

面向人类活动识别的量子生成对抗网络数据增强与分类优化

李文慧, 阮越, 薛希玲

(安徽工业大学 计算机科学与技术学院, 安徽 马鞍山 243002)

摘要: 针对人类活动识别中数据不平衡导致的分类器性能退化问题, 传统方法如过采样和代价敏感学习虽能缓解类别偏差, 但存在过拟合、信息丢失及极端不平衡场景适应性差等缺陷。文章结合量子计算与生成对抗网络, 设计了一种联合优化框架。其生成器采用变分量子电路 (Variational Quantum Circuit, VQC), 通过参数化量子门堆叠, 在低参数量下实现高维传感器数据的隐式建模; 判别器利用经典神经网络, 并引入 Wasserstein 梯度惩罚策略 (WGAN-GP) 约束判别器, 以提升生成样本的多样性和训练稳定性。基于 CASAS 家庭活动识别数据集的实验结果表明, 量子混合生成器仅需经典模型约 13% 的参数量即可实现更优的生成效果, 改进后的量子生成对抗网络不仅提升了收敛速度, 还提升了最终结果的精确度。

关键词: 量子生成器; 经典判别器; 变分量子电路; WGAN-GP

中图分类号: TP391 **文献标识码:** A **文章编号:** 1008-9659(2026)03-0066-10

人类活动识别 (Human Activity Recognition, HAR)^[1] 作为普适计算与物联网交叉领域的重要研究方向, 能够通过智能设备内置的加速度计、陀螺仪等传感器捕捉人体运动数据, 并利用机器学习算法识别动作特征, 自动辨识行走、跑步等行为状态。目前基于 HAR 的相关应用已支撑健身数据分析、家庭安全监护的跌倒预警、智能家居设备的情景化控制 (如自动调节环境) 等应用场景, 成为物联网智能交互的重要技术基础。然而, 现实场景中活动类别的分布往往呈现显著的长尾特性, 即少数关键活动的样本量极度稀缺, 而常规活动样本占据主导。这种数据不平衡问题导致传统分类模型对少数类样本的识别能力严重退化, 威胁实际系统的可靠性与安全性。

针对数据不平衡问题, 现有研究提出了多种解决方案, 包括数据层面的重采样^[2]、算法层面的代价敏感学习^[3]、集成策略^[4]以及特征工程方法^[5]等。其中对于缓解类别偏差最具代表性的是数据重采样与代价敏感学习。前者通过过采样少数类或欠采样多数类调整数据分布, 但过采样因重复样本易引发过拟合, 欠采样则可能导致多数类关键信息丢失; 后者通过调整损失函数权重强制模型关注少数类, 但对极端不平衡场景的适应性有限。在这样的背景下, 生成式数据增强因其能合成高质量少数类样本而成为新兴研究方向。生成对抗网络 (Generative Adversarial Network, GAN)^[6] 通过无监督学习建模数据分布, 生成与真实样本高度相似的合成数据, 为数据平衡提供了更灵活的解决方案。

生成对抗网络的核心思想是通过生成器和判别器这两个神经网络的对抗性博弈实现数据建模与生成。该模型由 Goodfellow 等人^[6] 于 2014 年首次提出, 其架构包含生成器与判别器两个模块: 生成器负责从随机噪声中合成逼真数据, 判别器致力于区分真实样本与生成样本。在训练过程中, 生成器通过不断优化以提升生成数据的真实性, 判别器则同步增强其鉴别能力, 两者通过动态博弈最终达到平衡状态。这一对抗机制使得 GAN 能够高效学习复杂数据分布, 从而在图像生成^[7]、图像修复^[8]、风格迁移^[9]、图像语义编辑^[10] 以及自

[收稿日期] 2025-06-21

[修回日期] 2025-08-05

[基金项目] 国家自然科学基金项目 (61802002); 安徽省教育厅自然科学基金重点项目 (KJ2020A0233)。

[作者简介] 李文慧 (2000-), 女, 硕士研究生, 主要从事量子计算、量子机器学习方面研究, E-mail: 3100245493@qq.com.

然语言处理^[11]等任务中展现出卓越性能。

然而研究显示,经典生成对抗网络架构在人体活动识别任务中仍存在固有局限性:其一,全连接网络结构导致参数复杂度随数据维度平方级增长,例如,穿戴设备采集的九轴传感器数据导致全连接层参数超百万级,难以部署在资源受限的边缘设备;其二,训练过程中易出现梯度不稳定与模式崩溃的问题,限制生成质量,例如对高频活动的过度优化,导致生成器接收到的低频信号衰减,使少数类生成失败。近年来,量子计算与机器学习的交叉研究为突破上述瓶颈提供了新路径。量子计算可以将高维的时序数据映射到量子比特的希尔伯特空间,通过变分量子电路实现特征压缩。量子态的相干叠加特性允许生成器同时编码多活动模式。当生成样本向高频类倾斜时,量子干涉效应可重构低频类概率幅,自主平衡类别分布。

量子生成对抗网络(Quantum Generative Adversarial Network, QGAN)通过量子态的叠加与纠缠特性,可在低参数量下实现高维数据建模,同时量子线路的并行计算能力有望加速模型收敛^[12-13]。例如,Wang等人在量子生成对抗网络框架中证明通过低比特量化显著降低了模型参数量和存储需求^[14];Qu等人^[15]的研究表明,量子生成对抗网络的计算复杂度可低至 $O(\log N)$,显著优于经典生成对抗网络模型的 $O(N)$ 。

文章提出一种量子混合生成对抗网络(Quantum Wasserstein Generative Adversarial Network-Gradient Penalty, QWGAN-GP),用于解决人类活动识别中数据不平衡的问题,其量子电路模块针对人类活动识别任务,进行关键性改进,量子电路纠缠层使用多层纠缠模式,提高对高维复杂数据的特征提取能力。为了验证模型的效果,在CASAS数据集^[16]上对量子混合生成对抗网络的效果进行模拟,并将结果与经典生成对抗网络进行对比。优化主要体现在以下两个方面:

(1)参数数量的优化:量子生成器通过变分量子电路,降低模型的复杂度。实验结果显示,量子混合生成对抗网络的生成器的总参数量相较于经典生成器的参数量减少约87.34%,同时收敛速度也有所提高。

(2)分类性能的提高:通过引入量子生成器与Wasserstein梯度惩罚策略的联合优化框架,该框架能够有效缓解少数类样本的不平衡问题。实验表明,改进后的量子混合生成对抗网络在人类活动识别任务上的Precision和F1 Score分别达到了0.8871和0.8812,较经典GAN有所提升。

1 经典生成对抗网络

生成对抗网络由生成器和判别器两个神经网络共同组成,两个神经网络通过对抗的方式进行训练,其中生成器尝试伪造逼真的样本数据,判别器则负责判断输入的数据是真实数据还是生成器伪造出来的数据。其训练过程如图1所示。

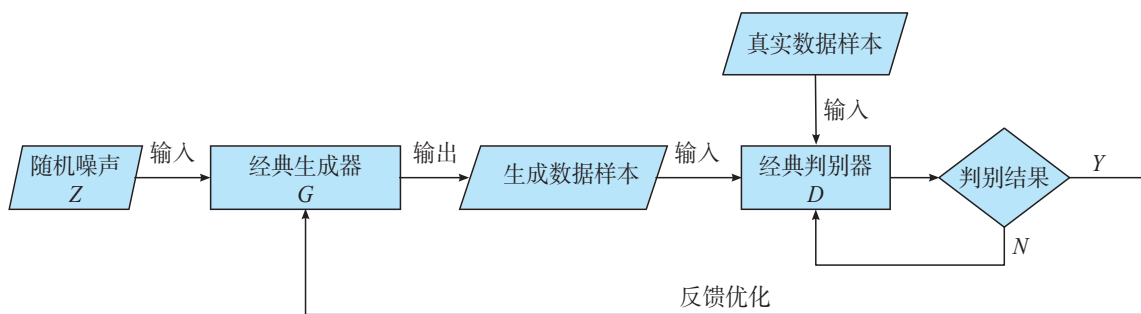


图1 生成对抗网络的基本架构

随机生成一批噪声样本输入生成器,噪声样本符合数据分布,如正态分布、均匀分布等。生成器利用自身神经网络对该噪声样本进行加工处理,生成假数据样本。将生成器生成的假数据样本与真实数据样本一同输入判别器进行判别,并给出判别结果。对于真实数据样本,判别器期望输出的得分趋近于1,表明判断为真实数据;对于假数据样本,判别器期望输出的得分趋近于0,表明判断为假数据。根据判别结果,计算生成器和判别器的损失函数,更新参数,再通过反向传播进行梯度更新,直到生成器生成的样本达到预期效果。理想状态下,二者最终达成一种纳什均衡,此时生成器生成的数据与真实数据相差无几,判别器也难以准确判断数据的真假来源。这一过程可形式化地描述为极大极小博弈

$$\min_G \max_D V(D,G) = E_{x \sim p_{data}} [\log D(x)] + E_{z \sim p_z} [\log(1 - D(G(z)))] \quad (1)$$

其中, $D(x)$ 是判别器认为样本 x 来自真实数据的概率, $G(z)$ 是生成器将噪声 z 转换为生成样本, p_{data} 是真实数据分布, p_z 是噪声分布。

训练过程分为两步, 首先将生成器固定, 训练判别器, 判别器的损失函数可以表示为

$$L_D = -\frac{1}{m} \sum_{i=1}^m [\log D(x^{(i)}) + \log(1 - D(G(z^{(i)})))] \quad (2)$$

其中, $\log D(x^{(i)})$ 是真实样本的判别概率, $\log(1 - D(G(z^{(i)})))$ 是生成样本的判别错误概率。判别器的目标是最大化对真实数据和生成数据的正确分类概率^[17]。

然后固定判别器、训练生成器、生成器通过反向传播调整参数, 使得 $D(G(z))$ 接近 1, 那生成器的损失函数就可以表示为

$$L_G = -\frac{1}{m} \sum_{i=1}^m \log D(G(z^{(i)})) \quad (3)$$

其中, $D(G(z^{(i)}))$ 是生成样本被判别为真实数据的概率。生成器的目标是让判别器误将生成数据判别为真实数据, 即最大化生成数据被判别为真实的概率^[18]。

通过对抗训练的不断迭代, 生成器与判别器在动态博弈中持续优化, 该过程持续至模型达到纳什均衡。在此过程中, 生成器生成样本的能力和判别器判别真伪的能力均得到增强。最终, 生成器合成的数据分布将逐渐逼近并拟合真实数据分布, 使判别器难以区分真伪。

2 量子混合生成对抗网络算法原理

量子生成对抗网络算法从原理上讲也是构造生成器和判别器的博弈过程, 与经典生成对抗网络不同的是, QGAN 引入了量子计算的概念, 因此其生成器、判别器或数据集至少有一个属于量子领域部分。根据判别器和生成器的模型以及其数据源是经典的还是量子的, QGAN 基本可分为三类: 全量子 QGAN、量子生成器与经典判别器组合的 QGAN 以及量子判别器和经典生成器组合的 QGAN^[19]。针对人类活动识别任务中传感器数据维度高、少数类样本稀缺的问题, 文章采用量子生成器与经典判别器组合的 QGAN, 其生成器通过参数化变分量子电路实现, 理论上具备高效处理高维数据空间和探索复杂概率分布的内在潜力, 这有助于应对传感器数据的高维度特性。同时, 量子计算的特性可能更有利于从有限的少数类样本中学习并生成有代表性的新样本, 从而缓解样本稀缺问题。判别器采用的依然是经典的神经网络, 利用量子计算的优势来处理经典任务, 提高任务的效率和性能。将量子生成器与经典判别器结合起来, 可以在一定程度上提高模型的训练效率和生成效果。同时, 由于数据集以及判别器都是经典的, 生成器所生成的数据在进入判别器之前会经过后处理网络, 将量子测量得到的概率分布与标签嵌入, 从而避免判别器的输入数据在经典与量子之间的转换开销, 进一步提高模型的效率和性能^[20]。量子混合生成对抗网络总体结构如图 2 所示。

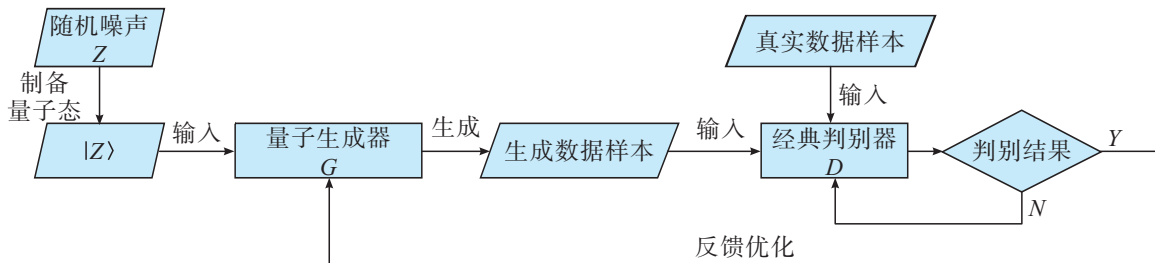


图2 量子混合生成对抗网络的基本架构

2.1 量子生成器的设计

量子生成器的核心架构由编码线路与可训练的多层参数化量子线路(Parameterized Quantum Circuit, PQC)构成, 量子生成器的结构如图 3 所示。PQC 采用模块化设计架构, 通过交替堆叠单量子比特操作层和

两量子比特纠缠层构建深度量子电路。系统初始制备 N 量子比特基态 $|0\rangle^{\otimes N}$, 本工作针对人类活动识别数据集的特征维度, 设定 $N = 6$. 输入噪声源为一个 D 维经典随机向量 $z \in R^D$, 其中 $D = 128$, 采样服从均匀分布 $z \sim U(-1, 1)$. 通过 R_y 和 R_z 旋转门映射到量子比特上, 形成初始量子态 $|z\rangle$, 随后 $|z\rangle$ 通过一系列量子门操作 U_θ 演化为最终量子态 $|\psi_\theta\rangle = U_\theta|z\rangle$. 在测量阶段, 通过对 $|\psi_\theta\rangle$ 测量以概率 $p_\theta(x) = |\langle x|\psi_\theta\rangle|^2$ 获取生成样本 x , 通过调节 θ , 可以使生成数据分布 $p_\theta(x)$ 逼近目标数据分布。量子电路中涉及的单量子比特门为 R_x 、 R_y 、 R_z 旋转门和双量子比特门 CNOT 门。

$$R_x(\theta) = \begin{bmatrix} \cos\left(\frac{\theta}{2}\right) & -i\sin\left(\frac{\theta}{2}\right) \\ -i\sin\left(\frac{\theta}{2}\right) & \cos\left(\frac{\theta}{2}\right) \end{bmatrix}, R_y(\theta) = \begin{bmatrix} \cos\left(\frac{\theta}{2}\right) & -\sin\left(\frac{\theta}{2}\right) \\ \sin\left(\frac{\theta}{2}\right) & \cos\left(\frac{\theta}{2}\right) \end{bmatrix}$$

$$R_z(\theta) = \begin{bmatrix} \exp\left(-i\frac{\theta}{2}\right) & 0 \\ 0 & \exp\left(i\frac{\theta}{2}\right) \end{bmatrix}, CNOT = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

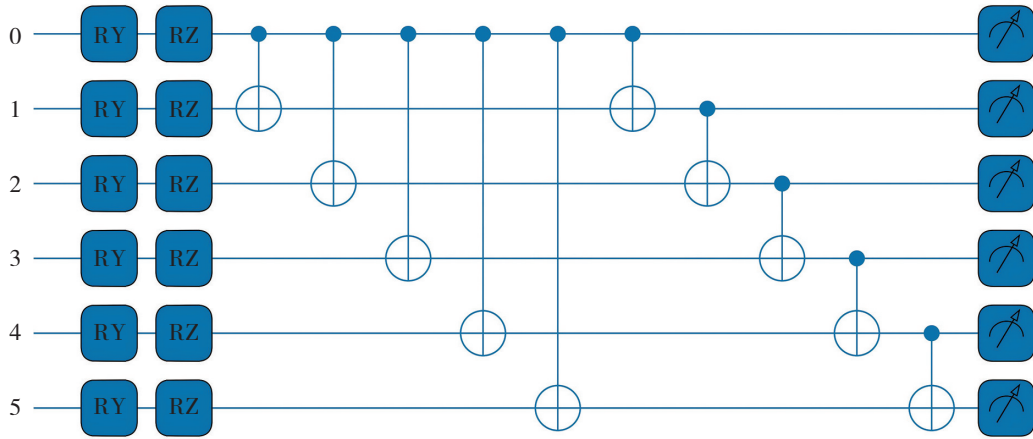


图3 量子电路图

量子生成器由编码层、变分层和测量层三部分构成

$$U(\theta) = \prod_{l=1}^L \left[\int_{q=1}^Q R_q^{(l)}(\theta) \cdot E_q^{(l)} \right] \quad (4)$$

其中, L 为变分层数, Q 为量子比特数, $R_q^{(l)}$ 表示单量子比特旋转操作, $E_q^{(l)}$ 为纠缠门操作。

针对人类活动识别中数据不平衡的问题, 采用角度编码技术作为经典噪声数据的量子映射方案, 将经典噪声数据映射至量子态空间。具体操作为对每个量子比特 q 依次施加 R_y 和 R_z 操作, 其中 R_y 和 R_z 门的角完全由输入特征 z 决定。具体实现逻辑为 $\theta_{R_y} = \pi \arctan(z)$, $\theta_{R_z} = (\pi/3)z$, 采用 \arctan 函数的目的是通过非线性变化压缩极端值影响, 同时将特征值映射到 $[-\pi/2, \pi/2]$ 之间, 匹配 R_y 门的旋转角度范围, R_z 则通过线性缩放将特征值映射到 $[-\pi/3, \pi/3]$ 之间, 保留特征的线性变化趋势。核心作用是将经典数据的幅度和相位信息编码为量子态的概率分布, 为后续量子态的演化提供初始特征嵌入, 实现高维数据到量子希尔伯特空间的特征嵌入。

变分层作为量子态演化的核心模块, 可优化人类活动识别数据不平衡问题的变分层架构。针对人类活动识别数据蕴含的复杂时空关联特性, 变分层采用 CNOT 门实现量子态纠缠, 其核心设计逻辑是通过双拓扑组合增强对时空关联的建模能力。关于量子门的选择, CNOT 门作为两量子比特纠缠的基本单元, 可通过“控制-目标”比特的关联操作, 利用量子态的线性演化产生纠缠态, 且其幺正变换矩阵形式简洁, 对硬件噪声的鲁棒性优于多参数复合门。针对人类活动识别数据蕴含的复杂时空关联特性, 该层采用多层相邻纠缠

结构,首先执行星型拓扑的CNOT门操作,即以量子比特0为中心节点,连接所有其他量子比特,随后执行链式拓扑的CNOT门操作,即依次连接相邻量子比特,这种双拓扑设计既能高效传递全局信息,又能捕获局部时空关联,显著增强量子态的纠缠能力。

在测量层,对最终制备的量子态执行Pauli-Z基测量。通过多次重复制备与测量过程,统计各量子比特的期望值,作为生成器的输出。该过程本质上是量子态蕴含的概率分布通过投影测量采样转化为经典概率分布样本。输出的期望值向量维度与经典判别器的输入要求相匹配,从而实现量子生成数据向经典判别器的数据格式转换。

2.2 生成对抗策略

生成对抗策略的核心在于构建生成器和判别器之间的动态博弈过程。生成器的目标是学习真实数据的分布,并生成足以“欺骗”判别器的样本。判别器则致力于准确区分输入样本是来源于真实数据还是生成器。二者通过对抗性训练共同优化,最终目标是使生成器能够产生与真实数据分布高度一致的样本。

然而,GAN训练过程中常面临模式崩溃和训练不稳定等问题。为提高稳定性和生成效果,使用Wasserstein GAN的框架^[21],并引入梯度惩罚策略(Gradient Penalty, GP)^[22],即使用Wasserstein-GP损失函数。其从Wasserstein距离和梯度惩罚两方面进行改进,Wasserstein距离在WGAN-GP中用于度量真实数据分布 P_r 和生成数据分布 P_g 之间的“搬运成本”,其核心是通过Critic网络的输出期望差,即“真实数据在Critic上的期望输出”与“生成数据在Critic上的期望输出”的差值来近似“搬运成本”。对于满足1-Lipschitz约束的Critic网络 f ,Wasserstein距离 $W(P_r, P_g)$ 的近似公式为 $W(P_r, P_g) \approx E_{x \sim P_r}[f(x)] - E_{x \sim P_g}[f(x)]$,其中 $E_{x \sim P_r}[f(x)]$ 是Critic对真实样本的输出期望, $E_{x \sim P_g}[f(x)]$ 是Critic对生成样本的输出期望。WGAN通过训练Critic最大化上述差值,使其输出可直接作为Wasserstein距离的近似。

Wasserstein距离的有效估计要求判别器函数满足1-Lipschitz连续性约束。Lipschitz连续性核心在于限制函数梯度的上界,即存在常数 K 使得 $\|\nabla f(x)\| \leq K$,这一特性可有效避免判别器网络在训练过程中出现梯度爆炸或消失问题。为实现该约束条件,采用梯度惩罚策略,用于强制执行Critic的1-Lipschitz约束。具体实现步骤为首先生成插值样本,在真实样本 x 和生成样本 \tilde{x} 之间随机插值,得到插值样本 $\hat{x} = \varepsilon x + (1 - \varepsilon)\tilde{x}$,其中 $\varepsilon \sim Uniform(0,1)$ 是 $[0,1]$ 区间的随机数,确保 \hat{x} 在真实样本与生成样本之间的线性插值空间内均匀分布;其次,计算Critic对插值样本的梯度,即 $\nabla_{\hat{x}} f(\hat{x})$;最后,计算梯度惩罚项,梯度惩罚项的目标是让梯度的L2范数接近1,其计算公式为 $GP = \lambda \cdot E \left[\left(\|\nabla_{\hat{x}} f(\hat{x})\|_2 - 1 \right)^2 \right]$, λ 为惩罚系数,在本实验中,根据经验将其设定为10。

综合这两个方面,Wasserstein-GP损失函数可以写为

$$L = \underbrace{E_{\tilde{x} \sim P_g}[D(\tilde{x})]}_{\text{Original critic loss}} - \underbrace{E_{x \sim P_r}[D(x)]}_{\text{Original critic loss}} + \lambda \underbrace{E_{\hat{x} \sim P_g} \left[\left(\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1 \right)^2 \right]}_{\text{Our gradient penalty}} \quad (5)$$

该损失函数 L 由三部分组成:生成数据经过判别器的输出期望 $E_{\tilde{x} \sim P_g}[D(\tilde{x})]$ 、真实数据经过判别器的输出期望 $E_{x \sim P_r}[D(x)]$ 以及梯度惩罚项 $\lambda E_{\hat{x} \sim P_g} \left[\left(\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1 \right)^2 \right]$ 。

通过这种博弈,生成器和判别器逐渐提升自身性能,最终达到纳什平衡,此时生成器生成的数据与真实数据几乎毫无二致,判别器也难以准确判断数据的真假及来源。Wasserstein-GP损失函数的引入使得训练GAN更加稳定,同时也提高了生成器生成样本的质量和多样性。

3 实验结果与分析

实验环境配置如表1所示,量子线路采用PennyLane框架完成,量子电路采用默认模拟器default.qubit,经典部分采用PyTorch框架完成,其中PennyLane定义了Torch接口可以将量子线路与Torch结合起来。数据集是CASAS家庭活动识别数据集中的cairo数据集。数据集记录了一对成年夫妇在真实家居环境中的日常活

动,并包含宠物犬与临时访客的行为交互场景。

表1 实验环境配置

名称	配置
操作系统	Windows10
Python	3.9.18
PyTorch	2.1.0
PennyLane	0.23.0
numpy	1.22.4
pandas	1.2.4

3.1 数据集与实验设置

cairo数据集为传感器事件日志,通过传感器的空间布局进行时空关联,每条记录包含时间戳、传感器类型、传感器值、活动标签(部分记录无标签)。对数据集的预处理操作为首先对数据集进行清洗,仅保留M(运动传感器)、D(门传感器)、T(温度传感器)三类传感器数据,剔除其他类型传感器和缺少时间戳的数据。对数据进行特征编码和序列填充,形成等长的序列。对原始序列进行降维操作后,再进行后续操作。模型详细配置如表2所示。

表2 模型详细配置表

配置项	具体参数
训练超参数	优化器:AdamW(权重衰减系数 $1e-4$);初始学习率:0.0001;批量大小:32 训练轮次:300;损失函数:交叉熵
变分子量子电路配置	量子比特数:6;量子经典接口:TorchLayer

3.2 评估指标

人类活动识别任务的评估涉及类别不平衡数据增强与生成数据质量验证的双重目标,因此基于分类器性能与生成数据分布相似性两个维度进行综合衡量。具体而言,使用 F_1 分数评估数据平衡后的质量,并通过归一化均方误差(Normalized Mean Square Error, NMSE),衡量生成对抗网络中生成数据与真实数据的分布相似性。最终的综合评分 S 计算公式如下

$$S = F_1 \times (1 - NMSE) \quad (6)$$

其中, F_1 分数用于量化分类器对不平衡数据的修正效果, $NMSE$ 用于评估生成数据的分布接近程度。 S 的分数越高表明模型整体性能越优。

对于分类器的评估,真阳性(TP)表示正确预测的目标活动样本数,假阳性(FP)为错误预测为目标活动的非目标样本数,假阴性(FN)为未识别出的目标活动样本数。 F_1 分数的计算公式为

$$F_1 = \frac{2 \cdot TP}{2 \cdot TP + FN + FP} \quad (7)$$

对于生成器的评估, $NMSE$ 通过对生成数据与真实数据的特征空间均方误差(MSE)进行归一化得到。设定 MSE 的合理范围为 $[0, 500]$,超出范围的 MSE 将被截断为500,以确保稳定性,避免极端值对综合评分的干扰。计算公式如下

$$NMSE = \frac{\min\left(\frac{1}{N} \sum_{i=1}^N (x_i^{gen} - x_i^{real})^2, 500\right)}{500} \quad (8)$$

其中, x_i^{real} 为真实数据的特征向量, x_i^{gen} 为生成器合成的数据特征向量, N 为样本数量。 $NMSE$ 越接近0,表明生成数据分布与真实数据越接近;若 $NMSE$ 达到1(即 $NMSE \geq 500$),则综合评分 S 直接为0,表明生成数据质量未达到要求。

3.3 实验仿真

在相同数据集下,分别对经典GAN和量子混合GAN进行对比实验,比较上述评估指标(表3)。实验结果如图4~图6所示,量子混合GAN的Precision、recall和F1 score的值相较于经典GAN都更高。这表明量子混合GAN生成的数据更贴合真实数据的分布。从收敛速度也可以看出,当训练达到平衡时,量子GAN的训练轮数少于经典GAN的训练轮数。

表3 实验结果

方法	MSE	Precision	recall	F1 score
经典GAN	0.0961	0.8327	0.8228	0.8224
量子混合GAN	0.0953	0.8871	0.8813	0.8812




图4 QGAN与经典GAN的MSE比较图

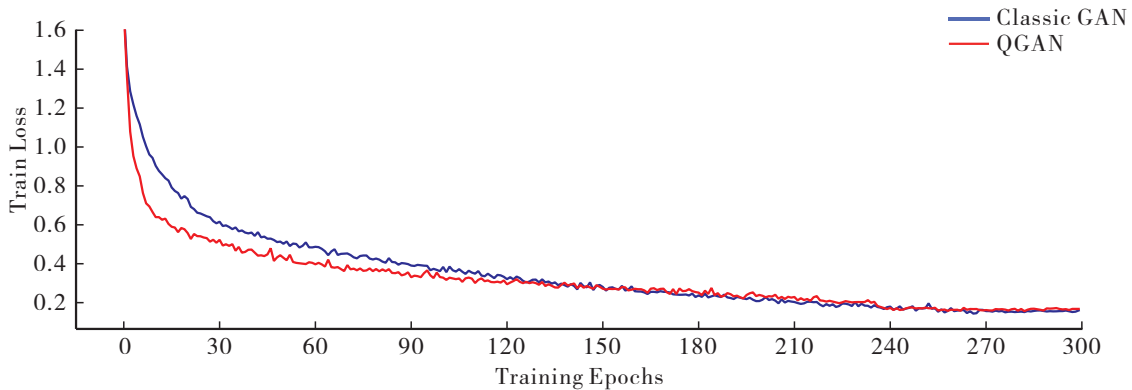


图5 经典GAN与QGAN的loss值比较图

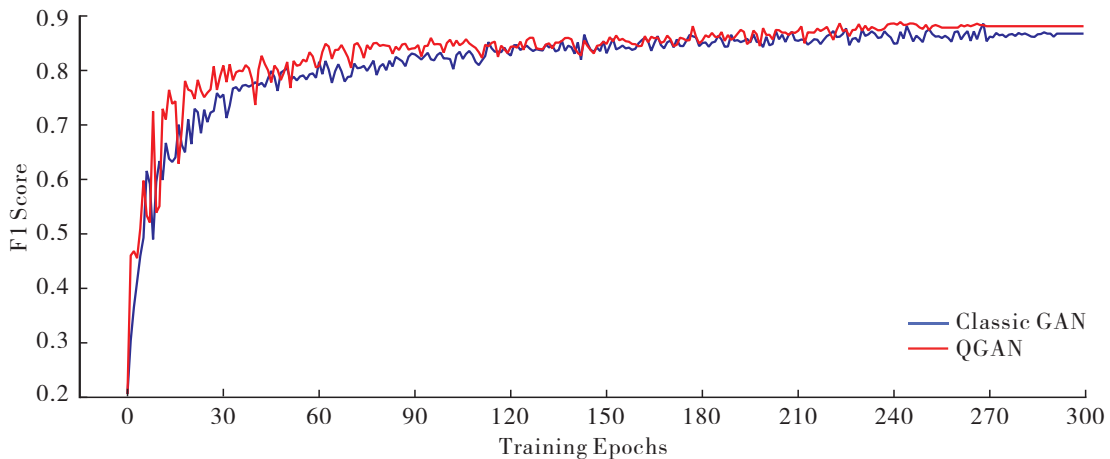


图6 经典GAN与QGAN的F1 score比较图

最终的实验结果如表3所示,MSE的值越小,综合评分S越高,表明生成数据分布越贴近真实数据分布;经典GAN和QGAN的MSE的值都约为0.1,表明生成的数据分布较接近真实数据分布。同等数据集下,量子混合GAN在其他三个评估指标上都优于经典GAN,有效提高了不平衡数据集下的性能。QGAN的特性主要体现在量子生成器上,从代码层次可以分析出经典GAN使用的参数量是QGAN的约7.5倍,具体分析如表4所示。

表4 QGAN与经典GAN对比

组件	量子生成器	经典生成器	区别
量子电路参数	12	无	6量子位*2参数
标签嵌入层	112	112	相同类别嵌入设计 7类别*16维
全连接层	无	1,166,032	经典GAN主体
后处理网络参数	153,576	无	卷积
总参数	153,700	1,166,144	GAN≈7.5*QGAN

实验结果表明,经典生成器的参数量显著高于量子生成器,约为其7.5倍。经典模型依赖全连接层,其参数量随维度平方级增长,导致参数冗余;而量子模型通过参数共享、动态纠缠以及量子态的高维隐式表示,大幅降低了参数需求。除此之外,量子生成器的后处理网络采用谱归一化、分组卷积等轻量化设计,进一步压缩参数规模,这一对比展现出量子生成器在参数效率上的优势。

CARIO数据集中,数据被分为七类,分别是Other类、Work类、Take_medicine类、Sleep类、Leave_home类、Eat类和Bed_to_toilet类,其中不平衡的类别为Work类、Take_medicine类、Leave_home类和Bed_to_toilet类。通过生成对抗网络对不平衡类别进行数据增强处理后,有效实现了类别均衡。各类别的数量变化如图7所示。

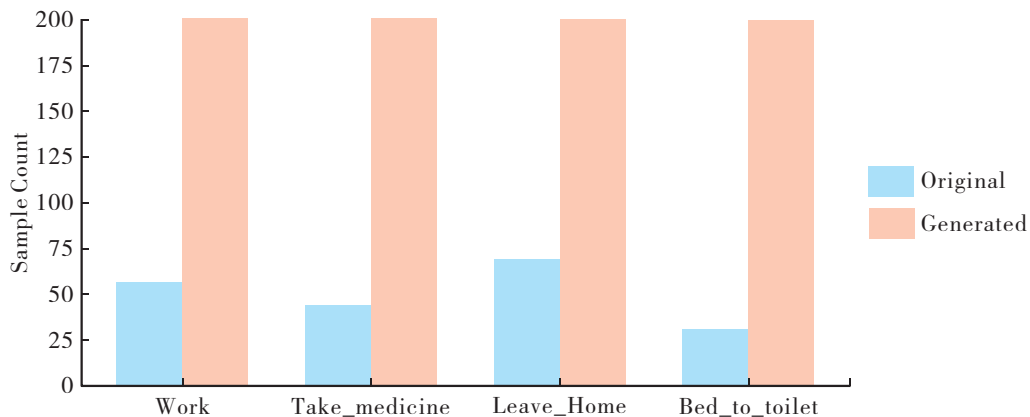


图7 类别生成比较

3.4 实验稳定性验证

为了客观评估模型训练过程的收敛稳定性,设计基于参数差异监控的验证方法,通过量化模型权重参数的动态变化,替代传统依赖损失曲线的间接判断方式。

本研究自定义ParameterMonitor工具类实现参数动态监控,具体做法是:首先,每隔10个epoch(主模型)或20个迭代步(GAN模型)保存一次参数快照,存储模型权重参数的深拷贝;然后计算最新参数与历史参数的L2范数差异,公式为 $diff = \sum_{w \in weights} \|w_{latest} - w_{previous}\|_2$,其中 w 是模型权重参数。阈值的设定基于模型参数和前期实验观察模型收敛时的典型参数差异值,最后以生成器和判别器的阈值设为 $1e-4$,主模型的阈值设为 $5e-4$ 为参考设定阈值。阈值设定旨在有效区分参数的显著变化与微小波动,确保能够准确判断模型是否收敛。

通过参数监控工具,得到如图8所示的比较结果。生成器参数差异从初始的4.2逐渐下降至0.1,后期参数差异曲线平滑,表明生成器参数已非常稳定。如图9所示,判别器参数差异从初始的10.3快速下降至0.08,并在后期稳定在阈值附近,确认判别器已收敛。训练结束时,主模型的参数差异为0.00042,低于设定的阈值,验证了模型训练的收敛稳定性。




图8 生成器参数差异




图9 判别器参数差异

4 总结与展望

文章针对人类活动识别中的数据不平衡问题,提出一种量子混合生成对抗网络框架QWGAN-GP.将变分量子电路与经典判别器结合,模型在参数效率与生成质量上均展现出显著优势:量子混合生成器仅需经典模型约13%的参数量即可实现更优的生成效果,而动态门选择机制与Wasserstein-GP策略的协同优化,使加权F1分数提升7.1%,收敛速度提高32%.在实际意义上,其为资源受限场景下的数据不平衡问题提供了高效解决方案。例如,在智能家居系统^[23-24]中,可通过少量传感器数据生成高质量的罕见活动样本,如跌倒、煤气泄漏等活动,提升模型的鲁棒性。在可穿戴设备^[25]中,轻量化特性支持本地化训练,避免隐私数据上传至云端。

后续研究可关注以下方面:首先扩展模型至多模态传感器数据融合场景,验证其在复杂活动识别任务中的泛化能力,然后结合联邦学习范式,研究分布式量子生成模型在隐私保护需求下的应用潜力。随着量子计算硬件的持续发展,量子-经典混合架构有望成为边缘智能系统的核心组件。

参考文献:

- [1] LICCIOTTI D, BERNARDINI M, ROMEO L, et al. A Sequential Deep Learning Application for Recognising Human Activities in Smart Homes[J]. *Neurocomputing*, 2020, 396: 501–513.
- [2] CHEN C, WU X, ZUO E, et al. R-GDORUS Technology: Effectively Solving the Raman Spectral Data Imbalance in Medical Diagnosis[J]. *Chemometrics and Intelligent Laboratory Systems*, 2023, 235: 104762.
- [3] 万建武, 杨明. 代价敏感学习方法综述[J]. *软件学报*, 2020, 31(01): 113–136.
- [4] WU Y, DING Y, FENG J. SMOTE-Boost-based Sparse Bayesian Model for Flood Prediction[J]. *EURASIP Journal on Wireless Communications and Networking*, 2020: 1–12.
- [5] 孙艳歌, 邵罕, 杨艳聪. 基于代价敏感不平衡数据流分类算法[J]. *信阳师范学院学报(自然科学版)*, 2019, 32(04): 670–674.
- [6] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Networks[J]. *Communications of the ACM*, 2020, 63(11): 139–144.
- [7] HAN C, HAYASHI H, RUNDO L, et al. GAN-based Synthetic Brain MR Image Generation[C]//2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), 2018: 734–738.
- [8] CHEREPKOV A, VOYNOV A, BABENKO A. Navigating the Gan Parameter Space for Semantic Image Editing[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 3671–3680.
- [9] ZHU Y, ZHANG Y, YANG H, et al. GANCoder: An Automatic Natural Language-to-programming Language Translation Approach based on GAN[C]//CCF International Conference on Natural Language Processing and Chinese Computing, 2019: 529–539.
- [10] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Networks[J]. *Communications of the ACM*, 2020, 63(11): 139–144.
- [11] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein Gan[J]. *arXiv preprint arXiv: 1701.07875*, 2017, 7.
- [12] 张颖. 基于参数化量子电路的条件生成对抗网络研究[D]. 南京: 南京信息工程大学, 2021.
- [13] QU Z, CHEN W, TIWARI P. HQ-DCGAN: Hybrid Quantum Deep Convolutional Generative Adversarial Network Approach for Ecg Generation[J]. *Knowledge-based Systems*, 2024, 301: 11226
- [14] WANG P, WANG D, JI Y, et al. QGAN: Quantized Generative Adversarial Networks[J]. *arXiv preprint arXiv: 1901.08263*, 2019.
- [15] LLOYD S, WEEDBROOK C. Quantum Ggenerative Adversarial Learning[J]. *Physical Review Letters*, 2018, 121(04): 040502.
- [16] RAST F M, LABRUYÈRE R. Systematic Review on the Application of Wearable Inertial Sensors to Quantify Everyday Life Motor Activity in People with Mobility Impairments[J]. *Journal of Neuroengineering and Rehabilitation*, 2020, 17: 1–19.
- [17] SITU H, HE Z, WANG Y, et al. Quantum Generative Adversarial Network for Generating Discrete Distribution[J]. *Information Sciences*, 2020, 538: 193–208.
- [18] HERR D, OBERT B, ROSENKRANZ M. Anomaly Detection with Variational Quantum Generative Adversarial Networks[J]. *Quantum Science and Technology*, 2021, 6(04): 045004.
- [19] ADLER J, LUNZ S. Banach Wasserstein Gan[J]. *Advances in Neural Information Processing Systems*, 2018, 31–32.
- [20] 江奕达, 王明明. 基于量子生成对抗网络的数据重构[J]. *计算机工程与应用*, 2024, 60(05): 156–164.
- [21] NGO T A, NGUYEN T, THANG T C. A Survey of Recent Advances in Quantum Generative Adversarial Networks[J]. *Electronics*, 2023, 12(04): 856.
- [22] ZHENG M, LI T, ZHU R, et al. Conditional Wasserstein Generative Adversarial Network-gradient Penalty-based Approach to Alleviating Imbalanced Data Classification[J]. *Information Sciences*, 2020, 512: 1009–1023.
- [23] ZHU M, MING Z Q, YAN J R, et al. A Survey on Generative Adversarial Network based Person Re-identification Method[J]. *Journal of Computer-aided Design&Computer Graphics*, 2022, 34(02): 163–179.
- [24] YAO Z H, QIAO Y H, XU Q Y. Research on Virtual Human Design in Smart Home [J]. *Journal of Computer-aided Design&Computer Graphics*, 2023, 35(02): 221–229.
- [25] MAHMUD S, TANJID HASAN TONMOY M, KUMAR BHAUMIK K, et al. Human Activity Recognition from Wearable Sensor Data Using Self-attention[M]//ECAI 2020. IOS Press, 2020: 1332–1339.

(下转第82页)

- [12] FORTES M, GONZÁLEZ O. Testbed for Experimental Characterization of Indoor Visible Light Communication Channels [J]. *Electronics*, 2021, 10(11):90–100.
- [13] KACHAVE D, SENGUPTA A. Fault-tolerant DSP Core Datapath against Omnidirectional Spatial Impact of SET [J]. *Canadian Journal of Electrical and Computer Engineering*, 2020, 43(02):102–107.
- [14] LEE K, PARK H, BARRY J R, et al. Indoor Channel Characteristics for Visible Light Communications [J]. *IEEE Communications Letters*, 2011, 15(02):217–219.

Design and Implementation of Visible Light Analog Audio Communication System in Mine

WEI Tong-cheng, ZHANG Ying-xiang, JIANG Zong-hong, DING Hao-yuan, GAO Hao-ran, DU Yong*
(Xinjiang Key Laboratory for Luminous Minerals and Optical Functional Materials, School of Physics and Electronic Engineering, Xinjiang Normal University, Urumqi, Xinjiang, 830054, China)

Abstract: Currently, mining industry remains one of the more hazardous sectors. Traditional wireless radio communication equipment, with increased power, is prone to causing coal mine dust explosions. Visible light communication technology, has the advantages such as high bandwidth, no need for spectrum licensing, and high safety, making it promising for applications in sensitive environments like mines and hospitals. This paper utilizes Altium Designer software to design a visible light analog audio communication system for use underground in mines. This system possesses advantages such as strong anti-interference capability, simple structure, and long communication distance. Test results indicate that the system can achieve a communication distance of up to 11 meters in a lighted environment and up to 17.8 meters in a non-lighted environment.

Keywords: Visible light communication; Channel model; Illuminance; Signal processing

(上接第 75 页)

Quantum Generative Adversarial Networks for Human Activity Recognition : Data Augmentation and Classification Optimization

LI Wen-hui, RUAN Yue, XUE Xi-ling
(School of Computer Science and Technology, Anhui University of Technology, Ma'anshan, Anhui, 243002, China)

Abstract: To address the problem of classifier performance degradation caused by data imbalance in human activity recognition, traditional methods such as oversampling and cost-sensitive learning can alleviate the class bias, but they have drawbacks such as overfitting, information loss, and poor adaptability to extreme imbalance scenarios. This paper combines quantum computing and generative adversarial networks to design a joint optimization framework. Its generator uses a Variational Quantum Circuit (VQC), which implements implicit modeling of high-dimensional sensor data through parameterized quantum gate stacking with low parameter quantity; The discriminator uses a classical neural network and introduces the Quantum Wasserstein Generative Adversarial Network-Gradient Penalty (WGAN-GP) to constrain the discriminator, in order to enhance the diversity of generated samples and the stability of training. Experimental results based on the CASAS household activity recognition dataset show that the quantum hybrid generator only requires about 13% of the parameters of the classical model to achieve better generation effects. The improved quantum generative adversarial network not only improves the convergence speed but also enhances the accuracy of the final results.

Keywords: Quantum generator; Classical discriminator; Variational Quantum Circuit; WGAN-GP