

APLICAÇÕES DA COMPUTAÇÃO QUÂNTICA: EXPANDINDO O CONHECIMENTO E EXPLORANDO O SEU POTENCIAL

Yan Alef Chagas Silva¹; Gleydson de Jesus²; Otto Pires²; Mauro Nooblath²; Anton Albino²; Lucas Queiroz²; Maria Heloísa Fraga²; João Marcelo Silva Souza²

¹ Bolsista e Mestrando em Modelagem Computacional – SENAI -CIMATEC; PD&I Proj. Inovação – Empresa Parceira; yan.chagas@fbter.org.br

² Centro Universitário SENAI CIMATEC; Salvador - BA; joao.marcelo@fieb.org.br

RESUMO

A computação quântica é uma ciência relativamente nova que busca trazer vantagens em relação a computação clássica, surgindo no início dos anos 80, Richard Feynman propôs a ideia de um computador quântico que era exponencialmente mais rápido em comparação aos computadores clássicos¹, e mostrado matematicamente por David Deutsch esse ganho computacional², dando início às investigações da área e crescimento da pesquisa em computação quântica no mundo. Baseado nisso foi fundado no *Latin American Quantum Computer Center*, onde exploramos as possibilidades da computação quântica aplicadas à indústria. Neste trabalho apresentaremos o curso de formação que foi ministrado pelo segundo ano para o exército brasileiro, além da aplicação de redes adversárias generativas em sua versão quântica (*Quantum GANs*) para o setor financeiro.

PALAVRAS-CHAVE: Computação Quântica; Aplicações; Indústria; Quantum GAN.

1. INTRODUÇÃO

Após Deutsch demonstrar matematicamente que os computadores quânticos são exponencialmente mais rápidos em comparação aos computadores clássicos², houve um crescimento no desenvolvimento de pesquisas relacionadas à computação quântica, e apesar de ser uma área recente, vem obtendo resultados relevantes em diversos setores, como na parte de segurança e criptografia, comunicação quântica, química quântica, energia, logística, entre outros. Comparado com outros países, o Brasil ainda está muito atrás quando se trata de investimento neste setor em³ relação a países como China e Estados Unidos, além disso, a busca pela supremacia quântica vem levantando mais cautela entre a divulgação do conhecimento entre países, buscando não ficar inerte sobre o setor, diversas iniciativas no país começaram a ser desenvolvidas, o *Latin American Quantum Computer Center* – LAQCC foi uma delas, implantado no Senai CIMATEC meados de 2021, buscamos trazer para o cenário industrial as vantagens da computação quântica. Percebendo isso, ainda em 2022 foi realizado o primeiro curso de tecnologias avançadas para o Exército brasileiro, onde um dos módulos desse curso era a parte de computação quântica, renovado uma segunda turma em 2023, com perspectivas da terceira turma ocorrer em 2024.

O módulo de computação quântica possui o objetivo de introduzir um panorama geral sobre a computação quântica trazendo toda a fundamentação teórica mínima necessária para que possa compreender conceitos como portas lógicas, circuitos quânticos, toda a parte teórica necessária de álgebra linear e mecânica quântica. Além disso, abordamos os algoritmos consagrados (Shor, Grover, Simon, Deutsch-Jozsa, variacionais, etc...) trazendo também aplicações desses algoritmos em diversos setores como por exemplo em logística, criptografia e comunicação. Adicionalmente, foi instruído todo o ferramental necessário para utilizar o simulador quântico *Kuatomu* que fica no centro de supercomputação do Senai CIMATEC, em parceria com a Atos, onde a linguagem utilizada é a myQLM e a biblioteca roda em python.

Das atividades e parcerias do LAQCC com empresas, surgem alguns temas norteadores para direcionar a pesquisa voltada a computação quântica, a preocupação com integridade e privacidade de dados são questões críticas no mercado financeiro, há problemas nas formas clássicas de coleta devido a demora para deixar esses dados anônimos, uma possível solução é a utilização de redes adversárias generativas. Uma rede generativa adversária (GAN) é uma técnica de *deep learning* que tem como objetivo gerar dados sintéticos a partir de um conjunto de dados dado usando um par de redes neurais, conhecidas como discriminador e gerador⁴, onde o objetivo do gerador é gerar dados sintéticos (ou comumente chamado de dados falsos, *fake data*, do inglês) enquanto o discriminador irá ser alimentado com dados reais da rede mais dados falsos do gerador, e deverá dizer se esses dados são falsos ou reais, e um tem o objetivo de “enganar” o outro, o gerador gerando dados com padrões maiores que cada vez mais seja difícil distinguir de dados reais, enquanto o discriminador tenta definir se os dados que ele está recebendo foram enviados pela rede ou pelo discriminador, por isso são chamados de adversários, e um aprende a partir dos parâmetros do outro, ajustando cada vez mais os seus parâmetros e treinando a GAN num todo. As GANs podem ser

caracterizadas como clássicas, quânticas e híbridas⁵. Propomos a utilização de uma rede generativa híbrida quântico-clássica, onde o gerador da rede é quântico, enquanto o discriminador é clássico, com o objetivo de gerar dados sintéticos de uma maneira segura.

2. METODOLOGIA

Nessa pesquisa focamos em transpor de maneira didática uma pessoa que nunca teve contato com tecnologias quânticas, mas que concluisse o curso habilitado para compreender os conceitos básicos do funcionamento da computação quântica, alguns algoritmos e suas aplicações. Para isso, foi realizada inicialmente uma investigação em alguns cursos mais conhecidos, como o *Qiskit Summer School*⁶, para termos uma visão do que as instituições consideram mais importante de transmitir em um curso de duração similar (60h), com isso realizamos um cronograma visando trazer desde o básico necessário da matemática e álgebra linear, passando por introdução a mecânica quântica, para então iniciar introdução a computação quântica, desde a parte teórica até a programação no simulador quântico do SENAI-CIMATEC, *Kuatomu*, uma vez os alunos habilitados com esse conhecimento, passamos para os principais algoritmos, aplicações desse algoritmos e uma atividade final de curso onde foi passado um problema para eles resolverem utilizando os algoritmos ensinados.

Após a criação do cronograma, foi realizada uma revisão da literatura dividida pelos temas, onde todo material pertinente para aquele tema foi separado e serviu como base para construção da respectiva aula, após a aula construída foram realizadas aulas testes com a equipe, para servir tanto de nivelamento como de teste para correções e edições. Feito isso seguimos a escala de aula enviada pelo Exército onde constituía de algumas aulas em Brasília, na base militar, e outras aulas remotas. Durando 4 semanas de aula, com 3 a 4 dias de aula na semana, para as aulas práticas e simulações foram utilizados *Jupyter notebooks*, com as bibliotecas necessárias utilizando o *Python*, os alunos foram cadastrados no HPC do CIMATEC, para que pudessem rodar as simulações nos supercomputadores do HPC via SSH.

Referente ao artigo de GANs foi realizada uma revisão da literatura sobre as redes adversárias generativas, focando nos modelos híbridos quântico-clássicos. Utilizamos um conjunto de dados fornecido pela empresa parceira com 14 *features*. Nossa arquitetura proposta de GAN híbrida consiste em um gerador quântico pareado com um discriminador clássico. O gerador quântico adota uma estratégia que envolve múltiplos geradores quânticos para construir pequenos patches dos dados finais, que são concatenados para formar o conjunto de dados completo. Para superar as limitações inerentes à linearidade dos modelos quânticos, introduzimos transformações não lineares por meio de medições parciais e *qubits* de ancila. As simulações foram realizadas em *Python* com os frameworks *Torch* e *PennyLane*, usando o simulador quântico *Kuatomu* fornecido pelo SENAI-CIMATEC.

A otimização foi feita com Gradiente Descendente Estocástico e o desempenho foi avaliado comparativamente com uma GAN clássica, utilizando a convergência da função de perda e o erro quadrático médio (*MSE*) entre os dados sintéticos gerados e o conjunto de dados original como métricas. Devido aos dados financeiros não possuírem representação visual, usamos o *MSE* como uma métrica para avaliar a qualidade da geração desses dados.


3. RESULTADOS E DISCUSSÃO

Ao rodar nossos testes, comparamos a dinâmica de aprendizado da GAN quântica com a Clássica. Na GAN clássica, a perda do Gerador começa alta em relação à do Discriminador e permanece próxima durante o treinamento. Aproximadamente na metade do treinamento, ocorre uma mudança onde a perda do Discriminador supera a do Gerador, resultando em uma estabilização de ambas as perdas até o fim do processo. Já na GAN quântica, as perdas do Gerador e do Discriminador permanecem estáveis desde o início, com a perda do Gerador consistentemente menor que a do Discriminador.

Conforme o treinamento avança, observamos divergência entre as perdas do Gerador e do Discriminador. Enquanto a GAN clássica reduz consistentemente a lacuna entre os dados sintéticos e originais, estabilizando-se ao final, a GAN quântica demonstra comportamento errático, com *MSE* superior, indicando disparidades de desempenho.

Para verificar se os erros vieram devido ao número excessivo de iterações de treinamento, limitamos o número máximo de iterações para cerca de 2500 (Figura 1), antes da divergência, aplicando o mesmo ajuste à GAN clássica para garantir consistência na avaliação. Os resultados mostraram convergência nos gráficos de perda para ambas as GANs, mas ao analisar o *MSE*, a GAN quântica permaneceu errática, enquanto a GAN clássica melhorou consistentemente. O comportamento inesperado da GAN quântica pode ser atribuído a diversas causas potenciais, como dificuldades na identificação de padrões nos dados, possíveis deficiências no pré-processamento e necessidade de aprimoramento na operação de medida parcial.

Figura 1 - Resultados limitando à 2500 iterações



4. CONSIDERAÇÕES FINAIS

Após o curso de tecnologias quânticas ser finalizado no primeiro ano, e obtivermos um resultado satisfatório como feedback dos alunos, identificamos alguns pontos de melhoria, como por exemplo trazer os elementos de mecânica quântica e álgebra linear aos poucos, mesclando-os com a aula de computação quântica e apresentando-os à medida que se faz necessário para a compreensão do conteúdo. Além disso buscamos realizar uma pesquisa antes do início do curso, sobre quais áreas os discentes atuam no Exército, para que pudéssemos trazer aplicações que fizessem mais sentido para o cotidiano deles, adicionalmente ao reformular o cronograma incluímos uma seção de comunicação quântica, que é um tema bastante relevante e de interesse para segurança nacional também. Essas alterações já foram incluídas na segunda turma que cursou em 2023, e a perspectiva é de que uma terceira turma realize este curso em 2024. Quanto a proposta de GAN quântica híbrida não conseguiu gerar dados sintéticos conforme o esperado, pretendemos revisitar a metodologia para identificar as causas e abordar as questões em aberto, além de explorar novas alternativas.

Agradecimentos

Gostaria de agradecer a todos envolvidos no projeto, em especial a equipe do Centro de Computação Quântica do SENAI-CIMATEC, onde esse trabalho só foi possível de ser realizado graças ao esforço conjunto.

5. REFERÊNCIAS

- ¹ FEYNMAN, R. **Simulating physics with computers**. Int J Theor Phys, v. 21, 1982. Disponível em: <https://link.springer.com/article/10.1007/BF02650179>. Acesso em: 12 de março 2024.
- ² DEUTSCH, D. **Quantum theory**, the Church–Turing principle and the universal quantum computer. Proc. R. Soc. Londres, 1985.
- ³ QURECA. **Overview of Quantum Initiatives Worldwide 2023**. 19 jul. 2023. Disponível em: <https://qureca.com/overview-of-quantum-initiatives-worldwide-2023/> . Acesso em: 12 mar. 2024.
- ⁴ GOODFELLOW, I. et al. **Generative adversarial networks**. Communications of the ACM, v. 63, 2020.
- ⁵ Ngo, T. et al. **A survey of recent advances in quantum generative adversarial networks**. Electronics, 2023
- ⁶ IBM, **Qiskit Summer School**. 2022. Disponível em: <https://github.com/Qiskit/platypus/tree/main/notebooks/summer-school> Acesso em: 14 mar. 2024.