

Diagnóstico de falhas em rolamentos com aprendizado de máquina quântico: estudo de caso experimental em bancada de testes

Arthur Dantas Benevides Costa^{a,b}

arthur.dbcosta@ufpe.br

Lavinia Maria Mendes Araújo^{a,b}

lavinia.mendes@ufpe.br

Caio Bezerra Souto Maior^{a,c}

caio.maior@ufpe.br

Isis Didier Lins^{a,b}

isis.lins@ufpe.br

Márcio José das Chagas Moura^{a,b}

marcio.cmoura@ufpe.br

^aCentro de Estudos e Ensaio em Risco e Modelagem Ambiental (CEERMA)

^bDepartamento de Engenharia de Produção (UFPE)

Av. da Arquitetura, s/n - Cidade Universitária, Recife - PE, 50740-550

^cCentro de Tecnologia (UFPE)

Av. Marielle Franco, s/n - Km 59 - Nova, PE, 55014-900

RESUMO

Este trabalho investiga a aplicação de técnicas de Aprendizado de Máquina Quântico (*Quantum Machine Learning* – QML) para o diagnóstico de falhas em máquinas rotativas, com foco na classificação do estado de integridade de rolamentos a partir de sinais de vibração. Para isso, foi utilizada uma bancada experimental que simula um sistema de transmissão mecânica, operando sob condições controladas que representam rolamentos saudáveis, com dano leve e com dano severo. Os dados de vibração foram coletados por acelerômetros piezoelétricos em regime de rotação constante. O conjunto de dados resultante foi utilizado no treinamento e avaliação de redes neurais quânticas, incluindo Redes Neurais Convolucionais Quânticas (QCNN), construídas com circuitos quânticos parametrizados (PQC). Os experimentos demonstraram que a QCNN alcançou acurácia de 74,17% com oito características de entrada, apresentando desempenho competitivo em comparação a outras arquiteturas quânticas avaliadas.

PALAVRAS CHAVE. Aprendizado de Máquina Quântico; Rolamentos; Sinais de Vibração.

Tópicos. SE-QPO, EST&AM – PO

ABSTRACT

This work investigates the application of Quantum Machine Learning (QML) techniques for fault diagnosis in rotating machinery, focusing on the classification of bearing integrity states using vibration signals. An experimental test bench was used to simulate a mechanical transmission system with controlled conditions representing healthy, light, and severe bearing damage. Vibration data were collected using piezoelectric accelerometers under a constant rotation speed. The resulting dataset was used to train and evaluate quantum neural networks, including Quantum Convolutional Neural Networks (QCNN), built with parameterized quantum circuits (PQC). Experiments showed that the QCNN achieved an accuracy of 74.17% with eight input features, performing competitively when compared to other quantum architectures tested.

KEYWORDS. Quantum Machine Learning; Bearings; Vibration Signals.

Paper topics. SE-QPO, EST&AM – PO

1. Introdução

Compreender como as máquinas se degradam ao longo do tempo é essencial para reduzir riscos e aumentar a eficiência em processos produtivos [Maior et al. 2019]. Quando falhas ocorrem em maquinários, podem gerar interrupções inesperadas, danos aos equipamentos e altos custos operacionais. Por isso, o monitoramento da condição desses componentes é importante para evitar prejuízos e garantir maior confiabilidade operacional.

Dentre as abordagens promissoras para monitoramento, destacam-se aquelas baseadas em sinais de vibração [Maior et al. 2023]. Esses sinais permitem identificar alterações no comportamento dinâmico dos rolamentos, especialmente em regimes de operação contínuos, e têm sido amplamente utilizados para detectar diferentes modos de falha. Neste estudo, emprega-se um conjunto de dados obtido experimentalmente com o objetivo de avaliar a aplicação de modelos quânticos na tarefa de classificação de falhas a partir da análise desses sinais.

Neste contexto, investiga-se o uso de Redes Neurais Convolucionais Quânticas (*Quantum Convolutional Neural Networks* – QCNN) [Herrmann et al. 2022], construídas a partir de circuitos quânticos parametrizados (PQC), para a tarefa de classificação dos estados dos rolamentos [Bermejo et al. 2024]. Essa arquitetura tem sido explorada como uma alternativa promissora para problemas com alta dimensionalidade, como os relacionados à análise de séries temporais complexas, oferecendo uma nova perspectiva ao campo do Aprendizado de Máquina Quântico (*Quantum Machine Learning* – QML) [Biswas, 2025]. Este estudo propõe uma abordagem experimental baseada em dados coletados em condições reais de bancada, contribuindo tanto para a avaliação prática da aplicabilidade do QML em manutenção preditiva quanto para a divulgação de uma base de dados inédita. Os resultados obtidos com a QCNN são comparados a modelos clássicos, visando explorar seus diferenciais e limitações em um cenário experimental controlado.

2. Referencial teórico

2.1. *Prognostics and Health Management* (PHM)

O PHM é uma abordagem que visa prever falhas e estimar a vida útil remanescente de componentes, com base em dados obtidos por sensores. Em sistemas rotativos, como motores e bombas, os rolamentos são frequentemente responsáveis por falhas significativas, respondendo por até 55% das ocorrências desse tipo [Maior et al. 2023]. A análise de vibração é uma das técnicas mais sensíveis e amplamente adotadas para monitoramento de integridade desses elementos, sendo capaz de detectar falhas como desgaste na pista interna ou externa e danos nas esferas. A utilização de bancadas experimentais para aquisição de sinais sob condições controladas permite avaliar o desempenho de modelos diagnósticos de forma sistemática, além de gerar conjuntos de dados valiosos para a pesquisa.

2.2. QCNN

As QCNNs são arquiteturas híbridas que adaptam o conceito de convolução para o domínio quântico. Em vez de aplicar kernels convolucionais clássicos, a QCNN utiliza blocos de circuitos quânticos (PQC) distribuídos em camadas, que atuam de forma localizada sobre subconjuntos de qubits [Herrmann et al. 2022]. Esses blocos aplicam transformações parametrizadas, seguidas por operações de pooling quântico, que reduzem a dimensionalidade do sistema. A estrutura hierárquica da QCNN permite capturar padrões espaciais nos dados, sendo particularmente útil em sinais temporais segmentados, como os de vibração.

3. Metodologia

3.1. Descrição da base de dados experimental

Os experimentos deste estudo utilizaram um conjunto de dados próprio, desenvolvido no CEERMA/UFPE, contendo sinais de vibração de rolamentos sob diferentes condições operacionais e modos de falha. O sistema é composto por um motor de indução trifásico operando a 15 Hz, conectado a mancais que abrigam rolamentos do tipo NSK 1205K C3, uma versão autoajustável com pista esférica. Esse tipo de rolamento é capaz de compensar desalinhamentos entre o eixo e a

carcaça, sendo ideal para aplicações sujeitas a vibrações, deflexões ou variações térmicas. As medições foram realizadas com acelerômetros piezoelétricos modelo 603C01, fixados magneticamente à carcaça dos mancais, com taxa de amostragem de 2048 amostras por segundo. A bancada operava em três condições de integridade dos rolamentos: (1) saudável; (2) dano leve (1mm na pista externa); e (3) dano severo (3mm na pista externa).

Os sinais de vibração foram segmentados em janelas de 512 pontos e submetidos a análise no domínio da frequência por meio da transformada de Hilbert combinada à transformada rápida de Fourier (FFT). A análise por envelope foi utilizada para destacar padrões repetitivos associados às falhas nos rolamentos, com foco nas frequências características como BPFO (*Ball Pass Frequency Outer*), BPFI (*Inner*), BSF (*Ball Spin Frequency*) e FTF (*Fundamental Train Frequency*), conforme os parâmetros geométricos dos rolamentos.

Para investigar o impacto da dimensionalidade dos dados na acurácia dos modelos quânticos, foram definidos dois subconjuntos de características: um com as 5 mais relevantes e outro com as 8 mais relevantes (com base no estudo de [Costa et al. 2024]). A base de dados foi então dividida em 80% para treinamento (5.404 exemplos) e 20% para teste (1.352 exemplos), com embaralhamento aleatório.

3.2. Arquitetura da QCNN

O modelo é composto por camadas convolucionais quânticas implementadas com PQCs, que operam sobre subconjuntos de qubits com operações de emaranhamento (portas CZ) e rotações parametrizadas ($R_y(\theta)$).

A topologia específica adotada foi:

- Codificação: os 32 atributos extraídos são mapeados em rotações R_y sobre 8 qubits, com múltiplos atributos por qubit.
- Camadas convolucionais quânticas: cada camada atua localmente em pares de qubits, com blocos compostos por camadas de emaranhamento e rotações parametrizadas [Bermejo et al. 2024].
- Pooling quântico: a cada etapa, parte dos qubits é descartada para redução dimensional [Herrmann et al. 2022].

A função de perda utilizada foi a *categorical crossentropy*, e o modelo foi treinado por 50 épocas com otimizador ADAM e taxa de aprendizado inicial de 0.001. A simulação foi executada utilizando *backend* clássico (Pennylane).

4. Resultados

Com oito características de entrada, a QCNN alcançou acurácia de 74,17%, enquanto com cinco características obteve 73,02%, demonstrando boa estabilidade e desempenho consistente mesmo com menos atributos. Esse comportamento reforça a robustez da arquitetura frente à variação na dimensionalidade da entrada, além de apresentar desempenho competitivo considerando a natureza experimental da base de dados utilizada.


Para fins de comparação, foram testadas outras combinações de codificação e arquiteturas de PQC, com base no trabalho de [Costa et al. 2024]. Esses modelos permitiram contextualizar os resultados da QCNN frente a outras abordagens típicas da literatura. Entre esses métodos, o ZFeaturemap com iSWAP obteve a maior acurácia geral, atingindo 80,23% com oito características e 78,90% com cinco. O YFeaturemap também apresentou desempenho elevado, com 79,45% (oito) e 78,05% (cinco). O Angle Encoding, apesar de não superar os métodos baseados em operadores de Pauli, também demonstrou ganho relevante com o aumento de características: de 74,88% para 78,36% na configuração "Ry, Rz, Ry + CZ".

O Amplitude Encoding obteve os menores valores médios entre os métodos testados, com acurácia variando de 70,09% a 72,86%, embora também tenha sido beneficiado pelo aumento no número de características. Já o ZZFeaturemap, mesmo sem apresentar os melhores desempenhos absolutos, teve resultados promissores com 76,61% usando "Real Amplitudes" e 74,17% com a

configuração QCNN, mas apresentou custo computacional elevado, o que pode limitar sua aplicação prática.

O gráfico de calor (*heatmap*) apresentado na Figuras 1 ilustra a comparação entre os métodos testados com cinco e oito características, evidenciando a melhoria geral de desempenho ao se utilizar um maior número de atributos na entrada.

Figura 1: *Heatmap* de acurácia dos modelos utilizando oito e cinco características



5. Conclusão

Os resultados obtidos neste estudo demonstram que o aumento no número de características de entrada, de cinco para oito, contribui de forma consistente para a melhoria da acurácia dos modelos de QML independentemente do método de codificação ou da arquitetura de PQC empregada. Entre os métodos avaliados, o ZFeaturemap destacou-se como o mais eficaz, alcançando a maior acurácia geral (80,23%) com a configuração iSWAP, seguido de perto pelo YFeaturemap e pelo Angle Encoding. O desempenho competitivo do ZZFeaturemap também foi observado, embora seu alto custo computacional possa limitar sua aplicação em contextos mais amplos. A análise também evidencia a importância de uma escolha cuidadosa da codificação e do número de características, uma vez que esses fatores impactam significativamente a eficácia dos modelos quânticos.

6. Agradecimentos

Os autores agradecem às seguintes agências brasileiras de fomento à pesquisa pelo apoio financeiro: à CAPES (001), ao CNPq (409701/2022-0, 308924/2021-5, 310892/2022-8, 402761/2023-5), à FAPESP e ao Programa de Recursos Humanos 38 da ANP (24/10387-4).

Referências

- Bermejo, Pablo. et al. Quantum convolutional neural networks are (effectively) classically simulable. *arXiv preprint arXiv:2408.12739*, 2024.
- Biswas, H. (2025). Data Encoding for VQC in Qiskit, A Comparison With Novel Hybrid Encoding. [local desconhecido].
- Costa, A. D. B., Araújo, L. M. M., Maior, C. B. S., Lins, I. D. e Moura, M. J. das C. (2024). Análise de métodos de codificação em redes neurais quânticas para diagnóstico de falha em rolamentos. [local desconhecido].
- Herrmann, J., Lima, S. M., Remm, A., Zapletal, P., McMahon, N. A., Scarato, C., Swiadek, F., Andersen, C. K., Hellings, C., Krinner, S. et al. (2022). Realizing quantum convolutional neural networks on a superconducting quantum processor to recognize quantum phases. *Nature Communications*, 13(1). <https://doi.org/10.1038/s41467-022-31679-5>.
- Maior, C. B. S., Araújo, L. M. M., Lins, I. D., Moura, M. das C. e Droguett Lopez, E. L. (2023). Prognostics and Health Management of Rotating Machinery via Quantum Machine Learning. *IEEE Access*, 11:25132–25151. <https://doi.org/10.1109/ACCESS.2023.3255417>.
- Maior, C. B. S., Moura, M. das C. e Lins, I. D. (2019). Particle swarm-optimized support vector machines and pre-processing techniques for remaining useful life estimation of bearings. *Eksplotacja i Niezawodność – Maintenance and Reliability*, 21(4):610–619. <https://doi.org/10.17531/ein.2019.4.10>.