

# Redes Neurais Quânticas vs. Clássicas na Identificação de Fragmentos Arqueológicos

Bruno Clemente Guingo e Renato Portugal

**Resumo**—Este estudo comparou cinco redes neurais convolucionais (CNNs: LeNet, AlexNet, VGG19, GoogLeNet, ResNet) e duas redes neurais quânticas (QNNs: 1-qubit para classificação binária e 2-qubits para multiclasse) na classificação de 1.918 imagens de artefatos arqueológicos do Projeto de Integração do Rio São Francisco (PISF), geridas pela Fundação Museu do Homem Americano (FUMDHAM). As imagens incluíam cerâmica (546), material lítico (529), louça (454) e vidro (389). Ambos os modelos obtiveram boa precisão, com leve vantagem das CNNs. Porém, as QNNs treinaram em segundos e usaram menos parâmetros, destacando seu potencial para eficiência computacional em tarefas de classificação de imagens arqueológicas.

**Palavras-Chave**—Artefatos arqueológicos, vestígios de arte rupestre, classificação de imagens arqueológicas, rede neural quântica.

**Abstract**—This study compared five convolutional neural networks (CNNs: LeNet, AlexNet, VGG19, GoogLeNet, ResNet) and two quantum neural networks (QNNs: 1-qubit for binary classification and 2-qubit for multiclass classification) in classifying 1,918 archaeological artifact images from the São Francisco River Integration Project (PISF), managed by the Foundation Museum of American Man (FUMDHAM). The image dataset comprised pottery (546), lithic materials (529), fine faience (454), and glass (389). Both models achieved good accuracy, with CNNs showing a slight advantage. However, QNNs trained within seconds and required fewer parameters, highlighting their potential for computational efficiency in archaeological image classification tasks.

**Keywords**—Archaeological artifacts, rock art remains, archaeological image classification, quantum neural network.

## I. INTRODUÇÃO

O patrimônio arqueológico brasileiro, especialmente aquele presente no semiárido nordestino, constitui-se em um acervo de relevância histórica e científica incomparável para a compreensão da ocupação humana e da evolução cultural nas Américas. Nesse contexto, destaca-se o Programa de Arqueologia Preventiva vinculado ao Projeto de Integração do Rio São Francisco com as Bacias Hidrográficas do Nordeste Setentrional (PISF), um dos maiores projetos de infraestrutura hídrica do país, e que durante as obras foi revelado um vasto acervo de artefatos ao longo de seus 477 quilômetros. O PISF fez o registro e coleta de

mais de 243 mil artefatos arqueológicos provenientes de 402 sítios e 584 ocorrências arqueológicas, além de gerar um acervo superior a 106 mil imagens fotográficas. Os vestígios resgatados incluem materiais líticos, cerâmicas, louças, fragmentos de vidro e outros achados, todos devidamente registrados no Instituto do Patrimônio Histórico e Artístico Nacional (IPHAN), conforme determinações legais do Decreto-Lei nº 25/1937. A gestão e salvaguarda desse acervo estão sob a responsabilidade da Fundação Museu do Homem Americano (FUMDHAM) em parceria com o Instituto Nacional de Arqueologia, Paleontologia e Ambiente do Semiárido (INAPAS), que realiza identificação, análise e preservação de acordo com protocolos arqueológicos e a legislação vigente que exigem processos meticulosos de catalogação.

Esses materiais, além de sua importância histórica, possuem características morfológicas e físicas que demandam análise minuciosa para correta classificação e interpretação.

Entretanto, a documentação desses artefatos por meio de fotografias apresenta desafios metodológicos. A observação direta de um fragmento arqueológico proporciona percepção tridimensional rica em detalhes, graças à visão binocular e à variação de perspectiva obtida com o movimento da cabeça, permitindo captar profundidade, volume e textura. Em contraste, a fotografia bidimensional congela uma única perspectiva, reduzindo a percepção de relevos e limitando a interpretação de características cruciais para a classificação tipológica. Essa limitação afeta especialmente atributos que dependem de microvariações de superfície ou relações espaciais complexas, essenciais para diagnósticos arqueológicos precisos.

No cenário contemporâneo, em que a quantidade de material coletado é vasta e crescente, torna-se imperativo desenvolver métodos automáticos e eficientes para a categorização desses artefatos. As Redes Neurais Convolucionais (CNNs), por exemplo, destacam-se pela capacidade de extrair e aprender automaticamente características visuais a partir de imagens, aplicando camadas de convolução, pooling e conexões totalmente conectadas que permitem a identificação de padrões hierárquicos e texturas [1]. Contudo, conjuntos de dados ruidosos, com degradação e variação de técnicas de confecção dos artefatos, podem comprometer o desempenho das CNNs.

Como alternativa emergente, as Redes Neurais Quânticas (QNNs) exploram princípios da mecânica quântica como superposição e emaranhamento para processar informações de forma paralela e mais eficiente, representando dados por meio de qubits.

Bruno Clemente Guingo, Faculdade de Educação Tecnológica do Estado do Rio de Janeiro - FAETERJ Petrópolis, Petrópolis-RJ, e-mail: bgingo@faeterj-petropolis.edu.br; Renato Portugal, Laboratório Nacional de Computação Científica, Petrópolis-RJ, e-mail: portugal@lncc.br

Dessa forma, a comparação entre CNNs e QNNs na classificação de imagens arqueológicas representa uma fronteira interdisciplinar que une arqueologia, ciência da computação e computação quântica.

O trabalho de identificação e classificação de artefatos arqueológicos realizado manualmente por especialistas é notoriamente trabalhoso e demorado, demandando horas de análise minuciosa para cada peça. Nesse contexto, um sistema automatizado representa um avanço significativo, oferecendo um ganho expressivo no parâmetro tempo de identificação.

## II. MODELOS NEURAIS

### A. Redes Neurais Clássicas

Os modelos escolhidos para este estudo foram selecionados com base na revisão da literatura feita pelos autores, sendo eles: LeNet [2], AlexNet [3], VGG19 [4], GoogLeNet [5] e ResNet [6]. Todos os modelos escolhidos foram treinados diversas vezes com os mesmos valores de parâmetros (número de epochs = 100, tamanho do lote = 32, tx de aprendizado = 0,001) num notebook x86/64, CPU i5-8265U de 1,60GHz x8, 8GB DDR4 e Ubuntu 22.04.4. (equipamento usado também nos modelos quânticos).

### B. Rede Neural Quântica - Qubit Único

A Rede Neural Quântica de Qubit Único [7] é um modelo neural quântico projetado para lidar com tarefas de aprendizado de máquina quântico, como regressão e classificação binária no contexto de aprendizado supervisionado. A rede, em sua forma reduzida, consiste em uma sequência simplificada de neurônios de único *qubit*, cada um representado por uma porta de rotação  $R_y(\theta_k)$ , onde

$$R_y(2\theta_k) = \begin{bmatrix} \cos \theta_k & -\sin \theta_k \\ \sin \theta_k & \cos \theta_k \end{bmatrix},$$

para  $k = 1, 2, \dots, K$ . Aqui,  $K$  denota o número de neurônios e representa a profundidade da rede. A entrada do circuito é inicializada no estado fundamental  $|0\rangle$ , e a saída é obtida por meio de uma medição na base computacional. Os ângulos  $\theta_k$  são funções dos dados de entrada, permitindo que a rede se adapte dinamicamente aos dados. Essa adaptabilidade é essencial para a eficácia da rede em diversas tarefas de aprendizado de máquina. Ao aumentar o número de neurônios, o modelo adquire graus adicionais de liberdade, permitindo que ele aprenda e represente padrões mais complexos durante o treinamento.




Fig. 1: Circuito da rede com 1 *qubit* para classificação binária. Fonte: [7]

A rede de um qubit é descrita pelo circuito na Fig. 1, com o estado de saída dado por

$$|\psi\rangle = \cos \theta |0\rangle + \sin \theta |1\rangle.$$

As probabilidades de classificação são:

$$\begin{aligned} p_0 &= \cos^2 \theta \quad (\text{Classe } 0), \\ p_1 &= \sin^2 \theta \quad (\text{Classe } 1). \end{aligned}$$

A entrada do modelo é determinada por uma função efetiva  $\theta_k(\vec{x})$ , que combina os dados de entrada de maneira inspirada na expansão em série de Taylor. Essa função é expressa como

$$\theta(\vec{x}) = w_0 + \vec{w}_1 \cdot \vec{x} + \vec{w}_2 \cdot (\vec{x} \circ \vec{x}) + \dots + \vec{w}_K \cdot \vec{x}^{\circ K},$$

onde  $\vec{x}^{\circ K}$  denota o produto de Hadamard ( $\circ$ ) aplicado  $K$  vezes. Os pesos  $\vec{w}_j$  (para  $j = 1, \dots, K$ ) são parâmetros treináveis,  $K$  representa o grau máximo dos termos, e  $\vec{x} \in \mathbb{R}^p$  é um vetor de características com  $p$  dimensões.

A versão reduzida da rede emprega um método de treinamento aprimorado para tarefas de classificação binária, denominado Método dos Mínimos Quadrados Lineares Baseado em Polinômios. Esse algoritmo melhora a flexibilidade ao incorporar potências sucessivas dos elementos do conjunto de dados no processo de treinamento. A função que mapeia os dados de entrada para o ângulo de rotação  $\theta(\vec{x})$  é definida como

$$\cos \theta(\vec{x}) = \sigma \left( w_0 + \sum_{k=1}^K \vec{w}_k \cdot \vec{x}^{\circ k} \right), \quad (1)$$

que representa o valor alvo da entrada  $\vec{x}$ , onde  $\sigma$  é a função sigmoide. O coeficiente  $w_0$  e os elementos de  $\vec{w}_k$  são determinados utilizando o método de regressão linear por mínimos quadrados, formulado como

$$\vec{W} = (XX^T)^+ X\vec{Y}, \quad (2)$$

onde  $\vec{W}$  é o vetor de coeficientes

$$\vec{W} = \begin{bmatrix} w_0 \\ \vec{w}_1 \\ \vdots \\ \vec{w}_K \end{bmatrix},$$

e  $\vec{Y}$  é o vetor de rótulos

$$\vec{Y} = [\sigma^{-1}(y_1) \quad \sigma^{-1}(y_2) \quad \dots \quad \sigma^{-1}(y_n)]^T.$$

A matriz  $X$  é construída a partir das entradas do conjunto de dados da seguinte forma:

$$X = \begin{bmatrix} 1 & 1 & \dots & 1 \\ \vec{x}_1^{\circ 1} & \vec{x}_2^{\circ 1} & \dots & \vec{x}_n^{\circ 1} \\ \vdots & \vdots & \vdots & \vdots \\ \vec{x}_1^{\circ K} & \vec{x}_2^{\circ K} & \dots & \vec{x}_n^{\circ K} \end{bmatrix},$$

onde  $X^T$  representa a transposta de  $X$ , e  $(XX^T)^+$  denota a pseudo-inversa de Moore-Penrose de  $XX^T$ . Esse método permite o cálculo eficiente dos valores ótimos dos pesos em uma única etapa, acelerando significativamente o processo de treinamento. A determinação da classe correta é feita como descrito no Algoritmo 1.

**Algoritmo 1** Atribuição de classes para QNN com 1 qubit

- 1: **Entrada:** Conjunto de treinamento  $\{(\vec{x}_i, y_i)\}_{i=1}^N$ , com  $y_i \in \{0, 1\}$
- 2: **Saída:** Parâmetro  $\theta(\vec{x})$  treinado
- 3: Converter rótulos para valores contínuos:  $y'_i = \sigma^{-1}(y_i)$
- 4: Construir matriz de características  $X$  conforme Eq. (2)
- 5: Calcular vetor de pesos  $\vec{W} = (X X^T)^+ X \vec{Y}$
- 6: Definir função ângulo:  $\theta(\vec{x}) = \sigma(w_0 + \sum_{k=1}^K \vec{w}_k \cdot \vec{x}^{\circ k})$
- 7: Aplicar fator de escala para polarizar saídas ( $\theta \approx 0$  ou  $\theta \approx \pi/2$ )
- 8: **return** Função  $\theta(\vec{x})$  treinada

**C. Rede Neural Quântica - Dois Qubits**

A rede neural quântica de dois *qubits* estende o modelo de um único *qubit* para permitir a classificação multiclasse, aproveitando os quatro possíveis resultados da medição de dois *qubits* na base computacional:  $|00\rangle$ ,  $|01\rangle$ ,  $|10\rangle$  e  $|11\rangle$ . Este modelo é projetado para tarefas de classificação com quatro classes, onde cada resultado de medição corresponde a uma das classes. Ao incorporar um *qubit* adicional, a rede aumenta seu poder expressivo, permitindo capturar padrões mais complexos nos dados.

A rede de dois *qubits* emprega portas de rotação parametrizadas para construir um circuito quântico que codifica dinamicamente as características de entrada. As probabilidades de saída, derivadas da medição dos dois *qubits* na base computacional, são mapeadas para as respectivas classes, proporcionando uma interpretação probabilística do processo de classificação. Essa abordagem garante a compatibilidade da rede com dispositivos quânticos de curto prazo, ao mesmo tempo que lida de forma eficaz com os desafios da classificação multiclasse.




Fig. 2: Circuito da rede com 2 *qubits* para classificação em 4 classes. Fonte: [8]

A rede é descrita pelo circuito na Fig. 2, com o estado de saída dado por

$$|\psi\rangle = \cos \theta_1 \cos \theta_2 |00\rangle + \cos \theta_1 \sin \theta_2 |01\rangle + \sin \theta_1 \cos \theta_3 |10\rangle + \sin \theta_1 \sin \theta_3 |11\rangle.$$

A probabilidade da rede retornar a primeira classe é  $\cos^2 \theta_1 \cos^2 \theta_2$ , da segunda classe é  $\cos^2 \theta_1 \sin^2 \theta_2$ , da terceira classe é  $\sin^2 \theta_1 \cos^2 \theta_3$ , e da quarta classe é  $\sin^2 \theta_1 \sin^2 \theta_3$ .

O método de treinamento para o caso de dois *qubits* é um processo iterativo empregado até que a classe correta seja determinada. Foi adotado o mesmo ansatz (1), usado no caso de um *qubit* único, para cada ângulo  $\theta_1(\vec{x})$ ,  $\theta_2(\vec{x})$  e  $\theta_3(\vec{x})$ . O vetor de pesos  $\vec{W}$  usado nesse ansatz é calculado utilizando a Eq. (2). Esse ansatz garante que, quando  $\theta_1(\vec{x})$  está próximo de 0, o resultado corresponde à Classe 1 ou 2, e quando está próximo de  $\pi/2$ , o resultado corresponde

à Classe 3 ou 4. Aplicando o mesmo ansatz a  $\theta_2(\vec{x})$  e  $\theta_3(\vec{x})$ , a rede identifica a classe correta para uma dada entrada  $\vec{x}$ . Por exemplo, para a Classe 3,  $\theta_1(\vec{x}) \approx 0$  e  $\theta_2(\vec{x}) \approx \pi/2$ .

A classe associada a uma entrada  $\vec{x}$  é determinada pela medida do estado quântico final da rede na base computacional. Para o circuito de dois qubits mostrado na Fig. 2, há quatro possíveis saídas:  $|00\rangle$ ,  $|01\rangle$ ,  $|10\rangle$  e  $|11\rangle$ , cada uma correspondendo a uma classe distinta. O estado de saída da rede é dado por

$$|\psi(\vec{x})\rangle = \cos \theta_1(\vec{x}) \cos \theta_2(\vec{x}) |00\rangle + \cos \theta_1(\vec{x}) \sin \theta_2(\vec{x}) |01\rangle + \sin \theta_1(\vec{x}) \cos \theta_3(\vec{x}) |10\rangle + \sin \theta_1(\vec{x}) \sin \theta_3(\vec{x}) |11\rangle.$$

As probabilidades associadas a cada classe são, portanto:

$$\begin{aligned} p_{00} &= \cos^2 \theta_1 \cos^2 \theta_2, \\ p_{01} &= \cos^2 \theta_1 \sin^2 \theta_2, \\ p_{10} &= \sin^2 \theta_1 \cos^2 \theta_3, \\ p_{11} &= \sin^2 \theta_1 \sin^2 \theta_3. \end{aligned}$$

O processo de determinação da classe é estruturado de forma hierárquica sobre os ângulos  $\theta_1$ ,  $\theta_2$  e  $\theta_3$ , cada um aprendido por meio de um procedimento supervisionado. Primeiramente, a rede utiliza  $\theta_1$  para separar os dados em dois supergrupos: um onde o primeiro qubit deve resultar em  $|0\rangle$  (Classes 1 e 2) e outro onde ele deve resultar em  $|1\rangle$  (Classes 3 e 4). Isso é realizado convertendo os rótulos em valores binários:  $y'_i = -1$  se o rótulo pertencer às Classes 3 ou 4, e  $y'_i = +1$  caso contrário. Utiliza-se o mesmo ansatz (1) do modelo de um qubit para parametrizar  $\theta_1(\vec{x})$ , e os pesos são obtidos por regressão linear conforme a Eq. (2). Um fator de escala grande garante que  $\theta_1$  se aproxime de 0 ou  $\pi/2$ , concentrando a probabilidade em um dos pares de classes.

Uma vez determinado  $\theta_1$ , os ângulos  $\theta_2$  e  $\theta_3$  são treinados para distinguir entre as classes dentro de cada supergrupo. Para amostras em que  $\theta_1(\vec{x}) \approx 0$ , o ângulo  $\theta_2$  diferencia entre as Classes 1 ( $|00\rangle$ ) e 2 ( $|01\rangle$ ); para  $\theta_1(\vec{x}) \approx \pi/2$ , o ângulo  $\theta_3$  diferencia entre as Classes 3 ( $|10\rangle$ ) e 4 ( $|11\rangle$ ). Cada ângulo é treinado independentemente com as amostras do subconjunto correspondente.

Esse procedimento se generaliza naturalmente para redes com  $n$  qubits. Nesse caso, existem  $2^n$  possíveis resultados de medição, correspondendo a  $2^n$  classes. O treinamento hierárquico é estendido de forma recursiva: cada qubit é responsável por dividir um subconjunto restante de classes em dois, utilizando um classificador binário controlado por um parâmetro  $\theta_k(\vec{x})$ . Em cada nível  $k$  da árvore de decisão (com  $1 \leq k \leq 2^n - 1$ ), um parâmetro  $\theta_k$  é treinado apenas com os dados que chegaram até esse nível, permitindo o refinamento progressivo da predição da classe final.

Esse processo de determinação de classe se generaliza naturalmente para redes com  $n$  qubits, nas quais existem  $2^n$  possíveis saídas correspondentes a  $2^n$  classes. A determinação da classe correta é feita de forma hierárquica por meio de classificações binárias sucessivas, como descrito no Algoritmo 2.

**Algoritmo 2** Atribuição hierárquica de classes para QNN com 2 qubits

---

```

1: Entrada: Conjunto de treinamento  $\{(\vec{x}_i, y_i)\}_{i=1}^N$ , com  $y_i \in \{0, 1, 2, 3\}$ 
2: Saída: Parâmetros  $\theta_1(\vec{x}), \theta_2(\vec{x}), \theta_3(\vec{x})$  treinados hierarquicamente
3: Inicializar:  $\mathcal{D} \leftarrow \{(\vec{x}_i, y_i)\}_{i=1}^N$ 
4: Inicializar:  $\mathcal{C} \leftarrow \{0, 1, 2, 3\}$  (Classes  $|00\rangle, |01\rangle, |10\rangle, |11\rangle$ )
5: for  $k = 1$  to 3 do
6:   Determinar subconjunto  $\mathcal{C}_k \subseteq \mathcal{C}$  associado a  $\theta_k$ :
7:   - Para  $k = 1$ :  $\mathcal{C}_1 = \{2, 3\}$  (Classes com primeiro qubit em  $|1\rangle$ )
8:   - Para  $k = 2$ :  $\mathcal{C}_2 = \{1\}$  (Classe  $|01\rangle$  no ramo  $\theta_1 \approx 0$ )
9:   - Para  $k = 3$ :  $\mathcal{C}_3 = \{3\}$  (Classe  $|11\rangle$  no ramo  $\theta_1 \approx \pi/2$ )
10:  Atribuir rótulos binários:
11:   $y'_i = -1$  se  $y_i \in \mathcal{C}_k$ , e  $+1$  caso contrário
12:  Treinar  $\theta_k(\vec{x})$  usando ansatz (1) e Eq. (2)
13:  Aplicar fator de escala para forçar  $\theta_k \approx 0$  ou  $\theta_k \approx \pi/2$ 
14:  if  $k = 1$  then
15:    Dividir  $\mathcal{D}$  em:
16:     $\mathcal{D}_0 = \{(\vec{x}_i, y_i) | \theta_1(\vec{x}_i) \approx 0\}$  (Classes 0 e 1)
17:     $\mathcal{D}_1 = \{(\vec{x}_i, y_i) | \theta_1(\vec{x}_i) \approx \pi/2\}$  (Classes 2 e 3)
18:  end if
19:  Atualizar  $\mathcal{D}$  para o subconjunto relevante:
20:  - Para  $k = 2$ : usar  $\mathcal{D}_0$ 
21:  - Para  $k = 3$ : usar  $\mathcal{D}_1$ 
22:  Remover de  $\mathcal{C}$  as classes já discriminadas por  $\theta_k$ 
23: end for
24: return Parâmetros treinados  $\theta_1, \theta_2, \theta_3$ 

```

---

## III. CONJUNTO DE DADOS DE IMAGENS

O conjunto de dados da coleção PISF contém mais de trinta mil imagens de diversas classes de artefatos arqueológicos. Entretanto, para este estudo, trabalhou-se com um subconjunto de 1.918 imagens, categorizadas nas quatro classes com maior representatividade amostral: cerâmica (546 imagens), material lítico (529 imagens), louça (454 imagens) e vidro (389 imagens). Todas as imagens estão em formato .jpg e têm as seguintes resoluções: 1.517 imagens em  $4608 \times 3546$  pixels, 229 imagens em  $4288 \times 2848$  pixels, 156 imagens com  $4000 \times 3000$  pixels e 16 imagens com  $4896 \times 3672$  pixels.

## A. Pré-Processamento dos Dados

O pré-processamento das imagens do conjunto de dados iniciou-se com o redimensionamento para  $256 \times 256$  pixels, visando padronizar as entradas e reduzir o custo computacional. Posteriormente, diversas técnicas de extração de características foram aplicadas as técnicas de Momentos Invariantes de HU [9], Wavelets [10], Transformada Discreta de Cosseno (DCT) nos canais RGB [11] e Zig-Zag [12] para servir de entrada às redes neurais quânticas, enquanto as redes neurais clássicas utilizaram diretamente as imagens originais como entrada.

## IV. RESULTADOS

## A. Redes Neurais Clássicas

A tabela I apresenta os melhores valores em acurácia, tempo de treinamento e número de camadas atingidos em cada modelo de CNNs que foi implementada.

TABELA I: Resultados de diferentes arquiteturas de CNN

Modelo	Acurácia (%)	Tempo	Camadas
LeNet	76.30	1h46m	10
AlexNet	28.38	1h	14
VGG19	89.12	1h48m	23
GoogLeNet	87.76	2h25m	315
ResNet	23.69	2h55m	179

Nota: Tempos de treinamento para o mesmo hardware e dataset.

## B. Rede Neural Quântica - Qubit Único

Para avaliar o desempenho do modelo, várias métricas foram utilizadas, incluindo acurácia, precisão, sensibilidade, especificidade e F1-score. Os resultados foram obtidos para  $K = 1$ ,  $K = 2$  e  $K = 3$ , onde  $K$  representa o número de neurônios. Cada iteração de treinamento foi conduzida entre diferentes classes de artefatos (material lítico, cerâmica, louça e vidro), resultando em seis tarefas de classificação distintas, todas avaliadas com validação cruzada de 10 *folds*. A tabela II apresenta os resultados obtidos.

TABELA II: Resultados de classificação para qubit único com diferentes valores de  $K$ 

Classificação	K=1		K=2		K=3	
	Acurácia	Vetor	Acurácia	Vetor	Acurácia	Vetor
1 e 2	0.744(31)	60	0.790(22)	50	0.747(33)	75
1 e 3	0.812(43)	75	0.826(47)	65	0.741(43)	40
1 e 4	0.855(25)	50	0.842(38)	50	0.788(47)	60
2 e 3	0.788(43)	50	0.784(35)	40	0.745(47)	50
2 e 4	0.887(19)	60	0.882(34)	50	0.873(24)	50
3 e 4	0.880(25)	100	0.894(19)	75	0.858(29)	30

Nota: Valores entre parênteses representam incerteza ( $\times 0.001$ ). Códigos: 1=Vidro, 2=Cerâmica, 3=Material Lítico, 4=Louça.

## C. Rede Neural Quântica - Dois Qubits

Para o estudo com o modelo de rede neural quântica de dois qubits, o mesmo conjunto de imagens foi utilizado e a rede passa a operar em multiclases, ou seja, efetua a classificação das quatro classes de imagens. A Tabela III apresenta os resultados obtidos utilizando os três valores de  $K$  (1, 2 e 3) para a classificação das quatro classes.

TABELA III: Resultados de classificação para dois qubits com diferentes valores de  $K$ 

Vetor	K=1		K=2		K=3	
	Acurácia	Vetor	Acurácia	Vetor	Acurácia	Vetor
5	0.438(40)	5	0.677(25)	5	0.541(38)	5
10	0.469(38)	10	0.693(22)	10	0.562(28)	10
20	0.510(35)	20	0.714(20)	20	0.591(33)	20
30	0.543(35)	30	0.750(18)	30	0.621(34)	30
40	0.553(26)	33	0.786(15)	40	0.619(40)	40
50	0.581(28)	35	0.750(18)	50	0.625(34)	50
60	0.588(36)	40	0.745(19)	60	0.624(25)	60
75	0.608(26)	50	0.740(20)	65	0.624(25)	75
100	0.625(40)	60	0.719(22)	100	0.626(35)	100
200	0.627(30)	75	0.703(23)	200	0.629(25)	200

Nota: Valores entre parênteses representam incerteza ( $\times 0.001$ ).

#### D. Tempo de Treinamento - QNNs

Foram feitos diversos testes para vários tamanhos de vetor e para os três valores de  $K$ . O tempo de treinamento está apresentado na tabela IV.

TABELA IV: Tempos de processamento para diferentes valores de  $K$

Vetor	K=1 (s)	K=2 (s)	K=3 (s)
5	0.6	0.6	0.6
10	0.6	0.6	0.6
20	1.2	0.6	1.2
30	1.2	1.2	2.4
40	1.2	1.8	4.2
50	1.8	3.0	4.8
60	1.8	3.6	4.8
65	1.8	4.2	4.8
75	2.4	4.2	5.4

Nota: Tempos médios de processamento em segundos.

#### V. ANÁLISE DOS RESULTADOS - COMPARAÇÃO

As CNNs demonstraram seu reconhecido desempenho em tarefas de visão computacional, com a VGG19 alcançando 89,12% de acurácia após 1 hora e 48 minutos de treinamento, utilizando sua arquitetura de 23 camadas. Este resultado não apenas corrobora estudos anteriores como apresentado em [13] e em [14], que reportaram acurácias entre 83,32% e 87,94% com arquiteturas similares, mas também reforça a maturidade desses modelos para aplicações em análise de artefatos culturais.

Em contraste, a implementação quântica obteve 78,6% de acurácia com  $K = 2$ , utilizando vetores de dimensionalidade reduzida. A diferença de aproximadamente 10 pontos percentuais em relação à VGG19 é compensada por características intrínsecas ao paradigma quântico: processamento paralelo probabilístico, menor demanda por parâmetros treináveis e potencial escalabilidade para problemas de alta dimensionalidade. A análise temporal revela outro aspecto relevante: o treinamento da VGG19 demandou cerca de 1h48m, enquanto o modelo quântico, embora com acurácia inferior, mostrou tempo de poucos segundos para vetores de pequena dimensão.

Embora essas redes operem de maneira diferente, a rede convolucional, tradicionalmente usada para análise de imagens, extrai características espaciais hierárquicas por meio de camadas convolucionais e depende de um grande número de parâmetros. Em contraste, a rede quântica, aproveitando os princípios da computação quântica, processa entradas de forma probabilística e em paralelo, com um número significativamente menor de parâmetros. Apesar da diferença na acurácia, a rede quântica se destaca por sua eficiência computacional.

#### VI. CONCLUSÕES

Os resultados mostraram que, embora as CNNs tenham alcançado uma acurácia ligeiramente superior (89,12%

contra 78,6% das QNNs), os modelos quânticos apresentaram vantagens significativas em velocidade de treinamento (segundos versus horas) e eficiência computacional, demandando menos parâmetros.

Uma contribuição do estudo foi o desenvolvimento de uma arquitetura quântica de dois qubits, otimizada para classificação multiclasse (vidro, cerâmica, louça e material lítico), que se mostrou escalável e eficaz.

Apesar disso, desafios persistem, como a diferença de acurácia em relação às CNNs, sugerindo a necessidade de melhorias em codificação de dados, expansão do número de qubits e abordagens híbridas.

O estudo reforça o potencial sustentável das QNNs, dado seu menor consumo energético, tornando-as uma alternativa viável para projetos com grandes volumes de dados e recursos limitados. Com o avanço do hardware quântico e otimizações em circuitos parametrizados, as QNNs podem se consolidar como uma ferramenta valiosa para identificação de imagens de fragmentos em arqueologia e áreas afins.

#### REFERÊNCIAS

- [1] Lecun, Y., Bengio, Y. e Hinton, G. *Deep learning*. Nature, v. 521, n. 7553, p.436–444, 2015.
- [2] Lecun, Y. et al., *Gradient-based learning applied to document recognition*. Proceedings of the IEEE, IEEE, v. 86, n. 11, p. 2278–2324, 1998.
- [3] Krizhevsky, A., Sutskever, I. e Hinton, G. E. *Imagenet classification with deep convolutional neural networks*. Advances in Neural Information Processing Systems, v. 25, p. 1097–1105, 2012.
- [4] Simonyan, K. e Zisserman, A. *Very deep convolutional networks for large-scale image recognition*. arXiv preprint, 2014.
- [5] Szegedy, C. et al. *Rethinking the Inception Architecture for Computer Vision*. Disponível em: <<https://arxiv.org/abs/1512.00567>>, 2015.
- [6] He, K. et al. *Deep residual learning for image recognition*. IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [S.l.: s.n.], p. 770–778, 2016.
- [7] Souza, L. C. e Guingo, B. C. e Giraldo, G. e Portugal, R. *Regression and classification with single-qubit quantum neural networks*. arXiv, 2412.09486, 2024
- [8] Guingo, B. C. *Redes Neurais Quânticas na Classificação de Imagens de Artefatos Arqueológicos*. Tese (Doutorado em Modelagem Computacional) – Laboratório Nacional de Computação Científica, Petrópolis, 2025.
- [9] Chacon, G. et al. *Aplicação da técnica de momentos invariantes no reconhecimento de padrões em imagens digitais*. Notas Técnicas, Centro Brasileiro de Pesquisas Físicas, Rio de Janeiro, v. 1, n. 2, 2011.
- [10] Mallat, S. *A Wavelet Tour of Signal Processing*. Third. Academic Press. ISBN 9780123743701. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B978012374370100001X>>, 2009.
- [11] Rao, K. R. e Yip, P. *Discrete cosine transform: algorithms, advantages, applications*. USA: Academic Press Professional, Inc., ISBN 012580203X, 1990.
- [12] Jensen, T. E. *The Slalom Method: How to zig-zag between digital methods and traditional methods in ethnography*. Qualitative Research, v. 24, n. 2, p. 229–248. Disponível em: <<https://doi.org/10.1177/14687941221138405>>, 2024.
- [13] Kuntitan, P. e Chaowalit, O. *Using deep learning for the image recognition of motifs on the center of sukhothai ceramics*. Current Applied Science and Technology, v. 22, n. 02, p. 1–15, 2022.
- [14] Chetouani, A. et al. *Classification of ceramic shards based on convolutional neural network*. In: 25th IEEE International Conference on Image Processing (ICIP). [s.n.], p. 1038–1042. Disponível em: <<https://doi.org/10.1109/ICIP.2018.8451728>>, 2018.