

一种量子条件生成对抗网络算法

刘文杰^{1,2}, 赵胶胶¹, 张颖³, 葛业波¹

(1. 南京信息工程大学计算机与软件学院, 江苏南京 210044; 2. 数字取证教育部工程研究中心, 江苏南京 210044;
3. 南京信息工程大学自动化学院, 江苏南京 210044)

摘要: 量子生成对抗网络是量子机器学习算法领域研究热点之一,但其生成过程具有较大的随机性,不太适用于现实场景.为了解决该问题,提出了一种生成过程可控的量子条件生成对抗网络(Quantum Conditional Generative Adversarial Network, QCGAN)算法,其中条件信息采用one-hot形式进行多粒子 W 态编码,并通过向生成器和判别器输入条件信息达到稳定模型生成过程的目的.性能评估表明,与经典GAN、CGAN相比,本算法可生成离散数据,且将时间复杂度从 $O(N^2)$ 降为 $O(N)$;与带条件约束的量子生成对抗网络QuGAN相比,QCGAN消耗更少的量子资源.最后,以BAS(3,3)数据集和量子混合态生成为例,选用PennyLane平台进行仿真实验,结果表明QCGAN算法经过训练可有效收敛到Nash均衡点,进而验证了算法的实验可行性.

关键词: 量子生成对抗网络; 条件信息; W 态编码; 参数化量子电路

中图分类号: TP391.41

文献标识码: A

文章编号: 0372-2112(2022)07-1586-08

电子学报 URL: <http://www.ejournal.org.cn>

DOI:10.12263/DZXB.20210512

A Quantum Conditional Generative Adversarial Network Algorithm

LIU Wen-jie^{1,2}, ZHAO Jiao-jiao¹, ZHANG Ying³, GE Ye-bo¹

(1. School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing, Jiangsu 210044, China;

2. Engineering Research Center of Digital Forensics (Ministry of Education), Nanjing, Jiangsu 210044, China;

3. School of Automation, Nanjing University of Information Science and Technology, Nanjing, Jiangsu 210044, China)

Abstract: Quantum generative adversarial network is one of the research hotspots in the quantum machine learning, but its generation process has a large randomness. To solve this problem, a quantum conditional generative adversarial network(QCGAN) algorithm is proposed. The one-hot method is used to encode conditional information into the multi-particle W state, and the purpose of stabilizing the model is achieved by inputting conditional information to the generator and discriminator. Compared with the classical GAN and CGAN, QCGAN can generate discrete data and reduce the time complexity from $O(N^2)$ to $O(N)$. In addition, our algorithm consumes less quantum resources than the conditionally constrained quantum generative adversarial network QuGAN. Finally, taking the BAS(3, 3) dataset and the generation of quantum mixed states as examples, the PennyLane platform is selected for simulation experiments. The results show that QCGAN algorithm can effectively converge to the Nash equilibrium point after training, which verifies the experimental feasibility of the algorithm.

Key words: quantum generative adversarial network; conditional information; W -state coding; parameterized quantum circuits

1 引言

生成对抗网络(Generative Adversarial Network, GAN)是一种深度学习模型,是近年来复杂分布上无监督学习最具有应用潜力的方法之一.它由Goodfellow^[1]在2014年提出,该模型由生成器和判别器两部分组成.

随后,很多学者利用GAN在图像生成^[2]、超分辨^[3]、图像转换^[4]等领域取得了优异成果,但其过程是不可控的.为了改善上述问题,Mirza等人^[5]提出了条件生成对抗网络(Conditional Generative Adversarial Network, CGAN),在输入层隐变量中增加条件约束引导GAN从条件分布中采样.2018年Miyato等人^[6]提出了一种基

于投影方法的 CGAN 算法,将条件约束信息增加到判别器中,提高了数据生成的质量.但 CGAN 生成离散数据的效果较差,并且巨大的计算开销可能会使 GAN 达到摩尔定律的极限.与经典 GAN 相比,量子 GAN 可能存在着潜在的指数优势^[7].

量子生成对抗网络(Quantum Generative Adversarial Network, QGAN)是一种基于量子电路^[8]的算法.2018 年 Lloyd 等人^[9]提出 QGAN,从理论角度分析了三种量子对抗学习场景以及 QGAN 潜在的量子优势.2019 年 Situ 等人^[10]提出利用量子玻恩规则生成离散数据,解决了离散数据生成问题.Zeng 等人^[11]提出了生成对抗量子电路(Generative Adversarial Quantum Circuits, GAQC)算法,利用量子玻恩规则探索量子电路有效采样能力,并利用 BAS(Bars-And-Stripes)数据集进行实验验证.由于受限于算法发展和可用的量子资源,先前的 QGAN 实验主要针对单量子比特量子态的生成和加载^[12].一些学者关于 QGAN 的应用也做了研究^[13,14].但这些算法生成过程具有较大的随机性.Dallaire-Demers 等人^[15]提出了一种带有条件约束的 QuGAN 算法.该算法加强了对生成数据的控制,但它求解梯度时需要复杂的受控操作和误差纠错,不适合目前的嘈杂中型量子时代.最近,Liu 等人^[16]提出了一个混合量子-经典条件生成对抗网络算法,该算法提高了生成过程的可控性,但只适合生成经典数据.

为解决这个问题,本文提出了一种量子条件生成对抗网络(Quantum Conditional Generative Adversarial Network, QCGAN)算法.采用 one-hot 形式进行多粒子 W 态编码,使生成器具备根据条件信息生成特定数据的能力.生成器和判别器都由参数化量子电路(Parameterized Quantum Circuit, PQC)构成,前者用来生成拟合训练集的新样本,后者用来判断新样本的真伪以及样本与条件信息是否匹配.该算法适用于经典和量子数据分布学习,降低了时间复杂度且可有效收敛到 Nash 均衡点.

2 生成对抗网络算法原理

2.1 条件生成对抗网络

针对 GAN 训练过程不可控的问题,条件生成对抗网络 CGAN 在生成器 G 和判别器 D 输入中加入条件变量 y 进行约束和指导.条件变量 y 可以是任何标签信息,如人脸图像的面部表情、图像类别等.在 CGAN 框架下, G 更关注与条件约束密切相关的样本特征,并控制训练过程以生成更高质量的数据. G 的输出可视为从条件分布 $p_G(x|y)$ 中进行采样,因此 CGAN 的目标函数为

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{real}}} [\log D(x|y)] + E_{x \sim p_G} [\log(1 - D(x|y))] \quad (1)$$

CGAN 算法需同时对噪声矢量 z 和条件变量 y 进行采样,因此为了提高 G 拟合真实分布的能力,根据生成目标设置合理的条件变量至关重要.最常见的一种方法是直接从训练数据中选定条件变量,让 G 和 D 在接收输入时就得到关于训练集的部分先验知识,此时 CGAN 可看作是弱监督或有监督模型.

2.2 量子生成对抗网络

尽管 CGAN 算法在很多领域都表现出优异的性能,但该算法无法直接生成离散数据.而量子生成对抗网络 QGAN 算法通过对生成器电路采样可直接生成离散数据,因此吸引了广泛关注.

量子生成对抗网络 QGAN 算法流程如图 1 所示,该算法从原理上也是构造 G 和 D 的零和博弈.与经典生成对抗网络不同的是, G 和 D 都由参数化量子电路 PQC 构成.量子数据集用密度矩阵表示,对应于经典数据集的协方差矩阵.量子数据集通过量子设备生成,可以直接作为 PQC 的输入,而经典数据集需要编码成量子态输入到 D 中.在博弈过程中, G 的目标是生成一个量子态迷惑判别器,让其无法判断这个量子态是目标态还是生成态.相反, D 的目标是要区分 G 生成的量子态和数据源的目标态.假设 G 和 D 有足够的力量,这个模型就会收敛到 Nash 均衡点,即判别器不能判别输入是真是假.Lloyd 等人^[9]指出,利用 QGAN 生成高维数据时,对抗性量子博弈学习有潜力以指数级加速收敛到 Nash 均衡点.

3 一种量子条件生成对抗网络算法

量子生成对抗网络 QGAN 算法生成过程具有较大的随机性,本文所提的 QCGAN 算法可提高生成过程的可控性,其流程如图 2 所示.该算法的 G 用来生成拟合训练集的新样本, D 用来判断新样本的真伪以及样本与条件信息是否匹配.在数据准备阶段,根据生成任务的目标和数据特征引入条件约束,并将经典条件信息编码为量子态 $|y\rangle$.下面对算法过程涉及的关键操作和训练策略进行详细说明.

3.1 条件信息的 W 态编码及电路设计

条件信息的 W 态编码及电路如图 3 所示. $|y\rangle$ 是按照真实样本概率分布将 m 类条件变量制备成的量子态

$$|y\rangle = \sum_{j=1}^m \alpha_j |y_j\rangle \quad (2)$$

其中, $\alpha_j = \left(p(x|y_j) \right)^{1/2}$, 且满足归一化条件 $\sum_{j=1}^m |\alpha_j|^2 = 1$.

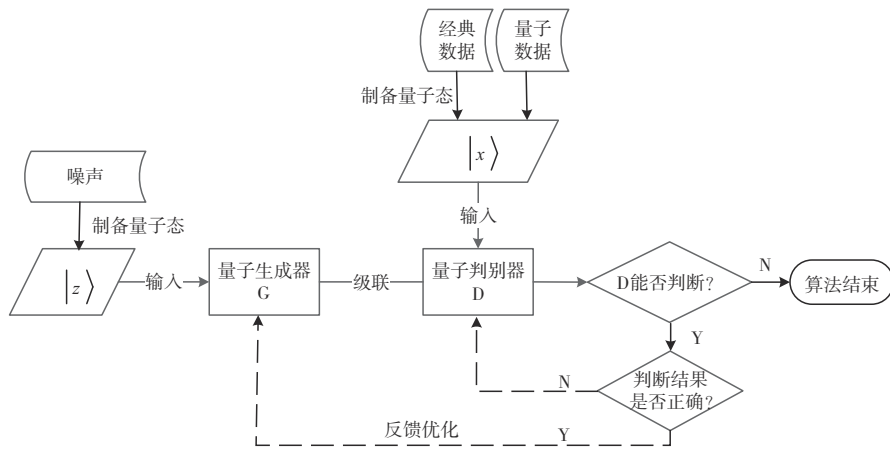


图1 量子生成对抗网络算法示意图

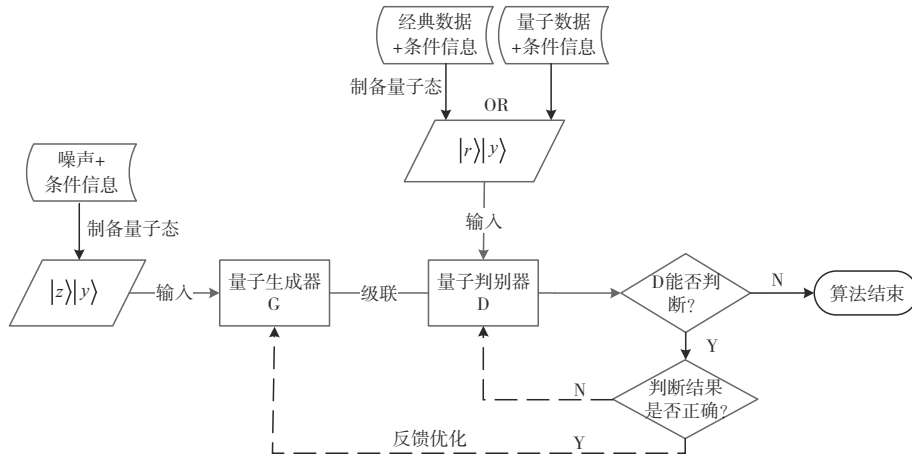


图2 量子条件生成对抗网络算法框架

用 one-hot 方法对条件信息进行编码. 假设待分类种类为 m , 制备 $|y\rangle$ 的电路如图 3 所示, 其中条件寄存器初态为 $|0\rangle^{\otimes m}$, 对应的量子位为 Q_1, Q_2, \dots, Q_m . 制备过程为: (1) 采用 R_y 和 CNOT 门, 通过调整单量子比特门旋转角度, 将量子比特制备成只包含 m 项的特殊态, 即

$$A_{2m-1} \dots A_2 A_1 |00 \dots 0\rangle_{23 \dots m} = \alpha_1 |0 \dots 00\rangle + \alpha_2 |0 \dots 01\rangle + \dots + \alpha_m |10 \dots 0\rangle \quad (3)$$

(2) 经过图 3 中的 II 之后, 量子态变为

$$|y\rangle = \alpha_1 |0 \dots 01\rangle + \alpha_2 |0 \dots 10\rangle + \dots + \alpha_m |10 \dots 0\rangle \quad (4)$$




图3 制备 m 分类 $|y\rangle$ 的量子电路

采用 one-hot 方式对条件信息进行量子态编码, 需要用到的量子比特数相对较多, 但可减少数据量子/经典后处理时再转换成其他编码形式的工作量.

3.2 量子生成器和量子判别器电路设计

在算法中, G 和 D 都由 PQC 构成, 且 PQC 由旋转层和纠缠层作为基础电路模块组成. 旋转层可由单量子比特 R_x, R_y 和 R_z 构成, 纠缠层可由 CNOT 门、SWAP 门或 CRX、CRY 和 CRZ 门组成, 其拓扑结构可为: 线型、环型、星型和全连接型.

生成器 G 电路如图 4 所示, 寄存器对应的量子位用 Q_j 表示, 其中 $j = \{1, 2, \dots, l\}$. 对 G 来说, 需要 $l(l = d + m)$ 个量子位, 其中数据寄存器有 d 个量子位, 用来生成样本数据; 条件信息寄存器有 m 个量子位, 用来接收 m 类条件信息. 它们的初始态分别为 $|z\rangle = |0\rangle^{\otimes d}$ 和 $|0\rangle^{\otimes m}$, $U_{|y\rangle}$ 表示制备量子态 $|y\rangle$ 的电路模块. 在电路中, 旋转层 $R_{G_i}(\theta)$ 和纠缠层 $E_{G_i}(\theta)$ 交替迭代 L_G 次, 其中 $i \in \{1, 2, \dots, L_G\}$, θ 是 G 的参数.

判别器 D 不仅要判断生成数据 $|G_\theta\rangle$ 和真实数据 $|r\rangle$




图4 生成器G的量子电路

的真伪,还要判断样本和条件信息 $|y\rangle$ 是否匹配,因此对数据寄存器和条件寄存器都要进行旋转层和纠缠层操作,其电路如图5所示.当旋转层 $R_{D_j}(\phi)$ 和纠缠层 $E_{D_j}(\phi)$ 交替迭代 L_D 次后,测量电路得到判别结果,其中 $j \in \{1, 2, \dots, L_D\}$.

用泡利Z测量D的最终态,其结果为 $\langle \sigma_i^z(\phi) \rangle_D =$

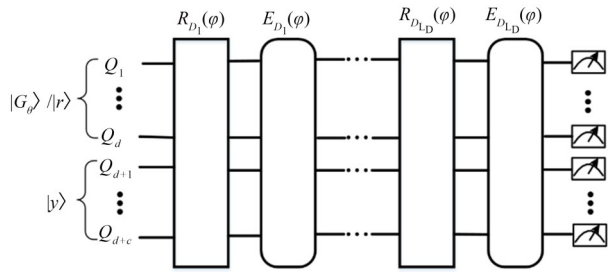


图5 判别器D的量子电路

$$\frac{\partial V_{D_\phi}}{\partial \phi_i} = \frac{1}{2} E_{r-p_{real}} \left[\frac{1}{D_\phi(|r\rangle|y\rangle)} (D_{\phi^+}(|r\rangle|y\rangle) - D_{\phi^-}(|r\rangle|y\rangle)) \right] - \frac{1}{2} E_{G_\theta-p_\theta} \left[\frac{1}{1 - D_\phi(|G_\theta\rangle|y\rangle)} (D_{\phi^+}(|G_\theta\rangle|y\rangle) - D_{\phi^-}(|G_\theta\rangle|y\rangle)) \right] \quad (8)$$

其中, $\theta^\pm = \theta \pm \frac{\pi}{2} e^i$, $\phi^\pm = \phi \pm \frac{\pi}{2} e^i$, e^i 为状态空间中第 i 个单位向量.

4 性能评析

为评估 QCGAN 算法的性能,从时间复杂度和算法功能角度与经典 GAN^[1], CGAN^[6], GAQC^[11] 和 QuGAN^[15] 进行比较,如表1所示.

由于损失函数可微性限制,经典算法(GAN、CGAN等)无法直接生成离散数据,而量子 QGAN 对电路采样可直接生成离散数据.对于生成 N 维数据分布,经典 GAN 算法时间复杂度为 $O(N^2)$. 而量子信息处理器仅

$\langle 0 | D_\phi^\dagger(|x\rangle|y\rangle) \sigma_i^z D_\phi(|x\rangle|y\rangle) |0\rangle$, 其中 i 表示量子位索引, $|x\rangle$ 表示输入到判别器的数据 $|G_\theta\rangle$ 或 $|r\rangle$.

3.3 对抗训练策略设计

量子条件生成对抗网络的训练是具有反馈回路的参数优化量子算法,生成器和判别器的可训练参数分别记为 θ 和 ϕ , 其目标函数为

$$\max V_{D_\phi} = E_{r-p_{real}} \left[\log D(|r\rangle|y\rangle) \right] + E_{G_\theta-p_\theta} \left[\log (1 - D(|G_\theta\rangle|y\rangle)) \right] \quad (5)$$

$$\max V_{G_\theta} = E_{G_\theta-p_\theta} \left[\log (D(|G_\theta\rangle|y\rangle)) \right]$$

其中, $|r\rangle$ 表示真实数据, $|G_\theta\rangle$ 表示生成的数据. Zeng 等人^[11]指出对于电路 $U(\eta) = e^{-\frac{i}{2}\eta\Sigma}$, B 的期望相对于参数 η 的梯度为

$$\frac{\partial \langle B \rangle_\eta}{\partial \eta} = \frac{1}{2} (\langle B \rangle_{\eta^+} - \langle B \rangle_{\eta^-}) \quad (6)$$

其中, $\langle \bullet \rangle_{\eta^\pm}$ 表示可观测量对于 $\eta^\pm = \eta \pm \frac{\pi}{2}$ 量子波函数的期望值,这是一种对量子电路梯度无偏估计方法. 根据该定理计算D的输出相对于参数 θ 和 ϕ 的梯度

$$\frac{\partial V_{G_\theta}}{\partial \theta_i} = \frac{1}{2} E_{G_\theta-p_\theta} \left[\log D(|G_\theta\rangle|y\rangle) \right] - \frac{1}{2} E_{G_\theta-p_\theta} \left[\log D(|G_\theta\rangle|y\rangle) \right] \quad (7)$$

需 $\log N$ (qubits), 其时间复杂度为 $O(N)$.

对于 GAQC 来说,需要 $2d$ (qubits) 制备真实数据和量子编码. 但其生成过程具有较大的随机性,不太适用于现实场景. 对于带条件约束的 QuGAN 和 QCGAN 算法, G 增加了条件信息的输入,消耗的量子资源也会增加. 其中, QuGAN 生成器和真实源都需要 d (qubits) 生成目标数据, m (qubits) 表示条件信息和 n (qubits) 辅助位; 判别器需要 m (qubits) 表示条件信息, s (qubits) 辅助位, 2 (qubits) 用来输出判断结果和求解梯度; 故 QuGAN 总资源消耗为 $2d + 3m + 2n + s + 2$ (qubits). 而 QCGAN 算法的 G 和 D 都只需 d (qubits) 生成目标数据, m (qubits) 表示条件信息, 故 QCGAN 总资源消耗为 $2d + 2m$ (qubits). 因

此, QCGAN 比 QuGAN 算法消耗更少量子资源.

表 1 五种生成对抗网络算法性能对比(生成数据类型中,C表示连续数据,D表示离散数据)

算法名称	生成数据类型	时间复杂度	条件约束	量子资源消耗 (qubits)
GAN ^[11]	C	$O(N^2)$	无	—
CGAN ^[6]	C	$O(N^2)$	有	—
GAQC ^[11]	C&D	$O(N)$	无	$2d$
QuGAN ^[15]	C&D	$O(N)$	有	$2d+3m+2n+s+2$
QCGAN	C&D	$O(N)$	有	$2d+2m$

5 实验与分析

本文采用 PennyLane 平台进行算法仿真, 分别完成经典数据和量子混合态的生成任务.

5.1 经典数据的生成

5.1.1 BAS(Bars-And-Stripes)数据集

与 GAQC 算法^[11]一样, 本文采用 BAS 数据集进行模型训练. 本实验生成目标是 BAS(3,3) 图像. 训练集中总共有 14 种有效模式图且符合均匀分布, 这些图像可分为三类: 横条纹、竖条纹和全色图(像素值全 0 或全 1), 根据 one-hot 规则分别标注为: 001、010 和 100 编码, 如图 6 所示.




图 6 BAS(3,3)数据集分类示意图

5.1.2 实验设置

在实验中, 训练集均包含 6 000 个训练样本. 为公平起见, 将 epoch 均设置为 200, 迭代训练次数为 10, 批次大小为 600, 初始学习率为 0.001, 衰减率为 0.1. 另外, 利用量子 Adam 优化器优化 G 和 D.

在 QCGAN 生成 BAS 数据过程中, 首先制备 $|W\rangle_3 = 1/\sqrt{3}(|001\rangle + |010\rangle + |100\rangle)$. 因此, 图 3 电路可简化为图 7. 初态为 $|000\rangle$, 首先采用 R_y 和 CNOT 门, 将 $|Q_{11}Q_{12}\rangle$ 制备成只包含三项的特殊态, 然后经过图中 II 将量子态演化成 $|W\rangle_3$.

GAQC 算法不需要条件信息的 W 态编码及电路设计, 因此 G 和 D 都只需要 9 (qubits) 处理数据的信息, QCGAN 算法除了要处理数据信息, 还需要 3 (qubits) 接收条件信息. 因此, 根据图 4 和 5, QCGAN 算法 G 和 D 的电路可简化为图 8 和 9. 其中, 图 8 中 $|y\rangle$ 是图 7 制备的




图 7 制备三粒子 W 态的量子电路

$|W\rangle_3$, 电路旋转层选用 R_y 门, 纠缠层选用环型连接 CRY 门. 它们的电路参数分别为 108 和 36 个, 且初始值从均匀分布 $U[0, 2\pi)$ 中随机采样.

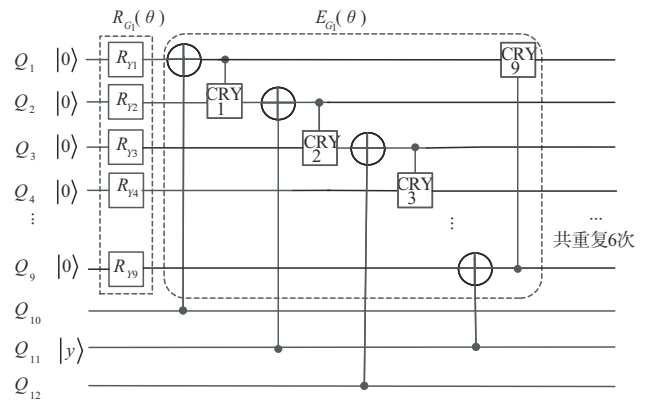


图 8 生成 BAS 数据的生成器 G 的量子电路

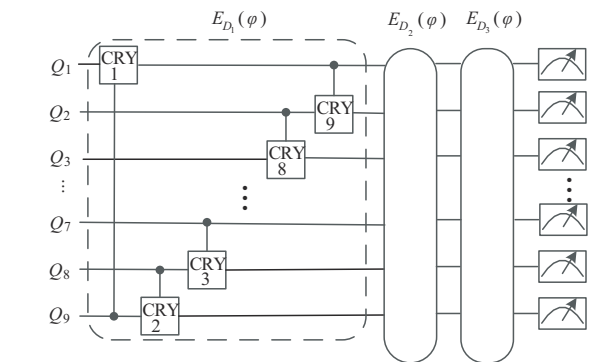


图 9 生成 BAS 数据的判别器 D 的量子电路

5.1.3 实验结果分析

GAQC 和 QCGAN 算法损失函数分别如图 10 和 11 所示. QCGAN 算法在迭代次数为 800 时就收敛到了 Nash 均衡点, 且模型基本趋于稳定. 因此, 与 GAQC 相比, QCGAN 生成图像的效率更高.

训练完成后, 对 G 进行 1000 次采样分析生成分布, 结果如图 12 所示. 其中, 图 12(a) 和 12(b) 分别是 GAQC 和 QCGAN 算法生成 BAS 数据的概率分布, 横坐标是用十进制数表示的 BAS 数据, 轴坐标表示对应的概率值. 红线表示目标概率分布, 蓝线表示经过训练后 G 输出的概率分布. 从图 12(a) 和图 12




图 10 GAQC 算法的损失变化曲线


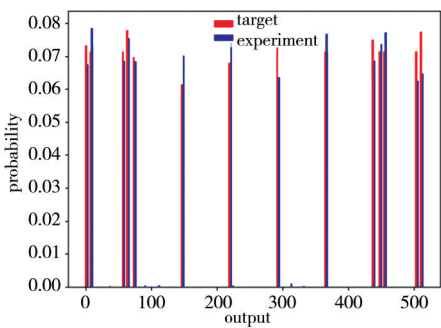



图 11 QCGAN 算法的损失变化曲线

(b) 可看出 QCGAN 算法生成的数据绝大多数都落在 14 种 BAS 有效模式图中, 且三类条纹图基本符合均匀分布. 图 12(c) 是 GAQC 算法生成的前 100 个像素图, 从中可看出 GAQC 有两处既没有正确生


成横或竖条纹. 而如图 12(d) 所示, 可看出 QCGAN 算法的 G 经过训练已具备生成 BAS(3,3) 数据的能力.




(a)



(b)



(c)



(d)

图 12 生成 BAS(3,3) 数据结果

GAQC 与 QCGAN 算法生成 BAS 数据准确率如表 2 所示. 从表中可看出, QCGAN 算法准确率为 0.968 3, 而 GAQC 算法准确率仅为 0.953 2. QCGAN 算法准确率高 的原因是该算法加入了条件变量, 使模型得到了更多 关于真实数据的信息.

表 2 算法生成 BAS 数据集的准确率

算法	准确率
GAQC ^[11]	95.32%
QCGAN	96.83%

5.2 量子数据的生成

5.2.1 实验准备

本节设计实验生成 $|\text{GHZ}\rangle_3 = 1/\sqrt{2}(|000\rangle + |111\rangle)$ 和 $|W\rangle_3 = 1/\sqrt{3}(|001\rangle + |010\rangle + |100\rangle)$ 的量子混合态 $\rho = P_1|\text{GHZ}\rangle_3\langle\text{GHZ}|_3 + P_2|W\rangle_3\langle W|_3$, 其中 $P_1 + P_2 = 1$. 制备 $|W\rangle_3$ 的电路如图 7 所示, 制备 $|\text{GHZ}\rangle_3$ 电路如图 13 所示. 将 $|\text{GHZ}\rangle_3$ 和 $|W\rangle_3$ 看作两类数据, 分别加上 $|0\rangle$ 和 $|1\rangle$ 的标签, 因此电路中数据和条件寄存器分别需要 3(qubits) 和 1(qubits). 因此, 图 4 和 5 的电路可简化为图 14 和 15, 其中参数个数分别为 24 和 8 且参数初始值从均

匀分布 $U[0, 2\pi)$ 中随机采样.




图 13 制备 $|\text{GHZ}\rangle_3$ 的量子电路




图 14 生成量子数据的生成器 G 的量子电路

将 epoch 设置为 300, 并采用 Adam 优化器进行优化. 定义 $F = |\langle\psi|\gamma\rangle|^2$ 表示两个状态 $|\psi\rangle$ 和 $|\gamma\rangle$ 的重叠情况, 反映了量子电路的保真度.

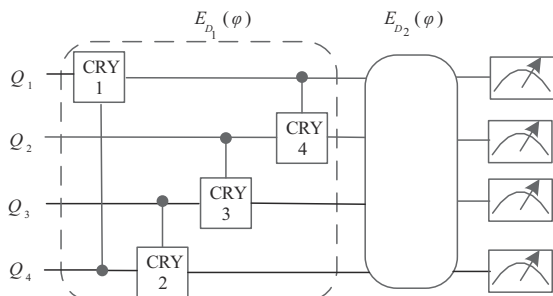


图 15 生成量子数据的判别器 D 的量子电路

5.2.2 实验结果分析

生成量子数据的损失函数如图 16 所示. 在迭代次数为 500 时, 生成器和判别器的损失函数已基本收敛到 Nash 均衡点, 但在后续的训练中 G 和 D 的损失函数值都出现了轻微的震荡(这是该类算法生成量子数据普遍存在的现象^[15]).




图 16 生成量子数据的损失变化曲线

QCGAN 算法生成态和目标态之间的保真度如图 17 所示. 从图中可看出, 通过对抗训练, G 生成的最终态和目标态的保真度逐渐增加并收敛于 1, 因此该算法能根据输入生成目标量子混合态.




图 17 生成量子数据的保真度变化曲线

将条件寄存器的输入分别置为 $|0\rangle$ 和 $|1\rangle$, 多次测量数据寄存器, 结果如图 18 所示. 当条件寄存器输入 $|0\rangle$, 期望输出为 $|GHZ\rangle_3$, 采样结果近似均匀分布的 000 和 111, 与期望相符; 当条件寄存器输入 $|1\rangle$, 期望输

出为 $|W\rangle_3$, 采样结果近似均匀分布的 001、010 和 100, 与期望相符. 因此生成器可以按照要求生成目标量子混合态, 并且能够在条件变量的指导下生成不同量子态.




图 18 分类生成量子态采样结果

6 总结

本文提出的 QCGAN 算法是一种适用于经典和量子数据分布学习的方案. 该算法通过在输入层增加条件约束, 有效引导网络生成符合特定要求的数据, 提高了生成过程的可控性. 与经典 GAN 相比, 本文提出的 QCGAN 算法的时间复杂度更低; 与 QuGAN 相比, QCGAN 消耗更少的量子资源. 另外, 以 BAS(3,3) 数据集和量子混合态生成为例, 选用 PennyLane 进行仿真实验, 结果表明 QCGAN 算法经过训练可有效收敛到 Nash 均衡点.

随着问题规模的扩大, 算法 PQC 中量子位或门数量会急剧上升, 容易出现“贫瘠高原”现象(由于运算规模急剧上升, 导致电路参数的梯度均值为 0、方差随着量子比特个数的增加呈指数减少). 下一步工作, 我们将研究通过优化量子电路结构, 改进电路参数优化迭代策略等手段, 减少一次迭代可训练参数个数和电路深度, 从而减轻贫瘠高原的负面影响.

参考文献

- [1] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Advances in Neural Information Processing Systems. Montreal, Canada: MIT Press, 2014, 2672-2680.
- [2] ZHU Jun-Yan, KRHENBUHL P, SHECHTMAN E, et al. Generative visual manipulation on the natural image manifold[C]//14th European Conference on Computer Vision. Berlin: Springer, 2016: 597-613.
- [3] LEDIG C, THEIS L, HUSZAR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 105-114.
- [4] WANG C Y, XU C, WANG C H, et al. Perceptual adversarial networks for image-to-image transformation[J]. IEEE Transactions on Image Processing, 2018, 27(8): 4066-4079.
- [5] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J]. arXiv preprint, 2014, arXiv: 1411.1784.
- [6] MIYATO T, KOYAMA M. CGANs with projection discriminator[J]. arXiv preprint, 2018, arXiv: 1802.05637.
- [7] GAO X, ZHANG Z Y, DUAN L M. A quantum machine learning algorithm based on generative models[J]. Science Advances, 2018, 4(12): eaat9004.
- [8] BENEDETTI M, GARCIA-PINTOS D, PERDOMO O, et al. A generative modeling approach for benchmarking and training shallow quantum circuits[J]. Npj Quantum Information, 2019, 5: 45.
- [9] LLOYD S, WEEDBROOK C. Quantum generative adversarial learning[J]. Physical Review Letters, 2018, 121(4): 040502.
- [10] SITU H Z, HE Z M, WANG Y Y, et al. Quantum generative adversarial network for generating discrete distribution[J]. Information Sciences, 2020, 538: 193-208.
- [11] ZENG J F, WU Y F, LIU J G, et al. Learning and inference on generative adversarial quantum circuits[J]. Physical Review A, 2019, 99(5): 052306.
- [12] BENEDETTI M, GRANT E, WOSSNIG L, et al. Adversarial quantum circuit learning for pure state approximation[J]. New Journal of Physics, 2019, 21(4): 043023.
- [13] STAMATOPOULOS N, EGGER D J, SUN Y, et al. Option pricing using quantum computers[J]. Quantum, 2020, 4: 291.
- [14] BARBEAU M, GARCIA-ALFARO J. Faking and discriminating the navigation data of a micro aerial vehicle using quantum generative adversarial networks[C]//IEEE

Global Communications Conference. Waikoloa: IEEE, 2019: 1-6.

- [15] DALLAIRE-DEMERS P L, KILLORAN N. Quantum generative adversarial networks[J]. Physical Review A, 2018, 98(1): 012324.
- [16] LIU W J, ZHANG Y, DENG Z L, et al. A hybrid quantum-classical conditional generative adversarial network algorithm for human-centered paradigm in cloud[J]. EURASIP Journal on Wireless Communications and Networking, 2021, 2021(1): 37.

作者简介



刘文杰 男, 1979年11月生, 湖北大冶人, 博士. 南京信息工程大学计算机与软件学院副教授、硕士生导师, 研究方向为量子算法、量子机器学习、量子安全多方计算和量子密码通信.
E-mail: wenjieliu@nuist.edu.cn



赵胶胶 女, 1996年8月生, 江苏徐州人. 南京信息工程大学计算机与软件学院硕士研究生, 主要研究方向为量子机器学习和量子算法.
E-mail: 2759312576@qq.com