

UTILIZAÇÃO DO APRENDIZADO DE MÁQUINA QUÂNTICO (AMQ) PARA RECONHECIMENTO DE DÍGITOS MANUSCRITOS

João Henrique Teixeira Ferreira^{1*}; Ricardo Dalke Meucci¹; Ricardo Luiz Ciuccio¹,

Jorge de Oliveira Echeimberg¹

¹ Centro Universitário Senac. *(joao.htferreira@senacsp.edu.br).

Resumo: A computação quântica tem avançado como uma das áreas mais promissoras da ciência e tecnologia contemporâneas, ao oferecer um modelo de processamento baseado em princípios fundamentais da mecânica quântica, como superposição, interferência e emaranhamento. Tais propriedades permitem representar e manipular informações em espaços de Hilbert de dimensões exponenciais, o que potencialmente habilita ganhos de expressividade e paralelismo inacessíveis a sistemas clássicos. Nesse contexto, o Aprendizado de Máquina Quântico (AMQ) surge como uma extensão natural do aprendizado de máquina tradicional, buscando explorar circuitos variacionais e kernels quânticos para aprimorar tarefas de classificação, reconhecimento de padrões e extração de características em cenários de alta complexidade. Entretanto, apesar do entusiasmo crescente, existem lacunas importantes sobre a real viabilidade e vantagem prática de arquiteturas quânticas na era NISQ (Noisy Intermediate-Scale Quantum), marcadas por ruído, decoerência e escalabilidade limitada. Assim, torna-se essencial investigar comparações entre modelos clássicos e quânticos sob condições equivalentes. Este trabalho apresenta um estudo comparativo sistemático entre Redes Neurais Convolucionais Clássicas (RNCC) e Redes Neurais Convolucionais Quânticas (RNCQ), adotando equivalência geométrica entre arquiteturas para assegurar imparcialidade científica. Utilizou-se o dataset de dígitos manuscritos, MNIST, reduzido de 28×28 para 8×8 pixels e apenas os algarismos 0 e 1. A RNCQ foi construída com circuitos variacionais atuando como kernels de 3×3 pixels, totalizando 18 qubits na arquitetura final. A codificação dos dados foi realizada via Angle Encoding e o emaranhamento implementado por portas CNOT para captura de correlações espaciais. As simulações quânticas foram conduzidas no framework PennyLane com aceleração por GPU, via `lightning.gpu`. Os resultados mostram que o desempenho da RNCQ foi limitado pela dinâmica de otimização, afetada pelo fenômeno dos Barren Plateaus, no qual a variância dos gradientes se anula. Demonstrou-se que um protocolo de treinamento adequado — inicialização uniforme dos parâmetros ($\theta \sim \mathcal{U}(0, 2\pi)$) e taxa de aprendizado elevada ($\eta=0,05$) — é eficaz para superar a estagnação, permitindo que o modelo aprenda de forma estável. A RNCQ obteve 99,50% de acurácia e métricas de Precision, Recall e F1-Score iguais, de 0,9950, desempenho próximo aos 99,75% e 0,9975 alcançados pela RNCC. A QCNN apresentou forte capacidade de generalização em regimes de poucos dados, utilizando apenas 2500 amostras de treino consumindo 13 horas para o treinamento de 10 épocas com loss estável, enquanto a CNN consumiu 1 minuto, mas com oscilação da loss ao longo das épocas, devido a taxa de aprendizado. Conclui-se que convoluções quânticas variacionais podem atuar como extratores de características competitivos em condições NISQ, desde que acompanhadas de estratégias de otimização adequadas. O estudo contribui para a compreensão da interação entre computação

quântica e aprendizado profundo. Do ponto de vista tecnológico, esses resultados reforçam o potencial do AMQ em aplicações que demandam alta capacidade de representação em ambientes de dados limitados, como diagnóstico assistido por imagem, detecção de anomalias, sistemas embarcados inteligentes e modelagem de sistemas físicos complexos. À medida que o hardware quântico evoluir em escala e estabilidade, arquiteturas híbridas poderão oferecer vantagens em eficiência energética, paralelismo e compactação de modelos, ampliando as possibilidades de integração entre inteligência artificial e computação quântica no setor produtivo.

Palavras-chave: Computação Quântica; Redes Neurais Convolucionais Quânticas; Barren Plateaus; Aprendizado de Máquina; Reconhecimento de Padrões.

UTILIZATION OF QUANTUM MACHINE LEARNING (QML) FOR HANDWRITTEN DIGIT RECOGNITION

João Henrique Teixeira Ferreira^{1*}; Ricardo Dalke Meucci¹; Ricardo Luiz Ciuccio¹,
Jorge de Oliveira Echeimberg¹

¹ Centro Universitário Senac. *(joao.htferreira@senacsp.edu.br).

Abstract: Quantum computing has advanced as one of the most promising fields in contemporary science and technology by offering a processing model grounded in fundamental principles of quantum mechanics, such as superposition, interference, and entanglement. These properties enable the representation and manipulation of

information in exponentially large Hilbert spaces, potentially allowing gains in expressivity and parallelism that are inaccessible to classical systems. In this context, Quantum Machine Learning (QML) emerges as a natural extension of traditional machine learning, seeking to exploit variational circuits and quantum kernels to enhance classification, pattern recognition, and feature extraction tasks in highly complex scenarios. However, despite growing enthusiasm, significant gaps remain regarding the real feasibility and practical advantage of quantum architectures in the NISQ (Noisy Intermediate-Scale Quantum) era, marked by noise, decoherence, and limited scalability. Therefore, it becomes essential to investigate comparisons between classical and quantum models under equivalent conditions. This work presents a systematic comparative study between Classical Convolutional Neural Networks (CCNN) and Quantum Convolutional Neural Networks (QCNN), adopting geometric equivalence between architectures to ensure scientific impartiality. The MNIST dataset of handwritten digits was used, reduced from 28×28 to 8×8 pixels and including only the digits 0 and 1. The QCNN was constructed with variational circuits acting as 3×3 pixel kernels, totaling 18 qubits in the final architecture. Data encoding was performed via Angle Encoding, and entanglement was implemented through CNOT gates to capture spatial correlations. Quantum simulations were conducted in the PennyLane framework with GPU acceleration via `lightning.gpu`. The results show that the QCNN's performance was limited by optimization dynamics, affected by the Barren Plateaus phenomenon, in which gradient variance vanishes. It was demonstrated that an appropriate training protocol — uniform parameter initialization ($\theta \sim \mathcal{U}(0, 2\pi)$) and a high learning rate ($\eta = 0,05$) — is effective in overcoming stagnation, allowing the model to learn stably. The QCNN achieved 99.50% accuracy with Precision, Recall, and F1-Score metrics all at 0.9950, a performance close to the 99.75% and 0.9975 achieved by the CCNN. The QCNN demonstrated strong generalization capability in low-data regimes, using only 2,500 training samples and requiring 13 hours for a 10-epoch training session with a stable loss. In contrast, the CNN took 1 minute but exhibited loss oscillation throughout the epochs due to the learning rate. It is concluded that variational quantum convolutions can act as competitive feature extractors under NISQ conditions, provided they are accompanied by suitable optimization strategies. From a technological perspective, these results reinforce the potential of QML in applications requiring high representational capacity in data-constrained environments, such as image-assisted diagnosis, anomaly detection, intelligent embedded systems, and modeling of complex physical systems. As quantum hardware evolves in scale and stability, hybrid architectures may offer advantages in energy efficiency, parallelism, and model compactness, expanding the possibilities for integrating artificial intelligence and quantum computing in the productive sector.

Keywords: Quantum Computing; Quantum Convolutional Neural Networks; Barren Plateaus; Machine Learning; Pattern Recognition.