

Análise de métodos de codificação em redes neurais quânticas para diagnóstico de falha em rolamentos

Arthur Dantas Benevides Costa^{a,b}

arthur.dbcosta@ufpe.br

Lavínia 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

Em diversos sistemas produtivos, o monitoramento da degradação dos equipamentos é importante, onde a identificação do estado de saúde do maquinário fornece informação útil à tomada de decisão. Dentre os vários componentes das máquinas, os elementos rolantes são como peças-chave para o bom funcionamento do sistema, requerendo correta política de manutenção. Nesse sentido, para uma precisa identificação do estado de saúde desses componentes, métodos de aprendizagem de máquina são utilizados. Especificamente, modelos de computação quântica podem ser aplicados através do aprendizado de máquina quântico (QML). Diante disso, esse trabalho busca investigar como diferentes métodos de codificação quântica, em modelos de QML, performam no diagnóstico de falha em elementos rolantes. Serão analisados métodos como codificação por ângulo, por amplitude, ZZFeaturemap e Pauli Z, X e Y *feature maps*. Para validação, serão utilizadas duas bases de dados de rolamento.

PALAVRAS-CHAVE. Computação quântica, sinais de vibração e codificação quântica.

Tópicos. SE-QPO, BDA e POI

ABSTRACT

In various production systems, monitoring the degradation of equipment is crucial, as identifying the health status of machinery provides useful information for decision-making. Among the various components of machines, rolling elements are key parts for the proper functioning of the system, requiring an appropriate maintenance policy. In this regard, machine learning methods are used for an accurate identification of the health status of these components. Specifically, quantum computing models can be applied through quantum machine learning (QML). Therefore, this work aims to investigate how different quantum encoding methods in QML models perform in diagnosing faults in rolling elements. Methods such as angle encoding, amplitude encoding, ZZFeaturemap, and Pauli Z, X, and Y *feature maps* will be analyzed. For validation, two bearing datasets will be used.

KEYWORDS. Quantum computing, vibration signals and quantum encoding.

Paper topics. SE-QPO, BDA and POI

1. Introdução

Com os constantes esforços em minimizar os riscos em sistemas produtivos, entender o comportamento de degradação de maquinários tornou-se um fator chave na engenharia de produção [Barraza et al. 2022]. Nesse contexto, as máquinas rotativas representam um dos principais focos de estudo sendo componentes fundamentais em diversas indústrias, desempenhando papéis cruciais na geração de energia, manufatura, transporte e diversas outras aplicações [Loparo et al. 2000].

Sob a perspectiva da pesquisa operacional, entender o comportamento das máquinas e fornecer informações sobre o estado de saúde dos componentes permite um apoio às decisões de manutenção, trazendo uma maior eficiência para o meio industrial. Nesse sentido, a abordagem de *Prognostic and Health Management* (PHM) é utilizada na comunidade científica e industrial para monitorar e estimar as condições de saúde dos ativos, utilizando, por exemplo, sinais de vibração [Maior et al. 2023]. Através do PHM, é possível planejar manutenções de maneira mais eficazes, evitando paradas não planejadas e reduzindo custos operacionais através contínuo monitoramento das condições operacionais dos ativos. Para a análise e diagnóstico de falhas, modelos de Aprendizado de Máquina (ML) e Aprendizado Profundo (DL) são largamente difundidos. Por outro lado, com os avanços tecnológicos, a Computação Quântica (QC) vem ganhando destaque entre pesquisadores e crescendo rapidamente no cenário mundial [Huang et al. 2020]. Assim, QC representa uma alternativa promissora para aprimorar os algoritmos de ML, melhorar a eficiência computacional e, consequentemente, a capacidade de previsão e diagnóstico em PHM, apesar das limitações atuais de hardware.

O foco desse trabalho é aplicar modelos de Aprendizado de Máquina Quântica (QML) para diagnóstico de modos de falha em rolamentos e comparar diferentes métodos de codificação quântica. Este estudo, uma extensão do trabalho anterior dos autores [Maior et al. 2023], visa explorar métodos de codificação alternativos para identificar o mais eficaz e viável na análise de vibração de rolamentos – utilizando as bases de dados da *Case Western Reserve University* (CWRU) e *Jiangnan University* (JNU). Nesse sentido, ao identificar os métodos mais eficientes, podemos melhorar a precisão do diagnóstico de falhas e otimizar os processos de manutenção, contribuindo para a eficiência e redução de custos.

2. Métodos de Codificação

A fim de utilizar o potencial da computação quântica, é necessária a codificação dos dados clássicos de modo que os circuitos presentes no modelo possam processar tais informações. Neste trabalho, são empregados seis métodos de codificação: *Angle Encoding*, *Amplitude Encoding*, *ZZFeaturemap* e *Pauli Feature Map* (*ZZFeaturemap*, *XFeaturemap* e *YFeaturemap*), cada um deles utilizado de forma independente no procedimento de QML [Date e Rath 2023]. No *Angle Encoding*, os dados são representados por meio de ângulos em um circuito quântico - cada componente do vetor é mapeado para um qubit (bit quântico – unidade básica da computação quântica), preservando a informação. No procedimento de *Amplitude Encoding*, a relação entre o número de qubits e o tamanho do espaço de estados está relacionada ao conceito de entropia da informação [Cuéllar et al. 2023]. A entropia de Shannon, uma medida da quantidade de informação contida em um sistema, é definida em termos do logaritmo na base 2 do número de estados possíveis. Para um sistema com N estados possíveis, o número de qubits é calculado como $\log_2(N)$. Ademais, no *ZZFeaturemap* cada qubit é inicialmente preparado no estado $|0\rangle$ e em seguida uma porta de rotação Z é aplicada. Após a rotação inicial, portas de interação ZZ ($ZZ(\gamma) = e^{-i\gamma Z_i Z_j / 2}$, γ é um parâmetro de controle que determina a intensidade da interação entre os qubits) são aplicadas entre pares de qubits. Além disso, a *Pauli Feature Map* é uma técnica de codificação na computação quântica que pode envolver a aplicação dos operadores Z , X ou Y nos qubits [Guo et al. 2022].

3. Metodologia

Este estudo considera dois bancos de dados público relacionados a rolamentos: o da Case Western Reserve University (CWRU) e os da Jawaharlal Nehru University (JNU) [Araújo 2023]. O primeiro conjunto de dados é composto por medições de vibração obtidas de rolamentos que apresentam diferentes modos de falhas - como desgaste no anel externo, interno e no elemento rolante - de diversos tamanhos: 7, 14 e 21 mils. Na segunda base, os dados de vibração coletados capturam as oscilações mecânicas em diferentes velocidades de rotação a qual os rolamentos são submetidos (600, 800 e 1000 RPM), com distintos modos de falhas associadas.

A partir desses dados de entrada, foram extraídas características (média, variância, raiz quadrada média, curtose, assimetria, pico a pico, índice de pico, pico, desvio padrão, potência, amplitude máxima, amplitude mínima, fator de forma e fator de crista) do sinal analisado para uso refinado posteriormente [Maior et al. 2023]. Ao longo deste estudo, foram realizados testes utilizando dados de entrada com 5, 8, 10 e 14 dessas características, com o objetivo de avaliar possíveis mudanças na qualidade das medições realizadas durante o QML combinado com os procedimentos de codificação mencionados anteriormente.

Como mencionado anteriormente, a etapa de codificação, que é o foco deste estudo, começa com a preparação de um conjunto de dados quânticos. Esses dados originam-se do processamento clássico de sinais de vibração (CWRU e JNU), envolvendo a extração de características desses sinais e organização desses dados em um formato adequado para o processamento quântico. Então, com o conjunto de dados preparado, o modelo é treinado para aprender padrões e características relevantes. Vale salientar que a avaliação do modelo quântico geralmente envolve o uso de um Circuito Quântico Parametrizado (PQC), componente chave na representação e manipulação de dados e informações quânticas. Sob essa perspectiva, neste trabalho, foram utilizadas quatro configurações de PQC junto com métodos de codificação: Redes Neurais Quânticas (com circuitos do tipo (i) "Ry, Rz, Ry + CZ", (ii) "Ry, Rz, Ry + iSWAP", (iii) *Real Amplitudes* e (iv) *Quantum Convolutional Neural Networks* (QCNN). Após o treinamento, o sistema passa à fase de amostragem, onde são extraídas informações ou resultados dos estados quânticos gerados. Em seguida, realiza-se a avaliação do modelo clássico, essencial para comparar a eficácia entre os métodos clássicos e quânticos.

4. Resultados

Utilizando a base de dados da CWRU, o uso da *Angle Encoding* em modelos QML que utilizam oito características apresentou a melhor acurácia em comparação aos modelos que utilizavam 14 características, atingindo valor de 93,81%. Além disso, o PQC das portas de rotação Ry, Rz e a porta CZ foram os mais eficazes nesta base. No caso do *Amplitude Encoding*, os modelos QML com dez características, combinados com o procedimento de *zero padding* (redimensionamento do número de características para 16), apresentaram a melhor precisão (92,71%), sendo ligeiramente inferiores aos alcançados pelo *Angle Encoding*. A configuração do PQC com iSWAP foi a mais eficiente neste método de codificação. Ademais, o método de codificação ZZFeaturemap apresentou melhores resultados utilizando as configurações de PQC com Real Amplitudes e QCNN, quando comparado aos modelos utilizando CZ e iSWAP.

Para a configuração de *Real Amplitudes*, o ZZFeaturemap obteve como performance 88,63% para a acurácia com cinco características. Já utilizando a QCNN o modelo performou melhor, alcançando uma acurácia de 93,24% e utilizando igualmente cinco características. Em contrapartida, apesar das performances interessantes – especialmente com a QCNN – o ZZFeaturemap pode se tornar inviável frente aos demais métodos de codificação já que seu custo computacional é bastante elevado. Para os métodos *Pauli Feature Map*, os modelos QML com oito características apresentaram as melhores precisões com codificação XFeaturemap e YFeaturemap, atingindo 91,74% e 89,44% (ambos utilizando o PQC iSWAP). Já o ZFeaturemap performou melhor com cinco características e o mesmo PQC, obtendo 95,74% de acurácia. Uma comparação direta entre esses três métodos de codificação mostra a qualidade do ZFeaturemap em lidar com os

dados da CWRU e um desempenho muito próximo entre os modelos que utilizam as portas Pauli X e Y. Esses resultados foram superiores em comparação ao *Angle Encoding*, independentemente da quantidade de características utilizadas. Este método de codificação foi particularmente eficaz para representações de dados mais compactas.

A base de dados JNU apresentou mudanças de desempenho e agregação dos modelos aos dados. Em geral a performance das codificações foi menor em comparação aos resultados utilizando a CWRU, o que é um resultado esperado visto que a JNU apresenta uma complexidade maior. Porém diferentemente da base anterior, nessa só foi realizada a extração de oito características devido à complexidade da base. O *Angle Encoding* continuou apresentando uma eficiência maior em comparação ao *Amplitude Encoding* – ambos utilizando CZ como PQC e com as respectivas acurácias: 70,21% e 65,26%. Ainda que mais custosos que os dois primeiros métodos de codificação, os métodos de *Pauli Feature Map* apresentaram um desempenho superior utilizando o iSWAP com as seguintes acurácias: 70,89% (ZFeaturemap), 70,91% (XFeaturemap) e 72,01% (YFeaturemap). Por fim, o ZZFeaturemap obteve a melhor performance dentre todos os métodos de codificação (74,06% com o *Real Amplitudes*), mas o modelo demorou consideravelmente mais que todos os outros juntos, sendo assim bastante custoso computacionalmente (levando em torno de 9h para rodar completamente).

5. Conclusão

Ao testar as abordagens *Angle Encoding*, *Amplitude Encoding*, ZZFeaturemap e Pauli Feature Map, buscou-se entender como tais estruturas influenciam o desempenho de modelos quânticos nas bases de dados de vibração de rolamentos. Pode-se observar que, embora atualmente existam limitações quanto ao uso dos métodos quânticos, os resultados obtidos com os métodos de codificação quântica obtiveram resultados satisfatórios. Em ambas as bases, as codificações da Pauli Feature Map foram particularmente eficazes para representações de dados, enquanto *Angle Encoding* e *Amplitude Encoding* demonstraram um desempenho comparável, mas ligeiramente abaixo. Ainda, o método ZZFeaturemap não apresentou melhoras significativas em comparação aos demais métodos e tornou-se muito custoso computacionalmente, sendo, possivelmente, inviável frente aos demais métodos. Sobre esses resultados, é importante destacar que foram utilizados simuladores quânticos e seu uso pode influenciar os resultados, pois o comportamento quântico real pode ser diferente. Finalmente, pode-se mencionar o estímulo à aplicação dos métodos e modelos apresentados em outros contextos, que não o de análise de vibração, para verificação das performances associadas.

6. Agradecimentos

Os autores agradecem às seguintes agências brasileiras de fomento à pesquisa pelo apoio financeiro: Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), 308924/2021-5, 310892/2022-8, 409701/2022-0, 402761/2023-5; Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Código Financeiro 001. Agradecemos também ao Programa de Recursos Humanos 38.1 (PRH 38.1) intitulado Análise de Risco e Modelagem Ambiental na Exploração, Desenvolvimento e Produção de Petróleo e Gás, financiado pela Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (ANP) e administrada pela Financiadora de Estudos e Projetos (FINEP), 044819.

Referências

Araújo, L. M. M. (2023). Prognostics and health management via quantum machine learning in the oil & gas industry. Dissertação de Mestrado, Universidade Federal de Pernambuco, Recife.
Barraza, J. F., Brauning, L. G., Perez, R. B., Morais, C. B. e Martins, M. R. (2022). Deep learning health state prognostics of physical assets in the Oil and Gas industry. *Journal of Risk and Reliability*, 598–616.

- Huang, H., Wu, D., Fan, D. e Zhu, X. (2020). Superconducting quantum computing: a review. *Science China – information sciences*.
- Loparo, K., Adams, M. L., Lin, W. e Abdel, M. F. (2000). Fault detection and diagnosis of rotating machinery. *IEEE*, 1005-1014.
- Maior, C. B. S., Araújo, L. M. M., Lins, I. D., Moura, M. J. das C. e Droguett, E. L. (2023). Prognostics and Health Management of Rotating Machinery via Quantum Machine Learning. *IEEE*, 25132 – 25151.
- Date, H. e Rath, M. (2023). Quantum Data Encoding: A Comparative Analysis of Classical-to-Quantum Mapping Techniques and Their Impact on Machine Learning Accuracy. *arXiv.org*.
- Guo, M-C., Liu, H-L., Li, Y-M., Qin, S-J., Wen, Q-Y., e Gao F. (2022). Quantum Algorithms for Anomaly Detection using Amplitude Estimation. *Physica A: Statistical Mechanics and its Applications*. *arXiv.org*.
- Cuéllar, M. P., Cano, C., Ruiz, L. G. B. e Servadei, L. (2023). Time series quantum classifiers with amplitude embedding. *Quantum Machine Intelligence*.