

APRENDIZADO DE MÁQUINA QUÂNTICA PARA MONITORAMENTO ESTRUTURAL: ESTUDOS PIONEIROS

QUANTUM MACHINE LEARNING FOR STRUCTURAL MONITORING: PIONEER STUDIES

Victor Higino Meneguitte Alves¹
Raphael Fortes Infante Gomes²
Alexandre Abrahão Cury³

DOI: 10.34019/2179-3700.2024.v24.46058

ENVIADO EM: 24/9/2024

APROVADO EM: 11/11/2024

RESUMO

Este artigo propõe um método inovador para o monitoramento de integridade estrutural (SHM, do inglês *Structural Health Monitoring*) utilizando aprendizado de máquina quântico (QML, do inglês *Quantum Machine Learning*) não supervisionado. O processo sugerido envolve a obtenção de dados brutos de aceleração, a extração de características desses dados e a sua inserção em estados quânticos para que um classificador quântico possa analisá-los. Anormalidades estruturais potenciais são detectadas avaliando-se uma função de pontuação de anomalia que é obtida através do treinamento do modelo com situações conhecidas como intactas e identificando variações em relação aos comportamentos típicos. Implementações experimentais em uma estrutura de laboratório de dois andares confirmam o modelo proposto, mostrando resultados promissores na identificação, localização e quantificação de anomalias. Este trabalho estabelece as bases para investigações futuras na interseção da computação quântica e da engenharia civil, através de experimentos, análises e discussões pertinentes, expandindo os limites da pesquisa em SHM.

¹Bolsista do projeto de IC(PIBIC). Atualmente mestrando no Programa Pós-graduação em Engenharia Civil da UFJF. Divulgador científico no Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia(CIDENG-CNPq). victor.meneguitte@estudante.ufff.br

¹Coorientador do projeto de IC. Professor do Curso de Engenharia Física da UNILA. Endereço profissional: Universidade Federal da Integração Latino-Americana. Avenida Tancredo Neves, 6731 - Bloco 6 Parque Tecnológico Itaipu 13565905 - Foz do Iguaçu, PR - Brasil.

³Orientador do projeto de IC. Professor do Departamento de Mecânica Aplicada e computacional da UFJF. Endereço profissional: Universidade Federal de Juiz de Fora, Faculdade de Engenharia, Departamento Mecânica Aplicada e Computacional, São Pedro, Rua José Lourenço Kelmer, CEP: 36.036-900 - Juiz de Fora, MG - Brasil. alexandre.cury@ufff.br

Palavras-chave: Monitoramento de Integridade Estrutural. Aprendizado de Máquina Quântico. Detecção de danos.

ABSTRACT

This paper proposes a novel method for Structural Health Monitoring (SHM) utilizing unsupervised Quantum Machine Learning (QML). The suggested process entails taking raw acceleration data, extracting characteristics from them, and embedding them into quantum states such that a quantum classifier can analyze them. Potential structural abnormalities are detected by evaluating an anomaly score function, which is derived via training the model with known intact situations and identifying variations from typical behaviors. Experimental implementations on a laboratory two-story frame to confirm the proposed framework, showing promising results in anomaly identification and quantification. This work establishes the groundwork for future investigations at the nexus of quantum computing and civil engineering through relevant experiments, analyses, and discussions, expanding the boundaries of SHM research.

Keywords: Structural Health Monitoring. Quantum Machine Learning. Damagedetection.

1 INTRODUÇÃO

As estruturas civis se deterioram ao longo do tempo devido ao seu uso natural e às variações operacionais/ambientais. Essas mudanças podem ser divididas em duas categorias principais: duradouras, como fadiga, corrosão e reações químicas, que afetam a vida útil da estrutura; súbitas, como terremotos e incêndios, que causam danos graves e imprevistos. Métodos tradicionais de inspeção, como a visual e a não destrutiva, embora úteis, apresentam altos custos, processos demorados e riscos para os técnicos responsáveis pela manutenção das estruturas. Assim, há um crescente interesse em métodos de Monitoramento da Saúde Estrutural (SHM, sigla do inglês *Structural Health Monitoring*) que ofereçam soluções mais autônomas, econômicas e seguras.

A detecção de danos estruturais tem como referência a escala de quatro níveis de Rytter (Rytter, 1993). Esta escala organiza as técnicas de SHM de acordo com a capacidade de responder a questões-chave em diferentes níveis de identificação de danos: Nível 1) detectar a presença de dano(s); Nível 2) localizar o(s) dano(s); Nível 3) quantificar o(s) dano(s); Nível 4) estimar a vida útil restante da estrutura. O monitoramento baseado em vibrações, que usa dados dinâmicos obtidos a partir de sensores instalados nas estruturas, é particularmente útil quando a inspeção visual se torna difícil ou inviável.

1.1 Trabalhos relacionados

Nas últimas décadas, o campo do processamento de sinais tem experimentado um crescimento considerável e se tornou um componente essencial das tecnologias de SHM, impulsionado pelos avanços em Aprendizado de Máquina (ML – *Machine Learning*) e Aprendizado Profundo (DL – *Deep Learning*). Mais recentemente, surgiu um novo campo com algoritmos promissores baseados na mecânica quântica: o Aprendizado de Máquina Quântico (QML – *Quantum Machine Learning*). A combinação do potencial do QML com as vantagens das Redes Neurais Convolucionais (CNN) levou à criação das CNN quânticas, ou QCNN. Desde então, pesquisadores têm avaliado essa técnica em diversos tipos de dados, mas poucos estudos exploraram o QML aplicado ao SHM. Trochunet *al.* (2021) usaram um QCNN híbrido para classificar imagens binárias, identificando edifícios danificados a partir de imagens de satélite. O QCNN híbrido teve acurácias ligeiramente inferiores às dos modelos tradicionais. O estudo ressaltou que comparar diretamente métricas entre os modelos tradicionais e híbridos clássicos-quânticos pode ser prematuro nos estágios iniciais do QML. A pesquisa de Correa-Jullianet *al.* (2022) examinou o uso de Máquinas de Vetores de Suporte Quântico para a detecção de falhas em turbinas eólicas.

Este trabalho contribui ao combinar: (i) uma nova estratégia para integrar circuitos quânticos a técnicas de agrupamento não supervisionado em SHM com dados de vibração, (ii) validação em estruturas reais e (iii) investigação da detecção, localização e quantificação de anomalias. O estudo também compara o desempenho da metodologia proposta com uma técnica clássica, destacando benefícios e limitações de ambas.

2 FUNDAMENTOS DE COMPUTAÇÃO QUÂNTICA

2.1 Bits quânticos (*qubits*)


Na computação clássica, os bits são unidades binárias que representam 0 ou 1, funcionando de forma determinística. Já a computação quântica, no entanto, introduz os *qubits*, que transformam o processamento de informações. Diferentemente dos bits clássicos, os *qubits* podem estar em superposição, representando simultaneamente os estados 0 e 1. Isso aumenta exponencialmente a capacidade de informação e permite cálculos paralelos, explorando múltiplas possibilidades ao mesmo tempo.

A esfera de Bloch (Figura 1) é uma ferramenta comum para representar geometricamente todos os possíveis estados de um *qubit*, visualizando-o como um

ponto na superfície da esfera ou como um vetor originário do centro (Kaye *et al.*, 2006). A Equação 1 representa formalmente o estado de um *qubit* nessa esfera, usando dois parâmetros: θ e φ . O parâmetro θ é o ângulo entre o eixo z e $|\Psi\rangle$, variando de 0 a π , e φ é o ângulo entre o eixo x positivo e a projeção de $|\Psi\rangle$ em sentido anti-horário, variando de 0 a 2π .

$$|\Psi\rangle = \cos \frac{\theta}{2} |0\rangle + \sin \frac{\theta}{2} e^{i\varphi} |1\rangle \quad (1)$$

Figura 1 - Representação de um *qubit* na esfera de Bloch.



Fonte: Kaye *et al.* (2006)

2.2 Portas lógicas quânticas

Portas lógicas quânticas permitem a manipulação de *qubits* de maneira semelhante à manipulação de bits clássicos. Representadas por matrizes unitárias, essas portas são fundamentais para alterar os estados dos *qubits* e realizar operações computacionais. Na esfera de Bloch, o impacto de uma porta quântica U sobre um estado de *qubit* $|\Psi\rangle$ pode ser visualizado como uma rotação do vetor de Bloch correspondente a $|\Psi\rangle$ para se alinhar com o vetor que representa $U|\Psi\rangle$ (Kaye *et al.*, 2006).

2.3 Codificação quântica

Ao lidar com dados clássicos em um algoritmo quântico, surgem desafios, pois a entrada deve estar relacionada a uma propriedade do hardware quântico. Para isso, são usadas técnicas de codificação (ou *embedding*) para representar informações clássicas em estados quânticos, que servem como entrada para o circuito, permitindo que computadores quânticos processem e manipulem esses dados. Existem vários métodos de codificação quântica, cada um com suas vantagens e limitações (Khan *et al.*, 2024). Neste trabalho, utiliza-se a técnica de codificação angular.

3 METODOLOGIA

3.1 Extração de características

A extração de características é essencial para a identificação de danos estruturais, focando em informações relevantes de sinais captados por sensores. Esse processo transforma os dados em um formato que destaca comportamentos normais e anormais. Este estudo usa 11 características extraídas a partir de dados brutos de aceleração (Tabela 1). O processamento necessário é mínimo. Estatísticas como média, variância, assimetria, curtose, dentre outras já comprovadas eficazes em SHM em pesquisas anteriores são utilizadas (Alves e Cury, 2021).

Tabela 1 – Estatísticas x_i extraídas do sinal y_i

Estatística	Definição
Pico	$x_{1,i} = \max(y_i)$
Média	$x_{2,i} = \frac{1}{N} \sum_{i=1}^N y_i$
Média quadrática	$x_{3,i} = \frac{1}{N} \sum_{i=1}^N y_i^2$
Raiz da média dos quadrados	$x_{4,i} = \left(\frac{1}{N} \sum_{i=1}^N y_i^2 \right)^{\frac{1}{2}}$
Quadrado da média das raízes	$x_{5,i} = \left(\frac{1}{N} \sum_{i=1}^N y_i ^{\frac{1}{2}} \right)^2$
Variância	$x_{6,i} = \frac{1}{N-1} \sum_{i=1}^N y_i - x_{2,i} ^2$
Desvio padrão	$x_{7,i} = \sqrt{x_{6,i}}$
Assimetria	$x_{8,i} = \frac{\sum_{i=1}^N (y_i - x_{2,i})^3}{(N-1)(x_{7,i})^3}$
Curtose	$x_{9,i} = \frac{\sum_{i=1}^N (y_i - x_{2,i})^4}{(N-1)(x_{7,i})^4}$
Fator de crista	$x_{10,i} = \frac{\max(y_i)}{x_{4,i}}$
Fator de forma	$x_{11,i} = \frac{x_{4,i}}{\frac{1}{N} \sum_{i=1}^N y_i }$

Fonte: Os autores (2024).


3.2 Fluxograma proposto

Este método adapta o algoritmo Quantum Variational Rewinding (QVR) de Baker et al. (2022), originalmente criado para séries temporais, usando características estatísticas

como entrada para os estados quânticos. Isso reduz a demanda por processamento e memória. A Figura 2 mostra os principais passos: coleta de medições de aceleração por uma rede de sensores (Fig. 2(a)), divisão das respostas vibracionais em amostras e extração de 11 indicadores estatísticos de cada amostra (Fig. 2(b)). As características, normalizadas por min-max para evitar viés, garantem peso igual para todos. Este processo é feito tanto para sinais intactos quanto para os relacionados à estrutura danificada.

O próximo passo envolve a codificação das características normalizadas em estados quânticos (Fig.2(b)) para serem processadas pelo circuito quântico proposto (Fig.2(c)). O treinamento do modelo usa apenas características do cenário intacto, definindo-se uma função de perda para medir a diferença entre os estados quânticos reais e esperados. O treinamento minimiza essa função usando técnicas clássicas de otimização, resultando em uma função de pontuação de anomalia que quantifica desvios do comportamento normal. Resumidamente, a abordagem transforma a detecção de anomalias em um problema de *clustering* no espaço quântico. Após o treinamento, a função de pontuação de anomalia é usada para testar cenários desconhecidos, ajustando-se um valor de limiar ζ para melhorar a detecção de anomalias (Fig.2(d)). Metade dos dados de teste é usada para ajustar ζ , enquanto a outra metade avalia a precisão do algoritmo. A precisão é determinada com base nos verdadeiros positivos (VP) e falsos positivos (FP), sendo o índice para avaliar danos dado pela métrica revocação (ou *recall*), dada por $VP/(VP + FP)$.

Figura 2 – Visão geral das etapas da metodologia.



Fonte: Os autores (2024).

total dos dados e alto potencial de anomalia, enquanto 50% sugere separação aleatória e baixo potencial de anomalia.

Para novos dados intactos, ambos os métodos se mostraram adequados, com variações menores (~5%) em torno de 50%, como mostrado na Figura 4(a). No cenário de dano I, a abordagem quântica com 1 *qubit* identificou o dano no sensor nº2 (Fig. 4(b)), enquanto o *k-means* identificou no sensor nº3, ambos aceitáveis (a referência é nº2 e nº3). Para 1 *qubit*, os índices de precisão aumentaram do novo dado intacto para o cenário de dano I $\left(\frac{Acc_{Damage I}}{Acc_{New intact}} - 1\right)$ em +22,2%/+41,5%/-2,1%/+9,8% para cada sensor. No cenário de dano II $\left(\frac{Acc_{Damage II}}{Acc_{New intact}} - 1\right)$, os aumentos foram de +5,5%/+64,2%/-21,3%/-9,8%, respectivamente. Outras proporções são mostradas na Tabela 2.


Tabela 2 - Razão entre os resultados de precisão da estrutura.

Model	Ratio	Sensor #1	Sensor #2	Sensor #3	Sensor #4
Autores (1 qubit)	$\frac{Acc_{Damage I}}{Acc_{New intact}} - 1$	+22.2%	+41.5%	-2.1%	+9.8%
	$\frac{Acc_{Damage II}}{Acc_{New intact}} - 1$	+5.5%	+64.2%	-21.3%	-9.8%
Autores (2 qubit)	$\frac{Acc_{Damage I}}{Acc_{New intact}} - 1$	+23.4%	+23,1	+6.4%	+8.8%
	$\frac{Acc_{Damage II}}{Acc_{New intact}} - 1$	+70.2%	+78.8%	+23.4%	+14.0%
k-means (euclidean)	$\frac{Acc_{Damage I}}{Acc_{New intact}} - 1$	+34.7%	+21.2%	+45.8%	+13.8%
	$\frac{Acc_{Damage II}}{Acc_{New intact}} - 1$	+81.3% *	+93.1%	+62.2%	+63.8% *
k-means (cityblock)	$\frac{Acc_{Damage I}}{Acc_{New intact}} - 1$	+31.5%	+12.4%	+42.7%	+16.7%
	$\frac{Acc_{Damage II}}{Acc_{New intact}} - 1$	+81.7% *	+58.3%	+59.7%	+66.1% *
k-means (coseno)	$\frac{Acc_{Damage I}}{Acc_{New intact}} - 1$	+38.6%	+25.1%	+32.8%	+20.7%
	$\frac{Acc_{Damage II}}{Acc_{New intact}} - 1$	+85.9% *	+86.8%	+50.9%	+73.7% *

*Indica aumento excessivo de falsos positivos

Fonte: Os autores (2024).

Figura 4 – Resultados de precisão: (a) Novo cenário intacto, (b) Dano I e (c) Dano II.



Fonte: Os autores (2024).

No cenário de dano II, o método QML manteve a indicação de anomalia no sensor n°2 e teve melhor desempenho com 1 *qubit*, como mostrado na Figura 4(c). No entanto, a confiabilidade do *k-means* é questionável. Com o aumento da severidade do dano, a precisão do *k-means* na localização de danos diminuiu, apresentando altos índices de falsos positivos nos sensores n°1 e n°4, conforme mostrado na Figura 4(b-c). Isso indica uma sensibilidade excessiva do *k-means* às mudanças estruturais, limitando sua eficácia em estágios avançados de dano, como terremotos ou incêndios. No entanto, ele ainda é capaz de detectar a presença de danos, uma tarefa menos complexa.

Para o objetivo secundário, a severidade do dano correlacionou-se com um aumento na precisão do modelo QML. A Figura 4(b-c) mostra que a abordagem QML identificou consistentemente danos no sensor n°2 e aumentou seus índices, especialmente com 1 *qubit*, onde houve um aumento de 16% nos índices do sensor n°2 do dano I para o II, indicando boa capacidade de quantificação. Os modelos de 2 *qubits* também mostraram picos de precisão no sensor n°2, conforme observado na Figura 4(c). Assim, a estratégia quântica superou a abordagem clássica na quantificação da anomalia.

5 CONCLUSÃO

O presente trabalho visou demonstrar o potencial do QML não supervisionado para monitoramento estrutural baseado em vibrações. A metodologia proposta mostrou resultados promissores na avaliação de danos em uma estrutura laboratorial de dois

andares, sendo as principais conclusões: A normalização min-max e a extração de características estatísticas padronizaram eficientemente os dados para o algoritmo. O método superou o *k-means* na análise de novos dados intactos, com variações mínimas em torno do limiar para classificação aleatória. A abordagem quântica se destacou na localização de danos, especialmente em estágios avançados, com maior precisão e menos falsos positivos que o *k-means*. Com o avanço do hardware quântico, o QML pode superar o ML clássico e trazer avanços para SHM. Futuras pesquisas devem explorar novas arquiteturas, codificações e comparar o impacto do ruído em máquinas quânticas reais.

REFERÊNCIAS

ALVES, Victor; CURY, Alexandre. A fast and efficient feature extraction methodology for structural damage localization based on raw acceleration measurements. **Structural Control and Health Monitoring**, v. 28, n. 7, p. e2748, 2021.

BAKER, J. S.; HOROWITZ, H.; RADHA, S. K.; FERNANDES, S.; JONES, C.; NOORANI, N.; SKAVYSH, V.; LAMONTAGNE, P.; SANDERS, B. C. Quantum variational rewinding for time series anomaly detection. **arXiv preprint arXiv:2210.16438**, 2022.

CORREA-JULLIAN, C.; COFRE-MARTEL, S.; SAN MARTIN, G.; LOPEZ DROGUETT, E.; DE NOVAES PIRES LEITE, G. ; COSTA, A. Exploring Quantum Machine Learning and feature reduction techniques for wind turbine pitch fault detection. **Energies**, v. 15, n. 8, p. 2792, 2022.

FINOTTI, R.; SILVA, C; OLIVEIRA, P.; BARBOSA, F.; CURY, A.; SILVA, R. Novelty detection on a laboratory benchmark slender structure using an unsupervised deep learning algorithm. **Latin American Journal of Solids and Structures**, v. 20, p. e512, 2023.

KAYE, Phillip; LAFLAMME, Raymond; MOSCA, Michele. **An introduction to quantum computing**. OUP Oxford, 2006.

KHAN, Mansoor A.; AMAN, Muhammad N.; SIKDAR, Biplab. Beyond Bits: A Review of Quantum Embedding Techniques for Efficient Information Processing. **IEEE Access**, 2024.

RYTTER, A. **Vibrational based inspection of civil engineering structures**. 1993. Tese de doutorado – Denmark: Department of Building Technology and Structural, Aalborg University, Aalborg, 1993.

TROCHUN, Y.; WANG, Z.; ROKOVYI, O.; PENG, G.; ALIENIN, O.; LAI, G.; GORDIENKO, Y.; STIRENKO, S. Hurricane damage detection by classic and hybrid classic-quantum neural networks. In: **2021 International Conference on Space-Air-Ground Computing (SAGC)**. IEEE, 2021. p. 152-156.