

# Aprendizagem de Máquina Quântica: Fundamentos, Potencial e Desafios para a Formação Científica

## Quantum Machine Learning: Fundamentals, Potential and Challenges for Scientific Training

Benedita Aparecida Moraes <sup>1\*</sup>

<sup>1</sup>Universidade Federal do Pará, Brasil

### RESUMO

A aprendizagem de máquina quântica (AMQ) representa uma das mais promissoras interseções entre a ciência da computação, a física quântica e a análise de dados, potencializando avanços significativos em diversas áreas científicas e tecnológicas. Este artigo explora os fundamentos teóricos e práticos da AMQ, explicando como algoritmos quânticos podem superar limitações dos métodos clássicos, principalmente em problemas envolvendo grandes volumes de dados e padrões complexos. A partir da análise detalhada das principais técnicas, desafios atuais e perspectivas futuras, este trabalho visa orientar estudantes sobre a relevância do tema para o desenvolvimento da pesquisa científica contemporânea e suas aplicações práticas na academia e indústria. A abordagem adotada enfatiza a necessidade de compreensão crítica sobre hardware, algoritmos e as condições em que a vantagem quântica realmente se manifesta, formando uma base sólida para a formação de futuros pesquisadores em ciência de dados e computação quântica.

**Palavras chave:** Aprendizagem de Máquina Quântica, Computação Quântica, Algoritmos Quânticos, Ciência de Dados, Formação Científica

**Recebido:** 21 de fevereiro de 2025

**Aceito:** 11 de abril de 2025

---

\* benedictaaparecidmoraess@yahoo.com

## ABSTRACT

Quantum machine learning (QML) represents one of the most promising intersections between computer science, quantum physics, and data analysis, enabling significant advances in several scientific and technological areas. This article explores the theoretical and practical foundations of QML, explaining how quantum algorithms can overcome limitations of classical methods, especially in problems involving large volumes of data and complex patterns. Based on a detailed analysis of the main techniques, current challenges, and future perspectives, this work aims to guide students on the relevance of the topic for the development of contemporary scientific research and its practical applications in academia and industry. The approach adopted emphasizes the need for critical understanding of hardware, algorithms, and the conditions under which the quantum advantage actually manifests itself, forming a solid foundation for the training of future researchers in data science and quantum computing.

**Keywords:** Quantum Machine Learning, Quantum Computing, Quantum Algorithms, Data Science, Scientific Education

### 1. Introdução

A busca por padrões em conjuntos de dados é um esforço humano ancestral, essencial para o desenvolvimento do conhecimento científico e tecnológico (Biamonte et al., 2018). Desde as primeiras observações astronômicas, passando pela criação de métodos matemáticos para análise de dados, até a implementação de técnicas computacionais avançadas, a identificação de regularidades em dados impulsionou progressos em diversos campos. Com o advento dos computadores digitais no século XX, técnicas de análise de dados como regressão linear, análise de componentes principais (PCA) e métodos de aprendizado supervisionado e não supervisionado tornaram-se acessíveis, transformando o modo como a ciência lida com informações complexas (LeCun, Bengio & Hinton, 2015).

Entretanto, limitações inerentes à computação clássica ainda impõem restrições ao processamento de grandes volumes de dados e à detecção de padrões em sistemas complexos. Neste contexto, a computação quântica surge como uma alternativa capaz de superar desafios fundamentais, utilizando propriedades como superposição e entrelaçamento para executar operações que seriam inviáveis ou demoraadamente lentas em computadores convencionais (Schuld, Sinayskiy & Petruccione, 2015).

A aprendizagem de máquina quântica, campo emergente que combina algoritmos quânticos com técnicas de aprendizado de máquina, promete revolucionar a análise de dados, proporcionando avanços em áreas como reconhecimento de padrões, otimização, classificação e previsão (Wittek, 2014). A relevância do tema para a formação

científica e acadêmica é crescente, visto que a compreensão desses conceitos possibilita aos estudantes desenvolver competências essenciais para atuar na fronteira da pesquisa interdisciplinar, unindo física, matemática, estatística e ciência da computação (Biamonte et al., 2018).

No entanto, a efetivação do potencial da AMQ depende não apenas do desenvolvimento teórico, mas também de avanços em hardware, algoritmos e da solução de desafios práticos como a entrada e saída de dados em sistemas quânticos, benchmarking e estimativas realistas de custo computacional (Arunachalam & de Wolf, 2017). O presente artigo pretende, portanto, fornecer uma visão aprofundada e acessível dos fundamentos, desafios e oportunidades da aprendizagem de máquina quântica, destacando sua importância para a formação científica de estudantes e pesquisadores interessados em temas de vanguarda.

## **2 Referencial Teórico**

A evolução dos métodos de análise de dados acompanha o próprio desenvolvimento da ciência moderna. Desde as primeiras tentativas de explicação de fenômenos naturais por modelos matemáticos, o desejo de compreender padrões intrincados impulsionou a criação de ferramentas como a regressão linear, análise de componentes principais e técnicas de otimização (LeCun, Bengio & Hinton, 2015). Com a consolidação da computação digital, tornou-se possível automatizar essas técnicas, viabilizando análises de dados em escalas cada vez maiores (Rosenblatt, 1958).

A aprendizagem de máquina clássica, fundamentada na análise matemática de dados, pode ser dividida em abordagens supervisionadas e não supervisionadas. No aprendizado supervisionado, algoritmos são treinados a partir de conjuntos de dados rotulados, desenvolvendo modelos capazes de classificar novos exemplos com base nos padrões extraídos do treinamento (Vapnik, 1995). Por outro lado, o aprendizado não supervisionado busca identificar categorias ou agrupamentos naturais dentro dos dados sem informações prévias de rótulos, permitindo a descoberta de estruturas subjacentes complexas (LeCun, Bengio & Hinton, 2015).

A ascensão dos algoritmos de redes neurais, inicialmente modelados a partir do perceptron (Rosenblatt, 1958), evoluiu para arquiteturas mais sofisticadas, como redes profundas e máquinas de Boltzmann, tornando possível a análise de conjuntos de dados

massivos e complexos (LeCun, Bengio & Hinton, 2015; Le, 2013). O desenvolvimento desses métodos esteve fortemente vinculado ao aumento exponencial da capacidade computacional, permitindo avanços como a aprendizagem profunda (deep learning) e o processamento de grandes volumes de dados em tempo real.

No entanto, muitos problemas relevantes, especialmente aqueles envolvendo otimização combinatória ou análise de sistemas físicos complexos, continuam além do alcance dos métodos clássicos devido ao crescimento exponencial da complexidade computacional com o aumento da dimensão do problema (Schuld, Sinayskiy & Petruccione, 2015). Por exemplo, a simulação de sistemas quânticos ou a análise de grandes conjuntos de dados requerem recursos computacionais que crescem de forma proibitiva em computadores tradicionais.

Nesse contexto, a computação quântica se apresenta como uma alternativa revolucionária, baseada em princípios fundamentais da mecânica quântica, como a superposição de estados e o entrelaçamento, permitindo a realização de operações matemáticas de maneira paralela e exponencialmente mais eficiente em determinados casos (Nielsen & Chuang, 2000). Algoritmos quânticos clássicos como o algoritmo de Shor para fatoração e o algoritmo de Grover para busca em bancos de dados já demonstraram vantagens teóricas expressivas sobre suas contrapartes clássicas (Shor, 1997; Grover, 1996).

A aprendizagem de máquina quântica emerge dessa convergência, com o objetivo de aplicar algoritmos quânticos para potencializar técnicas tradicionais de aprendizado de máquina e, assim, alcançar vantagens em tarefas como classificação, regressão, análise de padrões e otimização (Biamonte et al., 2018). Dentre os principais marcos desse campo, destaca-se o desenvolvimento de algoritmos quânticos para análise linear de dados, como o algoritmo de Harrow, Hassidim e Lloyd (HHL), que permite resolver sistemas de equações lineares de forma exponencialmente mais rápida em relação aos melhores métodos clássicos, sob certas condições (Harrow, Hassidim & Lloyd, 2009).

Além disso, técnicas como a análise de componentes principais quântica (qPCA) (Lloyd, Mohseni & Rebentrost, 2014), máquinas de vetores de suporte quânticas (Rebentrost, Mohseni & Lloyd, 2014) e métodos de otimização quântica utilizando algoritmos aproximados e annealers (Wiebe, Kapoor & Svore, 2014; Adachi &

Henderson, 2015) abrem novos horizontes para a análise de dados, tornando possível resolver problemas antes considerados intratáveis.

É importante ressaltar que, embora as promessas da aprendizagem de máquina quântica sejam impressionantes, muitos desafios permanecem. Questões como o problema da entrada e saída de dados em dispositivos quânticos (input/output problem), a necessidade de hardware robusto e escalável, e a validação prática da vantagem quântica são temas centrais de debate e pesquisa (Aaronson, 2015; Arunachalam & de Wolf, 2017). Para estudantes e pesquisadores, compreender essas limitações é tão importante quanto dominar os potenciais teóricos, já que o avanço da área depende da superação conjunta dos desafios matemáticos, computacionais e experimentais.

Portanto, o referencial teórico da aprendizagem de máquina quântica está alicerçado na interseção entre a matemática aplicada, ciência da computação, física quântica e estatística, formando uma base multidisciplinar essencial para a formação científica na área e para a atuação em projetos de pesquisa de fronteira (Biamonte et al., 2018; Schuld, Sinayskiy & Petruccione, 2015).

### **3 Metodologia**

A abordagem metodológica deste estudo consiste em uma revisão integrativa da literatura especializada, com ênfase nas principais contribuições e desafios da aprendizagem de máquina quântica. Para isso, foi realizada uma análise minuciosa dos avanços teóricos e práticos descritos por autores de referência no campo, combinando conceitos da computação clássica e quântica para elucidar o potencial e as limitações dessa área emergente (Biamonte et al., 2018; Schuld, Sinayskiy & Petruccione, 2015).

Inicialmente, foram identificados os marcos históricos do aprendizado de máquina clássico, como a evolução das técnicas de regressão, análise de componentes principais, métodos supervisionados e não supervisionados, além do surgimento das redes neurais e algoritmos de deep learning (LeCun, Bengio & Hinton, 2015; Rosenblatt, 1958). Essa contextualização permitiu estabelecer um paralelo com os avanços na computação quântica, especialmente quanto à aplicabilidade de algoritmos quânticos na resolução de problemas tradicionalmente complexos para máquinas clássicas (Nielsen & Chuang, 2000; Shor, 1997).

O levantamento bibliográfico foi realizado prioritariamente em bases como arXiv, Nature Physics, Physical Review Letters e Contemporary Physics, a partir da seleção de artigos que abordam tanto os fundamentos teóricos quanto implementações experimentais de algoritmos quânticos aplicados ao aprendizado de máquina. Foram priorizados textos de revisão, publicações seminais e estudos de caso que detalham aplicações reais, desafios de hardware, implementação de algoritmos como HHL, qPCA, SVM quântico, e protocolos de otimização baseados em annealing quântico (Harrow, Hassidim & Lloyd, 2009; Lloyd, Mohseni & Rebentrost, 2014; Rebentrost, Mohseni & Lloyd, 2014; Wiebe, Kapoor & Svore, 2014; Adachi & Henderson, 2015).

A análise dos dados seguiu uma abordagem qualitativa, sintetizando informações sobre os ganhos de eficiência computacional prometidos por algoritmos quânticos em tarefas de machine learning e evidenciando os principais obstáculos identificados pela literatura, tais como o input/output problem, requisitos de qRAM, escalabilidade dos sistemas, e benchmarking frente a algoritmos heurísticos clássicos (Aaronson, 2015; Arunachalam & de Wolf, 2017).

Além disso, foram avaliadas perspectivas de aplicações práticas, como a utilização de quantum annealers para treinamento de redes neurais profundas (Adachi & Henderson, 2015), a simulação de sistemas físicos por quantum simulators (Lloyd, 1996), e o papel da aprendizagem de máquina clássica na otimização do próprio hardware quântico (Wan et al., 2016). Essa análise comparativa permitiu não apenas mapear o estado da arte, mas também identificar lacunas e direções futuras de pesquisa.

Por fim, o estudo busca contextualizar os avanços recentes da aprendizagem de máquina quântica no escopo da formação científica e acadêmica, destacando a importância da compreensão multidisciplinar para a inserção do estudante neste novo paradigma tecnológico (Biamonte et al., 2018). A metodologia adotada enfatiza a robustez das fontes consultadas, a sistematização das evidências apresentadas e a busca por uma síntese crítica, favorecendo o entendimento aprofundado por parte de estudantes e pesquisadores.

#### **4 Resultados e Discussões**

Os resultados desta revisão destacam que a aprendizagem de máquina quântica representa uma das áreas mais promissoras da ciência contemporânea, oferecendo perspectivas inovadoras para o tratamento de grandes volumes de dados e para a resolução

de problemas considerados intratáveis por abordagens clássicas (Biamonte et al., 2018). A seguir, são detalhados e discutidos os principais achados, sempre vinculados à relevância na formação científica e acadêmica.

#### **4.1. Potencial de Aceleração Computacional**

Um dos resultados mais significativos da integração entre computação quântica e aprendizagem de máquina é o potencial de aceleração exponencial em operações matemáticas essenciais, como a inversão de matrizes, transformadas de Fourier e análise de componentes principais (Harrow, Hassidim & Lloyd, 2009; Lloyd, Mohseni & Rebentrost, 2014). O algoritmo HHL, por exemplo, é citado como um divisor de águas por permitir a solução de sistemas lineares em tempo polinomial no número de qubits, quando comparado à complexidade linear das soluções clássicas (Harrow, Hassidim & Lloyd, 2009). Essa característica torna-se central em tarefas de aprendizado supervisionado e não supervisionado, sendo vital para estudantes que buscam compreender as fronteiras da computação e seu impacto na ciência de dados.

#### **4.2. Aplicações Práticas e Limitações**

Apesar das vantagens teóricas, a implementação prática ainda enfrenta barreiras significativas. Entre os desafios mais recorrentes estão o problema de entrada e saída de dados (input/output problem), a necessidade de memória quântica de acesso aleatório (qRAM) e o alto custo operacional dos circuitos quânticos (Aaronson, 2015). Mesmo assim, avanços importantes vêm sendo alcançados com dispositivos específicos, como quantum annealers da D-Wave, que já permitem experimentos em otimização combinatória e treinamento de redes Boltzmann quânticas (Adachi & Henderson, 2015; Amin et al., 2016).

Além disso, o surgimento de quantum principal component analysis (qPCA) e quantum support vector machines (SVMs quânticos) representa avanços fundamentais para a classificação de grandes volumes de dados, com potencial de aplicação direta em áreas como processamento de imagens, bioinformática e análise financeira (Lloyd, Mohseni & Rebentrost, 2014; Rebentrost, Mohseni & Lloyd, 2014). Essas ferramentas são apresentadas na literatura como exemplos de algoritmos que não apenas replicam, mas ampliam as capacidades dos métodos clássicos, promovendo um novo patamar de análise de padrões complexos (Wiebe, Kapoor & Svore, 2014).

#### **4.3. Integração com Dados Quânticos e Clássicos**

Outro ponto relevante refere-se à versatilidade dos algoritmos quânticos, que podem ser aplicados tanto a dados clássicos convertidos em estados quânticos quanto a dados genuinamente quânticos, como aqueles gerados em experimentos de física de partículas ou sistemas ópticos (Biamonte et al., 2018; Lloyd, 1996). A análise eficiente desses dados por meio de quantum simulators abre espaço para avanços em física fundamental e na própria construção de novos dispositivos quânticos, consolidando a importância do domínio conceitual desses algoritmos para a formação de novos pesquisadores (Wiebe, Granade & Cory, 2015).

#### **4.4. Contribuições para a Formação Científica**

No contexto da formação científica e acadêmica, compreender os fundamentos e as aplicações da aprendizagem de máquina quântica é essencial para estudantes que pretendem atuar em áreas multidisciplinares, como ciência de dados, física computacional e engenharia de sistemas inteligentes (Schuld, Sinayskiy & Petruccione, 2015). O domínio desses conceitos contribui para o desenvolvimento de habilidades analíticas, raciocínio lógico e capacidade de resolução de problemas complexos, competências cada vez mais valorizadas no mercado de trabalho e na pesquisa científica internacional (LeCun, Bengio & Hinton, 2015).

#### **4.5. Desafios e Perspectivas Futuras**

Finalmente, a literatura ressalta quatro grandes desafios a serem superados para que a aprendizagem de máquina quântica atinja seu potencial pleno: (i) o problema de entrada de dados, (ii) o problema de saída, (iii) o real dimensionamento dos custos computacionais, e (iv) a validação do desempenho quântico frente a soluções heurísticas clássicas (Biamonte et al., 2018; Arunachalam & de Wolf, 2017). Superar esses obstáculos demanda esforço conjunto entre físicos, engenheiros e cientistas da computação, reforçando a necessidade de uma formação sólida e interdisciplinar para os estudantes.

### **5 Conclusão**

O avanço da aprendizagem de máquina quântica inaugura uma nova era de possibilidades para a análise de dados, solução de problemas complexos e desenvolvimento de tecnologias disruptivas (Biamonte et al., 2018). A combinação de princípios da mecânica quântica com métodos avançados de aprendizagem representa não

apenas uma evolução natural das capacidades computacionais, mas também um campo de pesquisa essencial para estudantes e futuros pesquisadores interessados em fronteiras científicas emergentes (Schuld, Sinayskiy & Petruccione, 2015).

Ao longo deste artigo, foi evidenciado que a aprendizagem de máquina quântica pode oferecer acelerações exponenciais para tarefas como inversão de matrizes, análise de componentes principais e otimização de funções, resultando em ganhos substanciais de eficiência em áreas como física, bioinformática e ciência de dados (Harrow, Hassidim & Lloyd, 2009; Lloyd, Mohseni & Rebentrost, 2014). Contudo, o texto também ressaltou que desafios importantes permanecem, principalmente no que se refere à implementação prática, à manipulação eficiente de dados clássicos e quânticos e à necessidade de desenvolvimento de hardware específico (Aaronson, 2015; Adachi & Henderson, 2015).

Para a formação científica e acadêmica, estudar a aprendizagem de máquina quântica permite ao estudante desenvolver um olhar crítico sobre as limitações atuais da computação clássica, além de compreender o papel central da interdisciplinaridade na construção de soluções inovadoras. Como argumenta LeCun, Bengio & Hinton (2015), a formação sólida em fundamentos teóricos e práticos é indispensável para que os futuros profissionais possam contribuir ativamente na superação dos desafios deste campo.

Diante desse cenário, a recomendação para estudantes é de se engajarem não apenas no aprendizado dos algoritmos e ferramentas quânticas, mas também na compreensão dos aspectos práticos e das limitações atuais, promovendo uma atitude crítica e construtiva frente ao desenvolvimento tecnológico (Arunachalam & de Wolf, 2017). Somente com essa base, será possível participar efetivamente do avanço da ciência de dados quânticos e contribuir para a construção de soluções cada vez mais eficazes para problemas de alta complexidade.

## REFERÊNCIAS

- Adachi, S. H., & Henderson, M. P. (2015). Application of quantum annealing to training of deep neural networks. Preprint at <https://arxiv.org/abs/arXiv:1510.06356>.
- Aaronson, S. (2015). Read the fine print. *Nature Physics*, 11, 291–293. <https://doi.org/10.1038/nphys3272>
- Amin, M. H., Andriyash, E., Rolfe, J., Kulchytsky, B., & Melko, R. (2016). Quantum Boltzmann machine. Preprint at <https://arxiv.org/abs/arXiv:1601.02036>.
- Arunachalam, S., & de Wolf, R. (2017). A survey of quantum learning theory. Preprint at <https://arxiv.org/abs/1701.06806>.
- Biamonte, J., Wittek, P., Pancotti, N., Rebentrost, P., Wiebe, N., & Lloyd, S. (2018). Quantum Machine Learning. *Nature*, 549, 195–202. <https://doi.org/10.1038/nature23474>
- Harrow, A. W., Hassidim, A., & Lloyd, S. (2009). Quantum algorithm for linear systems of equations. *Physical Review Letters*, 103(15), 150502. <https://doi.org/10.1103/PhysRevLett.103.150502>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436–444. <https://doi.org/10.1038/nature14539>
- Lloyd, S., Mohseni, M., & Rebentrost, P. (2014). Quantum principal component analysis. *Nature Physics*, 10, 631–633. <https://doi.org/10.1038/nphys3029>
- Rebentrost, P., Mohseni, M., & Lloyd, S. (2014). Quantum support vector machine for big data classification. *Physical Review Letters*, 113(13), 130503. <https://doi.org/10.1103/PhysRevLett.113.130503>
- Schuld, M., Sinayskiy, I., & Petruccione, F. (2015). An introduction to quantum machine learning. *Contemporary Physics*, 56(2), 172–185. <https://doi.org/10.1080/00107514.2014.964942>
- Wiebe, N., Kapoor, A., & Svore, K. M. (2014). Quantum deep learning. Preprint at <https://arxiv.org/abs/1412.3489>.
- Wiebe, N., Granade, C., & Cory, D. G. (2015). Quantum bootstrapping via compressed quantum Hamiltonian learning. *New Journal of Physics*, 17(2), 022005. <https://doi.org/10.1088/1367-2630/17/2/022005>