式:

李逸升, 徐永杰, 王书强, 等. 基于条件扩散模型的脑电增强在自闭症筛查中的应用 [J]. 集成技术, 2025, 14(3): 78-86.

Li YS, Xu YJ, Wang SQ, et al. Application of electroencephalography enhancement based on conditional diffusion model in autism screening [J]. Journal of Integration Technology, 2025, 14(3): 78-86.

# 基于条件扩散模型的脑电增强在自闭症筛查中的应用

李逸升 徐永杰 王书强 王怡珊\*

(中国科学院深圳先进技术研究院 深圳 518055)

**摘要** 随着深度学习技术的快速发展, 基于脑电等神经信号的自闭症筛查逐渐成为一种可行的诊断手段。然而, 由于脑电的数据采集较复杂, 尤其是儿童, 因此往往存在数据量不足的问题。数据增强方法常用于解决真实数据不足的问题, 其中生成式对抗网络是常用方法。然而, 受限于数据规模的不足和数据多样性的缺乏, 当前的数据增强方法在分类性能上仍未达到理想水平。本研究采用改进的条件扩散模型, 分别对原始脑电信号及其生成的脑功能连接时序图进行增强。实验结果表明, 该方法显著提升了自闭症分类性能。其中, 静息态和任务态数据的最高分类准确率分别达到 84.38% 和 79.01%, 表明了基于条件扩散模型的数据增强在提升自闭症筛查结果方面的有效性。

**关键词** 脑电; 脑功能连接时序图; 条件扩散模型; 数据增强

中图分类号 TP183 文献标志码 A doi: 10.12146/j.issn.2095-3135.20241127001

CSTR: 32239.14.j.issn.2095-3135.20241127001

## Application of Electroencephalography Enhancement Based on Conditional Diffusion Model in Autism Screening

LI Yisheng XU Yongjie WANG Shuqiang WANG Yishan\*

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

\*Corresponding Author: ys.wang@siat.ac.cn

**Abstract** With the rapid development of deep learning technology, autism screening based on neural signals such as electroencephalography (EEG) is gradually emerging as a novel diagnostic approach. However, due to the complexity of EEG data acquisition, especially for children, insufficient data often poses a challenge. Data augmentation methods are commonly used to address the scarcity of real-world data, with generative adversarial networks (GANs) being a frequently applied technique. However, due to the limited scale and diversity of data, current augmentation methods have not yet to achieve optimal classification performance.

收稿日期: 2024-11-27 修回日期: 2025-01-24

基金项目: 深圳市高层次人才团队项目 (KQTD20200820113106007)

作者简介: 李逸升, 硕士研究生, 研究方向为数据增强及生成模型; 徐永杰, 硕士, 研究方向为基于脑电信号的自闭症筛查方法; 王书强, 博士, 研究方向为脑影像计算和大数据分析技术; 王怡珊 (通讯作者), 博士, 研究方向为生理/神经信号分析处理方法, E-mail: ys.wang@siat.ac.cn.

This study introduces an improved conditional diffusion model to enhance both raw EEG signals and their corresponding functional connectivity temporal graphs. Experimental results demonstrate that this method significantly improves autism classification performance, achieving maximum classification accuracies of 84.38% and 79.01% for resting-state and task-state data, respectively. These findings validate the effectiveness of data augmentation based on the conditional diffusion model in enhancing autism screening outcomes.

**Keywords** electroencephalography; time-series maps of brain functional connectivity; conditional diffusion model; data augmentation

**Funding** This work is supported by Shenzhen Science and Technology Program, China (KQTD 20200820113106007)

## 1 引言

自闭症谱系障碍是一种神经发育障碍, 表现为社交沟通困难、兴趣狭窄和重复行为<sup>[1]</sup>。许多自闭症患者还伴有焦虑、抑郁或注意力缺陷多动障碍等共病症状, 进一步影响其生活质量。近年来, 自闭症的全球患病率约为 1%, 且呈上升趋势<sup>[2]</sup>。早期诊断和干预对改善患者生活质量和治疗效果至关重要<sup>[3]</sup>。

自闭症患者的大脑区域连接通常表现异常, 包括局部过度连接与整体连接不足、局部和长距离连接的混淆等<sup>[4-7]</sup>。研究表明, 初级感觉神经元突触功能的紊乱可能是自闭症的神经生理基础, 为异常连接提供了部分解释<sup>[8-10]</sup>。探索大脑功能连接模式有助于提高早期诊断精度并推动个性化治疗<sup>[9]</sup>。

近年来, 深度学习被广泛应用于神经影像数据分析, 为包括自闭症在内的精神疾病诊断提供了新工具<sup>[11-12]</sup>。功能性磁共振成像可揭示异常功能连接, 为揭示自闭症神经机制提供重要线索<sup>[13-14]</sup>。然而, 其数据采集复杂且成本高昂, 限制了进一步研究和应用的推广。

与之相比, 脑电具有成本低、易获取的优势。早期脑电研究多集中于多尺度熵和谱特征的

分析, 在自闭症检测中的分类准确率通常高于功能性磁共振成像<sup>[15-17]</sup>。近年来, 研究者开始利用脑电数据的功能连接识别自闭症。例如, Peya 等<sup>[18-19]</sup>使用皮尔逊相关系数将脑电数据转换为二维功能连接图, 并通过残差网络对连接图分类, 自闭症识别准确率达到 88.88%。但由于数据量有限, 方法的泛化性受限制。

近期的研究利用公开的自闭症脑电数据生成脑功能连接时序图, 并通过深度卷积生成对抗网络 (deep convolutional generative adversarial network, DCGAN) 扩充样本量至 4 倍。基于卷积神经网络 (convolutional neural network, CNN) 长短期记忆网络 (long short-term memory, LSTM) 的模型在静息态和任务态数据上的分类准确率分别达到 81.08% 和 74.55%<sup>[20]</sup>, 表明基于脑功能连接时序图的特征提取在自闭症检测中具有潜力。

通过生成对抗网络扩充数据虽然有所改进, 但数据规模仍然不够充足, 更重要的是, 生成对抗网络的训练稳定性和模式崩溃问题是一个重要挑战<sup>[21]</sup>。相比之下, 扩散模型以其稳定性和生成多样性逐渐受到关注, 在图像生成领域效果显著<sup>[22]</sup>, 并展现出在脑电数据增强中的潜在应用价值<sup>[23-24]</sup>。

在先前研究<sup>[20]</sup>的基础上, 本文进一步提出了

用于数据增强的条件扩散模型。此外,本研究采用了两种增强策略:其一是对原始脑电信号进行增强,并将扩充后的信号用于生成脑功能连接时序图;其二是直接对由脑电信号生成的脑功能连接时序图进行增强,并将扩充后的脑功能连接时序图用于自闭症/典型发育二元分类任务。

## 2 数据

本研究的数据来源于美国国家自闭症研究数据库的“女性自闭症谱系障碍多模式发育神经遗传学”项目<sup>[25]</sup>,包含143名自闭症患者和137名典型发育个体,性别比例均衡。脑电数据在静息状态和任务状态下采集。静息态实验中,受试者观看屏幕动画60 s后闭眼休息30 s,同时记录脑电信号。任务态实验采用两种视觉刺激:生物运动(点光源模拟行走者运动)和扰乱运动(随机打

乱的点光源),两者以1:1比例随机呈现。每次试验以注视点开始,随后呈现刺激画面,以评估受试者的脑活动。

数据使用128通道脑电设备采集,并以500 Hz采样率记录。数据采集者使用1 Hz高通滤波、60 Hz陷波滤波和100 Hz低通滤波,以抑制噪声。随后使用伪影检测算法去除眼动等伪迹。在剔除阻抗超过200 k $\Omega$ 的通道和无效通道后,保留了125个有效通道。在本研究的数据预处理中,脑电信号被降采样至250 Hz,以降低计算复杂度。

本研究选取了189名受试者(自闭症组97人,典型发育组92人)的静息态数据和165名受试者(自闭症组81人,典型发育组84人)的任务态数据。研究涉及脑电信号和脑功能连接时序图两种数据模态,其样本个数和数据形状如表1所示。

表1 两种数据类型的样本个数和数据形状

Table 1 The sample size and data structure of the two data types

数据模态	静息态		数据形状	任务态		数据形状
	样本个数			样本个数		
	自闭症	典型发育		自闭症	典型发育	
脑电信号	5 800	5 500	125×512	8 400	8 700	125×300
脑电功能连接时序图	97	92	400×40	81	84	400×40

在静息态实验中,每位受试者完成60次试验,每次试验的脑电信号被视为一个独立样本。在剔除无效样本后,最终纳入5 800个自闭症样本和5 500个典型发育样本参与后续的数据增强和分类实验。每次试验持续2 048 ms,脑电信号数据形状为125×512,其中125是通道数,512是采样点个数。类似地,在任务态实验中,每位受试者完成104次试验,最终纳入8 400个自闭症样本和8 700个典型发育样本参与研究。每次试验持续1 200 ms,对应的脑电信号数据形状为125×300。

本研究沿用先前研究<sup>[20]</sup>的方法计算脑电功能连接图。针对每个脑电序列,计算125个通道之间的皮尔逊相关性系数,反映通道间的功能连接。由于对称性,本文仅选取其中的7 750个系数作为特征。进一步地,针对每位受试者,提取第11~50次试验的数据特征,构建形状为7 750×40的脑功能连接时序矩阵。随后,通过SeleckKBest特征选择算法,选取与自闭症谱系障碍最相关的400个功能连接特征。经过归一化处理后,这些特征被转化为400×40的灰度图像,作为独立样本。样本总量与受试者数量相

对应。

### 3 方法

本文提出的用于数据增强的条件扩散模型是潜扩散模型的一种改进。潜扩散模型作为扩散模型的一种重要变体, 通过在潜空间中建模数据分布, 能以更高效的方式生成高质量的数据样本, 并支持在特定条件下生成符合约束的样本<sup>[26]</sup>。然而, 考虑到计算复杂度与样本多样性之间的权衡, 本研究摒弃了潜空间建模部分, 并引入了一种新的混合损失函数, 以确保生成样本的多样性。此外, 本研究对模型中 U-Net 架构的交叉注意力机制进行了改进, 使得模型能在给定样本标签 (如自闭症或典型发育) 下学习特定类别的数据分布, 从而为后续自闭症检测任务提供有力支持。由于本文使用的增强数据包括原始脑电信号和通过脑电信号生成的脑功能连接时序图两种模态, 因此, 针对这两种模态的交叉注意力机制有所区别。条件扩散模型的架构如图 1 所示。

#### 3.1 条件扩散模型

条件扩散模型的前向传播过程为原始数据  $\mathbf{x}_0$  逐步添加高斯噪声  $\epsilon_t, t \in [0, T]$ , 直至其变为服从均值为 0、方差为  $I$  的标准高斯分布  $\mathcal{N}(0, I)$  的噪声  $\mathbf{x}_T$ , 因此也被称为加噪过程或扩散过程。具体来说, 定义一组潜在变量  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T$ , 这些变量通过式 (1) 分布递推生成:

$$q(\mathbf{x}_t|\mathbf{x}_{t-1}) = \mathcal{N}(\mathbf{x}_t; \sqrt{1-\beta_t}\mathbf{x}_{t-1}; \beta_t I) \quad (1)$$

其中,  $\beta_t$  为一组预先设定的与时间步长  $t$  有关的噪声尺度;  $q(\mathbf{x}_t|\mathbf{x}_{t-1})$  为经过时间步长  $t$  后的条件分布。经过  $T$  步后可以得到条件分布  $q(\mathbf{x}_T|\mathbf{x}_0)$ , 表示如下:

$$q(\mathbf{x}_T|\mathbf{x}_0) = \mathcal{N}(\mathbf{x}_T; \sqrt{\bar{\alpha}_T}\mathbf{x}_0; (1-\bar{\alpha}_T)I) \quad (2)$$

其中,  $\bar{\alpha}_T = \prod_{t=1}^T (1-\beta_t)$ 。这意味着,  $\mathbf{x}_T$  的分布已接近标准高斯分布。

反向传播过程首先随机采样一个服从标准高

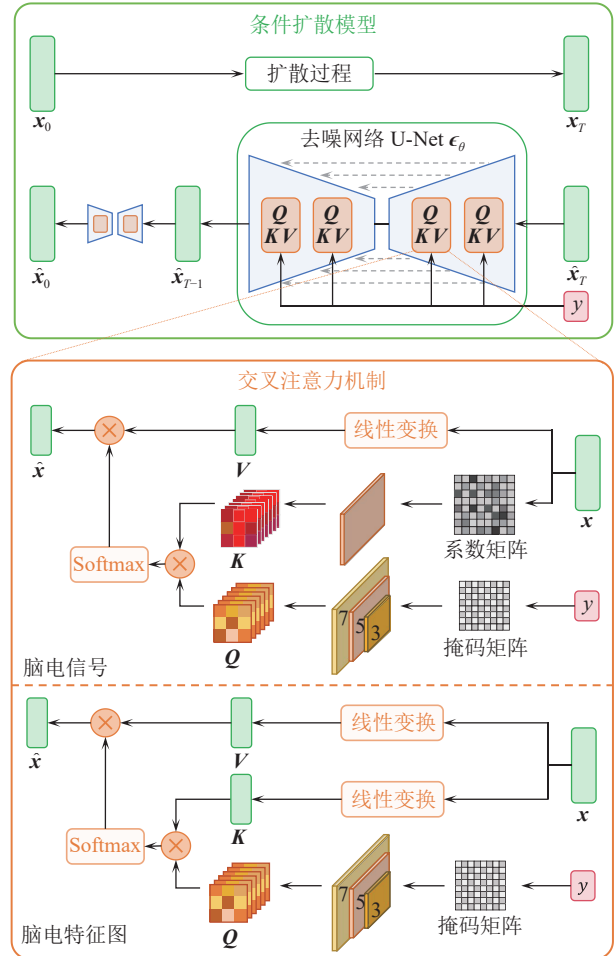


图 1 条件扩散模型的框架

Fig. 1 The framework of conditional diffusion model

斯分布的噪声  $\hat{\mathbf{x}}_T$ , 然后为  $\hat{\mathbf{x}}_T$  逐步去除噪声, 还原出数据  $\hat{\mathbf{x}}_0$ , 它是与原始数据  $\mathbf{x}_0$  具有相同分布的新数据, 因此反向传播过程也被称为去噪过程。去噪过程可以通过学习参数化的逆分布  $p_\theta(\hat{\mathbf{x}}_{t-1}|\hat{\mathbf{x}}_t, y)$  (即  $\hat{\mathbf{x}}_{t-1}$  在  $\hat{\mathbf{x}}_t$  和条件  $y$  下的分布) 实现, 其中  $\theta$  为模型要学习的参数。根据贝叶斯法则, 该逆分布可表示如下:

$$p_\theta(\hat{\mathbf{x}}_{t-1}|\hat{\mathbf{x}}_t, y) = \mathcal{N}(\hat{\mathbf{x}}_{t-1}; \mu_\theta(\hat{\mathbf{x}}_t, t, y), \Sigma_\theta(\hat{\mathbf{x}}_t, t)) \quad (3)$$

其中  $\mu_\theta$  和  $\Sigma_\theta$  分别为条件  $y$  下的高斯分布均值和协方差, 由神经网络习得。在本研究中, 条件  $y$  是样本标签, 即自闭症或典型发育两种条件之一。

为估计参数  $\mu_\theta$  和  $\Sigma_\theta$ , 本文利用变分推断优化模型最大化生成数据  $\hat{\mathbf{x}}_0$  的对数似然  $\log p_\theta(\hat{\mathbf{x}}_0|y)$ 。

由于直接优化对数似然比较复杂，因此引入了证据下界  $L_{\text{ELBO}}$ ，其定义如下：

$$L_{\text{ELBO}} = \log p_{\theta}(\hat{\mathbf{x}}_0 | y) \geq \mathbb{E}_{q(\mathbf{x}_{1:T} | \mathbf{x}_0)} \left[ \log \frac{p_{\theta}(\hat{\mathbf{x}}_{0:T} | y)}{q(\mathbf{x}_{1:T} | \mathbf{x}_0)} \right] \quad (4)$$

其中， $\mathbb{E}$ 表示期望； $p_{\theta}(\hat{\mathbf{x}}_{0:T} | y)$ 表示在条件  $y$  下， $\hat{\mathbf{x}}_0, \hat{\mathbf{x}}_1, \dots, \hat{\mathbf{x}}_T$  的联合条件分布； $q(\mathbf{x}_{1:T} | \mathbf{x}_0)$ 表示条件  $\mathbf{x}_0$  下， $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T$  的联合条件分布。

该证据下界目标函数可分解为多项，其中包含对每个时间步长  $t$  的噪声预测误差。具体地，优化目标的一个典型形式表示如下：

$$L_{\text{ELBO}} = \log p_{\theta}(\hat{\mathbf{x}}_0 | y) \geq \mathbb{E}_{q(\mathbf{x}_{1:T} | \mathbf{x}_0)} \left[ \|\boldsymbol{\epsilon}_t - \boldsymbol{\epsilon}_{\theta}(\hat{\mathbf{x}}_t, t, y)\|^2 \right] \quad (5)$$

其中， $\boldsymbol{\epsilon}_{\theta}(\hat{\mathbf{x}}_t, t, y)$ 为对前向传播噪声  $\boldsymbol{\epsilon}_t$  的预测； $\boldsymbol{\epsilon}_{\theta}$ 则为用于预测噪声的神经网络 U-Net。通过最小化两种噪声之间的均方差，模型可以根据条件变量  $y$  精准地预测前向传播每一步注入的噪声，然后通过逆向的去噪过程，最终生成目标数据  $\hat{\mathbf{x}}_0$ 。

均方差用于衡量两个时间序列在各时间点或两幅灰度图像在各像素点上的差平方的平均值，因此最小均方差损失属于点或像素级别的重建损失。然而，本研究旨在生成能准确反映大脑功能连接的脑电序列或时序图。如果仅依赖最小均方差损失，模型在训练过程中可能过度关注合成数据与原始数据在各时间点或像素点上的整体误差，而忽略数据的结构特征。这种倾向在一定程度上可能限制合成样本的多样性。为解决这一问题，需要引入能衡量时间序列或灰度图像整体结构和对比度的指标。为此，本研究采用结构相似性指数衡量结构性损失，输入  $\mathbf{x}$  和  $y$  的结构相似性指数  $\text{SSIM}(\mathbf{x}, y)$  计算如下：

$$\text{SSIM}(\mathbf{x}, y) = \frac{(2\mu_x \mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (6)$$

其中， $\mu_{(\cdot)}$ 和  $\sigma_{(\cdot)}^2$ 为输入的均值和方差； $\sigma_{xy}$ 为输入  $\mathbf{x}$  和  $y$  的协方差； $c_1$ 和  $c_2$ 为常数。结构相似性指数的值在  $[0, 1]$ ，值越大，结构相似性越高。具体地，本文定义了损失函数  $L_{\text{total}}$ ，作为训练条件扩散模型的优化目标，表示如下：

$$L_{\text{total}} = \lambda \cdot \text{SSIM}(\hat{\mathbf{x}}_t, \mathbf{x}_t) + (1 - \lambda) \cdot \|\boldsymbol{\epsilon}_t - \boldsymbol{\epsilon}_{\theta}(\hat{\mathbf{x}}_t, t, y)\|^2 \quad (7)$$

其中， $\lambda$ 为权重系数，用于平衡结构性损失和重建损失的影响。

### 3.2 交叉注意力机制

在条件扩散模型中，使用交叉注意力机制将条件信息有效编码并引入扩散过程，从而引导模型生成符合条件约束的输出。这种机制通过与条件信息的交互，使得扩散模型可根据条件信息对生成的样本进行控制和引导。

对于脑电信号，假设输入数据为  $\mathbf{x} \in \mathbb{R}^{C_{\text{in}} \times L_{\text{in}}}$ ，其中  $C_{\text{in}}$ 和  $L_{\text{in}}$ 分别为输入通道数和序列长度。交叉注意力机制的查询  $\mathbf{Q}$ 基于条件  $y$  计算。对于自闭症样本，构建一个  $1 \times 17 \times 17$  的掩码矩阵，矩阵元素在 0 和 1 之间交替排列，该矩阵通过将脑电电极的空间分布映射到二维平面上得到；对于典型发育样本，矩阵元素的排列顺序与之相反。随后，对掩码矩阵依次执行 3 次卷积核大小分别为  $3 \times 3$ 、 $5 \times 5$  和  $7 \times 7$  的二维卷积，每个卷积层后带一个激活函数，最终得到查询  $\mathbf{Q} \in \mathbb{R}^{C_{\text{out}} \times 17 \times 17}$ ，其中  $C_{\text{out}}$ 为输出通道数。脑电信号各通道之间的皮尔逊系数矩阵  $\mathbf{P} \in \mathbb{R}^{C \times 17 \times 17}$  用于计算注意力机制的键  $\mathbf{K}$ ，其中  $C$ 是输入通道数  $C_{\text{in}}$ 和输出通道数  $C_{\text{out}}$ 的统一。与掩码矩阵类似，计算得到的初始系数矩阵也被投影到二维平面。随后，对系数矩阵  $\mathbf{P}$  执行卷积操作，得到键  $\mathbf{K} \in \mathbb{R}^{C_{\text{in}} \times 17 \times 17}$ 。对输入数据  $\mathbf{x}$  进行线性变换，得到注意力机制的值  $\mathbf{V} \in \mathbb{R}^{C_{\text{in}} \times L_{\text{in}}}$ 。最后，通过式 (8) 得到输出数据  $\hat{\mathbf{x}} \in \mathbb{R}^{C_{\text{out}} \times L_{\text{in}}}$ ：

$$\hat{\mathbf{x}} = \text{Softmax} \left( \frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{C_{\text{out}}}} \right) \cdot \mathbf{V} \quad (8)$$

其中， $\text{Softmax}(\cdot)$ 为激活函数。

在生成反映大脑功能连接的时序图时，学习脑电信号通道之间的空间相关性至关重要。为此，条件生成模型依赖皮尔逊相关系数捕捉不同条件下通道间的相关性。然而，一维卷积操作可能会导致通道间信息的盲目融合，从而降低模型



的表达能力。因此, 在交叉注意力机制中, 查询  $Q$  和键  $K$  通过二维卷积操作获得, 这一方法的优势在于通过提前将脑电通道的空间分布映射到二维平面上, 可有效增强空间关系的建模能力。进一步地, 由于自闭症相关的功能连接可能涉及多个空间上非相邻的通道, 仅使用一个固定卷积核大小的卷积操作可能无法充分捕捉这些复杂的空间相关性。因此, 本研究采用了 3 种卷积核, 以确保能有效捕捉这些多尺度的空间关联。

与脑电信号不同, 脑功能连接时序图本身就是通过计算皮尔逊相关性系数得到的, 因此其交叉注意力机制的键  $K \in \mathbb{R}^{C_{in} \times L_{in}}$  和值  $V \in \mathbb{R}^{C_{in} \times L_{in}}$  均通过直接对输入数据  $x \in \mathbb{R}^{C_{in} \times L_{in}}$  做线性变换得到。查询  $Q$  仍然基于条件  $y$  计算, 与脑电信号类似, 对于自闭症和典型发育样本, 分别创建互为反向排列的掩码矩阵, 其形状为  $1 \times C_{out} \times L_{in}$ 。随后对矩阵执行 3 次卷积核分别为  $3 \times 3$ 、 $5 \times 5$  和  $7 \times 7$  的二维卷积, 得到查询  $Q \in \mathbb{R}^{C_{out} \times L_{in}}$ 。

## 4 结果

本研究采用了两种数据增强策略: (1) 利用

条件扩散模型将原始脑电信号分别扩展至 5 倍、10 倍和 20 倍, 随后基于扩展后的脑电信号生成脑功能连接时序图; (2) 基于原始脑电信号生成脑功能连接时序图后, 再利用条件扩散模型对其进行同样倍数的扩展。数据增强完成后, 使用文献[20]提出的卷积神经网络与长短期记忆模型的组合网络 CNN-LSTM, 对扩充后的脑功能连接时序图进行自闭症分类实验。

在分类实验中, 典型发育样本被视为负样本, 自闭症样本被视为正样本。分类性能通过 4 项指标综合评估: 准确率 (accuracy, ACC)、灵敏度 (sensitivity, SEN)、精确度 (precision, PRE) 和 F1 分数 (F1)。其中, 准确率衡量整体分类的正确性, 灵敏度反映对自闭症样本的识别能力, 精确度表示被识别为自闭症的样本中实际正确的比例, F1 分数则为精确度与灵敏度的调和平均值。由于正负样本比例均衡, 因此为确保分类结果的稳定性, 本实验采用 10 次 10 折交叉验证计算所有测试结果的平均值和标准差, 结果如表 2 所示。表中列出了文献[20]的原始分类结果 (未使用数据增强策略) 和通过 DCGAN 等方法将脑功能连接时序图扩展至 8 倍后的分类结果, 以

表 2 分类结果

Table 2 Classification results

数据增强策略		静息态				任务态			
模态	倍数	ACC/%	SEN/%	PRE/%	F1/%	ACC/%	SEN/%	PRE/%	F1/%
时序图 <sup>[20]</sup>	1 倍	75.66±2.12	78.35±2.22	75.25±2.06	76.77±2.33	69.09±2.04	71.60±2.01	67.44±2.18	76.77±2.81
	8 倍	81.08±1.22	86.32±3.21	78.89±1.58	82.37±1.85	74.55±2.44	81.25±2.65	70.67±2.24	75.56±2.61
	20 倍	81.08±1.22	86.32±3.21	78.89±1.58	82.37±1.85	74.55±2.44	81.25±2.65	70.67±2.24	75.56±2.61
脑电信号 (DCGAN)	5 倍	77.97±1.98	77.24±1.99	78.47±2.07	78.65±2.11	79.05±2.02	81.28±2.19	81.25±2.11	76.94±2.10
	10 倍	79.17±2.03	78.13±1.98	79.44±1.99	80.15±1.87	80.10±2.01	82.17±2.05	82.21±2.14	78.13±1.98
	20 倍	78.58±2.12	77.88±2.04	79.07±1.87	79.24±1.92	79.34±2.00	81.54±1.89	81.53±2.04	77.26±1.99
时序图	5 倍	81.64±3.09	86.38±2.82	80.04±5.52	82.92±2.14	78.34±3.20	82.32±3.52	77.10±4.79	79.51±2.67
	10 倍	82.44±1.14	86.83±1.86	80.54±1.90	83.54±0.97	78.74±1.38	82.52±2.07	77.31±1.90	79.81±1.28
	20 倍	81.72±1.53	86.21±2.01	79.86±2.22	82.88±1.30	78.68±1.23	82.58±2.02	77.17±1.40	79.77±1.20
脑电信号	5 倍	84.06±2.28	86.86±2.33	82.94±2.47	84.84±2.09	77.85±1.57	81.88±1.96	75.23±1.49	78.41±1.56
	10 倍	84.38±1.37	87.24±2.27	83.15±1.04	85.14±1.40	79.01±1.09	83.15±1.45	76.28±1.81	79.56±1.06
	20 倍	83.40±3.30	86.33±3.97	82.24±3.02	84.21±3.16	78.77±1.03	82.67±1.43	76.16±1.21	79.28±0.99

及直接使用 DCGAN 方法增强脑电信号后的分类结果。

分类实验结果表明:

(1) 数据增强策略显著提高了分类性能。无论采用何种增强策略和扩展倍数, 分类性能在准确率、灵敏度、精确度和 F1 分数 4 个指标上均得到全面提升。这表明数据增强策略能有效提高自闭症分类性能。

(2) 条件扩散模型的数据增强效果优于文献[20]中使用的 DCGAN 方法。无论扩展倍数为 5 倍、10 倍还是 20 倍, 条件扩散模型增强的数据在所有指标上均表现更优, 进一步验证了该方法的先进性。

(3) 对原始脑电信号进行增强的效果优于对脑功能连接时序图的直接增强。可能的原因如下: 原始脑电信号数量更充足, 有助于条件扩散模型的训练, 使其能有效捕获与自闭症分类相关的潜在特征, 而脑功能连接时序图的数量相对有限, 可能不足以支持模型充分学习数据分布, 从而生成的增强脑功能连接时序图可能无法完整保留关键分类信息。

(4) 数据扩展至 10 倍时, 分类性能达到最佳水平, 针对静息态和任务态脑电信号的最高分类准确率达到 84.38% 和 79.01%。这可能是由于 10 倍的样本数量能充分支持分类器训练, 而更大的扩展倍数可能引发过拟合现象。然而, 对于不同的数据集和应用场景, 最优的数据扩展倍数可能会有所不同。未来的工作中将使用更多的数据集, 通过研究数据扩展倍数与分类性能之间的关系, 建立更合理的理论模型。

(5) 无论是脑电信号还是脑功能连接时序图, 静息态数据的分类性能均优于任务态数据。这可能是因为任务态实验中不同的视觉刺激(生物运动和扰乱运动)对自闭症患者的脑电活动产生不同的影响, 进而降低了数据的分类准确性。此外, 任务态受试者容易受生物刺激的影响, 这种

刺激为脑电记录引入了更高强度的环境噪声<sup>[27]</sup>。

(6) 分类器对自闭症样本的识别能力更强, 具体表现在灵敏度指标显著高于准确率。这一结果可能具有实际意义, 因为在实际应用中, 典型发育样本的数量通常远多于自闭症样本, 因此对自闭症样本的高识别率具有更高优先级, 即相对来说, 将典型发育样本误判为自闭症, 比将自闭症样本误判为正常更可取。

(7) 分类结果中各指标的标准差均较低, 表明结果具有良好的稳定性。

综上所述, 数据增强能显著提升自闭症分类的性能, 而所提出的条件扩散模型进一步提升了数据增强的效果。然而, 分类性能并非随着数据扩展倍数的增加而无限提高, 其效果依赖原始样本的数量。当生成模型能充分学习样本数据分布时, 增强后的数据才能为分类任务提供有效支持。

## 5 讨论

本研究在算法层面仍存在进一步探索的空间。脑功能连接时序图为灰度图像, 像素值范围为 0~255, 图像尺寸为 400×40。然而, 脑功能连接时序图与普通视觉图像有一定差异。一方面, 脑功能连接时序图的每个像素实际上反映的是通道间的相关性。在经过特征选择后仅保留了与自闭症分类最相关的 400 个特征, 然后通过拼接 40 组特征系数构建了脑功能连接时序图。因此, 脑功能连接时序图的相邻像素之间的相关性较弱, 与视觉图像中相邻像素之间的强相关性不同。另一方面, 图像的高宽比差异过大。这两个差异可能会影响卷积神经网络的表现。条件扩散模型主要针对视觉图像设计, 直接应用于脑功能连接时序图时, 卷积运算可能存在盲目性, 导致效果不佳, 同时也缺乏足够的可解释性。为解决这一问题, 有必要进一步改进条件扩散模型, 使其能专门针对脑功能连接时序图进行优化。例

如, 可以引入新的损失函数来约束模型的生成, 或者设计专门的卷积核等。这将是未来进一步研究的重点。

任务态数据在自闭症筛查中具有重要的潜在价值。然而, 该研究在算法设计上主要侧重于空间信息的提取, 而对时间信息的挖掘相对不足。因此, 当面对具有不同时间分布潜在特征的静息态和任务态数据时, 采用同一模型进行分析可能导致一定的偏差, 难以有效体现任务态与静息态数据之间的差异。未来的研究将在算法层面降低任务态数据中噪声的干扰, 提高其分类性能。

## 6 结 论

本研究提出了一种针对脑电信号及其特征的新型数据增强方法, 通过改进后的条件扩散模型对初始脑电信号及其生成的脑功能连接时序图进行增强。扩展后的脑电信号和脑功能连接时序图被用于自闭症筛查。实验结果表明, 本研究所提出的数据增强方法显著提升了自闭症分类性能, 此外, 与生成式对抗网络相比, 本文提出的条件扩散模型具有明显的优势。本研究提出的方法有潜力为基于脑电信号的自闭症早期诊断提供新的技术支持, 弥补真实数据不足的问题。

## 参 考 文 献

- [1] Rahman MM, Usman OL, Muniyandi RC, et al. A review of machine learning methods of feature selection and classification for autism spectrum disorder [J]. *Brain Sciences*, 2020, 10(12): 949.
- [2] Sharma SR, Gonda X, Tarazi FI. Autism spectrum disorder: classification, diagnosis and therapy [J]. *Pharmacology & Therapeutics*, 2018, 190: 91-104.
- [3] Berg KL, Acharya K, Shiu CS, et al. Delayed diagnosis and treatment among children with autism who experience adversity [J]. *Journal of Autism and Developmental Disorders*, 2018, 48: 45-54.
- [4] Kana RK, Uddin LQ, Kenet T, et al. Brain connectivity in autism [J]. *Frontiers in Human Neuroscience*, 2014, 8: 349.
- [5] Keown CL, Datko MC, Chen CP, et al. Network organization is globally atypical in autism: a graph theory study of intrinsic functional connectivity [J]. *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging*, 2017, 2(1): 66-75.
- [6] Ardakani HA, Taghizadeh M, Shayegh F. Diagnosis of autism disorder based on deep network trained by augmented EEG signals [J]. *International Journal of Neural Systems*, 2022, 32(11): 2250046.
- [7] Hull JV, Dokovna LB, Jacokes ZJ, et al. Resting-state functional connectivity in autism spectrum disorders: a review [J]. *Frontiers in Psychiatry*, 2017, 7: 205.
- [8] Carroll L, Braeutigam S, Dawes JM, et al. Autism spectrum disorders: multiple routes to, and multiple consequences of, abnormal synaptic function and connectivity [J]. *The Neuroscientist*, 2021, 27(1): 10-29.
- [9] Caldeira GL, Peça J, Carvalho AL. New insights on synaptic dysfunction in neuropsychiatric disorders [J]. *Current Opinion in Neurobiology*, 2019, 57: 62-70.
- [10] Holiga Š, Hipp JF, Chatham CH, et al. Patients with autism spectrum disorders display reproducible functional connectivity alterations [J]. *Science Translational Medicine*, 2019, 11(481): eaat9223.
- [11] Kassraian-Fard P, Matthis C, Balsters JH, et al. Promises, pitfalls, and basic guidelines for applying machine learning classifiers to psychiatric imaging data, with autism as an example [J]. *Frontiers in Psychiatry*, 2016, 7: 177.
- [12] Litjens G, Kooi T, Bejnordi BE, et al. A survey on deep learning in medical image analysis [J]. *Medical Image Analysis*, 2017, 42: 60-88.
- [13] 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.



- [14] Huang ZA, Zhu ZX, Yau CH, 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.
- [15] Dong H, Chen D, Zhang L, et al. Subject sensitive EEG discrimination with fast reconstructable CNN driven by reinforcement learning: a case study of ASD evaluation [J]. *Neurocomputing*, 2021, 449: 136-145.
- [16] Baygin M, Dogan S, Tuncer T, et al. Automated ASD detection using hybrid deep lightweight features extracted from EEG signals [J]. *Computers in Biology and Medicine*, 2021, 134: 104548.
- [17] Tawhid MNA, Siuly S, Wang H, et al. A spectrogram image based intelligent technique for automatic detection of autism spectrum disorder from EEG [J]. *PLoS One*, 2021, 16(6): e0253094.
- [18] Peya ZJ, Akhand MAH, Srabonee JF, et al. EEG based autism detection using CNN through correlation based transformation of channels' data [C] // *Proceedings of the 2020 IEEE Region 10 Symposium*, 2020: 1278-1281.
- [19] Peya ZJ, Akhand MAH, Srabonee JF, et al. Autism detection from 2D transformed EEG signal using convolutional neural network [J]. *Journal of Computer Science*, 2022, 18(8): 695-704.
- [20] Xu Y, Yu Z, Li Y, et al. Autism spectrum disorder diagnosis with EEG signals using time series maps of brain functional connectivity and a combined CNN-LSTM model [J]. *Computer Methods and Programs in Biomedicine*, 2024, 250: 108196.
- [21] Arjovsky M, Chintala S, Bottou L. Wasserstein generative adversarial networks [C] // *Proceedings of the 34th International Conference on Machine Learning*, 2017: 214-223.
- [22] Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models [J]. *Advances in Neural Information Processing Systems*, 2020, 33: 6840-6851.
- [23] Shu K, Wu L, Zhao YC, et al. Data augmentation for seizure prediction with generative diffusion model [EB/J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2024: 1-15.
- [24] Tosato G, Dalbagnò CM, Fumagalli F. EEG synthetic data generation using probabilistic diffusion models [Z/OL]. *arXiv Preprint*, arXiv: 2303.06068, 2023.
- [25] Pelphrey K. Multimodal developmental neurogenetics of females with ASD [EB/OL]. [2024-11-27] [https://ndar.nih.gov/edit\\_collection.html?id=2021](https://ndar.nih.gov/edit_collection.html?id=2021).
- [26] Rombach R, Blattmann A, Lorenz D, et al. High-resolution image synthesis with latent diffusion models [C] // *Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022: 10684-10695.
- [27] Neuper C, Grabner RH, Fink A, et al. Long-term stability and consistency of EEG event-related (de-)synchronization across different cognitive tasks [J]. *Clinical Neurophysiology*, 2005, 116(7): 1681-1694.