

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¹, 徐永杰¹, 王书强¹, 王怡珊¹

¹ (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新兴的诊断手段。然而, 由于脑电的采集过程较为复杂, 尤其针对儿童, 因而往往存在数据量不足的问题。数据增强方法被常用弥补真实数据的不足, 其中生成式对抗网络是常用的方法。然而, 受限于数据规模的不足及数据多样性的缺乏, 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%。这一结果验证了基于条件扩散模型的数据增强在提升自闭症筛查效果方面的有效性。

关键词 脑电; 脑功能连接时序图; 条件扩散模型; 数据增强

Application of EEG Enhancement Based on Conditional Diffusion Model in Autism Screening LI

Yisheng¹, XU Yongjie², WANG Shuqiang³, WANG Yishan

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

Corresponding Author: Yishan WANG, Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen, 518055, China. Email: 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 yet to achieve optimal classification performance. 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.

Key words: electroencephalogram; time-series maps of brain functional connectivity; conditional diffusion model; data augmentation

来稿日期: yyyy-mm-dd 修回日期: yyyy-mm-dd

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

作者简介: 李逸升, 本科, 研究方向为数据增强及生成模型研究; 徐永杰, 硕士, 研究方向为基于脑电信号的自闭症筛查方法研究; 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.

1 引言

自闭症谱系障碍（Autism Spectrum Disorder, ASD）是一种神经发育障碍，表现为社交沟通困难、兴趣狭窄以及重复行为[1]。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[2]。早期诊断和干预对于改善患者生活质量和治疗效果至关重要[3]。

自闭症患者通常表现出异常的大脑区域连接，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现象等[4-7]。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[8-10]。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[9]。

深度学习近年来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[11, 12]。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[13, 14]。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[15-17]。近年来，研究者开始利用脑电数据的功能连接来识别自闭症。例如，Peya 等人使用皮尔逊相关系数将脑电数据转换为二维功能连接图，并通过残差网络分类，准确率达到 88.88% [18-19]。然而由于数据量十分有限，模型的泛化性受到限制。

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）扩充样本量至四倍。结合卷积神经网络（Convolutional Neural Network, CNN）与长短期记忆网络（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% [20]，说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。

尽管通过生成对抗网络扩充数据有所改进，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[21]。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[22]，并展现出在脑电数据增强中的潜在应用价值[23, 24]。

在先前研究[20]的基础上，本研究进一步提出了用于数据增强的条件扩散模型。研究中采用了两种增强策略：其一是对原始脑电信号进行增强，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。扩充后的脑功能连接时序图被用于自闭症/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[25]，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 秒后闭眼休息 30 秒，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 Ω 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）的静息态数据以及 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，其样本数量和数据维度详见表 1。

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 5800 个自闭症样本和 5500 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 2048 毫秒，脑电信号数据为 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 8400 个自闭症样本和 8700 个典型发育样本参与研究。每次试验持续 1200 毫秒，对于的脑电信号形状为 125×300 。

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			任务态		
	样本个数		数据形状	样本个数		数据形状
	自闭症	典型发育		自闭症	典型发育	
脑电信号	5800	5500	125×512	8400	8700	$125 \times 300 * 40$
脑电功能连接时序图	97	92	400×40	81	84	400×40

本研究沿用先前的另一项研究[20]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，仅选取其中的 7750 个系数作为特征。进一步地，针对每位受试者，提取第 11 次至第 50 次试验地数据的特征，构建形状为 7750×40 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

所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，能够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[26]。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，研究对模型中 U-Net 架构的交叉注意力机制进行了改进，使得模型能够在给定样本标签（如自闭症或典型发育）条件下，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。鉴于所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 $\epsilon_t, t \in [0, T]$ ，直到其变为服从标准高斯分布 $\mathcal{N}(\mathbf{0}, \mathbf{I})$ 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 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T$ ，这些变量通过以下条件分布递推生成：

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

其中 β_t 是一组预先设定的与时间步长 t 有关的噪声尺度。经过 T 步后可以得到条件分布：

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

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

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 $p_\theta(\hat{\mathbf{x}}_{t-1} | \hat{\mathbf{x}}_t, y)$ 实现。根据贝叶斯法则，该逆分布可以表示为：

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

其中 μ_θ 和 Σ_θ 分别是条件 y 下的高斯分布均值和协方差,由神经网络习得。在该研究中,条件 y 是样本标签,即自闭症或典型发育两种条件之一。

为了估计参数 μ_θ 和 Σ_θ ,利用变分推断来优化模型,使其最大化生成数据 \hat{x}_0 的对数似然 $\log p_\theta(\hat{x}_0|y)$ 。由于直接优化对数似然比较复杂,引入了证据下界,其定义如下:

$$L_{ELBO} = \log p_\theta(\hat{x}_0|y) \geq \mathbb{E}_{q(x_{1:T}|x_0)} \left[\log \frac{p_\theta(\hat{x}_{0:T}|y)}{q(x_{1:T}|x_0)} \right] \quad (4)$$

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

$$L_{ELBO} = \log p_\theta(\hat{x}_0|y) \geq E_{q(x_{1:T}|x_0)} [\| \epsilon_t - \epsilon_\theta(\hat{x}_t, t, y) \|^2] \quad (5)$$

其中 $\epsilon_\theta(\hat{x}_t, t, y)$ 是对前向传播噪声 ϵ_t 的预测,而 ϵ_θ 则是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,模型可以学习根据条件变量 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{x}_0 。

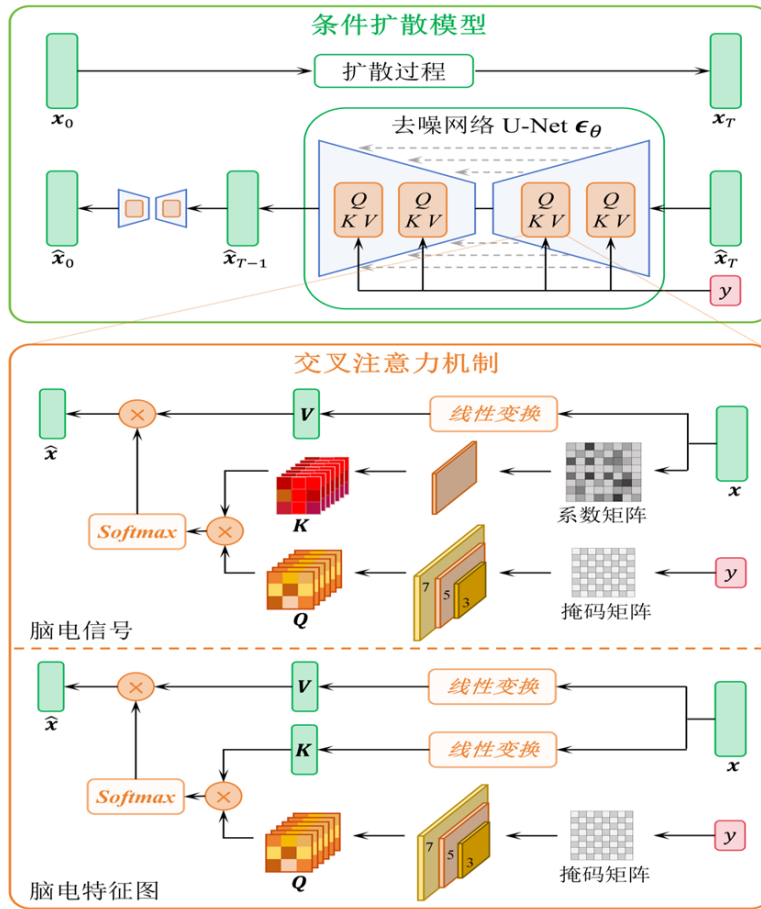


图 1 条件扩散模型的框架

Fig. 1 The framework of conditional diffusion model

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,本研究旨在生成能够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。为了解决这一问题,需要引入能够衡量时间序列或灰度图像整体结构和对比度的指标。为此,研究采用结构相似性指数作为结构性损失,其定义如下:

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

其中, $\mu_{(\cdot)}$ 和 $\sigma_{(\cdot)}^2$ 是输入的均值和方差, σ_{xy} 是输入 x 和 y 的协方差, c_1 和 c_2 是常数。结构相似性指数的值在 $[0, 1]$ 范围内, 值越大, 说明结构相似性越高。具体地, 定义了如下的损失函数 L_{total} , 作为训练条件扩散模型的优化目标:

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

其中 λ 是权重系数, 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, 使得扩散模型可以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 $\mathbf{x} \in \mathbb{R}^{C_{in} \times L_{in}}$, 其中 C_{in} 和 L_{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, 该矩阵是通过将脑电电极的空间分布映射到二维平面上得到的; 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三次卷积核大小分别为 3×3 、 5×5 、 7×7 的二维卷积, 每个卷积层后带一个激活函数, 最终得到查询 $\mathbf{Q} \in \mathbb{R}^{C_{out} \times 17 \times 17}$, 其中 C_{out} 是输出通道数。脑电信号各通道之间的皮尔逊系数矩阵 $\mathbf{P} \in \mathbb{R}^{17 \times 17}$ 用于计算注意力机制的键 \mathbf{K} 。与掩码矩阵类似, 计算得到的初始系数矩阵也被投影到了二维平面。随后, 对系数矩阵 \mathbf{P} 执行卷积操作, 得到键 $\mathbf{K} \in \mathbb{R}^{C_{in} \times 17 \times 17}$ 。对输入数据 \mathbf{x} 进行线性变换得到注意力机制的值 $\mathbf{V} \in \mathbb{R}^{C_{in} \times L_{in}}$ 。最后, 通过如下公式得到输出数据 $\hat{\mathbf{x}} \in \mathbb{R}^{C_{out} \times L_{in}}$:

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

其中 $\text{Softmax}(\cdot)$ 是激活函数。

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是至关重要的。为此, 条件生成模型依赖于皮尔逊相关系数来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之间信息的盲目融合, 从而降低模型的表达能力。因此, 在交叉注意力机制中, 查询 \mathbf{Q} 和键 \mathbf{K} 是通过二维卷积操作获得的, 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, 有效增强了空间关系的建模能力。进一步地, 考虑到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到这些复杂的空间相关性。因此, 本研究采用了三种不同大小的卷积核, 以确保能够有效地捕捉到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 $\mathbf{K} \in \mathbb{R}^{C_{in} \times L_{in}}$ 和值 $\mathbf{V} \in \mathbb{R}^{C_{in} \times L_{in}}$ 都是直接对输入数据 $\mathbf{x} \in \mathbb{R}^{C_{in} \times L_{in}}$ 做线性变换得到的。查询 \mathbf{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 $1 \times C_{out} \times L_{in}$ 。随后对矩阵执行三次卷积核大小分别为 3×3 、 5×5 、 7×7 的二维卷积, 得到查询 $\mathbf{Q} \in \mathbb{R}^{C_{out} \times L_{in}}$ 。

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, 使用研究[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。分类性能通过四项指标综合评估：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。鉴于正负样本比例均衡，为确保分类结果的稳定性，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，结果汇总于表 2。表中列出了研究[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，以及直接使用 DCGAN 方法增强脑电信号后的分类结果。

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	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
	[20] 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
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±1.4	79.77±1.2
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

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以及扩展倍数，分类性能在准确率、灵敏度、精确度和 F1 分数四个指标上均得到全面提升。这表明数据增强在自闭症分类任务中的重要作用。

(2) 条件扩散模型的数据增强效果优于研究[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。可能的原因是，原始脑电信号数量更为充足，有助于条件扩散模型的训练，使其能够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。这可能是由于 10 倍的样本数量能够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

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。这可能是因为在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到生物刺激的影响，这种刺激为脑电记录引入了更高强度的环境噪声[27]。

(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，数据增强能够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，其效果依赖于原始样本的数量。当生成模型能够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

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 至 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。首先，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有所不同。其次，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。由于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。为了解决这一问题，有必要进一步改进条件扩散模型，使其能够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以约束模型的生成，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，并且所提出的条件扩散模型相比于生成式对抗网络，具有明显的优势。本研究所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 M M, Usman O L, Muniyandi R C, 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 S R, Gonda X, Tarazi F I. Autism spectrum disorder: classification, diagnosis and therapy[J]. *Pharmacology & therapeutics*, 2018, 190: 91-104.
- [3] Berg K L, Acharya K, Shiu C S, 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 R K, Uddin L Q, Kenet T, et al. Brain connectivity in autism[J]. *Frontiers in human neuroscience*, 2014, 8: 349.
- [5] Keown C L, Datko M C, Chen C P, 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 H A, 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 J V, Dokovna L B, Jacokes Z J, 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 J M, 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 G L, Pe ęa J, Carvalho A L. New insights on synaptic dysfunction in neuropsychiatric disorders[J]. *Current opinion in neurobiology*, 2019, 57: 62-70.
- [10] Holiga Š, Hipp J F, Chatham C H, 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 J H, 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 B E, 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 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.
- [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 M N A, 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 Z J, Akhand M A H, Srabonee J F, et al. EEG based autism detection using CNN through correlation based transformation of channels' data[C]//2020 IEEE Region 10 Symposium (TENSYP). IEEE, 2020: 1278-1281.
- [19] Peya Z J, Akhand M A H, Srabonee J F, 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]//International conference on machine learning. PMLR, 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 Y, et al. Data augmentation for seizure prediction with generative diffusion model[J]. IEEE Transactions on Cognitive and Developmental Systems, 2024.
- [24] Tosato G, Dalbagno C M, Fumagalli F. EEG synthetic data generation using probabilistic diffusion models[J]. arXiv preprint arXiv:2303.06068, 2023.
- [25] Kevin Pelphrey, Multimodal developmental neurogenetics of females with ASD, 2012, 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 IEEE/CVF conference on computer vision and pattern recognition. 2022: 10684-10695.
- [27] Neuper C, Grabner R H, 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.