



**INSTITUTO LATINO-AMERICANO DE
CIENCIAS DA VIDA E DA NATUREZA
(ILACVN)**

ENGENHARIA FÍSICA

**Detecção de Anomalias em Séries Temporais do Bitcoin Utilizando o
Aprendizado de Máquina Quântico**

Dylan Rafael Sánchez Salinas

Foz do Iguaçu
2025



**INSTITUTO LATINO-AMERICANO DE CIENCIAS
DA VIDA E DA NATUREZA
(ILACVN)**

ENGENHARIA FISICA

Deteccão de Anomalias em Séries Temporais do Bitcoin Utilizando Aprendizado de Máquina Quântico

Dylan Rafael Sánchez Salinas

Trabalho de Conclusão de Curso apresentado ao Instituto Latino Americano da Vida e Natureza como requisito parcial à obtenção ao título de Bacharel em Engenharia Física.

Orientador: Prof. Dr. Raphael Fortes Infante Gomes.

Foz do Iguaçu
2025

DYLAN RAFAEL SÁNCHEZ SALINAS

Detecção de Anomalias em Séries Temporais do Bitcoin Utilizando Aprendizado de Máquina Quântico

Trabalho de Conclusão de Curso apresentado ao Instituto Latino-Americano de Ciências da Vida e da Natureza da Universidade Federal da Integração Latino-Americana, como requisito parcial a obtenção ao título de Bacharel em Engenharia Física

BANCA EXAMINADORA

Orientador: Prof. Dr. Raphael Fortes Infante Gomes
UNILA

Prof. Dr. Joylan Nunes Maciel
UNILA

Prof. Dr. Rodrigo Bloot
UNILA

Foz do Iguaçu, ____ de _____ de _____.

Dedico este trabalho a todas as pessoas que hoje já não estão fisicamente entre nós, mas que deixaram marcas profundas em minha vida. Sua presença, mesmo na ausência, continua a me guiar, a me inspirar e a fortalecer cada passo da minha jornada.

Suas lembranças, ensinamentos e amor permanecem vivos em meu coração, como luzes que nunca se apagam. Este trabalho, assim como tudo que faço, é também um tributo ao legado que deixaram e às histórias que compartilhamos.

A vocês, minha eterna gratidão e saudade. Sempre os levarei comigo.

AGRADECIMENTOS

Agradeço, antes de tudo, ao Professor Raphael Fortes, meu orientador, por sua paciência, dedicação e pelos valiosos ensinamentos que não apenas contribuíram significativamente para este trabalho, mas também enriqueceram minha jornada acadêmica e pessoal. Sua orientação foi essencial para que eu pudesse crescer e superar desafios.

Aos meus pais, Alberto Sánchez e Mabel Salinas, que me ensinaram desde cedo que o conhecimento é o maior tesouro que podemos conquistar. Seu amor incondicional, apoio inabalável e sacrifícios silenciosos foram a base sobre a qual construí cada passo desta trajetória. Sem vocês, nada disso seria possível. À minha irmã Mara Sánchez e ao meu irmão Pablo Sánchez, minha fortaleza em todos os momentos. Vocês são meu porto seguro, aqueles que sempre estiveram ao meu lado nos dias bons e nos dias difíceis, compartilhando sonhos, conquistas e aprendizados. Ter vocês na minha vida é um presente pelo qual sou eternamente grato.

Aos amigos que tornaram essa caminhada mais leve e significativa: Belén Sotopeña e Duban Bravo, que me acolheram desde o início e se tornaram mais do que amigos, uma verdadeira família. À Fernando Batistti e Esdras Rebecchi, que compartilharam comigo desafios, risadas, conversas intermináveis e vitórias, tornando essa jornada inesquecível. Obrigado por estarem ao meu lado, por me incentivarem e por tornarem tudo mais especial.

À UNILA, aos professores que, com seu conhecimento e dedicação, me ajudaram a crescer não só academicamente, mas também como pessoa. Aos colegas que, direta ou indiretamente, contribuíram para essa caminhada, seja com um conselho, uma palavra de incentivo ou simplesmente com a companhia nos momentos mais desafiadores.

A todos vocês, meu mais sincero e profundo obrigado! Sem vocês, essa conquista não teria o mesmo significado.

“O que observamos não é a própria natureza, mas a natureza exposta a nosso método de questionamento.”

Werner Heisenberg

RESUMO

Este trabalho investiga a aplicação do algoritmo denominado *Quantum Variational Rewinding* (QVR) na detecção de anomalias em séries temporais, com foco na variação do Bitcoin nos últimos anos. As criptomoedas, em particular o Bitcoin, apresentam uma volatilidade extrema, o que dificulta a previsão e análise de seu comportamento. Isso torna essencial o desenvolvimento de métodos mais avançados, como o QVR, para identificar padrões irregulares e prever variações no mercado. Métodos tradicionais de análise de séries temporais enfrentam dificuldades para identificar padrões ocultos em dados financeiros complexos, especialmente em mercados de alta volatilidade como o das criptomoedas. Nesse contexto, abordagens baseadas em Computação Quântica e aprendizado de máquina se destacam como ferramentas poderosas para detectar essas anomalias de forma mais eficiente e precisa. O *Quantum Variational Rewinding*, uma técnica inovadora, surge como uma solução promissora para enfrentar esses desafios, oferecendo uma forma avançada de modelar e analisar séries temporais financeiras.

A metodologia adotada envolve a coleta e normalização de dados históricos do Bitcoin, implementação do modelo QVR em um ambiente simulado de Computação Quântica e a análise dos resultados utilizando o coeficiente de Pearson, que mede a correlação entre os padrões identificados e as variações do preço do Bitcoin. Os experimentos demonstram que o QVR não apenas apresenta potencial, mas também evidenciou resultados promissores ao capturar padrões complexos em séries temporais financeiras, oferecendo uma abordagem inovadora e eficaz para a análise de dados financeiros altamente voláteis, como os de criptomoedas. Comparado a métodos tradicionais, o QVR se destaca ao identificar desvios significativos no comportamento das séries temporais do Bitcoin, indicando seu grande potencial em mercados voláteis.

Palavras-chave: computação quântica; aprendizado de máquina quântico; bitcoin; séries temporais; detecção de anomalias.

RESUMEN

Este trabajo investiga la aplicación del algoritmo denominado Quantum Variational Rewinding (QVR) en la detección de anomalías en series temporales, con enfoque en la variación del Bitcoin en los últimos años. Las criptomonedas, en particular el Bitcoin, presentan una volatilidad extrema, lo que dificulta la previsión y el análisis de su comportamiento. Esto hace esencial el desarrollo de métodos más avanzados, como el QVR, para identificar patrones irregulares y predecir variaciones en el mercado. Los métodos tradicionales de análisis de series temporales enfrentan dificultades para identificar patrones ocultos en datos financieros complejos, especialmente en mercados de alta volatilidad como el de las criptomonedas. En este contexto, enfoques basados en Computación Cuántica y aprendizaje automático se destacan como herramientas poderosas para detectar estas anomalías de forma más eficiente y precisa. El Quantum Variational Rewinding, una técnica innovadora, surge como una solución prometedora para enfrentar estos desafíos, ofreciendo una forma avanzada de modelar y analizar series temporales financieras.

La metodología adoptada implica la recolección y normalización de datos históricos del Bitcoin, la implementación del modelo QVR en un entorno simulado de Computación Cuántica y el análisis de los resultados utilizando el coeficiente de Pearson, que mide la correlación entre los patrones identificados y las variaciones del precio del Bitcoin. Los experimentos demuestran que el QVR no solo presenta potencial, sino que también evidenció resultados prometedores al capturar patrones complejos en series temporales financieras, ofreciendo un enfoque innovador y eficaz para el análisis de datos financieros altamente volátiles, como los de criptomonedas. En comparación con métodos tradicionales, el QVR se destaca al identificar desviaciones significativas en el comportamiento de las series temporales del Bitcoin, lo que indica su gran potencial en mercados volátiles.

Palabras clave: computación cuántica; aprendizaje de máquina cuántico; bitcoin; series temporales; detección de anomalías.

ABSTRACT

This work investigates the application of the algorithm known as Quantum Variational Rewinding (QVR) in anomaly detection in time series, focusing on the variation of Bitcoin in recent years. Cryptocurrencies, particularly Bitcoin, exhibit extreme volatility, which complicates the prediction and analysis of their behavior. This makes the development of more advanced methods, such as QVR, essential for identifying irregular patterns and predicting market fluctuations. Traditional time series analysis methods face difficulties in identifying hidden patterns in complex financial data, especially in highly volatile markets like cryptocurrencies. In this context, approaches based on Quantum Computing and machine learning stand out as powerful tools for detecting these anomalies more efficiently and accurately. Quantum Variational Rewinding, an innovative technique, emerges as a promising solution to tackle these challenges, offering an advanced way to model and analyze financial time series.

The adopted methodology involves the collection and normalization of historical Bitcoin data, implementation of the QVR model in a simulated Quantum Computing environment, and analysis of the results using the Pearson coefficient, which measures the correlation between the identified patterns and the Bitcoin price variations. The experiments demonstrate that QVR not only shows potential but also has shown promising results in capturing complex patterns in financial time series, offering an innovative and effective approach to analyzing highly volatile financial data, such as cryptocurrencies. Compared to traditional methods, QVR stands out by identifying significant deviations in the behavior of Bitcoin time series, indicating its great potential in volatile markets.

Key words: quantum computing; quantum machine learning; bitcoin; time series; anomaly detection.

LISTA DE ILUSTRAÇÕES

Figura 2.1 – Evolução do preço do Bitcoin	20
Figura 2.2 – Evolução do volume histórico do Bitcoin	21
Figura 2.3 – Blocos da Blockchain	23
Figura 2.4 – Difusão de uma transação.....	24
Figura 2.5 – Representação de um estado de um qubit na esfera de Bloch	29
Figura 2.6 – Loop híbrido quântico-clássico	38
Figura 3.1 – Divisão por períodos no preço do Bitcoin	41
Figura 3.2 – Estrutura do circuito quântico utilizado	50
Figura 3.3 – Evolução da função perda durante o treinamento do modelo QVR.....	52
Figura 4.1 – Evolução temporal do preço do Bitcoin considerando o ano 2019 como referência	57
Figura 4.2 – Evolução temporal do preço do Bitcoin considerando o ano 2023 como referência	57
Figura 4.3 – Evolução mensal da função perda por mês no ano de 2019	61
Figura 4.4 – Evolução mensal da função perda por mês no ano de 2023	61
Figura 4.5 – Detecção de anomalias em 2018 considerando o ano 2019 como referência	63
Figura 4.6 – Detecção de anomalias em 2020 considerando o ano 2019 como referência	66
Figura 4.7 – Detecção de anomalias em 2022 considerando o ano 2023 como referência	68
Figura 4.8 – Detecção de anomalias em 2024 considerando o ano 2023 como referência	70
Figura 4.9 – Correlação mensal entre os anos 2018 e 2019	73
Figura 4.10 – Correlação mensal entre os anos 2020 e 2019	74
Figura 4.11 – Correlação mensal entre os anos 2023 e 2022	77
Figura 4.12 – Correlação mensal entre os anos 2023 e 2024	78

LISTA DE QUADROS

Quadro 3.1 – Interpretação dos coeficientes de Pearson.....	55
--	----

LISTA DE TABELAS

Tabela 3.1 – Principais parâmetros coletados do Bitcoin.....	44
Tabela 4.1 – Evolução do indicador mensal de perda média ao longo do ano de 2019	59
Tabela 4.2 – Evolução do indicador mensal de perda média ao longo do ano de 2023	60
Tabela 4.3 – Coeficiente de Pearson para o período 2019 como referência	73
Tabela 4.4 – Coeficiente de Pearson para o período 2023 como referência	77

LISTA DE ABREVIATURAS E SIGLAS

CBIT	<i>Classical Bit</i> (Bit Classico)
POW	<i>Proof of Work</i> (Prova de Trabalho)
QBIT	<i>Quantum Bit</i> (Bit Quântico)
QML	<i>Quantum Machine Learning</i> (Aprendizado de Máquina Quântico)
QPU	<i>Quantum Processing Unit</i> (Unidade de Processamento Quântico)
QVR	<i>Quantum Variational Rewinding</i> (Rebobinamento Quântico Variacional)
USD	<i>United States Dollar</i> (Dólar Americano)
VQA	<i>Variational Quantum Algorithm</i> (Algoritmo Quântico Variacional)
NSIQ	<i>Noisy Intermediate Scale Quantum</i> (Computação Quântica de Escala Intermediária e Ruidosa)

SUMÁRIO

1 INTRODUÇÃO	15
2 FUNDAMENTAÇÃO TEÓRICA	18
2.1 Bitcoin	18
2.1.1 Definição.....	18
2.1.2 Blockchain	22
2.1.3 Difusão de transações	24
2.1.4 Protocolo de consenso	24
2.1.5 Prova de trabalho.....	25
2.1.6 Comentarios	26
2.2.Computação quântica	27
2.2.1 Qubits	27
2.2.2 Esfera de Bloch.....	28
2.2.3 Portas logicas de um qubit.....	29
2.2.3.1 <i>Porta X</i>	31
2.2.3.2 <i>Porta Y</i>	31
2.2.3.3 <i>Porta Z</i>	32
2.2.3.4 <i>Porta H</i>	32
2.2.3.5 <i>Portas de rotação arbitrarías</i>	33
2.2.4 Portas lógicas de dois qubits	34
2.2.4.1 <i>Porta CNOT</i>	34
2.2.5 Enmarahamento quântico.....	35
2.2.6 Quantum variational rewinding	36
3 METODOLOGIA	40
3.1. Dados	40
3.2. Tecnologias utilizadas	42
3.3 Infraestrutura computacional	43
3.3.1 Obtenção dos dados.....	43
3.3.2 Normalização dos dados	45
3.3.3 Construção do modelo quântico	46
3.3.4 Representação quântica	46

3.3.5 Operadores parametrizados	51
3.3.6 Definição do limiar de anomalia	52
3.3 Avaliação do modelo	54
4 ANÁLISE E RESULTADOS	56
4.1 Definição dos períodos de análise	56
4.2 Função de perda	59
4.3 Análise comparativa	62
4.3.1 Considerando o ano de 2019 como referência	62
4.3.1.1 <i>Comparação entre os anos 2019 e 2018</i>	63
4.3.1.2 <i>Comparação entre os anos 2019 e 2020</i>	65
4.3.2 Considerando o ano de 2023 como referência	67
4.3.2.1 <i>Comparação entre os anos 2023 e 2022</i>	68
4.3.2.2 <i>Comparação entre os anos 2023 e 2024</i>	70
4.4 Análise do coeficiente de Pearson	72
4.4.1 Coeficiente de Pearson para o ano de 2019 como referência	72
4.4.1.1 <i>Comparação entre 2018 e 2019</i>	74
4.4.1.2 <i>Comparação entre 2019 e 2020</i>	75
4.4.2 Coeficiente de Pearson para o ano de 2023 como referência	76
4.4.2.1 <i>Comparação entre os anos 2022 e 2023</i>	78
4.4.2.2 <i>Comparação entre os anos 2024 e 2023</i>	79
5 CONSIDERAÇÕES FINAIS	81
REFERÊNCIAS	85
APÊNDICE A – REGRAS FUNDAMENTAIS DA MEÂNICA QUÂNTICA	86
APÊNDICE A – MACHINE LEARNING	89

1 INTRODUÇÃO

A Computação Quântica é apontada como uma tecnologia promissora e revolucionária, trazendo novas possibilidades para o processamento de informações e a resolução de problemas computacionais complexos. Desde a sua concepção teórica proposta por Feynman (1982) até os avanços mais recentes, que incluem os computadores quânticos disponibilizados em nuvem pela IBM a partir de 2016, a área tem evoluído significativamente. Apesar do evidente progresso, a tecnologia ainda enfrenta limitações, como a susceptibilidade à decoerência e a baixa fidelidade dos qubits, o que limita suas aplicações em larga escala (NIELSEN; CHUANG, 2010). Para contornar essas restrições, a comunidade científica tem explorado abordagens como os Algoritmos Quânticos Variacionais (do inglês *Variational Quantum Algorithms*, ou VQA), que permitem explorar o poder da Computação Quântica em dispositivos ruidosos da era NISQ (*Noisy Intermediate-Scale Quantum*) (PRESKILL, 2018).

Inserido neste contexto, o Aprendizado de Máquina Quântico (*Quantum Machine Learning* - QML) tem se destacado como uma abordagem promissora para diversas aplicações, incluindo a detecção de anomalias em séries temporais financeiras (BISHOP, 2006). No cenário atual, onde as criptomoedas desempenham um papel cada vez mais relevante, a volatilidade extrema do Bitcoin representa um desafio significativo para investidores e reguladores. Métodos clássicos de análise de séries temporais enfrentam dificuldades para identificar padrões ocultos em dados financeiros complexos, tornando necessário o desenvolvimento de novas abordagens baseadas em Computação Quântica e aprendizado de máquina (ALPAYDIN, 2010).

Diante desse panorama, este trabalho investiga a aplicação do *Quantum Variational Rewinding* (QVR) para a detecção de anomalias em séries temporais do preço do Bitcoin. O QVR é um algoritmo baseado em operadores unitários parametrizados que modelam a evolução temporal dos dados, permitindo identificar padrões normais e detectar desvios significativos (BAKER et al., 2022,).

O QVR pode ser aplicado para análise de séries temporais financeiras, utilizando circuitos quânticos para identificar anomalias (PENNYLANE, 2024). Um estudo recente demonstra que algoritmos quânticos podem prover ganhos computacionais referentes à análise de séries temporais, especialmente no setor financeiro (JOHN; O'HARA; SALEH, 2022).

1.1 Objetivos:

Este trabalho possui como objetivo geral avaliar a eficácia do algoritmo QVR na detecção de anomalias nos preços do Bitcoin, com foco na sua capacidade de identificar padrões irregulares e desvios significativos. Para esta finalidade, definimos os seguintes objetivos específicos:

- Coletar e processar dados históricos do Bitcoin para a análise, teste e validação do modelo.
- Implementar o modelo *Quantum Variational Rewinding* e aplicá-lo à detecção de anomalias em séries temporais financeiras.
- Investigar o impacto de eventos externos no comportamento do mercado de Bitcoin

1.2 Estrutura do trabalho:

O trabalho foi organizado de acordo com a seguinte estrutura: o Capítulo 2 apresenta os fundamentos teóricos da Computação Quântica e do Bitcoin, abordando conceitos essenciais como qubits, superposição, emaranhamento, portas lógicas quânticas e a estrutura da tecnologia *blockchain*. Na sequência, o Capítulo 3 descreve a metodologia empregada na pesquisa incluindo a coleta e a normalização dos dados, além da implementação do modelo QVR. Por fim, no Capítulo 4, são apresentados os resultados e uma análise detalhada do desempenho do modelo QVR na detecção de anomalias nos preços do Bitcoin, bem como as conclusões e possíveis desdobramentos para trabalhos futuros.

2.1 BITCOIN

A era digital transformou radicalmente a forma como vivemos e interagimos com as tecnologias contemporâneas, especialmente no que diz respeito às transações financeiras. O comércio eletrônico e os pagamentos internacionais se tornaram cada vez mais comuns, exigindo soluções para que as transações sejam mais eficientes e flexíveis. No entanto, os métodos tradicionais de pagamento - muitas vezes centralizados e burocráticos - não acompanharam essa evolução. Nesse contexto, o Bitcoin surge como uma alternativa inovadora para este fim, prometendo maior autonomia, rapidez e alcance global na realização de operações monetárias. Desde o seu surgimento, a criptomoeda tem sido objeto de intenso debate e curiosidade, impulsionada por características que frequentemente são associadas à criptomoeda, como o suposto anonimato, a descentralização e a agilidade nas transações transfronteiriças.

2.1.1 Definição:

Segundo (RISKBANK, 2014), o Bitcoin é uma moeda virtual, ou seja, um meio de pagamento digital em que suas unidades representam valores monetários. Ele foi projetado para ser utilizado em pagamentos dentro de comunidades virtuais específicas, como redes de usuários que utilizam softwares especializados para gerenciar transações. Diferentemente das moedas tradicionais, o emissor de uma moeda virtual pode ser tanto uma empresa não financeira quanto um indivíduo, e esse emissor não está sujeito à supervisão de uma autoridade governamental. Dessa forma, a emissão destes ativos não é regulamentada por nenhum governo.

Cada moeda virtual opera sob um conjunto de regras próprias que determinam onde e como ela pode ser usada, além de dispor de uma infraestrutura técnica que viabiliza os pagamentos. A combinação desses elementos - moeda virtual, regras específicas e infraestrutura técnica - compõe o que chamamos de esquema de moeda virtual. Tais

esquemas podem ser enquadrados em diversos tipos de categorias, que se distinguem através do modo como permitem a compra, a venda e o uso dessas moedas. Por exemplo, em esquemas de moedas virtuais fechados, a moeda não pode ser comprada e nem vendida, apenas adquirida e utilizada em contextos específicos (como em jogos online). Já em esquemas com fluxo unidirecional, embora a moeda virtual possa ser comprada com a sua contraparte física, o procedimento não pode ser revertido (como ocorre com o *Amazon Coins*). Por outro lado, esquemas com fluxo bidirecional permitem que a moeda virtual seja comprada, vendida e utilizada fora de um site ou em um ambiente específico, como no caso do Bitcoin. Vale ressaltar que, embora a divisão em categorias facilite o entendimento, há casos em que as mesmas podem se sobrepor em relação a um mesmo objeto. Um exemplo disso são os tokens de utilidade, que podem funcionar dentro de um ecossistema fechado, mas também ser negociados em mercados secundários, criando uma característica híbrida entre um esquema fechado e um fluxo bidirecional) (NARAYANAN et al., 2016)

Outro aspecto importante para entender os conceitos referentes ao uso de moedas virtuais é a distinção entre esquemas centralizados e descentralizados. Assim como ocorre com o dinheiro físico, as transações desta classe de ativos envolvem a transferência de propriedade que, por sua vez, deve ser registrada para evitar fraudes (como a duplicação de uma unidade da própria moeda). Nos esquemas centralizados, as transações são verificadas e registradas por uma entidade central (geralmente o emissor) que administra todas as contas e viabiliza os pagamentos. Já nos esquemas descentralizados (como o Bitcoin), a verificação e o registro de transações ocorrem por meio de uma rede de usuários que desempenham atividades específicas para esse fim (NAKAMOTO, 2008).

Os esquemas descentralizados frequentemente utilizam mensagens criptografadas, o que confere anonimato e segurança aos participantes. Por essa razão, as moedas virtuais descentralizadas são frequentemente chamadas de criptomoedas. O anonimato e a segurança oferecidos por essa tecnologia são os conceitos fundamentais nos quais o Bitcoin se baseia, tornando-o um exemplo paradigmático de moeda virtual descentralizada.

A volatilidade mede a variação dos preços de um ativo em um determinado período. O Bitcoin é conhecido por sua alta volatilidade em comparação com ativos tradicionais, como o ouro ou o S&P 500 (HULL, 2022). Desde o seu surgimento, a cotação anual do

Bitcoin vem apresentando uma valorização significativa, marcada por momentos de alta volatilidade. A Fig. 2.1 ilustra a evolução do preço do Bitcoin em USD ao longo dos anos, destacando seus principais picos e quedas.

Figura 2.1: Evolução do preço do Bitcoin.



Fonte: Figura elaborada pelo autor.

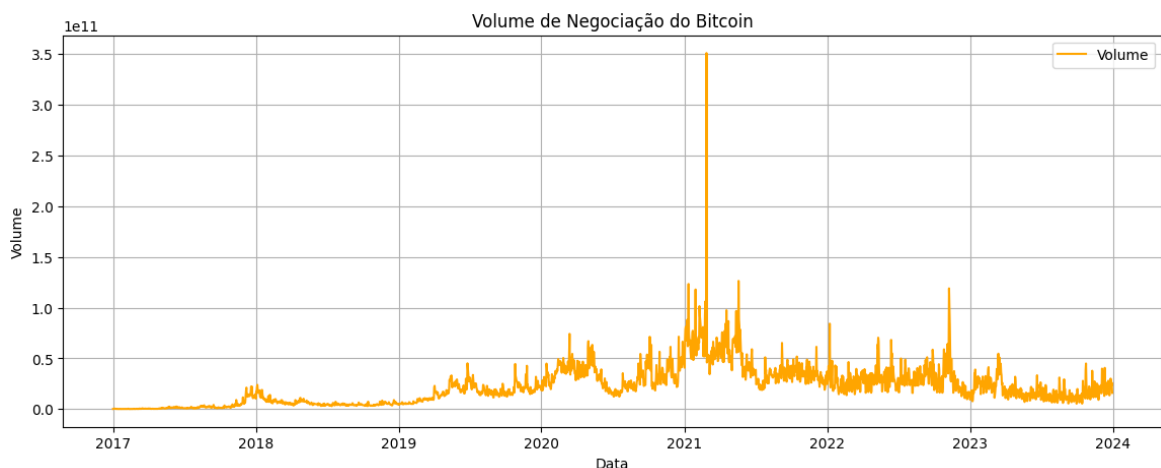
A volatilidade do Bitcoin é influenciada por diversos fatores. Sua baixa liquidez relativa, quando comparada a mercados financeiros tradicionais, pode amplificar movimentos bruscos de preço (SHIMON, 2023). Além disso, a intensa especulação dos investidores contribui para grandes oscilações, muitas vezes impulsionadas por expectativas de mercado. As mudanças regulatórias também desempenham um papel crucial, visto que anúncios governamentais sobre restrições ou aceitações do Bitcoin podem impactar significativamente seu valor.

Por fim, a oferta limitada do Bitcoin, com um máximo de 21 milhões de unidades em circulação, torna eventos como o *halving* um fator determinante na sua escassez e, conseqüentemente, sua volatilidade. O *halving* é um mecanismo programado no protocolo do Bitcoin que reduz pela metade a recompensa concedida aos mineradores a cada 210.000 blocos minerados, aproximadamente a cada quatro anos. Essa redução no ritmo de emissão de novas moedas tem o objetivo de controlar a inflação do ativo e pode impactar

a dinâmica de oferta e demanda, influenciando seu preço no mercado.

A relação entre volume e volatilidade é crucial para entender o comportamento desta criptomoeda, já que grandes movimentações de volume geralmente precedem mudanças bruscas no seu respectivo preço. Por outro lado, um volume baixo pode indicar uma falta de liquidez, tornando o mercado mais suscetível a manipulações. A Figura 2.2 apresenta a evolução do volume de negociação do Bitcoin ao longo dos anos, destacando períodos de alta liquidez e possíveis correlações com movimentos de preço extremos. O gráfico utiliza notação científica facilitar a leitura dos valores expressos em bilhões.

Figura 2.2: Evolução do volume histórico do Bitcoin.



Fonte: Figura elaborada pelo autor.

Os picos significativos de volume refletem momentos de intensa atividade no mercado. Podemos notar que entre 2017 e 2018 o volume aumentou consideravelmente, acompanhando a primeira grande bolha especulativa do Bitcoin, que elevou o preço inicial de aproximadamente 1.000 USD para quase 20.000 USD. Um segundo aumento expressivo ocorreu entre 2020 e 2021, impulsionado pelo crescente interesse institucional. O pico extremo em 2021 pode estar associado à liquidação de grandes posições alavancadas, levando a flutuações abruptas no mercado.

A volatilidade extrema do Bitcoin pode dificultar a identificação de anomalias reais em seus preços, uma vez que os métodos tradicionais de análise de séries temporais podem gerar diversos falsos positivos, interpretando oscilações normais como eventos atípicos. Portanto, a implementação de técnicas contemporâneas avançadas que utilizam princípios de Aprendizado de Máquina pode ajudar a capturar padrões mais sutis e diferenciá-los de movimentos naturais do mercado

2.1.2 *Blockchain*:

A tecnologia conhecida como *blockchain* foi inicialmente apresentada por Satoshi Nakamoto em seu artigo titulado “*Bitcoin: A Peer-to-peer Electronic Cash System*”. Esse documento estabeleceu a base matemática para definir o Bitcoin, a primeira criptomoeda a surgir no mercado. Além de sustentar todas as criptomoedas, a tecnologia *blockchain* encontrou aplicações amplas na indústria financeira tradicional e abriu portas como contratos inteligentes, que automatizam a execução de acordos sem a necessidade de dispor de intermediários.

Segundo (JOHN; O’HARA; SALEH; 2022) uma *blockchain* é um livro-razão eletrônico que registra transações em partes discretas chamadas de blocos. A nomenclatura confirma o fato de que estes blocos são concatenados em uma única cadeia imutável. Ademais, as transações são adicionadas a uma *blockchain* apenas ao serem incorporadas em um novo bloco, o qual é anexado ao final da cadeia dos blocos preexistentes. Portanto, o processo pelo qual novos blocos são criados e aceitos na *blockchain* é especialmente importante.

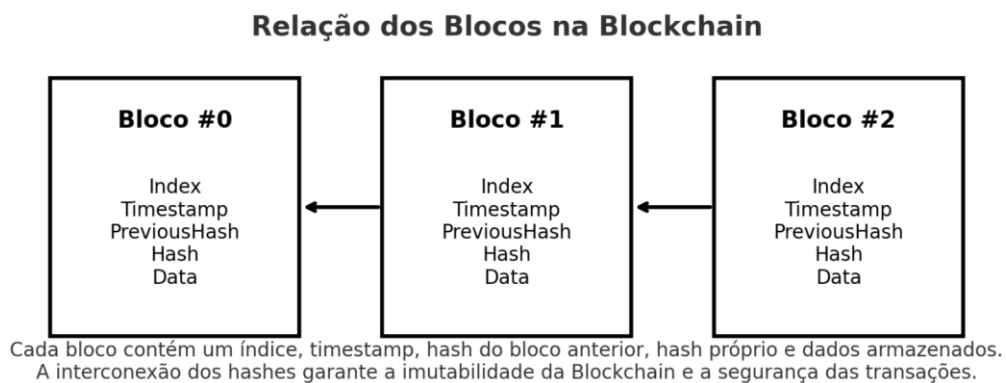
O problema fundamental solucionado pela *blockchain* consiste em estabelecer um mecanismo de confiança em um sistema distribuído. Em um cenário tradicional (como o de transações bancárias), confia-se em uma entidade central (como um banco ou um cartório) para garantir a autenticidade e a sequência cronológica das transações (DI PIERRO, 2017). Já na *blockchain*, esse controle é distribuído entre diversos participantes da rede, chamados nós, que validam e registram as transações coletivamente. Cada nó mantém

uma cópia completa do histórico de transações, eliminando a necessidade de uma autoridade central e dificultando fraudes, pois qualquer tentativa de alteração em um bloco invalidaria toda a cadeia subsequente.

Um elemento central desse mecanismo é o *hash* criptográfico, que é o resultado de uma função matemática que transforma um conjunto de dados (como informações de transações) em uma saída de tamanho fixo. Na *blockchain*, cada bloco contém o *hash* do anterior, formando uma sequência interligada. Dessa forma, qualquer modificação em um bloco altera todos os *hashes* subsequentes, tornando a alteração facilmente detectável e rejeitada pela rede.

A Fig. 2.3 ilustra a estrutura básica da *blockchain*, destacando como os blocos são encadeados por meio de funções de *hash*. Cada bloco contém um índice (*index*), um carimbo de tempo (*timestamp*), o *hash* do bloco anterior (*previous hash*), seu próprio *hash* e os dados armazenados (*data*). Note que a interconexão dos *hashes* garante a imutabilidade da *blockchain*, com base na premissa de que qualquer tentativa de modificação em um bloco altera os primeiros e invalida os blocos subsequentes. Esse mecanismo impede alterações fraudulentas e garante a segurança e a confiabilidade das transações do Bitcoin.

Figura 2.3: Blocos da Blockchain.




Fonte: Figura elaborada pelo autor.

2.1.3 Difusão de Transações:

Narayanan et al. (2016) apresentam um exemplo simples que ajuda a compreender o funcionamento das transações na rede Bitcoin. Suponha que Alice deseja efetuar um pagamento para Bob. Em sistemas financeiros tradicionais, Alice e Bob dependeriam de uma entidade central (como um banco) para verificar e registrar a transação. No entanto, no sistema Bitcoin, Alice transmite sua intenção de pagamento para toda a rede através do sistema *peer-to-peer* (P2P), como indicado na Fig. 2.4.

O sistema P2P é uma arquitetura de rede descentralizada na qual os participantes se comunicam diretamente uns com os outros, sem a necessidade de um servidor central intermediário. No contexto do Bitcoin, essa estrutura permite que as transações sejam propagadas para todos os nós da rede, garantindo que a informação seja distribuída de forma confiável e resistente a tentativas de censura ou controle centralizado (NARAYANAN et al., 2016).

Figura 2.4: Difusão de uma transação.



Fonte: Narayanan et al.,2016

A transação inclui detalhes como o endereço público de Bob, o valor a ser transferido e a assinatura digital de Alice, que autentica a operação. Essas informações são difundidas para todos os nós da rede, que verificam a validade da transação. Um aspecto interessante desse sistema descentralizado é que Bob não precisa estar conectado para receber os fundos; já que seu endereço público funciona como uma “caixa postal”, onde os bitcoins são enviados e registrados na blockchain (Narayanan et al.,2016)

2.1.4 Protocolo de Consenso:

Nos sistemas que utilizam a *blockchain*, o “consenso” é o mecanismo pelo qual a rede decide qual bloco será adicionado à cadeia, garantindo que todos os participantes (nós) concordem com o histórico de transações. Embora existam diferentes protocolos de consenso, todos buscam a mesma finalidade: assegurar a integridade dos dados e tornar a rede resistente à ataques, com o objetivo de validar as transações de maneira segura sem a necessidade de submetê-las a uma autoridade central. No caso do Bitcoin, o método utilizado é a Prova de Trabalho (*Proof of Work* - PoW) como forma de proteger a rede contra fraudes e garantir sua confiabilidade (NAKAMOTO, 2008).

2.1.5 Prova de Trabalho:

De acordo com Nakamoto (2008), o *Proof of Work* (PoW) é um protocolo de consenso que exige esforço computacional para validar cada bloco na *blockchain*. Esse esforço consiste em encontrar um *nonce* (um número arbitrário) que, ao ser processado por um algoritmo de *hash* (como o SHA-256), deve produzir um resultado que atenda a um critério específico (como um número de bits iniciais iguais a zero). Esse processo é conduzido pelos mineradores, que competem entre si para resolver esse problema maximizando os recursos computacionais disponíveis.

Assim que um minerador encontra um *hash* válido, o bloco correspondente é adicionado à *blockchain* e aceito pela rede. Esse mecanismo torna extremamente difícil modificar um bloco já registrado, pois qualquer alteração exigiria refazer todo o esforço computacional de todos os blocos subsequentes, inviabilizando a manipulação dos últimos.

O PoW também resolve o problema de como estabelecer a "maioria" em um sistema descentralizado. Em vez de "um IP, um voto", considera-se "um CPU, um voto" (NAKAMOTO, 2008), garantindo que a rede seja controlada pelo poder computacional acumulado e não por identidades falsas. Isso impede que invasores com poucos recursos dominem a rede, pois a cadeia válida sempre será a que contém o maior trabalho computacional acumulado.

Além disso, para evitar que novos blocos sejam minerados rapidamente, o protocolo

ajusta automaticamente a dificuldade da mineração a cada 2016 blocos. Se os blocos estiverem sendo minerados muito rápido, o rigor aumenta; se estiverem lentos, ele diminui. Esse mecanismo mantém um ritmo relativamente constante de produção de novos blocos, contribuindo para a estabilidade do sistema. No contexto do Bitcoin, a mineração baseada no *Proof of Work* resolve dois problemas essenciais (NAKAMOTO, 2008):

- Segurança – impedindo ataques e tornando a *blockchain* resistente a adulterações;
- Processamento de transações – garantindo que novos blocos sejam validados e adicionados corretamente à cadeia.

Com isso, a Prova de Trabalho garante que a rede do Bitcoin permaneça descentralizada, segura e resistente a fraudes.

2.1.6 Comentários:

O Bitcoin representa um avanço significativo no conceito de dinheiro digital, combinando descentralização, segurança criptográfica e transparência por meio da tecnologia *blockchain*. Seu protocolo de consenso baseado na PoW garante a integridade da rede ao tornar computacionalmente inviável qualquer tentativa de fraude ou manipulação.

No entanto, sua volatilidade extrema e a dinâmica do mercado fazem do Bitcoin um elemento financeiro singular, cujos preços são influenciados por fatores técnicos, econômicos e comportamentais. Esse comportamento caótico torna a análise de séries temporais um desafio, especialmente na detecção de anomalias que podem indicar mudanças de tendência, manipulação de mercado ou eventos significativos na rede.

A compreensão desses fundamentos é essencial para o desenvolvimento de modelos de detecção de anomalias no preço do Bitcoin, especialmente ao explorar abordagens mais avançadas.

2.2 COMPUTAÇÃO QUÂNTICA

Nesta seção, apresentamos os fundamentos teóricos da Computação Quântica. Através de uma revisão da literatura, exploraremos conceitos-chave relacionados a qubits, superposição, emaranhamento e portas quânticas. Além disso, discutimos os resultados mais relevantes obtidos nos últimos anos com o uso de algoritmos quânticos, os quais servirão de base para o desenvolvimento das propostas nos capítulos seguintes.

2.2.1 Qubits:

Desde a invenção dos primeiros computadores na década de 1940, a arquitetura utilizada na computação permaneceu quase inalterada, baseando-se nos princípios da máquina de Turing (GÜRER,2002). Todas as operações lógicas estão associadas ao conceito de bit, que corresponde à menor unidade de informação. Na computação digital, um bit só pode assumir dois valores: 0 e 1, os quais podem ser lidos ou modificados pelo hardware.

De forma análoga ao bit clássico, um quantum bit (ou qubit) está associado a um sistema quântico de dois níveis e consiste na unidade fundamental nos processos de transmissão de informação quântica. Embora os valores de um qubit possam representar variáveis de decisão clássicas (como 0 ou 1), suas propriedades se distinguem das de um bit clássico considerando que o primeiro também pode existir em uma superposição de estados, ou seja, em uma combinação simultânea dos estados 0 e 1 (NIELSEN & CHUANG,2001).

Nesse contexto, um sistema de dois bits clássicos pode ser representado por quatro possibilidades distintas: 00, 01, 10 e 11, assumindo sempre uma única configuração instantânea. Por sua vez, graças ao princípio de superposição, um sistema de dois qubits pode ser descrito por uma combinação simultânea dos quatro estados, residindo em ao menos um deles para cada instante de tempo t .

Assim como um bit clássico, um sistema quântico de dois níveis pode ser expresso em função de uma base ortonormal definida por (NIELSEN; CHUANG, 2010):

$$|0\rangle = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \quad |1\rangle = \begin{bmatrix} 0 \\ 1 \end{bmatrix}. \quad (2.1)$$

Desse modo, um qubit pode ser expresso como a combinação linear dos estados $|0\rangle$ e $|1\rangle$ definidos na Eq. (2.1) tal que

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle. \quad (2.2)$$

onde α e β são as amplitudes de probabilidade que satisfazem a condição de normalização dada por $|\alpha|^2 + |\beta|^2 = 1$. Essa relação decorre do Postulado II da Mecânica Quântica é descrito por um vetor unitário em um espaço de Hilbert (ver Apêndice A)

De acordo com o Postulado I da Mecânica Quântica (ver Apêndice A), os parâmetros associados aos coeficientes α e β só podem ser determinados até que uma medição seja realizada sobre o sistema. Esse processo pode ser entendido como uma observação que faz com que o qubit colapse para um dos seus estados de base, ou seja: $|0\rangle$ ou $|1\rangle$. Em outras palavras, o sistema assume a configuração de um estado clássico após a medição. Logo, enquanto o valor de um bit clássico é determinístico, um qubit só pode ser descrito em termos de probabilidades. Mais especificamente, $|\alpha|^2$ representa a probabilidade de obter o estado $|0\rangle$ após a referida medição, enquanto $|\beta|^2$ indica a probabilidade de que o sistema colapse para o estado $|1\rangle$.


2.2.2 A esfera de Bloch:

A esfera de Bloch (Fig. 2.5) é uma representação geométrica que permite identificar os parâmetros que definem um qubit em uma esfera tridimensional de raio unitário. Desse modo, o estado do qubit pode ser reescrito como:

$$|\psi\rangle = \cos\frac{\theta}{2}|0\rangle + e^{i\phi}\sin\frac{\theta}{2}|1\rangle, \quad (2.3)$$

onde os parâmetros θ e ϕ definem respectivamente os ângulos axial e azimutal que permitem localizar o estado quântico $|\psi\rangle$ na esfera. Neste caso, θ representa a inclinação do vetor ao longo do plano vertical, enquanto ϕ define a rotação no plano horizontal. Os polos da esfera ($\theta = 0$ e $\theta = \pi$) correspondem aos estados puros $|0\rangle$ e $|1\rangle$, enquanto os pontos no equador ($\theta = \pi/2$) representam superposições que possuem probabilidades idênticas de colapso idênticas em relação aos referidos estados (visto que $|e^{i\phi}|^2 = 1$).

Figura 2.5: Representação do estado de um qubit na esfera de Bloch.



Fonte: (NIELSEN, CHUANG,2010)

Entretanto, não há uma generalização direta da esfera de Bloch para sistemas com múltiplos qubits, o que limita a nossa intuição para visualizar para casos mais complexos. Apesar da aparente restrição, esta ferramenta é amplamente utilizada para introduzir os conceitos fundamentais da área de Computação Quântica, aprofundar a compreensão sobre as operações que atuam em qubits e os respectivos erros associados às mesmas, analisar o fenômeno de decoerência e auxiliar o desenvolvimento de algoritmos.

2.2.3 Portas lógicas de um qubit:

Em um computador clássico, a única operação reversível não trivial que pode ser

realizada em um bit clássico é a NOT, que inverte o seu respectivo valor de 0 para 1 e 1 para 0. Para reverter esta transformação, basta aplica-la novamente e o valor original do bit será restaurado. Por sua vez, as operações realizadas nos qubits em um computador quântico são bem mais gerais e sofisticadas. Segundo (MERMIM, 2007), as operações que podem atuar sobre um único qubit são representadas por transformações lineares unitárias, cuja característica fundamental consiste em preservar a norma da respectiva função de onda. Isso significa que essas transformações não alteram a magnitude dos estados quânticos, ou seja, o valor absoluto das amplitudes de probabilidade permanece inalterado.

Antes de definir as operações unitárias, é fundamental discorrer sobre um conceito que desempenha um papel central na Mecânica Quântica: o de operação hermitiana. Um operador A é chamado de hermitiano quando a seguinte condição é satisfeita:

$$A^\dagger = A, \quad (2.4)$$

onde A^\dagger representa o adjunto hermitiano de A , cuja representação matricial é equivalente à transposta conjugada da matriz original. Estes operadores correspondem a observáveis físicos (como energia e momento), visto que seus respectivos autovalores são expressos por números reais (SAKURAI; COMMINS, 1995).

Neste contexto, a maioria dos operadores unitários utilizados em algoritmos quânticos são hermitianos. Isso ocorre porque qualquer operador unitário U pode ser expresso como:

$$U = e^{-\frac{iHt}{\hbar}}, \quad (2.5)$$

onde H é um operador hermitiano associado ao sistema. Note que a Eq. (2.5) permite relacionar as operações unitárias com a dinâmica da evolução temporal descrita pela equação de Schrödinger, conforme estabelecido pelo Postulado I da Mecânica Quântica (ver Apêndice A).

Adicionalmente, as transformações unitárias U satisfazem a condição:

$$UU^\dagger = U^\dagger U = I, \quad (2.6)$$

onde U^\dagger é o operador hermitiano adjunto de U e I representa a operação de identidade. A Eq. (2.6) implica que a transformação unitária é reversível, uma vez que o resultado da aplicação sucessiva de U e U^\dagger recupera o estado original. Consequentemente, as operações desta natureza podem ser revertidas de forma precisa e sem perda de informação, cujas implicações são cruciais para a preservação dos qubits.

A função das portas lógicas quânticas consiste em implementar operações que atuam sobre sistemas físicos, alterando propriedades intrínsecas de qubits (como as amplitudes de probabilidade e a respectiva fase) e promovendo rotações na esfera de Bloch. A seguir, apresentaremos os exemplos mais importantes referentes às portas lógicas que atuam em um e dois qubits.

2.2.3.1 Porta NOT (X)

A ação da porta X é equivalente à da porta NOT clássica. Ela permuta os estados $|0\rangle$ e $|1\rangle$ ao aplicar a transformação:

$$X|0\rangle = |1\rangle, \quad X|1\rangle = |0\rangle, \quad (2.7)$$

e sua representação matricial é dada por:

$$X = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}. \quad (2.8)$$

Quando ela atua em um qubit arbitrário descrito por $\alpha|0\rangle + \beta|1\rangle$, os coeficientes são invertidos, e o resultado final é expresso por $\beta|0\rangle + \alpha|1\rangle$.

2.2.3.2 Porta (Y)

A porta Y realiza uma rotação que combina a troca de estados e insere uma fase

imaginária. Sua ação é descrita por:

$$Y|0\rangle = i|1\rangle, \quad Y|1\rangle = -i|0\rangle. \quad (2.9)$$

e a respectiva representação matricial é dada por:

$$Y = \begin{pmatrix} 0 & -i \\ i & 0 \end{pmatrix}. \quad (2.10)$$

Esta porta é útil em operações que exigem manipulações de fase e trocas simultâneas de estados.

2.2.3.3 Porta (Z)

A porta Z mantém o estado $|0\rangle$ inalterado e insere uma fase igual a “ -1 ” no estado $|1\rangle$:

$$Z|0\rangle = |0\rangle, \quad Z|1\rangle = -1|0\rangle, \quad (2.11)$$

cuja ação é descrita pela seguinte matriz:

$$Z = \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix}. \quad (2.12)$$

Repare que os autoestados do operador Z descritos na Eq. (2.11) constituem a base computacional padrão definida nas Eqs. (2.1) e (2.2).

2.2.3.4 Porta Hadamard (H)

A porta Hadamard é crucial para implementar a maioria dos algoritmos quânticos, visto que ela gera superposições equitativas da base computacional padrão. Ao aplicá-la sobre os estados de base $|0\rangle$ e $|1\rangle$, obtemos:

$$H|0\rangle = \frac{|0\rangle + |1\rangle}{\sqrt{2}}, \quad H|1\rangle = \frac{|0\rangle - |1\rangle}{\sqrt{2}}, \quad (2.13)$$

e sua representação matricial é dada por:

$$H = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}. \quad (2.14)$$

Por sua vez, a ação desta porta em um qubit arbitrário descrito por $\alpha|0\rangle + \beta|1\rangle$ resulta em $\frac{\alpha+\beta}{\sqrt{2}}|0\rangle + \frac{\alpha-\beta}{\sqrt{2}}|1\rangle$.

2.3.1.5 Portas de rotação arbitrárias

As operações rotação arbitrárias são descritas por transformações unitárias e desempenham um papel essencial na implementação de algoritmos quânticos, pois permitem a manipulação precisa das amplitudes e fases dos estados quânticos e permitem modificar o estado de um qubit em torno dos eixos da esfera de Bloch. Esta classe é definida pelas seguintes operações:

Rotação em torno do eixo X :

Consiste em uma operação que altera o estado de um qubit através da seguinte matriz unitária:

$$R_X(\theta) = \begin{bmatrix} \cos(\theta/2) & -i \sin(\theta/2) \\ -i \sin(\theta/2) & \cos(\theta/2) \end{bmatrix}. \quad (2.15)$$

A matriz descrita pela Eq. (2.15) gera uma rotação de θ radianos em torno do eixo X da esfera de Bloch.

Rotação em torno do eixo Y :

A rotação em torno do eixo Y é dada pela matriz:

$$R_Y(\theta) = \begin{bmatrix} \cos(\theta/2) & -\sin(\theta/2) \\ \sin(\theta/2) & \cos(\theta/2) \end{bmatrix}, \quad (2.16)$$

gerando uma rotação de θ radianos em torno do respectivo eixo.

Rotação em torno do eixo Z :

A rotação em torno do eixo Z aplica uma fase relativa aos estados da base computacional, sendo representada por:

$$R_Z(\theta) = \begin{bmatrix} e^{-i\theta/2} & 0 \\ 0 & e^{i\theta/2} \end{bmatrix}. \quad (2.17)$$

Diferentemente das rotações R_X e R_Y , essa porta modifica a fase relativa entre os referidos estados sem alterar as probabilidades de medição em relação aos mesmos, e sua aplicação é essencial em algoritmos que envolvem processos de interferência quântica.

As portas de rotação são amplamente utilizadas em protocolos de correção de erros e em algoritmos quânticos variacionais.

2.2.4 Portas lógicas de dois qubits:

A Computação Quântica se torna ainda mais versátil ao permitir a manipulação de múltiplos qubits para gerar sistemas correlacionados que não podem ser descritos por estados separáveis. Este fenômeno conhecido é como emaranhamento quântico, cujo efeito possibilita o desenvolvimento de algoritmos específicos que superam suas respectivas contrapartes clássicas em eficiência e velocidade.

2.2.4.1 Porta CNOT (Controlled-NOT)

A porta CNOT atua simultaneamente em dois qubits. Por convenção, sua ação

resulta na aplicação da porta X no qubit-alvo somente se o qubit de controle estiver em $|1\rangle$.

Exemplo:

$$CNOT|00\rangle = |00\rangle, \quad CNOT|10\rangle = |11\rangle. \quad (2.18)$$

Sua representação matricial é dada por:

$$CNOT = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \end{pmatrix}. \quad (2.19)$$

2.2.5 Emaranhamento Quântico:

O emaranhamento quântico é um fenômeno intrínseco da Mecânica Quântica no qual dois ou mais qubits tornam-se correlacionados de modo que o estado de um não pode ser dissociado dos demais, independentemente da distância entre eles. Isso significa que o resultado da medição de um qubit determina instantaneamente o do outro, cujo efeito foi denominado por Einstein de “ação fantasmagórica a distância” (EINSTEIN; PODOLSKY; ROSEN, 1935).

Para ilustrar esse fenômeno, considere dois qubits inicialmente preparados no estado $|00\rangle$. Ao aplicar uma porta Hadamard no primeiro qubit, criamos uma superposição entre os estados $|0\rangle$ e $|1\rangle$:

$$H|0\rangle = \frac{1}{\sqrt{2}}(|0\rangle + |1\rangle). \quad (2.20)$$

Em seguida, aplicamos uma porta CNOT onde o primeiro qubit atua como controle e o segundo como alvo. Neste caso, o novo estado passa a ser descrito por:

$$|\Phi^+\rangle = \frac{1}{\sqrt{2}}(|00\rangle + |11\rangle). \quad (2.21)$$

A Eq. (2.21) apresenta um dos estados da base de Bell (Bell, 1964), que representa um dos exemplos mais emblemáticos do emaranhamento quântico. Uma característica essencial deste fenômeno reside no seguinte fato: se realizarmos uma medição no primeiro qubit e o mesmo colapsar para $|0\rangle$, saberemos instantaneamente que o segundo qubit também estará no estado $|0\rangle$. De modo semelhante, o mesmo padrão ocorre quando um dos qubits colapsa para o estado $|1\rangle$, independentemente da separação espacial entre eles.

2.2.6 Quantum Variational Rewinding:

O *Quantum Variational Rewinding* (QVR) é um modelo avançado de aprendizado de máquina quântico desenvolvido para a detecção de anomalias em séries temporais. Ele combina técnicas de Computação Quântica e otimização clássica para explorar padrões sutis nos dados, superando abordagens convencionais que dependem exclusivamente de métodos estatísticos ou de redes neurais clássicas (BAKER et al., 2022).

O diferencial do QVR reside na utilização de circuitos quânticos variacionais, permitindo que padrões temporais sejam codificados e analisados diretamente no espaço de Hilbert. Esse processo ocorre por meio de três componentes fundamentais. Primeiro, a codificação quântica dos dados transforma as séries temporais clássicas em estados quânticos utilizando a técnica de codificação angular (*Angle Embedding*), onde cada ponto temporal x_t é convertido em uma rotação no espaço quântico representada por:

$$|\psi_t\rangle = R_Y(x_t)|0\rangle, \quad (2.22)$$

Essa codificação preserva a estrutura dos dados e permite que as relações temporais sejam manipuladas de modo eficaz no circuito. Em seguida, aplica-se uma evolução temporal variacional, na qual o modelo implementa uma transformação unitária governada por um Hamiltoniano parametrizado $\mathcal{H}(\theta)$ tal que:

$$U(\theta) = e^{-i\mathcal{H}(\theta)t}. \quad (2.23)$$

A Eq. (2.23) determina a dinâmica temporal dos dados após a conversão inicial, permitindo que o modelo aprenda os padrões estabelecidos como “normais” para as séries analisadas. Desse modo, a evolução dos estados quânticos é ajustada iterativamente por meio de técnicas de otimização, garantindo uma representação mais precisa das relações presentes no conjunto de dados.

Por fim, as etapas de medição e detecção de anomalias são realizadas com o auxílio de um operador O que é um observável Hermitiano, cujo valor médio serve de referência para identificar desvios em relação ao comportamento esperado da série analisada. Se o valor obtido ultrapassa um limiar previamente estabelecido, o mesmo pode ser ajustado durante o treinamento para minimizar falsos positivos e maximizar a eficácia do modelo.

A implementação do QVR é realizada em um ciclo híbrido quântico-clássico, no qual circuitos quânticos são executados em unidades de processamento quântico (QPU) para calcular expectativas de operadores, enquanto algoritmos clássicos ajustam os parâmetros variacionais do modelo.

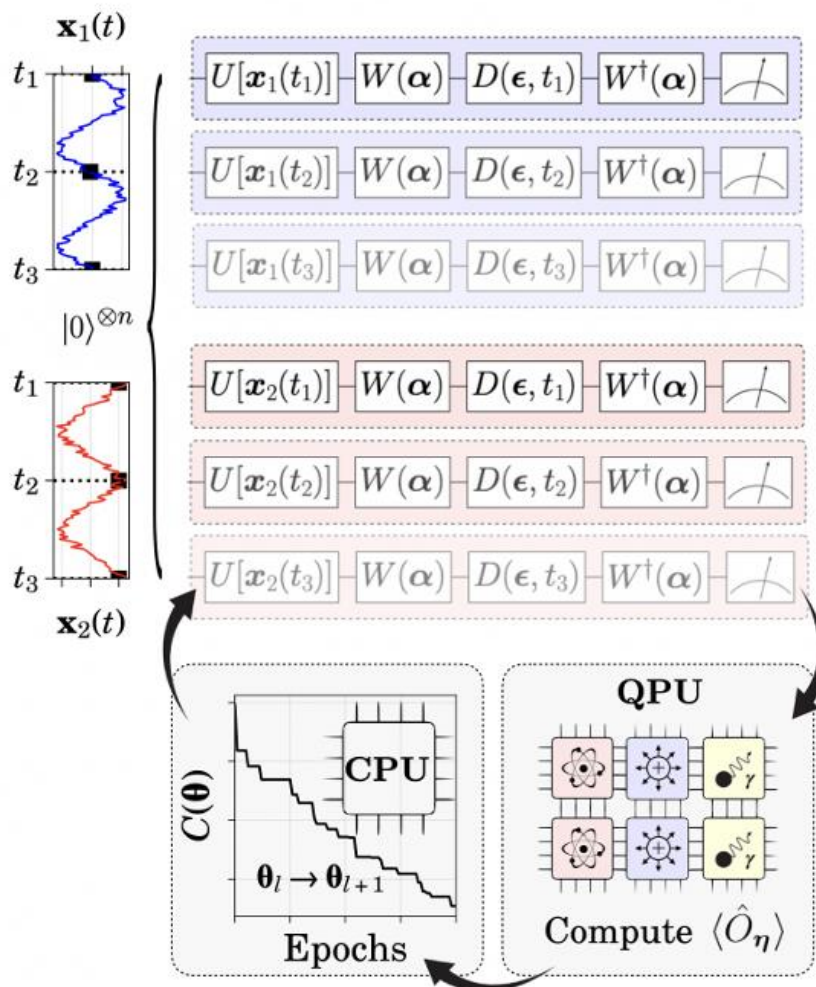
(BAKER et al., 2022) apresenta experimentos conduzidos com séries temporais com variáveis atreladas à finanças. Para estes modelos, o QVR demonstrou um desempenho superior em relação a alguns métodos clássicos, especialmente em cenários onde há uma quantidade limitada de dados para treinamento. Os resultados indicam que essa abordagem pode ser promissora para aplicações em análise de mercado, detecção de fraudes e previsão de falhas em sistemas críticos. Além disso, a implementação do QVR em um hardware quântico da era NISQ (*Noisy Intermediate-Scale Quantum*) confirma sua viabilidade prática, mesmo diante das limitações impostas pelo ruído e pela profundidade dos circuitos.

Dado o potencial do *Quantum Variational Rewinding*, as pesquisas futuras podem focar em otimizações estruturais, incluindo técnicas de mitigação de erros e a adaptação do modelo para outras áreas (como o monitoramento de redes neurais quânticas e a análise preditiva em domínios biomédicos e industriais). A função perda, fundamental para o

treinamento, será definida posteriormente, com o objetivo de minimizar os erros de previsão e otimizar os parâmetros do modelo.

A Fig. 2.6 exibe o fluxo de execução do QVR. Repare que os circuitos quânticos são parametrizados e executados em QPUs, enquanto os resultados das medições são processados por algoritmos clássicos para otimização de parâmetros variacionais. Esse ciclo iterativo permite o ajuste contínuo do modelo, refinando a identificação de anomalias em séries temporais.

Figura 2.6: Loop híbrido quântico-clássico para treinamento do modelo QVR



FONTE: (BAKER ET AL., 2022)

3 METODOLOGIA

Este capítulo apresenta a metodologia empregada para a detecção de anomalias nos preços dos Bitcoin utilizando aprendizado de máquina quântico. O objetivo é fornecer uma descrição detalhada do processo adotado para a coleta, o tratamento dos dados e o desenvolvimento do algoritmo *Quantum Variational Rewinding*. A abordagem proposta visa identificar variações anormais nos preços da criptomoeda em diferentes períodos históricos, permitindo uma análise comparativa e a compreensão dos efeitos de eventos externos sobre o comportamento do mercado de Bitcoin.

3.1 DADOS

Os dados utilizados nesta pesquisa foram extraídos da API Yfinance que contém registros do preço do Bitcoin em períodos diários. A seleção do conjunto de dados foi realizada considerando a necessidade de avaliar variações ao longo do tempo, de forma que fosse possível estabelecer uma linha de base de normalidade e identificar desvios significativos. Para essa análise, os dados foram organizados em quatro períodos distintos. A evolução do preço do Bitcoin ao longo dos períodos analisados pode ser visualizada na Fig. 3.1, onde destacamos as fases pré-pandemia, o período de referência de 2019, a pandemia e o pós-pandemia. Esta representação gráfica facilita a identificação das tendências e volatilidades associadas a cada fase do mercado.

Figura 3.1: Divisão por períodos no preço do Bitcoin.



FONTE: Figura elaborada pelo autor.

O primeiro período corresponde ao ano de 2019, adotado como referência para definir um padrão de comportamento normal da criptomoeda. O segundo período, referente aos anos de 2017 e 2018, representa a fase pré-pandemia, em que os preços do Bitcoin apresentavam uma dinâmica influenciada por fatores de mercado convencionais. O terceiro período engloba os anos de 2020 e 2021, caracterizados pelo impacto direto da pandemia de COVID-19 e suas consequências no comportamento econômico global, refletindo-se também na volatilidade da criptomoeda. Por fim, o quarto período abrange os anos de 2022 em diante, permitindo avaliar a evolução do Bitcoin no contexto pós-pandemia.

A segmentação desses períodos busca identificar possíveis correlações entre eventos externos e as oscilações da criptomoeda, fornecendo uma base para a aplicação do modelo quântico de detecção de anomalias temporais.

3.2 TECNOLOGIAS UTILIZADAS.

A implementação desta pesquisa exigiu uma infraestrutura computacional robusta e integrada, garantindo suporte adequado para a execução de algoritmos de aprendizado de máquina quântico. A plataforma *Google Colab* foi escolhida devido à sua capacidade de fornecer um ambiente baseado em nuvem, permitindo a execução de modelos sem a necessidade de uma infraestrutura local robusta. Neste estudo, os experimentos foram conduzidos utilizando apenas uma CPU (Intel(R) Xeon(R) CPU @2.20 GHz com 2 núcleos) garantindo acessibilidade e replicabilidade das simulações. Esta opção resultou em um processamento eficiente dos dados e uma maior escalabilidade dos experimentos realizados.

Para a construção do modelo foi utilizada a biblioteca *PennyLane* (PENNYLANE, 2025), que proporciona uma interface flexível para a simulação e implementação de circuitos quânticos. Essa ferramenta foi fundamental para a modelagem do algoritmo *Quantum Variational Rewinding*, permitindo a manipulação de estados quânticos e a simulação da evolução temporal dos dados. Complementando esse ambiente, a biblioteca *PyTorch* (PYTORCH, 2025) foi utilizada para a implementação dos algoritmos de otimização, fornecendo um suporte eficiente para o treinamento do modelo, além de permitir a integração direta com a estrutura de Computação Quântica.

Por sua vez, a orquestração dos fluxos de trabalho quântico foi realizada através do *Covalent*, uma ferramenta que facilita a execução de processos híbridos entre computação clássica e quântica. Sua utilização foi essencial para a distribuição eficiente das tarefas, garantindo que diferentes etapas da pesquisa fossem processadas de forma organizada e integrada.

Além disso, a manipulação dos dados foi realizada por meio das bibliotecas *Pandas* (PANDAS, 2025) e *NumPy* (NUMPY, 2025), que possibilitaram a estruturação das séries temporais e a preparação dos conjuntos de treinamento e teste. Já as bibliotecas *Matplotlib* (MAPTPLOTLIB, 2025) e *Seaborn* (SEARBORN, 2025) foram empregadas na análise dos resultados, permitindo a geração de gráficos que auxiliaram na visualização da evolução dos preços do Bitcoin e na interpretação das anomalias identificadas pelo modelo.

Por fim, a obtenção dos dados foi feita por meio da API *YFinance* (YFINANCE, 2025),

uma ferramenta amplamente utilizada para a coleta de informações financeiras em tempo real. Essa API garantiu que os dados analisados fossem atualizados de forma contínua, permitindo a realização de um estudo dinâmico sobre as flutuações do Bitcoin ao longo dos períodos estabelecidos. A combinação dos referidos recursos computacionais garantiu um ambiente sólido para a execução desta pesquisa, permitindo que o modelo fosse desenvolvido, testado e validado com alta precisão e eficiência.

3.3 Infraestrutura Computacional

A infraestrutura computacional foi configurada para garantir um ambiente eficiente para o desenvolvimento e teste do modelo selecionado. Os dados utilizados no estudo foram obtidos conforme descrito anteriormente, permitindo acesso contínuo às séries temporais do Bitcoin, incluindo informações sobre fechamento, máximas, mínimas, abertura e volume de negociação.

3.3.1 Obtenção dos dados

Como mencionado anteriormente, a coleta dos dados foi realizada através da API YFinance, que permite o acesso automatizado a séries temporais de ativos financeiros. Os dados extraídos incluem os preços diários de fechamento, máximas, mínimas, abertura e volume de negociação do Bitcoin desde 2015 até a data mais recente disponível.

A tabela 3.1 apresenta uma amostra dos dados coletados, destacando os principais parâmetros utilizados no processamento

Tabela 3.1: amostra dos dados históricos de preço e volumem do Bitcoin

Data	Preço de Fechamento (USD)	Máxima (USD)	Mínima (USD)	Abertura (USD)	Volume
2015-01-01	314.25	320.43	314.00	320.43	8036550
2015-01-02	315.03	315.83	313.57	314.08	7860650

2015-01-03	281.08	315.14	281.08	314.85	33054400
2015-01-04	264.20	287.23	257.61	281.15	55629100
2015-01-05	274.47	278.34	265.08	265.08	43962800

Fonte: Elaborado pelo autor.

Os dados apresentados na tabela 3.1 evidenciam a elevada variação nos preços do Bitcoin ao longo do tempo. Desde o início de 2015, observa-se que o mercado desta criptomoeda já apresentava uma volatilidade significativa, com oscilações diárias expressivas. Os principais indicadores apresentados são:

- Preço de fechamento: representa o valor do Bitcoin ao final do dia de negociação, refletindo o último preço pelo qual o ativo foi comercializado antes do encerramento do mercado;
- Máxima: indica o maior preço alcançado pelo Bitcoin dentro do período de um dia, fornecendo uma visão do pico de valorização da criptomoeda;
- Mínima: mostra o menor preço registrado durante o dia, evidenciando até que ponto o ativo desvalorizou-se antes de qualquer recuperação;
- Abertura: é o preço inicial do Bitcoin ao começar o dia de negociação, influenciado por fatores como a movimentação do mercado em períodos anteriores;
- Volume: refere-se ao número total de unidades negociadas dentro do dia, sendo um indicador de liquidez e interesse do mercado no ativo.

A variação entre os preços de abertura e fechamento em um curto período reflete a sensibilidade do ativo a eventos internos e externos, como mudanças na regulamentação, adoção institucional e crises econômicas globais. Além disso, o volume de negociação registrado na tabela 3.1 destaca a liquidez do Bitcoin ao longo do tempo. A análise desse volume é essencial para compreender o comportamento do mercado, pois picos de negociação podem indicar momentos de grande especulação, entrada de novos investidores ou reação a notícias relevantes. Dessa forma, a volatilidade combinada com altos volumes pode representar padrões de anomalia significativos, os quais devem ser detectados pelo modelo proposto. Os dados coletados foram posteriormente normalizados e segmentados em períodos específicos para análise comparativa, conforme descrito nas próximas seções.

3.3.2 Normalização dos Dados

A normalização dos dados foi realizada para garantir que os valores de diferentes períodos fossem comparáveis e pudessem ser processados de maneira eficiente pelo modelo. Sem a correção, os valores extremos poderiam distorcer a análise e comprometer a identificação precisa de anomalias. Essa etapa é fundamental para que o modelo quântico interprete corretamente os dados, garantindo que padrões e variações não sejam ofuscados por flutuações desproporcionais.

A técnica utilizada foi o *Min-Max Scaling* (SCIKITLEARN, 2024), um método que transforma os valores para um intervalo padronizado entre 0 e 1, preservando a estrutura e as relações entre os dados originais. Esse processo facilita a convergência do modelo, reduzindo o impacto de escalas diferentes e permitindo que padrões temporais sejam analisados com maior precisão. A técnica é mais adequada para manter a distribuição relativa dos dados dentro de um intervalo fixo.

A normalização é essencial para evitar que valores extremos dominem a análise e permite que o modelo quântico processe os dados de forma mais estável. A equação

utilizada para a normalização foi:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}, \quad (3.1)$$

onde X é o valor original de cada variável embutida no conjunto de dados, X_{min} e X_{max} correspondem respectivamente ao menor e maior valor observado neste conjunto, enquanto X_{max} equivale ao valor normalizado resultante.

Essa técnica permite preservar as relações entre os preços e facilita o aprendizado do modelo. A normalização foi aplicada separadamente para cada período analisado, garantindo que os padrões internos de cada segmento fossem mantidos.

3.3.3 Construção do Modelo Quântico

A construção do modelo quântico para a detecção de anomalias nos preços do Bitcoin baseia-se no algoritmo *Quantum Variational Rewinding*. Essa abordagem inovadora utiliza princípios da Computação Quântica para identificar padrões em séries temporais e detectar desvios significativos ao longo do tempo. O modelo é desenvolvido utilizando a biblioteca *PennyLane*, que permite a simulação de circuitos quânticos em uma CPU, garantindo a execução em um ambiente de computação clássica. Na próxima seção detalharemos todas as etapas do modelo, desde a representação dos dados até a implementação dos circuitos e a lógica do algoritmo de detecção de anomalias.

3.3.4 Representação Quântica dos Dados.

A conversão dos dados clássicos para uma representação quântica é um passo essencial no desenvolvimento do modelo, já que ela permite que as informações sejam processadas no espaço de Hilbert e manipuladas através de operações unitárias em circuitos quânticos. Sem essa conversão não seria possível explorar as vantagens da Computação Quântica na detecção de padrões e possíveis anomalias temporais.

O objetivo principal desta conversão consiste em garantir que os preços normalizados do Bitcoin possam ser interpretados pelo modelo quântico de forma eficiente, preservando as relações temporais e estruturais dos dados. Este processo é fundamental para que o QVR consiga aprender padrões normais e detectar desvios significativos ao longo do tempo. Para este fim, utilizamos a técnica de *Angle Embedding* que associa cada valor numérico a uma rotação de um qubit no espaço vetorial. Essa abordagem já foi explorada em aplicações anteriores de aprendizado de máquina quântico para detecção de anomalias em séries temporais, conforme discutido por Alves et al. (2025). A transformação dos dados segue os seguintes passos:

1) Mapeamento para ângulos quânticos:

Após a normalização, cada valor X_{norm} é convertido em um ângulo θ utilizando a seguinte relação:

$$\theta = \pi \cdot X_{norm}. \quad (3.2)$$

Assim, um valor normalizado para 0 corresponde a um ângulo de 0 radianos, enquanto conversão para 1 equivale a um ângulo de π radianos.

2) Inicialização do qubit:

Antes de realizar qualquer processamento quântico, é necessário definir um estado inicial para os qubits. Por convenção, os circuitos geralmente são inicializados com os qubits no estado $|0\rangle$. Esta escolha possui as seguintes implicações:

- Ela serve como ponto de partida para diversas operações quânticas, garantindo a previsibilidade e o controle sobre as transformações aplicadas ao longo do circuito;
- Se um qubit que reside em $|0\rangle$ estiver associado ao estado fundamental de um

sistema físico, a inicialização pode minimizar a interferência de ruídos externos.

3) Aplicação da rotação $R_Y(\theta)$:

A operação de rotação é utilizada para modificar o estado de um qubit, permitindo que o sistema assumira qualquer configuração associada a uma superposição dos estados da base computacional padrão. Neste caso, a operação $R_Y(\theta)$ aplica uma rotação em torno do eixo Y da esfera de Bloch, alterando as propriedades do qubit de acordo com os coeficientes da matriz descrita pela Eq. (2.16). Essa transformação é responsável pela conversão da informação embutida em um dado clássico para o estado quântico equivalente descrito pela respectiva função de onda $|\psi\rangle$.

Ademais, a rotação $R_Y(\theta)$ é particularmente útil uma vez que ela preserva as relações de fase entre os estados e permite representar dados contínuos de forma suave dentro do espaço de Hilbert. Esse tipo de transformação é amplamente utilizado em algoritmos quânticos de aprendizado de máquina, visto que ela permite mapear informações numéricas diretamente para estados quânticos manipuláveis.

4) Estado final do Qubit:

Após a aplicação da porta $R_Y(\theta)$, o qubit passa a residir no seguinte estado:

$$|\psi\rangle = \cos(\theta/2) |0\rangle + \sin(\theta/2) |1\rangle, \quad (3.4)$$

permitindo que a informação seja processada e manipulada dentro do circuito quântico de forma eficiente.

A técnica de *Angle Embedding* foi escolhida para este modelo por vários motivos. Primeiramente, ela preserva a estrutura dos dados, garantindo que as relações entre os

preços sejam mantidas. Além disso, essa abordagem permite a aplicação direta de operações quânticas, facilitando a evolução temporal dos estados e a detecção de padrões anômalos.

3.3.5 Operadores Parametrizados


Diferentemente dos modelos convencionais de aprendizado de máquina quântico que utilizam circuitos variacionais profundos (*Variational Quantum Circuits*), o modelo baseado no QVR empregado nesta pesquisa fundamenta-se na evolução temporal de um sistema quântico por meio de operadores unitários parametrizados. Em vez de múltiplas camadas de portas quânticas treináveis, o QVR otimiza um conjunto reduzido de parâmetros que descrevem a evolução e o *rewinding* do estado quântico.

O modelo aprender a aplicar um operador $e^{-iH(\theta)t}$ que governa a evolução temporal do estado quântico. A estrutura inicial do circuito segue a técnica de *Angle Embedding*, na qual os valores normalizados dos preços do Bitcoin são convertidos em ângulos de rotação de um qubit. Esses ângulos são então aplicados ao qubit por meio de rotações R_Y e R_Z , que modificam seu estado quântico de acordo com os padrões extraídos dos dados.

A Figura 3.2 ilustra a estrutura do circuito quântico utilizado no modelo QVR. O circuito inicia com a inserção dos dados via *Angle Embedding*, seguida por uma sequência de operações unitárias parametrizadas, compostas por rotações nos eixos Y e Z . Essa sequência de transformações permite representar padrões complexos na evolução da série, sendo fundamental para a capacidade do modelo de identificar e caracterizar desvios anômalos. As rotações parametrizadas e otimizadas durante o treinamento, são ajustadas de modo que, para séries normais, o modelo seja capaz de reverter o estado do qubit para sua configuração inicial. Quando essa reversão não ocorre de forma eficiente, o sistema sinaliza a presença de um comportamento anômalo.

Figura 3.2: Estrutura do circuito quântico utilizado no modelo QVR. O circuito é composto por um único qubit, onde os dados são inseridos via *Angle Embedding* e passam por uma

sequência de rotações parametrizadas antes da medição final.



FONTE: (AUTOR)

A etapa de treinamento do modelo consiste na otimização dos parâmetros do Hamiltoniano $\mathcal{H}(\theta)$, garantido que o circuito aprenda a distinguir entre padrões normais e anômalos. Utilizamos descida de gradiente, com o otimizador Adam para minimizar a função de perda, que mede a capacidade do modelo de recuperar estados quânticos normais. O processo de treinamento segue os seguintes passos:

- O modelo recebe como entrada os dados da série temporal e os converte em estados quânticos.
- Aplica-se o operador unitário $e^{-iH(\theta)t}$, que simula a evolução temporal da série usando a evolução quântica do sistema.
- O modelo mede o estado resultante e calcula um escore, comparando a reversibilidade do estado.
- Os parâmetros do Hamiltoniano são ajustados iterativamente usando descida de gradiente com o otimizador Adam, reduzindo progressivamente o erro da previsão.
- Após 100 épocas de treinamento, o modelo é capaz de avaliar novas séries temporais e atribuir um escore de anomalia, classificando desvios do comportamento normal.

3.3.5 Treinamento do Modelo Quântico

O treinamento do modelo consiste na otimização dos parâmetros utilizando descida de gradiente, garantindo que o modelo aprenda a diferenciar padrões normais e anômalos. Para isso, minimizamos a seguinte função de perda:

$$\mathcal{L}(\phi) = \frac{1}{|X||T|} \sum_{x \in X} \sum_{t \in T} [1 - F(\phi, x_t)]^2 + P_T(\sigma), \quad (3.5)$$

onde $F(\phi, x_t)$ avalia o quanto o modelo consegue recuperar o estado original da série temporal.

O treinamento foi realizado por 100 interações, onde cada etapa:

- O modelo recebe os dados normalizados e aplica a codificação.
- O operador variacional $e^{-iH(\theta)t}$ é aplicado para gerar os estados quânticos evoluídos.
- A função de perda é calculada comparando a fidelidade dos estados quânticos com o estado inicial.
- A penalização $P_T(\sigma)$ é aplicada para regularizar a variação dos parâmetros.
- O otimizador Adam ajusta os parâmetros do modelo.
- O processo se repete até que a perda atinja um valor estável, indicando a convergência do modelo.

A Figura 3.3 apresenta a evolução da função perda ao longo de um treinamento, demonstrando a redução progressiva do erro à medida que o modelo ajusta seus parâmetros. Esse comportamento indica que o modelo está convergindo adequadamente para uma solução otimizada capaz de identificar padrões normais da série temporal

Figura 3.3: Evolução da função perda durante o treinamento do modelo QVR.



FONTE: (PennyLane AI, 2024)

Essa abordagem reduz significativamente a complexidade computacional comparada a arquiteturas baseadas em circuitos variacionais profundos (que dependem da sequência de portas lógicas associadas a cada qubit), conforme discutido por Barenco et al. (1995), Bernstein e Vazirani (1997) e Bouland et al. (2019), minimizando também os desafios associados ao ruído e ao entrelaçamento em implementações experimentais. Além disso, a escolha de um único qubit torna a simulação mais eficiente, permitindo uma interpretação mais clara dos resultados e garantindo que o modelo seja adequado para series temporais financeiras, como a do Bitcoin.

Entretanto, para dados com um grande número de observações, como series temporais com t muito grande, o volume de operações (ou portas) necessárias no circuito pode aumentar consideravelmente. Mesmo com um único qubit, o número de passos temporais e operações que precisam ser realizadas pode afetar a eficiência computacional do modelo. Isso é um fator importante a considerar, especialmente para dados em grande escala, já que a implementação de múltiplas portas no circuito pode resultar em desafios

adicionais desempenho.

3.3.6 Definição do Limiar de Anomalia

Após o treinamento do modelo, é necessário definir um limiar de anomalia ζ que permita classificar séries como normais ou anômalas. Essa decisão baseia-se no escore calculado pelo modelo QVR. O objetivo é garantir que series temporais normais apresentam um escore próximo de zero, enquanto series anômalas exibam valores significativamente maiores.

A função que define o escore de anomalia é baseada na métrica de fidelidade entre os estados quânticos obtidos e o estado inicial $|0\rangle^{\otimes n}$. Como descrito na literatura de QVR ([PennyLane AI, 2024]), a função $F(\phi, x_t)$ mede a capacidade do modelo de rebobinar o estado quântico para sua configuração original antes da aplicação do unitário *embedding* $U(x_t)$. O escore de anomalia é definido como:

$$a_X(y) = \frac{1}{|T|} \sum_{t \in T} [1 - F(\phi^*, y_t)]^2, \quad (3.6)$$

onde ϕ^* representa os parâmetros otimizados do modelo, e $F(\phi, x_t)$ é a expectativa do estado quântico em relação a sua reversibilidade.

Para determinar o limiar de detecção ζ , analisamos a distribuição dos escores de anomalia gerados pelo modelo para séries normais. A estratégia adotada consiste em definir ζ com base a um percentil superior da distribuição dos valores de $a_X(x)$ para os dados normais $x \in X$. Isso significa que qualquer valor superior a ζ será classificado como anômalo.

A penalização da variância σ da distribuição também foi incorporada a função de perda do modelo para evitar classificações excessivamente sensíveis a pequenas variações. Essa regularização é implementada por meio de uma função de penalidade

$P_T(\sigma)$, que reduz o impacto das dispersões estatísticas elevadas.

Dessa forma, ao minimizar a função perda do modelo e estabelecer um limite estatístico para ζ , conseguiremos separar automaticamente padrões normais de comportamentos anômalos, garantindo maior robustez na detecção de anomalias no preço do Bitcoin.

3.4 AVALIAÇÃO DO MODELO

A avaliação do modelo foi conduzida com o objetivo de validar a capacidade do *Quantum Variational Rewinding* na detecção de anomalias nos preços do Bitcoin. Para garantir robustez dos resultados, utilizamos o coeficiente de correlação de Person como principal métrica de validação, analisando sua relação com as oscilações dos preços do Bitcoin.

O coeficiente de correlação de Pearson mede a relação linear entre variáveis (Hernández et al., 2018). No contexto deste estudo, empregamos essa métrica para analisar se os escores de anomalia produzidos pelo QVR apresentavam uma correlação significativa com as oscilações históricas dos preços do Bitcoin. A correlação de Pearson é definida como:

$$r = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum(X_i - \bar{X})^2} \cdot \sqrt{\sum(Y_i - \bar{Y})^2}}, \quad (3.7)$$

onde X e Y representam respectivamente os escores de anomalia gerados pelo modelo e os preços históricos do Bitcoin, enquanto \bar{X} e \bar{Y} denotam as medias das respectivas séries temporais. O QUADRO 3.1 apresenta a interpretação dos valores do coeficiente de

correlação de Pearson.

Quadro 3.1: interpretação dos valores do coeficiente de correlação de Pearson.

Valor de r	Interpretação
Próximo de 1	Forte correlação positiva (os escores de anomalia aumentam quando os preços sobem)
Próximo de 0	Sem correlação (não há relação linear entre os scores e os preços)
Próximo de -1	Forte correlação negativa (comportamento inverso a realidade)

Fonte: Elaborado pelo autor.

Além das métricas quantitativas, a avaliação do modelo incluiu uma análise visual dos escores de anomalia ao longo do tempo. Foram gerados gráficos comparativos entre os escores calculados pelo QVR e os preços do Bitcoin, permitindo verificar se as anomalias detectadas coincidiam com eventos históricos relevantes.

Esses gráficos foram fundamentais para validar empiricamente a capacidade do modelo de identificar momentos de alta volatilidade e desvios inesperados no mercado. Essa análise comparativa fornece um indicativo visual da eficácia do modelo na detecção de padrões anômalos.

4 ANÁLISES E RESULTADOS.

Nesta seção apresenta uma análise aprofundada dos resultados obtidos com a aplicação do algoritmo *Quantum Variational Regression* na detecção de anomalias em séries temporais do preço do Bitcoin. O principal objetivo é examinar e compreender o desempenho do modelo, identificando padrões recorrentes e eventos atípicos ao longo de diferentes períodos históricos dos dados financeiros. Essa abordagem permite avaliar a eficácia do QVR na modelagem de tendências do mercado e na antecipação de variações anômalas que possam impactar a dinâmica do Bitcoin.

4.1 DEFINIÇÃO DOS PERÍODOS DE ANÁLISE

A escolha dos períodos analisados foi fundamentada em eventos macroeconômicos e padrões de comportamento do mercado que influenciaram significativamente a volatilidade do Bitcoin. Os períodos selecionados foram:

- 2019 (referência histórica): esse ano foi escolhido por apresentar um período de relativa estabilidade antes da pandemia de COVID-19, o que permite utilizá-lo como um parâmetro de comportamento normal do mercado (Fig. 4.1).
- 2023 (referência moderna): considerado um período recente e relevante, 2023 apresentou menor volatilidade em comparação com 2022 e 2024, tornando-se uma base útil para comparar mudanças estruturais no mercado (Fig. 4.2).

Para ilustrar visualmente os períodos analisados, apresentamos as seguintes representações gráficas:

Figura 4.1: Evolução temporal do preço do Bitcoin considerando o ano de 2019 como referência.



Fonte: Elaborado pelo autor.

Figura 4.2: Evolução temporal do preço do Bitcoin considerado o ano 2023 como referência.



Fonte: Elaborado pelo autor.

Os gráficos acima destacam os períodos de referência escolhidos para o estudo. O primeiro gráfico evidencia os anos de 2018, 2019 (referência) e 2020, permitindo compreender as variações antes e depois da pandemia de COVID-19. O segundo gráfico destaca 2022, 2023 (referência) e 2024, possibilitando avaliar a evolução recente do mercado e a continuidade dos padrões identificados. Essas representações ajudam a visualizar de forma clara as mudanças estruturais do mercado ao longo do tempo.

A justificativa para a comparação desses períodos com seus predecessores e sucessores é a seguinte:

- 2019 vs. 2018: essa comparação permite avaliar se a estabilidade de 2019 já estava sendo construída em 2018 ou se ocorreram mudanças significativas no mercado. Além disso, 2018 marca um período de correção do mercado após a alta expressiva de 2017, sendo um momento de grande interesse para análise.
- 2019 vs. 2020: o objetivo dessa comparação é entender os impactos da pandemia sobre o Bitcoin, avaliando se a crise global alterou permanentemente a estrutura do mercado ou se os padrões anteriores foram retomados após a crise.
- 2023 vs. 2022: o mercado em 2022 foi caracterizado por uma elevada instabilidade e eventos regulatórios importantes. Compará-lo com 2023 ajuda a entender se houve uma normalização ou se a volatilidade ainda persistiu.
- 2023 vs. 2024: essa comparação busca avaliar a continuidade dos padrões

identificados em 2023 e verificar se o comportamento do mercado seguiu a mesma estrutura no ano seguinte.

4.2 FUNÇÃO DE PERDA:

O desempenho do modelo foi medido por meio da função de perda, que quantifica a capacidade do QVR de reconstruir séries temporais sem introduzir distorções significativas. A função de perda representa a diferença entre os valores previstos pelo modelo e os valores reais do mercado, sendo um indicador essencial para avaliar a precisão do aprendizado do QVR.

A fim de analisar detalhadamente o comportamento do modelo ao longo do tempo, calculamos a função de perda para cada mês dos períodos de referência, 2019 e 2023. Abaixo, apresentamos os valores médios obtidos para cada mês em ambos os anos.

Tabela 4.1: Evolução do indicador mensal de perda média ao longo do ano de 2019.

Mês	Perda Média
1	0.000329
2	0.000370
3	0.000909
4	0.007843
5	0.033135
6	0.065686
7	0.086606
8	0.086078
9	0.071818
10	0.048452
11	0.048104
12	0.031524

FONTE: Elaborado pelo autor.

Tabela 4.2: Evolução do indicador mensal de perda média ao longo do ano de 2023.

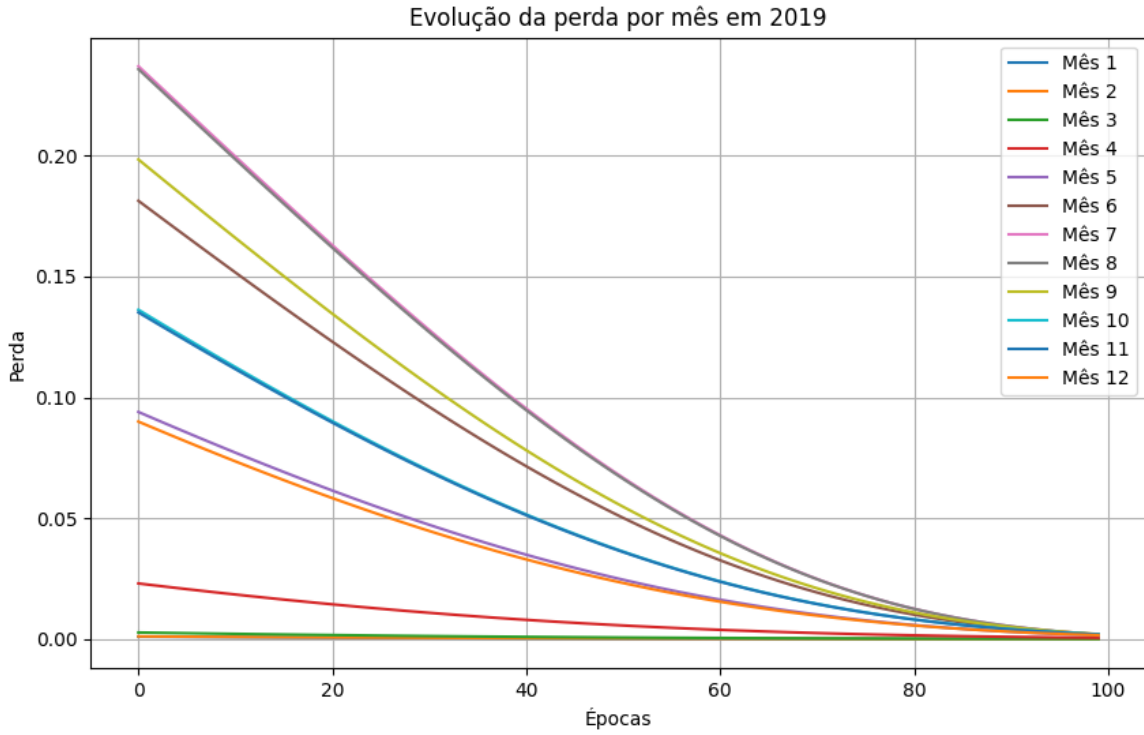
Mês	Perda Média
1	0.005829
2	0.012908
3	0.020922
4	0.037114
5	0.030365
6	0.032000
7	0.043307
8	0.032276
9	0.024786
10	0.042452
11	0.081234
12	0.118371

Fonte: Elaborado pelo autor

A análise dessas tabelas nos permite identificar padrões interessantes:


Os valores de perda em 2019 foram relativamente baixos, com um aumento gradual a partir do meio do ano, o que sugere que o modelo conseguiu capturar bem os padrões de um mercado relativamente estável. Já no ano de 2023, observamos valores de perda mais elevados em vários meses, especialmente no final do ano, sugerindo maior dificuldade do modelo em prever corretamente as oscilações recentes do mercado. Na sequência da análise quantitativa, apresentamos as curvas de evolução da perda para cada um dos meses em ambos os períodos analisados.

Figura 4.3 Evolução mensal da função de perda no ano de 2019.



Fonte: Elaborado pelo autor.

Figura 4.4 Evolução mensal da função de perda no ano de 2023.



Fonte: Elaborado pelo autor.

A análise dos gráficos reforça os padrões observados nas tabelas 4.1 e 4.2.

- Em 2019, a função de perda começou relativamente baixa para a maioria dos meses e convergiu de maneira estável, indicando que o modelo conseguiu capturar padrões consistentes do mercado pré-pandemia. Já em 2023, observamos uma variação maior na função de perda entre os diferentes meses, com picos iniciais mais altos e uma convergência mais lenta, sugerindo que a dinâmica do mercado recente pode ser mais difícil de modelar com precisão.
- Comportamento geral: em ambos os casos, a perda estabilizou-se após aproximadamente 80 épocas, indicando que o modelo conseguiu minimizar o erro ao longo das iterações. Para aprimorar a eficácia do QVR, foram exploradas diferentes combinações de hiperparâmetros buscando minimizar desvios e melhorar a precisão na detecção de anomalias. O ajuste fino da função de perda foi essencial para garantir que o modelo operasse de forma estável em diferentes cenários de mercado.

4.3 ANÁLISE COMPARATIVA


4.3.1 Considerando o ano de 2019 como referência

Para analisar a dinâmica do mercado ao redor do ano de 2019, realizamos comparações com os períodos adjacentes: 2018 (pré-referência) e 2020 (pós-referência). Essa abordagem permite avaliar as oscilações estruturais no comportamento do Bitcoin e identificar mudanças significativas antes e depois de um período considerado estável. A seguir, apresentamos uma análise detalhada dessas comparações, destacando os padrões identificados e as anomalias detectadas pelo modelo.

4.3.1.1 Comparação entre os anos de 2018 e 2019.

A comparação entre 2019 e 2018 permite avaliar a evolução estrutural do mercado e identificar se a estabilidade observada em 2019 já vinha sendo consolidada no ano anterior. O gráfico abaixo apresenta a trajetória do preço do Bitcoin em 2018 (linha azul) e a compara com o comportamento esperado para 2019 (linha vermelha tracejada), modelado a partir do QVR. Além disso, os pontos pretos representam as anomalias detectadas pelo modelo, que indicam desvios significativos em relação ao padrão de 2019. Esse método permite uma análise quantitativa das discrepâncias, destacando períodos de maior volatilidade e eventos de mercado atípicos.

Figura 4.5: Detecção de anomalias em 2018 considerando o ano de 2019 como referência.



FONTE: Elaborado pelo autor.

Analisando a Figura 4.5, observamos que:

- **Tendencia global:** em 2018, o Bitcoin passou por uma forte correção após o pico de 2017, registrando quedas acentuadas nos primeiros meses do ano. O modelo QVR detectou um grande número de anomalias no primeiro trimestre, refletindo a alta volatilidade do mercado nesse período. No segundo semestre de 2018, os preços começaram a se estabilizar, aproximando-se do padrão observado em 2019. No entanto, em novembro de 2018, um novo evento de queda acentuada foi identificado como anômalo, coincidindo com um crash documentado nesse período. A comparação entre os anos de 2018 e 2019 permite avaliar se a estabilidade observada em 2019 já vinha sendo construída no ano anterior.
- **Anomalias Detectadas:** em 2018, o mercado exibiu elevada volatilidade, particularmente no primeiro semestre, refletindo a forte correção após a bolha de 2017. O modelo identificou anomalias significativas nesse período, indicando oscilações abruptas nos preços. Durante o segundo semestre, as anomalias diminuíram gradativamente à medida que o mercado buscava uma estabilização, embora eventos isolados ainda tenham sido detectados, especialmente no final do ano, como a queda brusca observada em novembro de 2018.
- **Eventos Relevantes:** o primeiro semestre de 2018 foi marcado por forte volatilidade e uma série de eventos que impactaram diretamente o preço do Bitcoin. Entre janeiro e fevereiro, o mercado passou por um período de correção acentuada após o pico histórico de dezembro de 2017. Esse movimento gerou uma liquidação massiva de ativos, aumentando a incerteza entre investidores. Paralelamente, reguladores

globais intensificaram o debate sobre a regulamentação das criptomoedas, com destaque para medidas implementadas na China e na Coreia do Sul, que restringiram transações e limitaram o acesso de investidores estrangeiros às *exchanges* locais. Essas ações ampliaram a pressão vendedora e resultaram na detecção de diversas anomalias pelo modelo QVR.

- Em março: novas restrições impactaram o mercado, como a proibição de anúncios relacionados a criptomoedas por grandes empresas de tecnologia, incluindo Facebook e Google. Essa decisão reduziu a visibilidade de projetos no setor e afetou a captação de novos investidores, intensificando a queda dos preços. No segundo trimestre, a volatilidade permaneceu elevada devido ao fechamento de grandes *exchanges* na Ásia e à contínua incerteza regulatória global. No entanto, no segundo semestre, o mercado iniciou uma fase de estabilização gradual, exceto por novembro, que registrou uma nova queda abrupta associada ao *hard fork* do Bitcoin Cash e ao aumento das pressões regulatórias internacionais. Esse evento marcou uma das quedas mais expressivas do Bitcoin desde 2017, rompendo níveis críticos de suporte e atingindo patamares abaixo de US\$ 4.000. O modelo QVR identificou esse período como uma das principais anomalias do ano.


4.3.1.2 Comparação entre os anos de 2020 e 2019.

Para avaliar o impacto da pandemia de COVID-19 no mercado de Bitcoin, comparamos a evolução dos preços em 2020 com o comportamento registrado em 2019. Essa análise é essencial para entender como eventos globais inesperados podem alterar a estrutura do mercado e gerar anomalias significativas na série temporal.

Visualização e anomalias detectadas: a Figura 4.6 apresenta a evolução

dos preços do Bitcoin em 2020 (linha azul) em relação ao comportamento esperado com base no modelo de referência de 2019 (linha vermelha tracejada). Os pontos pretos indicam as anomalias detectadas pelo modelo, ou seja, momentos em que os preços se desviaram significativamente da tendência projetada.

Figura 4.6: Detecção de anomalias em 2020 considerando o ano de 2019 como referência.



Fonte: Elaborado pelo autor.

Interpretação das anomalias detectadas:

- O Bitcoin iniciou 2020 em alta, impulsionado por um sentimento otimista e crescente interesse institucional. Tensões geopolíticas, como o aumento do conflito entre EUA e Irã, levaram investidores a buscar ativos alternativos, elevando temporariamente o preço do Bitcoin. Em fevereiro, a criptomoeda atingiu US\$ 10.000, mas começou a apresentar volatilidade atípica, capturada pelo modelo como anomalias.

- Em março, a pandemia de COVID-19 desencadeou um pânico financeiro global, levando os mercados tradicionais e o Bitcoin a quedas históricas. O gráfico destaca uma forte anomalia negativa em 12 de março de 2020, data conhecida como a “Quinta-feira Negra das Criptomoedas”, quando liquidações em massa fizeram o preço despencar de US\$ 8.000 para menos de US\$ 4.000 em poucos dias.
- Após a forte queda, o Bitcoin iniciou uma recuperação acelerada, com anomalias positivas detectadas entre abril e junho. Esse movimento foi impulsionado por pacotes de estímulo econômico dos bancos centrais, principalmente do Federal Reserve dos EUA, que injetou liquidez na economia. Além disso, em maio ocorreu o *halving* do Bitcoin, evento que reduziu a recompensa dos mineradores, historicamente associado a novos ciclos de alta.
- A partir de outubro, o modelo identificou anomalias positivas expressivas, coincidindo com a entrada de investidores institucionais no mercado. Empresas como MicroStrategy e Tesla começaram a alocar parte de seus ativos em Bitcoin, impulsionando a demanda. Em dezembro, o Bitcoin rompeu a marca de US\$ 20.000 pela primeira vez desde 2017, sinalizando um novo ciclo de valorização. O gráfico evidencia múltiplas anomalias nesse período, refletindo uma alta acelerada do preço, muito além do padrão previsto pelo modelo baseado em 2019.

4.3.2 Considerando o ano 2023 como referência

Para compreender a dinâmica do mercado ao longo do ano de 2023, investigamos sua relação com os períodos 2022 (pré-referência) e 2024 (pós-referência). O objetivo dessa análise é identificar padrões de comportamento distintos e avaliar como fatores


macroeconômicos, eventos regulatórios e tendências do mercado impactaram a trajetória do Bitcoin. A seguir, detalhamos as principais anomalias detectadas e os insights obtidos a partir da comparação entre esses períodos.

4.3.2.1 Comparação entre os anos 2023 e 2022.

O Bitcoin apresentou mudanças significativas entre 2022 e 2023, refletindo um período de estabilização após a forte volatilidade enfrentada no ano anterior. A análise comparativa permite identificar padrões de mercado distintos e entender a transição entre os dois anos.

A Figura 4.7 ilustra a evolução do Bitcoin em 2023 (linha azul) em relação ao padrão projetado com base em 2022 (linha vermelha tracejada). Os pontos pretos indicam as anomalias detectadas, ou seja, desvios significativos em relação ao comportamento esperado.

Figura 4.7: Detecção de anomalias em 2023 considerando o ano 2022 como referência.



Fonte: Elaborado pelo autor.

Interpretação das Anomalias Detectadas:

No início de 2022, o Bitcoin apresentou valores significativamente superiores ao padrão de 2023, ultrapassando US\$ 45.000. O modelo QVR identificou múltiplas anomalias nesse período, refletindo uma volatilidade extrema no mercado. Essa oscilação pode ser atribuída a fatores macroeconômicos, como:

- Aumento das taxas de juros pelo Federal Reserve dos EUA, reduzindo a liquidez nos mercados financeiros e impactando ativos de risco, incluindo o Bitcoin.
- Crise geopolítica na Ucrânia (fevereiro de 2022), que gerou incerteza global e deslocou o capital para ativos considerados mais seguros, como ouro e dólar.

Em maio de 2022, o Bitcoin sofreu uma queda acentuada, passando de US\$ 40.000 para menos de US\$ 30.000. No entanto, o modelo QVR não identificou esse movimento como uma anomalia, possivelmente porque o preço real (linha azul) se aproximou do comportamento do mercado representado pela linha verde, resultando em um desvio abaixo do limiar necessário para ser considerado uma anomalia.


Durante a segunda metade de 2022, o preço do Bitcoin permaneceu em níveis mais baixos, com menor volatilidade do que no primeiro semestre. Apesar disso, o modelo ainda identificou anomalias no final do ano, pois o mercado operou abaixo do padrão estabelecido para 2023. Esse período coincidiu com o colapso da *exchange* FTX

em novembro de 2022, que desencadeou novas quedas e intensificou o sentimento negativo no setor.

4.3.2.2 Comparação entre os anos de 2024 e 2022

A figura 4.8 apresenta a comparação entre o preço do Bitcoin em 2024 (linha azul) e o padrão de 2023 (linha vermelha tracejada), junto com o preço real de 2023 (linha verde). Os pontos pretos representam as anomalias detectadas pelo modelo QVR, indicando momentos em que o comportamento do Bitcoin em 2024 se desviou significativamente do padrão estabelecido pelo modelo com base em 2023.

Figura 4.8: Detecção de anomalias em 2024 considerando o ano de 2023 como referência.



Fonte: Elaborado pelo autor.

Interpretação das Anomalias detectadas:

Desde o início de 2024, o modelo QVR identificou múltiplas anomalias, sugerindo um comportamento de mercado significativamente diferente do padrão de 2023. Já em janeiro, o Bitcoin apresentou oscilações acima do esperado, marcando um início de ano atípico. A partir de fevereiro, essa divergência se intensificou, com uma valorização acelerada que resultou na formação de diversas anomalias ao longo do período.

O modelo identificou múltiplas anomalias entre fevereiro e março, período em que o Bitcoin ultrapassou US\$ 50.000, muito acima do comportamento esperado. Esse aumento pode estar relacionado a fatores como:

- Expectativas sobre o *halving* do Bitcoin (previsto para abril de 2024), levando a um aumento na demanda antecipada.
- Fluxos institucionais elevados, possivelmente impulsionados pela aprovação de ETFs de Bitcoin à vista nos EUA.

Entre abril e setembro, o preço do Bitcoin manteve um patamar elevado, mas com variações bruscas em torno dos US\$ 60.000 a US\$ 70.000, gerando anomalias intermitentes. A presença dessas anomalias pode estar associada a:

- Ajustes pós-*halving*, que normalmente afetam a taxa de emissão de novos Bitcoins e geram incerteza de curto prazo no mercado.
- Impactos macroeconômicos e regulatórios, incluindo possíveis mudanças nas políticas de juros ou regulamentações para ativos digitais.

No último trimestre do ano, o Bitcoin apresentou uma nova tendência de alta acentuada, superando US\$ 100.000 pela primeira vez.

O modelo QVR detectou uma grande concentração de anomalias, indicando que o comportamento do Bitcoin se distanciou completamente do padrão de 2023. Possíveis explicações para essa valorização incluem:

- Expansão da adoção institucional e maior participação de grandes players financeiros.
- Redução da oferta circulante de Bitcoin pós-halving, aumentando a pressão de compra.
- Cenário macroeconômico favorável ao Bitcoin, como políticas monetárias mais flexíveis ou aumento da inflação.

4.4 ANÁLISE DO COEFICIENTE DE PEARSON

4.4.1 Coeficiente de Pearson para o período de referência 2019


A tabela 4.3 apresenta os coeficientes de correlação de Pearson calculados mês a mês para os respectivos anos de referência. Na sequência, a Figura 4.9 exibe a representação gráfica das correlações observadas entre os anos de 2018 e 2019, enquanto a Figura 4.10 ilustra a comparação entre 2019 e 2020. Essas representações visuais permitem uma análise mais clara das tendências identificadas pelos coeficientes de Pearson, facilitando a interpretação da dinâmica dos preços do Bitcoin ao longo dos períodos analisados.

Tabela 4.3: Valores mensais do Coeficiente de Pearson para as comparações entre os anos de 2018 vs. 2019 e 2020 vs. 2019.

Mês	Pearson (2018 vs 2019)	Pearson (2020 vs 2019)
1	0.00	-0.747370
2	0.00	-0.088904
3	0.00	-0.627251
4	0.57	0.446355
5	-0.89	0.167636
6	-0.78	-0.686899
7	-0.73	-0.548907
8	-0.21	0.007989
9	0.06	-0.228681
10	-0.30	0.508980
11	0.76	-0.874882
12	0.26	-0.137057


Fonte: Elaborado pelo autor.

Figura 4.9: Correlação mensal entre os anos de 2018 e 2019.



Fonte: Elaborado pelo autor.

Figura 4.10: Correlação mensal entre os anos de 2020 e 2019.



Fonte: Elaborado pelo autor.

4.4.1.1 Comparação entre os anos de 2018 e 2019.

A tabela 4.3 e a Figura 4.9 apresentam os coeficientes de Pearson calculados mensalmente para comparar os padrões de preço do Bitcoin entre 2018 e 2019. A correlação foi variável ao longo do período, refletindo a dinâmica distinta de cada ano.

Interpretação dos Resultados:

- No primeiro trimestre (janeiro a março): correlação inexistente (0.00). Durante esse período, não há relação estatística entre os anos, indicando que os mercados operaram sob condições distintas.
- Em abril: correlação moderada positiva (0.57). Indica um breve alinhamento dos preços, possivelmente associado à estabilização do mercado em ambos os anos.
- De maio a julho: correlação fortemente negativa (-0.89 a -0.73). Esses valores demonstram uma inversão de tendência, sugerindo que os preços em 2018 e 2019

se moveram em direções opostas.

- De agosto a outubro: redução da divergência (-0.21 a 0.06). Esse período apresenta uma oscilação em torno de valores próximos a zero, sinalizando menor impacto de eventos comuns entre os anos.
- Em novembro e dezembro: correlação positiva crescente (0.76 e 0.26). No final de 2018, os preços começaram a apresentar maior similaridade com 2019, sugerindo uma convergência nos padrões de mercado.

4.4.1.2 Comparação entre os anos de 2019 e 2020.

A tabela 4.3 e a figura 4.10 apresentam os coeficientes de Pearson mensais para comparar os padrões de preço do Bitcoin entre 2020 e 2019. A correlação variou significativamente ao longo do ano, refletindo os impactos da pandemia da COVID-19 e eventos macroeconômicos que afetaram o mercado financeiro.

Interpretação dos Resultados:

- Primeiro trimestre (janeiro a março): correlação negativa intensa (-0.75 a -0.63). Esse período foi marcado pelo choque inicial da pandemia da COVID-19, resultando em grande volatilidade e desvios acentuados entre os dois anos.
- Abril: correlação moderada positiva (0.45). indica um breve alinhamento dos preços, possivelmente associado à recuperação inicial do mercado após as medidas de estímulo econômico.
- Maio e junho: correlação instável (0.17 e -0.69)
- A correlação voltou a cair, refletindo a incerteza do mercado e o impacto da crise global sobre ativos especulativos como o Bitcoin.

- Julho a setembro: correlação reduzida (-0.55 a 0.01). Esse período apresentou uma oscilação em torno de valores baixos, sugerindo que os fatores estruturais de 2020 estavam divergindo do padrão observado em 2019.
- Outubro e novembro: movimentos opostos (0.51 e -0.87). Em outubro, o mercado apresentou um breve alinhamento, mas em novembro, a forte correlação negativa reflete a disparada do preço do Bitcoin em 2020, impulsionada pela adoção institucional e novos fluxos de capital.
- Dezembro: correlação levemente negativa (-0.14). O mercado seguiu sua nova trajetória ascendente, mantendo-se desconectado do padrão observado em 2019.

4.4.2 Coeficiente de Pearson para o período de referência 2023

A tabela a seguir apresenta os coeficientes de correlação de Pearson calculados mensalmente para analisar a relação entre os padrões de preço do Bitcoin nos anos de 2022 e 2023, bem como entre 2023 e 2024.

Tabela 4.4: valores mensais do Coeficiente de Pearson para as comparações entre os anos de 2023 vs. 2022 e 2023 vs. 2024

Mês	Pearson (2022 vs 2023)	Pearson (2024 vs 2023)
1	-0.820184	-0.340257
2	-0.513400	0.520389
3	0.650561	0.770412
4	-0.363104	0.850184
5	0.838161	0.820512
6	-0.533386	0.810394
7	-0.767727	0.860248
8	0.785526	0.820135
9	-0.519125	0.790614
10	0.696882	0.820573
11	-0.781117	0.930812

12	0.023576	0.450271
-----------	----------	----------

Fonte: Elaborado pelo autor.

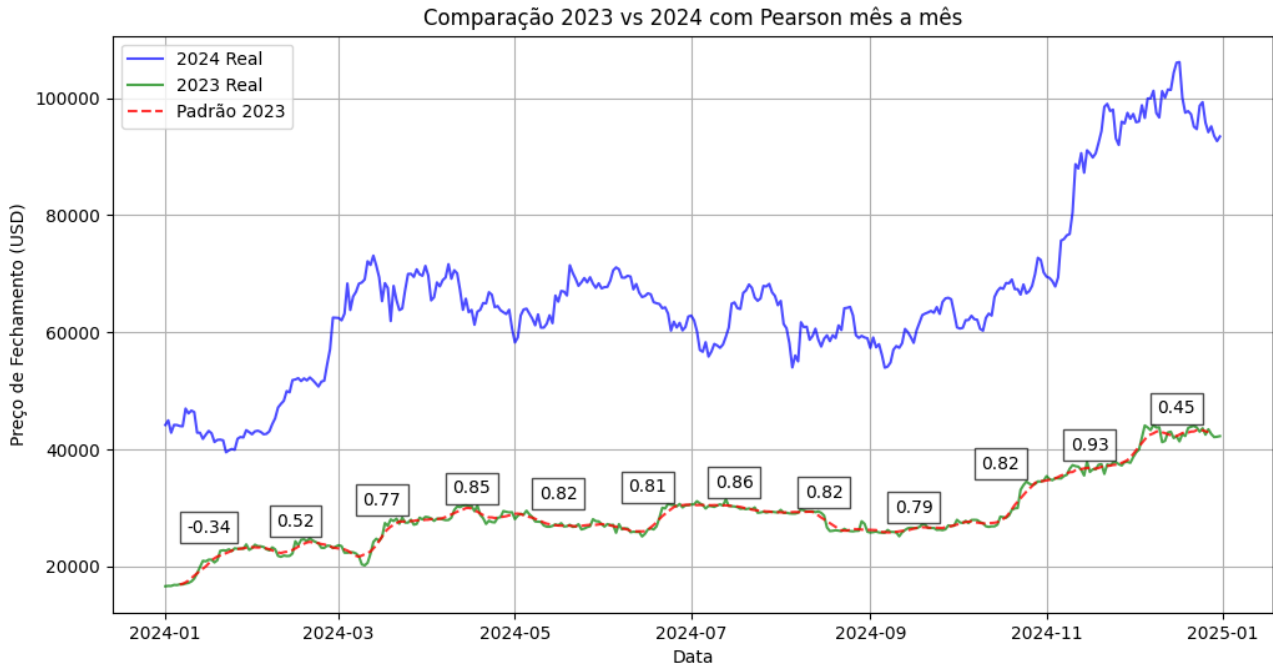
Na sequência, são apresentadas as representações gráficas das correlações observadas entre os anos de 2022 e 2023 (Figura 4.11), assim como entre 2023 e 2024 (Figura 4.12), permitindo uma análise visual das tendências identificadas pelos coeficientes de Pearson.

Figura 4.11: Correlação mensal entre os anos de 2022 e 2023.



Fonte: Elaborado pelo Autor.

Figura 4.12: Correlação mensal entre os anos de 2024 e 2023.



Fonte: Elaborado pelo Autor.

4.4.2.1 Comparação entre os anos de 2022 e 2023

Tabela 4.4 e a Figura 4.11 apresentam os coeficientes de Pearson calculados mensalmente para comparar os padrões de preço do Bitcoin entre 2023 e 2022. Os valores indicam uma correlação instável ao longo do período, refletindo a natureza volátil do mercado e as mudanças estruturais ocorridas entre esses anos.

Interpretação dos Resultados:

- No primeiro semestre (janeiro a junho): correlações predominantemente negativas. Os coeficientes mostram valores negativos, atingindo um mínimo de -0.82 em janeiro e -0.77 em julho. Isso indica que os preços em 2023 e 2022 seguiram direções opostas na maior parte do primeiro semestre. Eventos macroeconômicos, como mudanças na política monetária global e oscilações na adoção institucional do Bitcoin, podem ter contribuído para essa divergência.
- No segundo semestre (julho a dezembro): oscilações e menor divergência. A

correlação começa a se tornar positiva a partir de agosto (0.79), sugerindo uma aproximação entre os preços dos dois anos. Esse comportamento pode estar relacionado a padrões sazonais no mercado de criptomoedas e ao aumento do interesse institucional. Em novembro (-0.78) e dezembro (0.02): divergência no final do ano. Enquanto outubro e novembro ainda apresentaram forte correlação negativa, dezembro indicou uma correlação quase neutra. Isso sugere que, no final de 2023, o Bitcoin começou a se distanciar das dinâmicas de 2022, possivelmente devido a novos fatores que impulsionaram o mercado.

4.4.2.2 Comparação entre os anos de 2024 e 2023

A Tabela 4.4 e a Figura 4.12 apresentam os coeficientes de Pearson calculados mensalmente para comparar os padrões de preço do Bitcoin entre 2023 e 2024. Essa análise busca avaliar o grau de repetição dos ciclos de mercado e identificar possíveis padrões recorrentes.

Interpretação dos Resultados:

- No primeiro trimestre (janeiro a março): correlação inicial fraca. A correlação inicia negativa em janeiro -0.34, mas rapidamente sobe para 0.52 em fevereiro e 0.77 em março. Isso indica que, no início de 2024, os preços ainda não seguiam o padrão de 2023, mas a similaridade aumentou rapidamente.
- No segundo trimestre (abril a junho): correlação alta e estável. Os coeficientes se mantêm acima de 0.80, sugerindo que o comportamento dos preços nesses meses foi muito semelhante ao de 2023. Essa estabilidade pode estar relacionada a fatores estruturais do mercado, como períodos de baixa volatilidade e ciclos de liquidez previsíveis.
- No terceiro trimestre (julho a setembro): pequenas variações, mas manutenção da correlação elevada. Com valores entre 0.79 e 0.86, o mercado manteve uma estrutura altamente similar à de 2023.

- No quarto trimestre (outubro a dezembro): correlação extremamente alta em novembro 0.93. A alta correlação sugere que 2024 seguiu de perto o padrão de 2023, especialmente no final do ano. Isso pode indicar repetição de padrões cíclicos, possivelmente devido a comportamentos especulativos e fatores macroeconômicos previsíveis.

5. CONSIDERAÇÕES FINAIS.

Este estudo investigou a aplicação do *Quantum Variational Rewinding* (QVR) na detecção de anomalias em séries temporais do Bitcoin, utilizando abordagens comparativas entre diferentes períodos históricos. A metodologia empregada envolveu o desenvolvimento de um modelo de aprendizado de máquina quântico para identificar padrões atípicos nos preços da criptomoeda, analisando suas causas subjacentes e impactos no mercado financeiro. A análise dos resultados obtidos demonstrou a capacidade do QVR em identificar eventos de alta volatilidade e choques exógenos no mercado, reforçando a eficiência da abordagem para capturar padrões não convencionais nos dados históricos do Bitcoin.

Na sequência, o desempenho da abordagem QVR foi validado ao longo do estudo, com a identificação de anomalias significativas, tais como a crise da COVID-19 em 2020, o colapso da FTX em 2022 e a crescente adoção institucional do Bitcoin entre 2020 e 2024. Além disso, a análise da função de perda demonstrou que, após o ajuste adequado de hiperparâmetros, o modelo conseguiu reconstruir padrões de referência com alta precisão, consolidando sua confiabilidade na detecção de padrões atípicos.

Ao comparar diferentes períodos, observou-se que a relação entre 2019 e 2018 apresentou trajetórias divergentes no comportamento dos preços do Bitcoin, especialmente de maio a julho. A análise entre 2019 e 2020 destacou uma forte correlação negativa no primeiro trimestre, refletindo o impacto da pandemia e sua subsequente recuperação gradual. Já a relação entre 2023 e 2022 revelou uma instabilidade acentuada, sugerindo mudanças estruturais significativas no mercado. Em contraste, a correlação entre 2023 e 2024 apresentou valores elevados, particularmente no segundo semestre,

sugerindo a repetição de ciclos de mercado.

Por sua vez, o coeficiente de Pearson foi essencial para quantificar a relação linear entre os preços de fechamento nos diferentes períodos analisados. Observou-se que determinados períodos apresentaram forte alinhamento nos preços, enquanto outros indicaram movimentos opostos. Destaca-se que a correlação entre 2023 e 2024 foi a mais alta, sugerindo a presença de ciclos recorrentes no comportamento do mercado. Por outro lado, a relação entre 2020 e 2019 apresentou correlação altamente negativa no primeiro trimestre, refletindo a volatilidade induzida pela crise sanitária global.

De modo geral, o estudo demonstrou que modelos quânticos de aprendizado de máquina têm grande potencial na análise de séries temporais financeiras, oferecendo uma abordagem alternativa para a identificação de padrões e previsão de tendências. Embora existam métodos tradicionais para esse tipo de análise, a computação quântica pode trazer vantagens em cenários de alta complexidade, explorando propriedades como a superposição e a interferência quântica. A detecção de anomalias via QVR pode beneficiar *traders*, instituições financeiras e pesquisadores, fornecendo insights sobre riscos e oportunidades de mercado. Além disso, a análise estatística (especialmente com a utilização do coeficiente de Pearson) mostrou-se uma ferramenta valiosa para avaliar a similaridade entre diferentes contextos de mercado.

No entanto, algumas limitações foram identificadas. A dependência do modelo em relação ao período de referência pode influenciar os resultados obtidos, e a sensibilidade do QVR a eventos macroeconômicos extremos requer refinamento na modelagem. Para estudos futuros, sugere-se a exploração do QVR em outros mercados

financeiros (como ações e *commodities*), bem como a integração de dados macroeconômicos e indicadores financeiros à modelagem. Além disso, a combinação do QVR com outros métodos de *machine learning* pode aprimorar a precisão das previsões e ampliar sua aplicabilidade.

Os resultados obtidos evidenciaram que a modelagem baseada em QVR é uma abordagem robusta para análise de séries temporais e detecção de anomalias no mercado de criptomoedas. De modo específico, a identificação de padrões recorrentes e a influência de eventos externos reforçam a relevância da abordagem empregada.

REFERÊNCIAS

- JOHN, Kose; O'HARA, Maureen; SALEH, Fahad. **Bitcoin and Beyond. *Annual Review of Financial Economics***, v. 14, p. 95–115, 2022. Disponível em: <https://doi.org/10.1146/annurev-financial-111620-011240>. Acesso em: 13 jan. 2025.
- SVERIGES RIKSBANK. ***Economic Review 2014:2***. Publisher: Claes Berg. Editors: Claes Berg, Tomas Edlund, Kristian Jönsson, Cecilia Roos-Isaksson and the Communications Division. SE-103 37 Stockholm, Sweden: Sveriges Riksbank, 2014. ISSN 2001-029X. Disponível em: <https://www.riksbank.se/en/Press-and-published/Reports/Economic-Review>. Acesso em: 6 jan. 2025.
- D I PIERRO, M. **What Is the Blockchain? *Computing in Science & Engineering***, v. 19, n. 5, p. 92–94, 2017. Disponível em: <https://doi.org/10.1109/MCSE.2017.3571551>. Acesso em: 6 jan. 2025.
- NAKAMOTO, S. ***Bitcoin: A Peer-to-Peer Electronic Cash System***. 2008. Disponível em: <https://bitcoin.org/bitcoin.pdf>. Acesso em: 14 jan. 2025.
- GÜRER, Denise. **Pioneering women in computer science. *ACM SIGCSE Bulletin***, v. 34, n. 2, p. 175-180, 2002.
- NIELSEN, Michael A.; CHUANG, Isaac L. **Quantum computation and quantum information. *Physics Today***, v. 54, p. 60-62, 2001.
- ALPAYDIN, Ethem. ***Introduction to Machine Learning***. 2. ed. Cambridge: The MIT Press, 2010.
- MITCHELL, Tom M. ***Machine Learning***. New York: McGraw-Hill, 1997.
- SUTTON, Richard S.; BARTO, Andrew G. ***Reinforcement Learning: An Introduction***. 2. ed. Cambridge: The MIT Press, 2018.
- BISHOP, Christopher M. ***Pattern Recognition and Machine Learning***. New York: Springer, 2006.
- GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. ***Deep Learning***. Cambridge: The MIT Press, 2016.
- DOMINGOS, Pedro. ***The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World***. New York: Basic Books, 2015.
- MURPHY, Kevin P. ***Machine Learning: A Probabilistic Perspective***. Cambridge: The MIT Press, 2012.
- LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. **"Deep Learning."** *Nature*, v. 521, p. 436-444, 2015.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. ***The Elements of Statistical Learning: Data Mining, Inference, and Prediction***. 2. ed. New York: Springer, 2009.

PEDREGOSA, Fabian; VAROQUAUX, Gaël; GRAMFORT, Alexandre; et al. Scikit-learn: **Machine Learning in Python**. *Journal of Machine Learning Research*, v. 12, p. 2825-2830, 2011. Disponível em: <http://jmlr.org/papers/v12/pedregosa11a.html>. Acesso em: 15 jan. 2025.

MÜLLER, Andreas C.; GUIDO, Sarah. ***Introduction to Machine Learning with Python***. 1st ed. O'Reilly Media, 2016.

SAKURAI, Jun John; COMMINS, Eugene D. **Modern quantum mechanics, revised edition**. [S.I.]: American Association of Physics Teachers, 1995.

IBM. **O que é o bosque aleatório?** Disponível em: <https://www.ibm.com/mx-es/topics/random-forest>. Acesso em: 20 jan. 2025.

PADILLA-OSPINA, Ana Milena; MEDINA-VÁSQUEZ, Javier Enrique; OSPINA-HOLGUÍN, Javier Humberto. **Métodos de aprendizado automático em estudos prospectivos desde um exemplo de financiamento da inovação na Colômbia**. *Revista Investigación, Desarrollo e Innovación*, v. 11, n. 1, p. 9-21, 2020.

BELL, J. S. On the Einstein Podolsky Rosen paradox. *Physics Physique Физика*, v. 1, n. 3, p. 195-200, 1964.

EINSTEIN, A.; PODOLSKY, B.; ROSEN, N. **Can quantum-mechanical description of physical reality be considered complete?** *Physical Review*, v. 47, n. 10, p. 777, 1935.

ANTONOPOULOS, Andreas. ***Mastering Bitcoin: Unlocking Digital Cryptocurrencies***. 2. ed. Sebastopol: O'Reilly Media, 2017.

HULL, John C. ***Opções, futuros e outros derivativos***. 10. ed. São Paulo: Pearson, 2022.

SHIMON, Goldstein. **Comparação de volatilidade entre Bitcoin, ouro e S&P 500**. *Journal of Financial Markets*, v. 35, p. 150-165, 2023.

BAKER, J. S. et al. **Quantum variational rewinding for time series anomaly detection**. *arXiv preprint arXiv:2210.16438*, 2022. Disponível em: <https://arxiv.org/abs/2210.16438>. Acesso em: 20 dez. 2024.

PENNYLANE AI. ***Univariate Quantum Variational Rewinding***. 2024. Disponível em: https://pennylane.ai/qml/demos/tutorial_univariate_qvr. Acesso em: 6 jan. 2025.

ALVES, V. H. M.; GOMES, R. F. I.; CURY, A. **New perspectives on structural health monitoring using unsupervised quantum machine learning. Mechanical Systems and Signal Processing**, v. 229, p. 112489, 2025. Disponível em: <https://doi.org/10.1016/j.ymssp.2025.112489>.

PENNYLANE. **PennyLane Documentation**. Disponível em: <https://pennylane.ai/>. Acesso em: 19 mar. 2025.

PYTORCH. **PyTorch Documentation**. Disponível em: <https://pytorch.org/>. Acesso em: 19 mar. 2025.

PANDA. **Pandas Documentation**. Disponível em: <https://pandas.pydata.org/>. Acesso em: 19 mar. 2025.

NUMPY. **NumPy Documentation**. Disponível em: <https://numpy.org/>. Acesso em: 19 mar. 2025.

MATPLOTLIB. **Matplotlib Documentation**. Disponível em: <https://matplotlib.org/>. Acesso em: 19 mar. 2025.

SEABORN. **Seaborn Documentation**. Disponível em: <https://seaborn.pydata.org/>. Acesso em: 19 mar. 2025.

YFINANCE. **YFinance Documentation**. Disponível em: <https://pypi.org/project/yfinance/>. Acesso em: 19 mar. 2025.

SCIKIT-LEARN DEVELOPERS. **MinMaxScaler. Scikit-learn**, 2024. Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html>. Acesso em: 19 mar. 2025.

Hernández Lalinde, J. D., Espinosa Castro, F., Rodríguez, J. E., Chacón Rangel, J. G., Toloza Sierra, C. A., Arenas Torrado, M. K., Carrillo Sierra, S. M., & Bermúdez Pirela, V. J. (2018). **Sobre el uso adecuado del coeficiente de correlación de Pearson: definición, propiedades y suposiciones**. Archivos Venezolanos de Farmacología y Terapéutica, 37(5). Disponible en: <https://www.redalyc.org/articulo.oa?id=55963207025>

BARENCO, A.; BENNETT, C. H.; CLEVE, R.; DIVINCENZO, D. P.; MARGOLUS, N.; SHOR, P.; SLEATOR, T.; SMOLIN, J. A.; WEINFURTER, H. **Elementary gates for quantum computation**. Phys. Rev. A, v. 52, p. 3457, 1995.

BERNSTEIN, E.; VAZIRANI, U. Quantum complexity theory. **SIAM Journal on Computing**, v. 26, p. 1411, 1997.

BOULAND, A.; FEFFERMAN, B.; NIRKHE, C.; VAZIRANI, U. **On the complexity and verification of quantum random circuit sampling**. Nature Physics, v. 15, p. 159, 2019.

APÊNDICE A – REGRAS FUNDAMENTAIS DA MECÂNICA QUÂNTICA

A Mecânica Quântica é baseada em um conjunto de postulados fundamentais que definem a estrutura matemática e as propriedades dos sistemas quânticos. A seguir, detalhamos os postulados mais importantes:

1. Estados Quânticos e Espaços de Hilbert:

O estado de um sistema quântico é descrito por um vetor unitário complexo que reside em um espaço de Hilbert, onde o sistema pode ser associado a uma função de onda $|\psi\rangle$ tal que:

$$\langle\psi|\psi\rangle = 1.$$

Se dois estados quânticos distintos $|\psi_i\rangle$ e $|\psi_j\rangle$ pertencem a uma base vetorial ortonormal, a condição $\langle\psi_i|\psi_j\rangle = 0$ para $i \neq j$ garante que ambos serão mutuamente excludentes.

2. Observáveis e Operadores Hermitianos:

Todo observável físico está associado a um operador hermitiano A que atua no espaço de Hilbert. Os autovalores de A são números reais que representam os possíveis resultados de uma medição e obedecem à relação dada por:

$$A|a_i\rangle = a_i|a_i\rangle,$$

onde $|a_i\rangle$ são os autovetores associados aos autovalores a_i . Por sua vez, se um estado quântico $|\psi\rangle$ arbitrário for expresso em uma base ortonormal $\{|a_i\rangle\}$, a probabilidade de se obter o estado $|a_i\rangle$ após a ação de um observável A sobre $|\psi\rangle$ é dada por:

$$P(a_1) = |\langle a_1|\psi\rangle|^2.$$

3. Medição Quântica e o Colapso do Estado:

Se o resultado da medição de um estado quântico $|\psi\rangle$ arbitrário expresso em uma base ortonormal $\{|a_i\rangle\}$ for dado pelo autovalor a_i , o sistema irá colapsar para o respectivo autoestado

$$|\psi'\rangle = |a_i\rangle$$

após a medição.

4. Evolução Temporal e a Equação de Schrödinger:

A evolução de um sistema quântico isolado é descrita pela equação de Schrödinger:

$$i\hbar \frac{d}{dt} |\psi(t)\rangle = H |\psi(t)\rangle,$$

onde H é o Hamiltoniano do sistema. A solução para essa equação é dada por:

$$|\psi(t)\rangle = e^{-iHt/\hbar} |\psi(0)\rangle,$$

cujas dinâmicas garantem que a evolução do sistema é unitária.

5. Sistemas Compostos e Emaranhamento:

O estado de um sistema de múltiplos qubits é descrito pelo produto tensorial de seus respectivos subsistemas:

$$|\psi\rangle = |\psi_1\rangle \otimes |\psi_2\rangle \otimes \dots \otimes |\psi_n\rangle.$$

Consequentemente, estados emaranhados (como os constituintes da base de Bell) não podem ser escritos como um produto de sistemas individuais. Esse fenômeno é essencial para a implementação dos principais protocolos de transmissão de informação quântica (como o teletransporte quântico e a criptografia quântica).

6. Princípio da Incerteza de Heisenberg:

Dois observáveis representados por operadores A e B satisfazem a relação de comutação dada por:

$$[A, B] = AB - BA = i\hbar C,$$

Neste caso, a incerteza associada às medidas de A e B obedece ao Princípio de Heisenberg:

$$\sigma_a \sigma_b \geq \frac{\hbar}{2} |\langle C \rangle|,$$

o qual estabelece limites para a precisão que define se certas grandezas físicas podem ser medidas simultaneamente.

APÊNDICE B – MACHINE LEARNING

O campo de Machine Learning tem suas raízes em diversas disciplinas, como Estatística, Psicologia, Inteligência Artificial e Biologia. Cada uma dessas áreas trouxe contribuições únicas que convergiram para formar uma disciplina sólida e em constante evolução.

Neste capítulo, exploraremos os conceitos fundamentais de *Machine Learning* e suas aplicações práticas. Vamos discutir como essa tecnologia se tornou uma ferramenta indispensável para resolver problemas complexos em diversas áreas, incluindo a detecção de anomalias em séries temporais. Além disso, serão apresentados os principais tipos de aprendizado de máquina, seus componentes e os desafios enfrentados na implementação, destacando a relevância do tema para o contexto deste trabalho.

DEFINIÇÃO

O Aprendizado de Máquina (*Machine Learning*) é a área da Ciência da Computação que busca programar computadores para otimizar um critério de desempenho a partir de dados de exemplo ou experiências passadas. Em termos práticos, trata-se de construir modelos matemáticos que sejam capazes de fazer interferências ou previsões com base em padrões detectados nos dados.

De acordo com Alpaydin (2010), o aprendizado de máquina “consiste em programar computadores para otimizar parâmetros de um modelo usando dados de treinamento ou experiências passadas”. Em outras palavras, em vez de programar explicitamente uma solução para cada problema, utilizamos algoritmos que aprendem a partir dos dados para encontrar padrões e regularidades.

O conceito de *Machine Learning* é essencial em problemas onde a relação

entre a entrada e a saída pode ser definida através de um algoritmo tradicional. Exemplos incluem a classificação de e-mails como spam ou não, a previsão de comportamento de consumidores em grandes bases de dados ou o reconhecimento de rostos em imagens. Nestes casos, o algoritmos de aprendizado são desenvolvidos para detectar padrões nos dados, criar aproximações úteis e permitir que sistemas computacionais tomem decisões ou façam previsões com base nesses padrões.

CATEGORIAS DE MACHINE LEARNING

Machine Learning pode ser dividido em três categorias principais, dependendo do tipo de dados e do problema a ser resolvido. A seguir, exploramos cada uma dessas categorias com suas respectivas características:

1. **Aprendizado Supervisionado:** Nesta categoria, o modelo é treinado com dados rotulados, ou seja, entradas com suas respectivas saídas conhecidas. O objetivo principal é encontrar uma relação matemática entre as entradas e as saídas para realizar previsões em novos dados. (ALPAYDIN,2010). Exemplos comuns incluem:
 - **Classificação:** Determinar se um e-mail é spam ou não.
 - **Regressão:** Previsão de preços de imóveis ou tendências no mercado financeiro. Algoritmos como regressão linear são frequentemente aplicados. De acordo com Alpayin (2010), o aprendizado supervisionado é uma das abordagens mais comuns devido à disponibilidade de base de dados rotulados em diversos setores.

2. **Aprendizado Não Supervisionado:** Diferente do aprendizado supervisionado, este tipo de aprendizado lida com dados não rotulados. O objetivo principal neste caso é identificar padrões ou estruturas ocultas nos dados, sem que haja uma saída específica associada às entradas (MITCHELL,1997). Exemplos comuns:
 - **Agrupamento (Clustering):** Técnicas como k-means ou

hierárquico são usadas para segmentar clientes em perfis de consumo semelhantes, ajudando a personalizar estratégias de marketing.

- Redução de Dimensionalidade: Métodos como PCA (Análises de Componentes Principais) ajudam a simplificar conjuntos de dados complexos, mantendo as informações mais relevantes. Mitchell (1997) destaca que o aprendizado não supervisionado é essencial em cenários onde os rótulos são escassos ou inexistentes, como em grandes volumes de dados brutos.
3. Aprendizado por Reforço: Este tipo de aprendizado se baseia-se na interação de um agente com um ambiente. O agente aprende a tomar decisões para maximizar uma recompensa acumulada ao longo do tempo, utilizando técnicas como Q-learning e redes neurais profundas de reforço (SUTTON; BARTO,2018). Exemplos:
- Jogos: Algoritmos que treinam agentes para vencer jogos complexos como xadrez ou Go, como observado em sistemas como AlphaGo.
 - Robótica: Controle de robôs para realizar tarefas adaptativas em ambientes dinâmicos.
 - Navegação: Desenvolvimento de sistemas autônomos, como veículos auto-dirigidos, que aprendem a lidar com situações complexas e variáveis em tempo real. Sutton e Barto (2018) enfatizam que o aprendizado por reforço é particularmente eficaz em problemas onde o feedback imediato não está disponível, mas há um objetivo claro a ser alcançado.

Estas três categorias abrangem grande parte da maioria de problemas enfrentados na área de aprendizado de máquina, cada uma com sua própria técnica, desafios e aplicações específicas.

COMPONENTES FUNDAMENTAIS

Para implementar um algoritmo de Machine Learning de forma eficiente, é necessário compreender os principais componentes que constituem o processo de aprendizado. Cada um desempenha um papel crítico na construção e no treinamento de modelos:

1. **Modelo:** O modelo é a estrutura matemática ou computacional usada para representar os padrões nos dados. Ele pode ser visto como uma função que mapeia entradas (variáveis independentes) para saídas (variáveis dependentes). Por exemplo, uma regressão linear é um modelo que descreve a relação linear entre duas variáveis. Modelos podem variar de simples regressões a complexas redes neurais profundas (BISHOP,2006).
2. **Dados:** Os dados são a base do aprendizado de máquina e são geralmente divididos em:
 - **Treinamento:** Usado para ajustar o parâmetro do modelo.
 - **Validação:** Auxilia na escolha dos melhores hiperparâmetros e na prevenção de sobreajuste.
 - **Teste:** Mede o desempenho final do modelo em dados não vistos (DOMINGOS,2015). Dados de alta qualidade são cruciais para garantir o sucesso do modelo. A coleta, limpeza e análise previa dos dados desempenham um papel fundamental (MURPHY,2012).
3. **Função Perda:** A função de perda quantifica o erro entre a saída prevista pelo modelo e a saída real esperada. O objetivo do treinamento é minimizar essa função, ajustando os parâmetros do modelo. Por exemplo, o erro quadrático médio (MSE) é uma função de perda comum para problemas de regressão (GOODFELLOW; BENGIO; COURVILLE,2016).
4. **Otimização:** O processo de ajuste dos parâmetros do modelo para minimizar a função de perda é chamado de otimização. Métodos como gradiente

descendente e suas variantes são amplamente usados para essa finalidade. A eficiência dos algoritmos de otimização é essencial para lidar com grandes volumes de dados e modelos complexos (LECUN; BENGIO, HINTONS,2015).

5. Generalização: A capacidade de um modelo de performar bem em dados não vistos é conhecida como generalização. Um modelo que generaliza bem evita problemas como:

- Sobreajuste (Overfitting): Quando o modelo se ajusta excessivamente aos dados de treinamento, perdendo a capacidade de generalizar. Esse fenômeno é amplamente discutido na literatura, como destacado por Bishop (2006), que aborda métodos para mitigar o sobreajuste e explora seu impacto no desempenho.
- Subajuste (Underfitting): Quando o modelo não captura adequadamente os padrões nos dados de treinamento (Bishop,2006).

Esses componentes formam a base para a construção de sistemas de aprendizado de máquina e devem ser cuidadosamente considerados durante seu desenvolvimento.

MÉTODOS

Nesta seção, abordaremos as principais técnicas e algoritmos de aprendizado de máquina, destacando suas características e aplicações práticas.

Preparação de Dados

A preparação é uma etapa essencial no desenvolvimento de modelos de aprendizado de máquina, garantindo que a estrutura do problema seja bem exposta aos algoritmos utilizados. Cada algoritmo possui requisitos específicos sobre os dados, tornando o pré-processamento uma etapa crítica para otimizar os resultados (BROWNLEE,2016).

1. Reescalonamento de Dados:

O reescalonamento ajusta os valores dos atributos para uma escala comum, geralmente entre 0 e 1. Essa técnica é útil para algoritmos baseados em otimização, como gradiente descendente, e para aqueles que dependem de medidas de distância, como k-Nearest Neighbors (BROWNLEE,2016).

2. Padronização:

A padronização transforma os dados, para que tenham media 0 e desvio padrão 1. Isso é fundamental para algoritmos que assumem uma distribuição Gaussiana nos dados, como regressão linear e análise discriminante linear. Hastie et al. (2009) destacam que a padronização melhora significativamente a performance de algoritmos sensíveis a escalas diferentes nos dados.

3. Normalização:

A normalização ajusta os valores de cada observação para que tenham um comprimento igual a 1. Essa técnica é ideal para dados esparsos e algoritmos que utilizam medidas de distância ou ponderação de entradas, como redes neurais (HASTIE et al,2009).

4. Binarização:

A binarização converte os valores dos dados em 0 ou 1 em um limiar. Essa técnica é útil para transformar probabilidades em valores binários ou criar novas variáveis indicadoras durante a engenharia de atributos (PEDREGOSA et al,2011).

Regressão Linear

A regressão linear é uma abordagem fundamental para a resolução de problemas. Utiliza uma equação linear para prever valores contínuos a partir de variáveis de entrada, sendo amplamente utilizado devido a sua simplicidade. A equação geral é expressada

como:

$$\hat{y} = w[0].x[0] + w[1].x[1] + \dots + w[p].x[p] + b, \quad (3.1)$$

onde:

- $x[0]$ a $x[p]$ representam características (onde p é o número de características) de um único ponto de dados.
- w e b são os parâmetros do modelo que são aprendidos.
- \hat{y} é a previsão

Para um conjunto de dados com uma única característica, a fórmula se reduz a equação de uma reta:


$$\hat{y} = w[0].x[0] + b, \quad (3.2)$$

onde $w[0]$ é a inclinação e b é o deslocamento no eixo y . Esses coeficientes são ajustados para minimizar o erro quadrático médio (MSE) entre as previsões do modelo e os valores reais (MÜLLER; GUIDO, 2016).

Exemplo com um conjunto de Dados;

A regressão linear foi aplicada a um conjunto de dados [wave] que é um conjunto de dados sintético frequentemente utilizado para exemplos didáticos em regressão e aprendizado de máquina, contendo apenas uma característica. A *Fig.* a seguir ilustra os resultados obtidos.

Figura 3.1: Predições de um modelo linear no conjunto de dados (wave) (MÜLLER; GUIDO, 2016).



Neste exemplo o resultado indica que a inclinação da linha é aproximadamente 0.4, e o ponto de interseção com o eixo y está ligeiramente abaixo de zero, como mostrado na *Fig.* acima.

Esses resultados mostram que o modelo é simples e tem um desempenho consistente entre os conjuntos de dados indicando subajuste (underfitting). Modelos lineares são ideais como ponto de partida, mas podem ser limitados em cenários mais complexos ou com dados de alta dimensionalidade (MÜLLER; GUIDO, 2016).

Random Forests:

Os bosques aleatórios (random forests) são uma técnica de aprendizado de máquina amplamente utilizada, pertence a classe de algoritmos baseados em ensembles. Eles combinam a robustez e simplicidade dos árvores de decisão individuais com a capacidade de generalização por meio da agregação de múltiplos modelos. Introduzido por Breiman (2001), este método tem sido reconhecido como um dos mais eficazes para resolver problemas de classificação e regressão.


Os hiperparâmetros principais que definem os bosques aleatórios são:

- Tamanho de nó: Controla a granularidade das divisões nos dados.

- Quantidade de árvores: Determina o número de árvores incluídas no modelo.
- Quantidade de características: Limita o número de variáveis consideradas em cada divisão, adicionando diversidade e reduzindo a correlação entre as árvores.

No caso de problemas de regressão, as previsões finais são feitas pelas medias das previsões de todas as árvores, enquanto para problemas de classificação, utiliza-se o voto majoritário entre as árvores para definir a classe final. Esse processo é ilustrado na seguinte Fig. 3.2.

Figura 3.2: Funcionamento do algoritmo de Bosques Aleatórios. Cada árvore de decisão é treinada em uma amostra aleatória e contribui para previsão final por media (regressão) ou voto majoritário (classificação) (IBM,2025).



A Fig. 3.2 mostra visualmente como várias árvores de decisão colaboram em um bosque aleatório para chegar a uma previsão final. Cada árvore é treinada em uma amostra diferente para gerar uma previsão independente. Essas previsões são combinadas (por media ou por votação) para produzir um resultado robusto e generalizável.

No estudo sobre inovação em pequenas e médias empresas (PMEs) colombianas, os bosques aleatórios foram utilizados para prever se uma empresa inovaria ou não. O método combinou árvores profundas, o que frequentemente gera sobreajuste, mas

compensou isso utilizando a técnica de bagging e analisando a moda das previsões de cada árvore. Este processo melhorou a generalização e permitiu identificar as variáveis financeiras mais relevantes para a inovação (PADILLA-OSPINA; MEDINA-VÁSQUEZ; OSPINA-HOLGUÍN, 2020).

Esse método é reconhecido por sua capacidade de lidar com dados de alta dimensionalidade, prevenir sobreajustes e ser eficaz em diversos contextos. Além disso, a validação out-of-bag garante que os resultados sejam consistentes e aplicáveis a dados nunca vistos (IBM,2025).

Avaliação de modelos

A avaliação de modelos é uma etapa essencial no processo de aprendizado de máquina, pois permite medir a eficácia do modelo em generalizar para novos dados. A avaliação adequada garante que o modelo não esteja apenas ajustando os dados de treinamento, mas também sendo útil para prever em cenários reais.