

Aprendizagem de Máquina Quântica Aplicada à Confiabilidade Humana: Codificações de Sinais de EEG para Detecção de Sonolência

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

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

^b Departamento de Engenharia de Produção (UFPE)

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

^c Centro de Tecnologia (UFPE)

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

RESUMO

O estado de alerta de operadores é uma informação essencial para a prevenção de falhas humanas em sistemas críticos. Sinais de eletroencefalograma (EEG) têm sido amplamente utilizados para identificar padrões cerebrais associados à sonolência, viabilizando o desenvolvimento de sistemas preditivos. Neste trabalho, investiga-se a aplicação de algoritmos de Aprendizado de Máquina Quântico (*Quantum Machine Learning* - QML) na classificação de sinais de EEG, com foco na exploração de diferentes técnicas de codificação de dados clássicos em circuitos quânticos. A abordagem combina redes neurais quânticas com estratégias de codificação — *Angle Encoding*, *Amplitude Encoding* e *Pauli Feature Maps* — com o objetivo de analisar o potencial dessas estratégias para aprimorar as métricas do diagnóstico de sonolência. Os resultados indicam que codificações com maior capacidade de representação, como as *Pauli Feature Maps*, alcançam melhor desempenho classificatório, enquanto métodos mais simples, como *Angle Encoding*, se destacam pela eficiência computacional.

PALAVRAS-CHAVE. Computação Quântica, Sinais EEG, Codificação Quântica.

Tópicos. SE-QPO, EST&AM – PO

ABSTRACT

The alertness state of operators is essential information for preventing human errors in critical systems. Electroencephalogram (EEG) signals have been widely used to identify brain patterns associated with drowsiness, enabling the development of predictive systems. This study investigates the application of Quantum Machine Learning (QML) algorithms in the classification of EEG signals, focusing on the exploration of different techniques for encoding classical data into quantum circuits. The approach combines quantum neural networks with encoding strategies — *Angle Encoding*, *Amplitude Encoding*, and *Pauli Feature Maps* — with the aim of analyzing the potential of these strategies to enhance drowsiness diagnosis metrics. The results indicate that encoding methods with greater representational capacity, such as *Pauli Feature Maps*, achieve better classification performance, while simpler methods like *Angle Encoding* stand out for their computational efficiency.

KEYWORDS. Quantum Computing, EEG Signals, Quantum Encoding.

Paper topics. SE-QPO, EST&AM – PO

1. Introdução

O fator humano representa um elemento crítico na confiabilidade de sistemas produtivos, especialmente em ambientes industriais com alto grau de complexidade operacional. A presença de operadores em estados de sonolência ou fadiga pode comprometer decisões em tempo real, reduzir o desempenho e aumentar a probabilidade de acidentes [Aksoy et al. 2024].

Técnicas de Aprendizado de Máquina (*Machine Learning* - ML) e Aprendizado Profundo (*Deep Learning* - DL) têm sido aplicadas em estudos recentes [Badrouchi et al. 2021]. No entanto, devido à alta dimensionalidade e complexidade desses sinais, o uso de ML e DL para classificação enfrenta desafios quanto à eficiência computacional e capacidade de generalização.

Nesse sentido, a Computação Quântica (QC) surge como um campo a ser explorado para verificar se propriedades da mecânica quântica, como superposição e emaranhamento, conseguem conferir melhorias na detecção de sonolência. A partir da combinação entre algoritmos de aprendizado e circuitos quânticos, o Aprendizado de Máquina Quântico (*Quantum Machine Learning* – QML) tem se consolidado como um novo paradigma para a análise de dados complexos. O estudo de [Lins et al. 2024] propôs o uso de QML na classificação de estados de sonolência com sinais de EEG, utilizando como técnica de codificação exclusivamente o *Angle Encoding*. A pesquisa demonstrou o potencial da computação quântica aplicada ao monitoramento cognitivo, servindo como base para novas investigações no tema.

Este trabalho dá continuidade e avança em relação ao estudo de [Lins et al. 2024] ao comparar diferentes métodos de codificação quântica aplicados ao problema de detecção de sonolência com sinais EEG. São analisadas seis estratégias distintas de codificação: *Angle Encoding*, *Amplitude Encoding*, *Pauli Feature Maps* (*XFeaturemap*, *YFeaturemap*, *ZFeaturemap* e *ZZFeaturemap*).

2. Métodos de codificação quântica

O *Angle Encoding* é uma técnica amplamente utilizada por sua simplicidade e eficiência. Nela, os valores das features extraídas dos sinais EEG são mapeados diretamente como ângulos de rotação em portas quânticas aplicadas a qubits, como R_x ou R_y . Cada componente do vetor de entrada é associado a um qubit, permitindo a preservação da estrutura original dos dados na forma de rotações sobre o estado quântico [Weigold et al. 2021].

O *Amplitude Encoding*, por sua vez, explora a capacidade dos estados quânticos de representar vetores em espaços de alta dimensão. Nesse método, os dados são normalizados e embutidos diretamente nas amplitudes dos estados dos qubits, permitindo uma representação compacta e eficiente. Entretanto, a preparação de estados com amplitudes arbitrárias demanda operações complexas, o que pode aumentar significativamente o custo computacional do modelo [Weigold et al. 2021].

As *Pauli Feature Maps*, que incluem *XFeaturemap*, *YFeaturemap* e *ZFeaturemap*, utilizam operadores da base de Pauli para incorporar não linearidades no processo de codificação. Esses mapas são compostos por blocos de Hadamard, rotações controladas e operações de emaranhamento, com repetições parametrizadas. Sua estrutura é adequada para capturar interações complexas entre variáveis, sendo particularmente útil em cenários com correlações entre os sinais EEG [Bischof et al. 2025].

Por fim, o *ZZFeaturemap* representa uma evolução de segunda ordem baseada na aplicação controlada do operador Pauli-Z. Ele é caracterizado por uma combinação de portas Hadamard, rotações parametrizadas e operações ZZ de emaranhamento entre pares de qubits. Embora esse método se destaque em termos de expressividade, ele também impõe um custo computacional significativamente maior, tornando-se mais indicado em contextos em que a acurácia é mais crítica do que a eficiência de processamento [Bischof et al. 2025].

3. Metodologia

Para a avaliação das codificações quânticas na classificação de sonolência com sinais EEG, este estudo utilizou dados do banco público, DROZY [Massoz et al. 2016]. O banco contempla

diferentes sujeitos em situações reais de indução de fadiga, com anotações que indicam os estados de alerta ou sonolência dos participantes ao longo do tempo [Lins et al. 2024].

A partir dos sinais brutos de EEG, foram extraídas características estatísticas comumente utilizadas em problemas de classificação e análise de sinais temporais. Dentre essas, destacam-se: média, desvio padrão, curtose, assimetria, energia, amplitude pico-a-pico, entre outras. A extração dessas features tem como objetivo a redução da dimensionalidade dos dados, sem perda relevante de informação, viabilizando o processamento em circuitos quânticos limitados pelo número de qubits.

Cada vetor de entrada foi codificado pelas seis estratégias listadas e processado em arquiteturas quânticas compostas por circuitos parametrizados (PQC), implementados através da linguagem de programação quântica TensorFlow Quantum e do simulador da Google, Cirq. Para uma descrição mais aprofundada tem-se [Maior et al. 2023] e [Lins et al. 2024].

Foram testadas quatro arquiteturas de QNNs:

- Ry/Rz + CZ: rotações de Euler do tipo Ry, Rz, Ry com entrelaçamento CZ (aplica uma operação de fase Z se ambos os qubits estiverem no estado $|1\rangle$);
- Ry/Rz + iSWAP: rotações de Euler do tipo Ry, Rz, Ry com entrelaçamento iSwap (troca os estados $|01\rangle$ e $|10\rangle$, adiciona um fator de fase imaginária i);
- Real Amplitudes: circuito parametrizado composto por camadas de rotações do tipo Ry aplicadas individualmente em cada qubit, seguidas por portas de entrelaçamento CNOT entre qubits adjacentes;
- QCNN: arquitetura convolucional com pooling e entrelaçamento.


Os circuitos foram amostrados com medições no operador Pauli-Z, resultando em saídas clássicas usadas como entrada para uma rede densa com 3 camadas (100 neurônios, função de ativação ReLU, e saída binária com ativação sigmoid). O treinamento usou *binary crossentropy*, otimizador Adam (LR=0.01), *batch size* 256 e *early stopping* com paciência de 30 épocas.

4. Resultados

As avaliações foram conduzidas individualmente para cinco sujeitos do banco de dados DROZY, além de um último cenário gerado pela concatenação dos registros dos cinco sujeitos. Além disso, outro fator levado em consideração foi o uso de simuladores quânticos para executar os modelos, simplificando assim fatores como presença de ruído no sinal.

Em relação ao desempenho das codificações (Figura 1), observou-se que os métodos baseados em Feature Maps com operadores de Pauli (*XFeaturemap*, *YFeaturemap* e *ZFeaturemap*) apresentaram desempenho consistente e estável entre os diferentes sujeitos. O *Angle Encoding*, embora mais simples, também demonstrou resultados competitivos, destacando-se pela menor complexidade computacional.

Figura 1: *Heatmap* de acurácia dos modelos de QNN



No entanto, foi possível notar uma variação significativa de desempenho entre os sujeitos, com destaque para o Sujeito 1, cujos modelos apresentaram as maiores taxas de acurácia em praticamente todas as configurações testadas. Esse comportamento pode ser explicado pela

variabilidade interindividual natural nos sinais de EEG, relacionados à transição entre estados de vigília e sonolência são mais marcantes e definidos, facilitando o processo de aprendizado dos modelos.

Por outro lado, o *Amplitude Encoding*, mesmo apresentando baixo custo computacional, revelou-se limitada em termos de desempenho, possivelmente devido à perda de representatividade na etapa de preparação do estado quântico. Essa codificação foi a única a não superar, em nenhum cenário, os demais métodos testados. Já a codificação *ZZFeaturemap* implicou em longas execuções, especialmente quando combinada com arquiteturas mais complexas, como QCNN e *Real Amplitudes*. No entanto, sua performance em termos de acurácia foi superior em grande parte dos testes, indicando um *trade-off* entre precisão e viabilidade computacional.

5. Conclusão

Os resultados demonstraram que a escolha da codificação tem impacto direto no desempenho dos modelos, tanto em termos de acurácia quanto de custo computacional. Enquanto métodos como *ZZFeaturemap* se destacaram pela expressividade, apresentando alto desempenho classificatório, outras abordagens mais simples, como *Angle Encoding*, mostraram-se mais vantajosas quando se considera a relação entre eficiência e tempo de execução. Por outro lado, o *Amplitude Encoding* revelou limitações no contexto analisado.

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

- Aksoy, G., Cattán, G., Chakraborty, S. e Karabatak, M. (2024). Quantum machine-based decision support system for the detection of schizophrenia from EEG records. *Journal of Medical Systems*, 48(1). <https://doi.org/10.1007/s10916-024-02048-0>.
- Badrouchi, S., Ahmed, A., Mongi Bacha, M., Abderrahim, E. e Ben Abdallah, T. (2021). A machine learning framework for predicting long-term graft survival after kidney transplantation. *Expert Systems with Applications*, 182. <https://doi.org/10.1016/j.eswa.2021.115235>.
- Bischof, L., Teodoropol, S., Fuchslin, R. M. e Stockinger, K. (2025). Hybrid quantum neural networks show strongly reduced need for free parameters in entity matching. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-025-88177-z>.
- Lins, I. D., Araújo, L. M. M., Maior, C. B. S., Ramos, P. M. da S., Moura, M. J. das C., Ferreira-Martins, A. J., Chaves, R. e Canabarro, A. (2024). Quantum machine learning for drowsiness detection with EEG signals. *Process Safety and Environmental Protection*, 186:1197–1213. <https://doi.org/10.1016/j.psep.2024.04.032>.
- Maior, C. B. S., Moura, M. J. das C., Santana, J. M. M. e Lins, I. D. (2020). Real-time classification for autonomous drowsiness detection using eye aspect ratios. *Expert Systems with Applications*, 158. <https://doi.org/10.1016/j.eswa.2020.113505>.
- Massoz, Q., Langohr, T., François, C. e Verly, J. G. (2016). The ULg Multimodality Drowsiness Database (called DROZY) and Examples of Use. <http://www.drozy.ulg.ac.be>. Acessado: [inserir data de acesso].
- Weigold, M., Barzen, J., Leymann, F. e Salm, M. (2021). Encoding patterns for quantum algorithms. *IET Quantum Communication*, 2(4):141–152. <https://doi.org/10.1049/qtc2.12032>.