

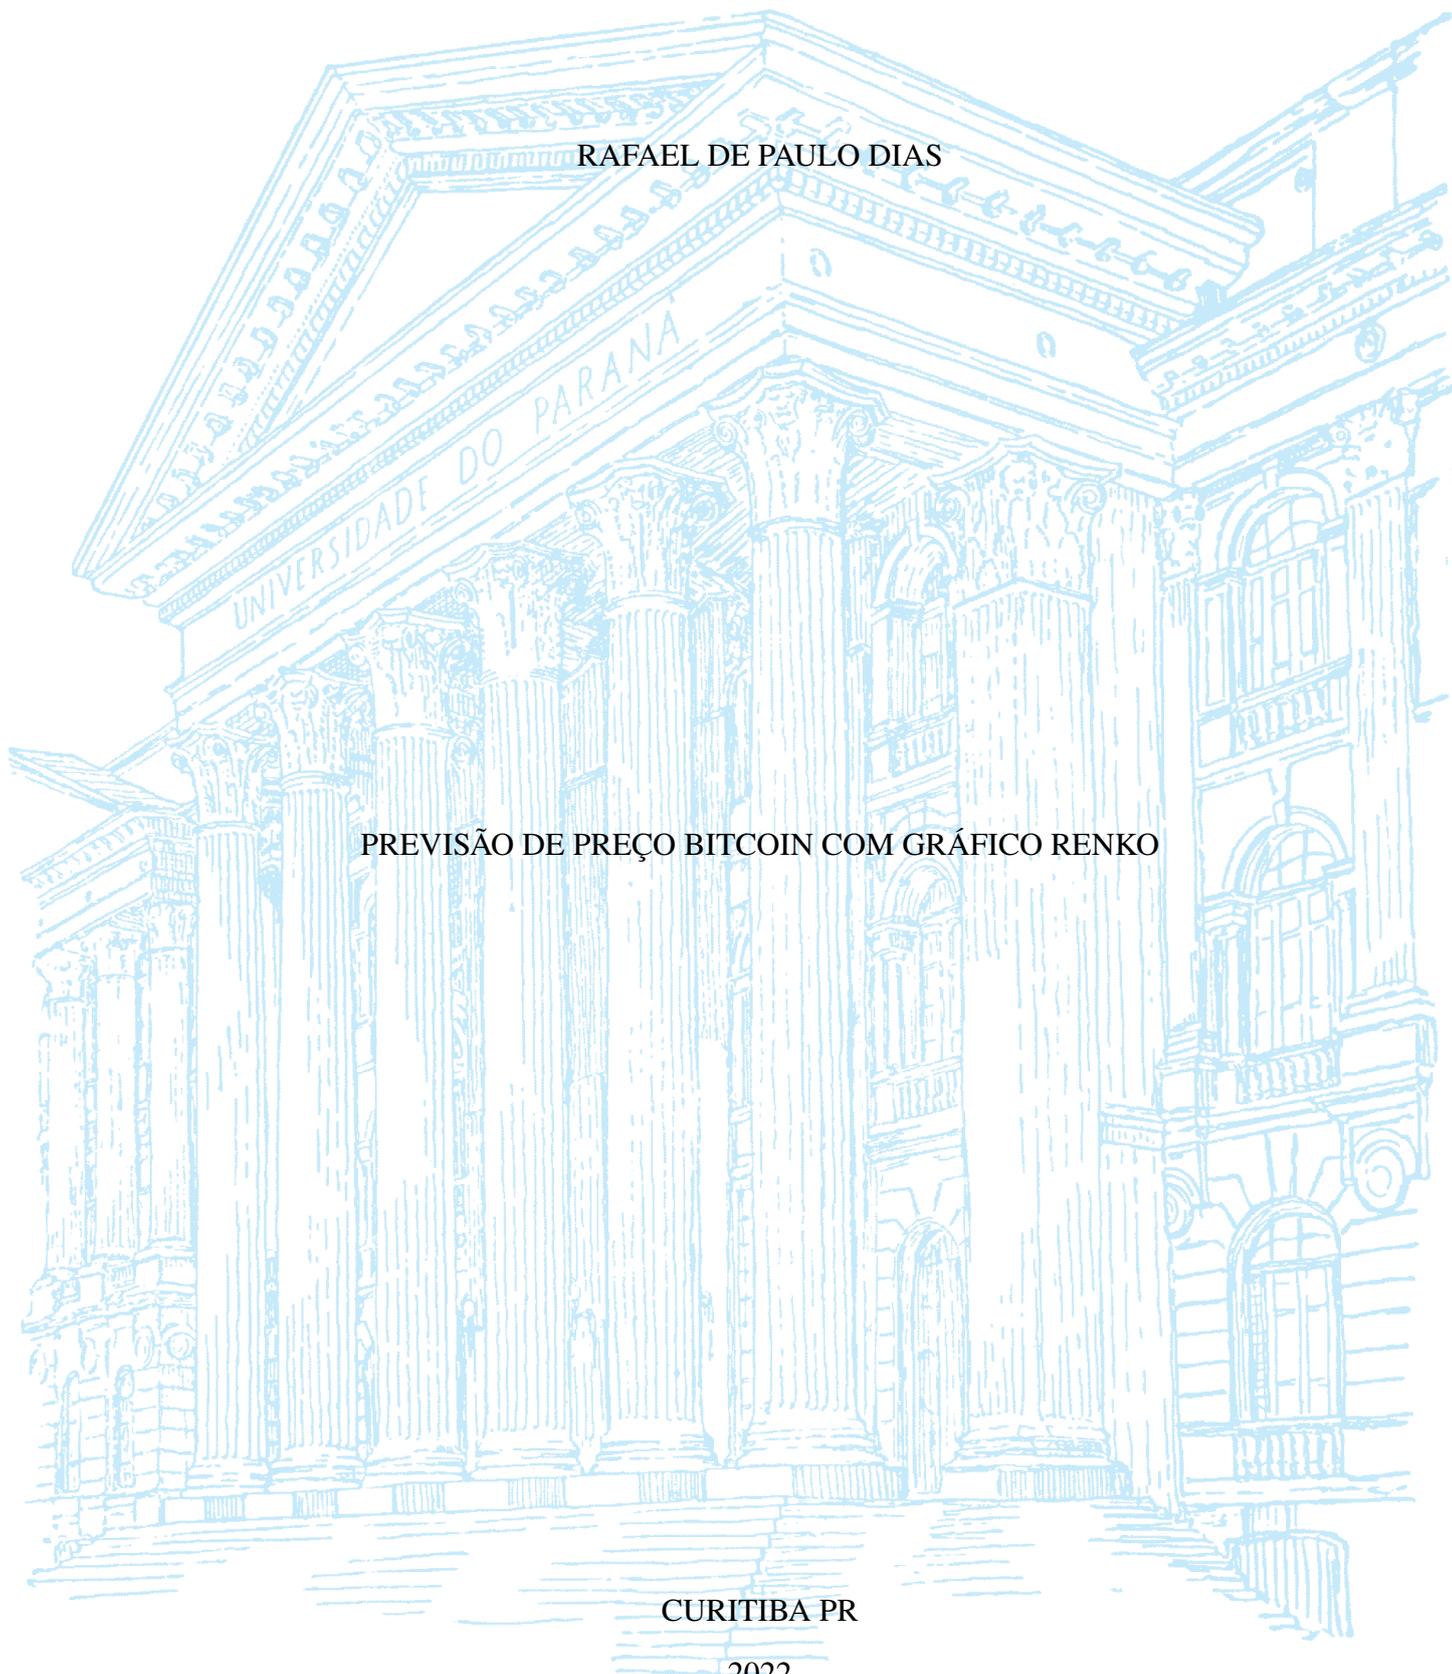
UNIVERSIDADE FEDERAL DO PARANÁ

RAFAEL DE PAULO DIAS

PREVISÃO DE PREÇO BITCOIN COM GRÁFICO RENKO

CURITIBA PR

2022



RAFAEL DE PAULO DIAS

PREVISÃO DE PREÇO BITCOIN COM GRÁFICO RENKO

Trabalho apresentado como requisito parcial à conclusão do Curso de Bacharelado em Ciência da Computação, Setor de Ciências Exatas, da Universidade Federal do Paraná.

Área de concentração: *Ciência da Computação*.

Orientador: Fabiano Silva.

CURITIBA PR

2022

*“Talk is cheap. Show me the code.”
(Linus Torvalds)*

AGRADECIMENTOS

Aos meus pais, Elza e Juvino, pela confiança e tranquilidade que me proporcionaram para concluir este trabalho e no decorrer dos semestres.

Aos meus amigos Andrey, Brendon, Douglas, Lucas e Marlon, que me ajudaram desde o primeiro dia de aula.

Ao meu orientador, Fabiano, por me ajudar a encontrar o caminho e realizar um bom trabalho.

À UFPR, por proporcionar essa oportunidade, a realização de um sonho.

RESUMO

Bitcoin vem recebendo muita atenção nos últimos anos pela mídia e pelo público baseado na porcentagem de lucros de seu início até seu topo histórico em novembro de 2021 e de sua queda dentre novembro de 2021 a julho de 2022. Existem diversos estudos que tentam prever, o preço do Bitcoin, este trabalho apresenta formas de previsão do preço utilizando o gráfico Renko para remover os ruídos, auxiliando a obter o sentido da tendência do ativo, e combinando com o auxílio de métodos estatísticos. Para a previsão do sentido do preço foi utilizado o método Naive para servir como base de referência para os modelos: SES (Simple Exponential Smoothing); Holt, versão avançada do SES com uma função para tratar tendência; Damped, versão modificada do Holt com um parâmetro para amortecer a curva e; Comb, uma combinação de SES, Damped e Holt. Os resultados foram satisfatórios e foram obtidos acurácia média de +1,85% sobre a base de referência combinando os modelos com Naive e +0,83% sem combinar. A combinação de modelos demonstrou maior acurácia e apresentou menor número de sinais (para comprar ou vender) com uma média de 96,84%. Dentro da faixa de dados usada para teste, observou-se que a técnica de investimento com operações “comprado e vendido”, apresentou melhores resultados que a somente “comprado” e somente “mantido”.

Palavras-chave: Bitcoin. Renko.

ABSTRACT

Bitcoin has received a lot of attention in recent years by the media and the public based on the percentage of profits from its inception to its all-time high in November 2021 and from its fall from November 2021 to July 2022. There are several studies that try to predict the price of Bitcoin, this work presents ways of forecasting the price using the Renko chart to remove noise, helping to get the sense of the asset's trend, and combining it with the help of statistical methods. For the prediction of the price direction, the Naive method was used to serve as a reference base for the models: SES (Simple Exponential Smoothing); Holt, advanced version of SES with a function to handle trend; Damped, modified version of Holt with a parameter to dampen the curve; Comb, a combination of SES, Damped and Holt. The results were satisfactory and an accuracy of +1.85% was obtained over the baseline by combining the models with Naive and +0.83% without combining. The combination of models showed greater accuracy and presented a lower number of signals (to buy or sell) with an average of 96,84%. Within the range of data used for testing, it was observed that the investment technique with "bought and short" operations, presented better results than the "bought" and only "hold" technique.

Keywords: Bitcoin. Renko.

LISTA DE FIGURAS

2.1	Gráfico padrão formato vela histórico total Bitcoin.	14
2.2	Gráfico Renko temporal formato pelo histórico total Bitcoin.	14
2.3	Gráfico Renko atemporal formato pelo histórico total Bitcoin.. . . .	14
2.4	True Range.	15
2.5	Múltiplas divisões treino-teste.	16
4.1	Gráfico padrão formato vela.	22
4.2	Gráfico de vela transformado em Renko com versão temporal.	23
4.3	Gráfico de vela transformado em Renko com versão atemporal.	23
4.4	Gráfico de vela transformado em Renko com versão temporal removendo duplicados.	23
4.5	Gráfico de vela transformado em Renko com versão atemporal removendo duplicados.	24
4.6	Gráfico Renko versão teste temporal.	24
4.7	Gráfico Renko versão teste atemporal, mantendo a ultima observação, forma correta de avaliação.	25
4.8	Gráfico Renko versão teste atemporal, mantendo a primeira observação, forma incorreta de avaliação.	25
4.9	Acurácia SES & NAIVE +12,4%.	26
4.10	Acurácia SES +6,4%.	27
4.11	Acurácia Naive +6,4%.	27

LISTA DE TABELAS

4.1	Múltiplas divisões aplicado ao Renko.	20
4.2	Acurácia individual dos modelos.. . . .	21
4.3	Acurácia dos modelos combinado com Naive.	21
4.4	Resultado médio dos modelos combinado com Naive.. . . .	22
4.5	Resultado médio individual dos modelos.	22
4.6	Estratégia comprado e vendido SES & NAIVE lucro 153,75%.	26
4.7	Estratégia comprado SES & NAIVE prejuízo 18,75%.. . . .	26
4.8	Estratégia comprado e vendido NAIVE lucro 96%.	28
4.9	Estratégia comprado NAIVE prejuízo 26%.	28

LISTA DE ACRÔNIMOS

ARIMA	AutoRegressive Integrated Moving Average.
B3	Brasil, Bolsa, Balcão.
CNN	Convolutional Neural Network.
CRNN	Convolutional Recurrent Neural Network.
DNN	Deep Neural Network.
LR	Linear Regression.
LSTM	Long short-term memory.
MAE	Mean Absolute Error.
MSE	Mean Squared Error.
NN	Neural Network.
RF	Random Forest.
RMSE	Root Mean Square Error.
RNN	Recurrent Neural Network.
SVM	Support Vector Machines.

LISTA DE SÍMBOLOS

α	Parâmetro de suavização para o nível da série
γ	Parâmetro de suavização para tendência
ϕ	Parâmetro de modificação de tendência

SUMÁRIO

1	INTRODUÇÃO	11
1.1	MOTIVAÇÃO	11
1.2	OBJETIVO	12
1.3	ORGANIZAÇÃO	12
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	RENKO	13
2.1.1	Limitações no uso do Gráfico Renko	14
2.1.2	Definindo tamanho do tijolo	15
2.2	BACKTEST	15
2.3	MODELOS DE PREVISÃO	16
2.3.1	Naive Forecasting	16
2.3.2	SES (Simple exponential smoothing)	16
2.3.3	Holt	16
2.3.4	Damped	16
2.3.5	Comb	17
3	TRABALHOS RELACIONADOS	18
4	DESENVOLVIMENTO	20
4.1	RESULTADOS	20
4.1.1	Baseline	20
4.1.2	Acurácia e Número de sinais	21
4.1.3	Retorno	21
4.1.4	Explicação detalhada no desenvolvimento da primeira divisão	22
4.1.5	Análise de resultados primeira divisão	25
5	CONCLUSÃO	29
	REFERÊNCIAS	30

1 INTRODUÇÃO

Bitcoin é uma versão de dinheiro eletrônico peer-to-peer (pessoa-a-pessoa) que pode ser enviado diretamente de uma parte para outra, sem passar por uma instituição financeira, proposto em 2008 por Satoshi Nakamoto (Nakamoto, 2008), esse tipo de tecnologia é chamada de criptomoeda.

O valor de fechamento do Bitcoin obtido no par BTC/USD¹ em 30/03/2013 foi de 93 USD, e na data 04/07/2022 19,763 USD dados acessados em Tradingview². O maior valor que o Bitcoin já chegou a valer no seu fechamento foi 67,526 em 08/11/2021, nesta mesma data o valor de mercado de todas as criptomoedas chegou a fechar em 2,657T USD, e o valor de mercado do Bitcoin era 1,225T USD, representando 46% do mercado.

Fazendo uma comparação entre Bitcoin e o mercado de ações do Brasil, o valor de mercado do Bitcoin na data 04/07/2022 fechou em 385B USD³ em comparação com o valor de mercado de todas as ações B3 (Brasil, Bolsa, Balcão) consultado em 05/07/2022 avaliado em 771B USD⁴, o valor de mercado do Bitcoin representava 49,9% do mercado de ações B3.

Prever o sentido do preço do mercado financeiro propõe um grande desafio para investidores, seja para proteger seu capital ou em busca de lucros, para o investidor que procura utilizar ferramentas que irão contribuir diminuindo sua taxa de erro e tentar prever o próximo sentido do ativo de interesse, dentre as diversas formas de selecionar o momento de compra de um ativo. A proposta deste trabalho é utilizar somente o preço de fechamento e ferramentas estatísticas para auxiliar nessa escolha. Diante do que foi apresentado escolhemos um mercado desafiador que está em crescimento desde julho de 2010 o mercado de criptomoedas. Neste trabalho serão apresentadas abordagens para tentar prever o sentido do preço do Bitcoin, principal moeda do mercado de criptomoedas.

O trabalho consiste em criar abordagens para prever o sentido que o ativo Bitcoin vai tomar com modelos estatísticos. Para remoção de ruídos (volatilidade, sinais de compra e venda falsos, padrões de compra e venda) iremos estruturar o preço do Bitcoin através do gráfico Renko, gerando um formato atemporal possibilitando a remoção de ruído e enxergar a tendência com mais facilidade para auxiliar na compra ou venda do ativo.

Baseado na análise dos trabalhos relacionados, esse trabalho pretende disponibilizar a fonte de dados⁵, os modelos utilizados⁶ para servirem de base em outras pesquisas de forma reprodutível, além de uma explicação do pré-processamento utilizado sobre os dados.

A métrica utilizada na avaliação dos modelos é o sentido do preço de fechamento, com essa informação será possível comparar com o real sentido do mercado e identificar a acurácia dos modelos.

1.1 MOTIVAÇÃO

A motivação deste estudo é analisar o resultado combinando ferramentas de previsão com gráfico Renko para auxiliar o investidor a tomar decisão de compra/venda do ativo Bitcoin.

¹Valor do Bitcoin em dólares dos Estados Unidos da América.

²<https://www.tradingview.com/chart/?symbol=BITFINEX%3ABTCUSD>

³<https://www.tradingview.com/chart/?symbol=CRYPTOCAP%3ABTC>

⁴https://www.b3.com.br/pt_br/market-data-e-indices/servicos-de-dados/market-data/consultas/mercado-a-vista/valor-de-mercado-das-empresas-listadas/bolsa-de-valores-diario/

⁵<https://github.com/rafaelcsc/crypto/tree/main/data>

⁶<https://github.com/rafaelcsc/crypto>

O estudo proposto pode servir de base para uma ferramenta que auxilie investidores na identificação da tendência do ativo. Com base apenas na consulta do diário do valor de fechamento (O horário de fechamento é 21:00 UTC-3) seria possível tomar a decisão de compra/venda.

1.2 OBJETIVO

O objetivo desse trabalho é explorar a combinação de modelos de previsão com a representação dos dados no formato de gráficos Renko para identificar onde comprar/vender o ativo Bitcoin.

Outro objetivo é disponibilizar todo código fonte para auxiliar na identificação de possíveis erros e para que possa ser utilizado no desenvolvimento de outros trabalhos.

1.3 ORGANIZAÇÃO

Este trabalho está organizado da seguinte forma. O Capítulo 2, apresenta o formato de gráfico Renko, como foram realizados os testes preliminares e os modelos de previsão utilizados. O Capítulo 3, apresenta a fundamentação teórica, pesquisas e trabalhos que foram realizados na área de previsão e como os resultados são apresentados. O Capítulo 4 procura explicar os detalhes do desenvolvimento e as escolhas que foram tomadas durante a construção deste trabalho e também os resultados de acurácia e lucro/prejuízo da avaliação experimental realizada. No Capítulo 5 é apresentada a conclusão trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta sessão serão apresentadas as técnicas utilizadas no desenvolvimento do trabalho. Como o gráfico Renko irá ajudar no desenvolvimento, suas limitações e as informações necessárias para gera-los. Também será apresentado o backtest e os modelos de previsão utilizados.

2.1 RENKO

Renko é um tipo de gráfico, desenvolvido pelos japoneses, ele é construído utilizando o movimento do preço, ao invés do preço e intervalo de tempo, como a maioria dos gráficos são. O nome Renko foi pensado no nome japonês para tijolo, "renga", como o gráfico aparenta uma série de tijolos. Se o preço move uma quantidade, um novo bloco é posicionado a um ângulo de 45 graus, para cima ou para baixo. O tijolo subindo é normalmente cor verde, enquanto um tijolo de baixa é cor de vermelho (Mitchell, 2021).

Desenvolvido com a intenção de remover pequenas movimentações de preço e facilitar a vida de investidores apresentando somente a tendência. Como a tendência fica mais simples de se identificar a formação de preço é perdida devido a simplicidade da construção do gráfico com tijolo (Mitchell, 2021).

Na construção do gráfico Renko deve-se definir o tamanho do tijolo, que vai representar a magnitude do movimento do preço, conforme o gráfico 2.2 o valor do tamanho do tijolo foi de 1047 baseado no ATR (Average True Range), só existe um único tijolo entre os anos de 2013 e 2017, as informações foram agrupadas em um único tijolo devido ao valor não ultrapassar 1047 durante esses anos.

O gráfico Renko pode apresentar o intervalo de tempo, mas o tempo não é fixo. Um tijolo pode levar meses para se formar assim como o primeiro tijolo do exemplo no gráfico 2.2, existe a possibilidade dependendo do tamanho do tijolo, mais de uma se formar no dia, um dos desafios deste trabalho é encontrar um tamanho para atingir um equilíbrio.

Aumentar ou diminuir o tamanho do tijolo vai afetar na suavização do gráfico, diminuir a caixa pode apresentar mais oscilações, podendo destacar possível reversão de preço antecipadamente. Já uma caixa de tamanho grande pode reduzir as oscilações e ruído mas irá apresentar lentamente o sinal de reversão (Mitchell, 2021).

Os gráficos Renko são efetivos em identificar suporte e resistência como tem pouco ruído, um exemplo seria o preço no gráfico 2.3 de 40k USD. Quando uma forte tendência é formada, investidores que utilizam esse gráfico conseguem aproveitar por muito tempo, apresentado no gráfico 2.3, a possibilidade de compra e venda conforme a tendência é disponibilizada no gráfico.

O desafio deste trabalho consiste em identificar a partir de que momento é interessante comprar ou vender, conforme será visto nos resultados é possível combinar ferramentas de previsão para auxiliar na compra ou venda, e conseguir resultados satisfatórios.

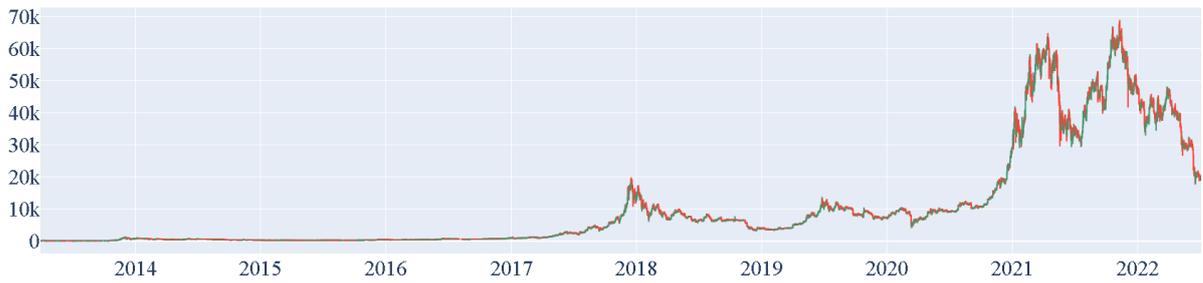


Figura 2.1: Gráfico padrão formato vela histórico total Bitcoin.

FONTE: elaborado pelo autor (2022).



Figura 2.2: Gráfico Renko temporal formato pelo histórico total Bitcoin.

FONTE: elaborado pelo autor (2022).

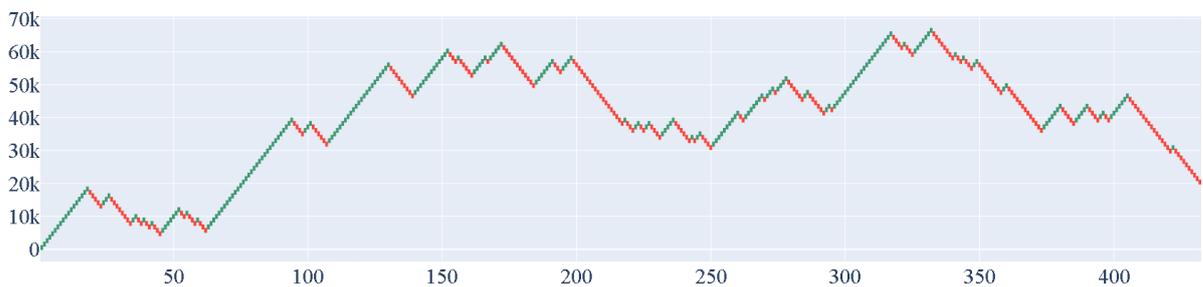


Figura 2.3: Gráfico Renko atemporal formato pelo histórico total Bitcoin.

FONTE: elaborado pelo autor (2022).

2.1.1 Limitações no uso do Gráfico Renko

O gráfico Renko não apresenta muitos detalhes como gráficos de vela, devido a sua forma de trabalhar sem o tempo. Um ativo que está dentro de uma caixa por um longo tempo não oferece informação do que está acontecendo durante o tempo, alguns investidores podem considerar como algo positivo outros como algo negativo (Mitchell, 2021).

Topos e Fundos são ignorados, somente preço de fechamento é utilizado. Isso deixa de fora informações da variação dos preços visto que topos e fundos podem variar bastante do preço de fechamento. O uso de somente o preço de fechamento vai desconsiderar o ruído, mas pode significar que o preço pode sair da caixa e formar mais de um tijolo antes de um possível alerta. Podendo ser tarde demais para gerenciar perdas (Mitchell, 2021).

Como esse gráfico foi projetado para seguir a tendência dos ativos, podem aparecer falsos sinais onde a cor do tijolo mude rapidamente. Por esse motivo a importância de usar Renko em conjunto com outras formas de análise técnica (Mitchell, 2021).

2.1.2 Definindo tamanho do tijolo

O tamanho do tijolo neste trabalho está sendo definido por ATR (Average True Range), um indicador de análise técnica introduzido por J. Welles Wilder Jr, que mede a volatilidade do ativo decompondo a faixa de preço de um ativo para aquele período (Wilder, 1978).

O TR(True Range) 2.4 é calculado baseado no maior valor dentre:

1. Distância entre o máximo e mínimo do dia atual.
2. Distância entre preço de fechamento do dia anterior ao preço da alta do dia atual.
3. Distância entre preço de fechamento do dia anterior ao preço de baixa do dia atual.

$$TR = \text{MAX}[(H - L), \text{Abs}(H - C_p), \text{Abs}(L - C_p)]$$

$$ATR = \left(\frac{1}{n}\right) \sum_{i=1}^{(n)} TR_i \quad (2.1)$$

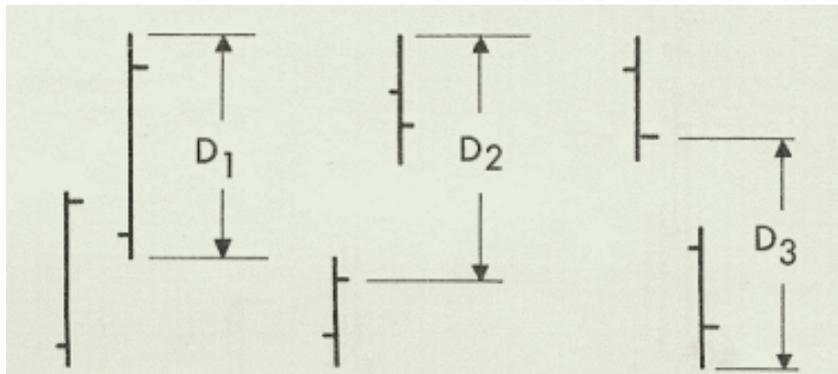


Figura 2.4: True Range.

FONTE: (Wilder, 1978).

2.2 BACKTEST

Os modelos de validação cruzada não funcionam para séries temporais (Brownlee, 2016), pois eles podem acessar informações do futuro e não apresentam, a verdadeira acurácia, visto que o modelo gerado não vai ter acesso às informações do futuro.

O método selecionado para avaliar os modelos, foi múltiplas divisões treino-teste 2.5, resultando em mais modelos sendo treinados, e em troca, maior acurácia da performance dos modelos sobre as informações que não foram ainda vistas (Brownlee, 2016).

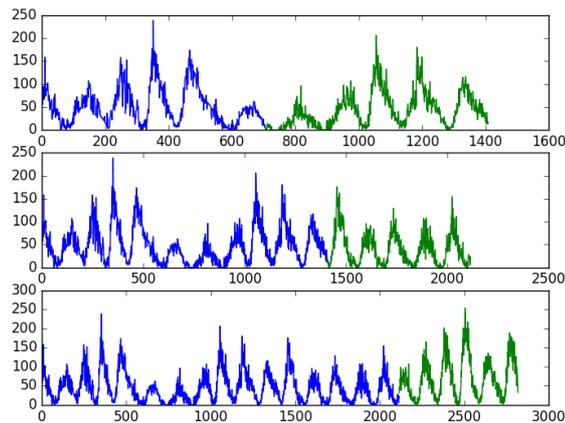


Figura 2.5: Múltiplas divisões treino-teste.

FONTE: (Brownlee, 2016).

2.3 MODELOS DE PREVISÃO

Serão descritos os modelos de previsão deste trabalho, no desenvolvimento foram utilizados somente o preço de fechamento.

2.3.1 Naive Forecasting

O valor da caixa anterior vai ser reproduzido no futuro, e como estamos tentando prever o sentido, se o último valor foi de alta, o próximo valor também vai ser alta, caso contrário vai ser de baixa (Makridakis et al., 2020).

2.3.2 SES (Simple exponential smoothing)

O modelo SES suaviza os dados utilizando médias moveis com pesos para informações mais recentes (Gardner Jr, 1985), e foi comparado com médias móveis e obteve melhor acurácia.

$$S_t = \alpha X_t + (1 - \alpha)S_{t-1} \quad (2.2)$$

2.3.3 Holt

Holt (Holt, 2004) estendeu a SES (Simple exponential smoothing) para permitir a previsão de dados com tendência. Este método envolve uma equação de previsão e duas equações de suavização (uma para o nível (S) e outra para tendência (T)).

$$\begin{aligned} S_t &= \alpha X_t + (1 - \alpha) (S_{t-1} + T_{t-1}) \\ T_t &= \gamma (S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \\ \hat{X}_t(m) &= S_t + mT_t \end{aligned} \quad (2.3)$$

2.3.4 Damped

A maioria dos métodos de série temporal assume que a tendência irá continuar. Mas recentes descobertas empíricas sugerem que é possível aumentar a acurácia amortecendo ou ignorando a tendência (Gardner Jr e McKenzie, 1985). O Damped vai utilizar o método double

exponential smoothing (Holt linear), como o método Holt tem uma tendência constante será adicionado um parâmetro adicional para amortecer a tendência:

$$\begin{aligned}
 S_t &= \alpha X_t + (1 - \alpha) (S_{t-1} + \phi T_{t-1}) \\
 T_t &= \gamma (S_t - S_{t-1}) + (1 - \gamma) \phi T_{t-1} \\
 \hat{X}_t(m) &= S_t + \sum_{i=1}^m \phi^i T_t
 \end{aligned}
 \tag{2.4}$$

2.3.5 Comb

Média aritmética simples de Holt, SES, Damped (Makridakis et al., 2020).

$$Comb = (Holt + SES + Damped) / 3
 \tag{2.5}$$

3 TRABALHOS RELACIONADOS

Foram selecionados alguns trabalhos relacionados para auxiliar no desenvolvimento do tema proposto.

Neste trabalho os autores utilizaram a moeda Ethereum que na época representava a criptomoeda com segundo maior valor de mercado e utilizou range de 1 hora, teve como objetivo responder a pergunta : "O preço do Ethereum vai aumentar amanhã?", o autor conseguiu uma acurácia de 61,17% utilizando ARIMA, e seu segundo melhor resultado foi 56,94% de acurácia com LR (Chen et al., 2019).

Phaladisailoed utilizou a moeda Bitcoin com range de 1 minuto, teve como objetivo apresentar o melhor resultado através do menor MSE e menor R^2 , obtendo 0,00002 MSE (Erro Médio Quadrado) 0,992 R^2 . O autor concluiu que fatores além do preço é interessante considerar para utilizar na previsão como dados de mídias sociais, políticas e leis de países contra ou a favor do Bitcoin (Phaladisailoed e Numnonda, 2018).

Almasri utilizou 3 moedas Bitcoin, Dash e Bitcoin Cash com range de 1 hora e 1 dia, utilizando a ferramenta Encog Machine Learning Framework, uma ferramenta de algoritmos que suporta normalização de classes e processamento de dados. O objetivo era prever o preço de fechamento das moedas, o framework obteve previsões entre 75% e 97,3% no preço de fechamento. O autor concluiu que moedas de cripto tem forte influência de fatores social-psicológicos, e citou a necessidade de data mining para auxiliar na previsão do preço (Almasri e Arslan, 2018).

Tandon trabalhou com a moeda Bitcoin com range 1 dia, comparando resultados com 10-fold cross validation, que é uma técnica par avaliar a capacidade de generalização de um modelo, a partir de um conjunto de dados. O objetivo do trabalho foi obter o Mean Absolute Error, RNN e LSTM combinados com 10-fold cross validation obtendo o menor resultado de 0,0043s e em segundo 0,1518s RNN e LSTM combinados e o pior resultado foi Linear Regression de 476,6748s. O autor concluiu que a combinação foi mais eficiente devido a instabilidade do preço do Bitcoin, obtendo o resultado médio após realizar todos os cross validation, que ficou abaixo dos outros modelos, o autor indicou para trabalhos futuros remover o ruído para aumentar a eficiência do trabalho (Tandon et al., 2019).

Os autores trabalharam com a moeda Bitcoin com range de 1 dia, utilizando modelos de rede neural. O objetivo do trabalho foi de prever o preço de fechamento, utilizando observações de teste entre [5;10;20;50;100], o trabalho explorou diversas formas de abordar o problema transformando as features em log em relação aos valores sem transformação, a comparação demonstrou que tem efeito na acurácia exemplo de acurácia DNN com log 53,06%, DNN sem log 50,85% e CNN com log 52,48% e CNN sem log 49,86%. Foram explorados os efeitos do datasplit com sequencial, random e k-fold onde novamente teve impacto na acurácia: DNN sequencial 53,06%, DNN random 52,46% e DNN k-fold 53,60%, outra exploração foi feita baseado em como os dados foram normalizados baseado no primeiro valor das observações (first value-based normalization e min max), a normalização com first value-based normalization obteve maior acurácia exemplo acurácia: DNN normalizando a partir do primeiro valor 53,06% e 51,71% min max (Ji et al., 2019).

O autor realizou um teste de compra e venda com cada modelo, utilizando 20 dados de teste para regressão e 50 dados de teste como classificação, na regressão SVM obteve o melhor resultado, melhor resultado diga-se perdeu menos dinheiro, já na classificação DNN conseguiu um retorno de 8,77% em 50 trades, utilizando a estratégia prevendo abaixo do preço é venda e prevendo acima do preço é compra.

Adegboruwa utilizou a moeda Bitcoin com range de 1 dia, utilizando o modelo LSTM, neste trabalho foi proposto estudar a eficiência do LSTM. Utilizando métrica de performance RMSE, MAE, R^2 . Utilizou Teste de Dickey-Fuller aumentado para avaliar raiz unitária, o autor removeu a tendência do dataset. Os resultados obtidos após remover tendência foram superiores aos valores com tendência. O autor conclui que remover a tendência tem bons resultados, e que é possível explorar outros métodos para remover tendência (Adegboruwa et al., 2019).

Baseado nos trabalhos relacionados cada um tem seu objetivo entre avaliação por acurácia, prever o próximo preço de fechamento e tentar prever o sentido, não existe um padrão para disponibilização de código para efetivamente validar as informações nem um padrão de baseline, baseado nisso esse trabalho vai aproveitar alguns pontos que foi sugerido como remoção de ruído e validação cruzada, e também disponibilizar o código para que seja avaliado.

Como foi apresentado nos trabalhos relacionados a falta de um baseline, foi encontrado na competição M4 (Makridakis et al., 2020), essa competição tem o objetivo de aprender com evidências empíricas como melhorar a precisão da previsão e como esse aprendizado poderia ser usado para avançar a teoria e a prática na previsão, essa competição apresentou uma lista de modelos para serem utilizados como benchmark, e será explorado alguns neste trabalho.

Baseado nos resultados das hipóteses apresentado na competição M4 (Makridakis et al., 2018), onde a combinação de modelos estatísticos obteve o melhor resultado explicado nas hipótese. Foram então selecionado os modelos abaixo para auxiliar na previsão.

- Naive
- SES
- Holt
- Damped
- Comb

Titulo	Modelos	Métrica de avaliação	Melhor resultado
(Chen et al., 2019)	LR, Naive Bayes, Support Vector Machine, Random Forest, ARIMA e RNN	Sentido do preço	ARIMA = 61%
(Phaladisailoed e Numnonda, 2018)	Theil-Sen Regression, Huber Regression, LSTM e GRU	MSE, R^2	MSE = 0,00002 $R^2 = 0,992$
(Almasri e Arslan, 2018)	SVM, NN, Bayes Networks, Hidden Markov Models	Acurácia	Entre 75% e 97,3%
(Tandon et al., 2019)	LSTM, RNN, LR, RF	MAE	MAE = 0,0043s
(Ji et al., 2019)	DNN, LSTM, CNN, ResNet, CRNN, Ensemble, SVM	Acurácia	DNN = 53,06%
(Adegboruwa et al., 2019)	LSTM	RMSE, MAE	RMSE = 0,016 MAE = 0,011

4 DESENVOLVIMENTO

Neste capítulo será apresentado todo processo de desenvolvimento e escolhas que levaram ao resultado, o primeiro passo consiste em transformar o gráfico do Bitcoin diário de velas entre as datas 30/03/2013 a 04/07/2022 na figura 2.1, no total de 3377 dias de observações, e gerar as múltiplas divisões de treino/teste do tamanho original dividido por 5, sendo tamanho base 675 observações que será incrementada a cada divisão como explicado na tabela 4.1, demonstrando o tamanho do ATR, e a quantidade de observações para treino/teste ficou na versão Renko.

Divisão	Obs dias	ATR	Obs Renko treino	Obs Renko teste
1	675	40	76	32
2	1350	11	560	240
3	2025	91	867	371
4	2700	579	126	54
5	3377	698	548	235

Tabela 4.1: Múltiplas divisões aplicado ao Renko.

4.1 RESULTADOS

Serão apresentadas todas as decisões tomadas para conseguir gerar os resultados, as informações utilizadas para gerar os sinais foram utilizada de dados do passado, ou seja, as informações do tijolo anterior foi a única informação a ser considerada para decisão. O ATR foi selecionado o maior dos últimos 60 dias do período de teste, a divisão treino/teste foi de 70/30, e o treino foi utilizado para obter os melhores parâmetros para cada uma das múltiplas divisões e cada modelo. Os sinais de compra e venda gerados pelos modelos foram obtidos através do último tijolo e também combinados com o penúltimo tijolo, o ultimo tijolo precisa de um sinal maior que o atual e o valor do modelo precisa estar abaixo do preço de fechamento para gerar sinal de compra, para sinal de venda o ultimo tijolo precisa de um sinal menor que o atual e o valor do modelo precisa estar acima do preço de fechamento.

4.1.1 Baseline

O valor baseline do trabalho é 66,6% (este valor foi definido baseado na dinâmica do Renko, onde a compra no sentido correto obtém um ganho de no mínimo um tijolo, e a compra no sentido incorreto implica no mínimo na perda de dois tijolos, logo o baseline precisa acertar duas vezes para errar uma vez), e todos os resultados apresentados serão mais ou menos em relação ao baseline, para não passar uma informação errada aos leitores, sem ter o conhecimento do risco/retorno, ao ver o resultado 79% vai ser apresentado como +12,4%.

Sobre o risco/retorno o acerto de uma previsão representa o lucro de ao menos um tijolo, o erro representa a perda de ao menos dois tijolos. Como o valor flutua entre os tijolos para surgir o próximo no mesmo sentido basta o ativo fechar acima do valor do ATR, para surgir no sentido contrário o valor precisa ser 2 vezes menor que o ATR.

4.1.2 Acurácia e Número de sinais

O resultado da acurácia e número de sinais a seguir apresentam a média de sinais obtidos pela média dos resultados das múltiplas divisões na tabela 4.1, foi gerado dois resultados o primeiro na tabela 4.2 sem combinar resultado com o Naive, na tabela 4.3 e o segundo combinando o resultado. O primeiro obteve maior acurácia e também maior quantidade de sinais, a expectativa de combinar os modelos com Naive seria utilizar os modelos como um sistema de confirmar o sinal do Naive, obtendo uma acurácia maior com menor número de sinais.

Modelo	Num Sinais	Acurácia
Naive	90	+ 0,2%
SES	90	+ 0,89%
Holt	70	+1,07%
Damped	78	+1,18%
Comb	79	+0,18%

Tabela 4.2: Acurácia individual dos modelos.

Modelo	Num Sinais	Acurácia
SES e Naive	89	+1,56%
Holt e Naive	67	+1,98%
Damped e Naive	76	+1,86%
Comb e Naive	75	+2%

Tabela 4.3: Acurácia dos modelos combinado com Naive.

4.1.3 Retorno

O retorno foi obtido com as estratégias a seguir:

- **Comprado e Vendido:** nessa estratégia ocorre uma compra quando o último tijolo deu sinal de alta e ocorreu confirmação dos modelos, e quando o último tijolo deu sinal de baixa e ocorreu confirmação dos modelos ocorre uma venda.
- **Comprado:** na estratégia compra, ocorre uma compra quando o último tijolo deu sinal de alta e ocorre confirmação dos modelos, e caso contrário vender o ativo e aguardar outro sinal de compra.
- **Mantido:** na estratégia mantido, é uma modificação para comprar e segurar o ativo por um longo tempo, nesse modo escolhido, ocorre a compra na primeira observação do teste e vendido na última observação do teste.

A estratégia “mantido” não teve bons resultados ficou entre -5,4% e -1,8%, as demais estratégias foram listadas na tabela 4.4 que representa a combinação dos modelos com Naive, e na tabela 4.5 que representa os resultados sem combinar com Naive, somente o Comb que vai ser composto por outros 3 modelos.

Modelo	Compra e Venda	Compra
SES e Naive	70,7%	18,3%
Holt e Naive	87,2%	25,2%
Damped e Naive	96,7%	29,9%
Comb e Naive	89,2%	24,8%

Tabela 4.4: Resultado médio dos modelos combinado com Naive.

Modelo	Compra e Venda	Compra
Naive	56,2%	11,6%
SES	59,5%	14,2%
Holt	90,5%	27,6%
Damped	96,4%	31,2%
Comb	83,5%	23,3%

Tabela 4.5: Resultado médio individual dos modelos.

4.1.4 Explicação detalhada no desenvolvimento da primeira divisão

Nesta subseção será explicada a transformação necessária para gerar o Renko na primeira divisão. Na figura 4.1, representa a primeira divisão de 675 observações geradas a partir das primeiras observações na figura 2.1, representando as datas entre 30/03/2013 até 13/01/2015.



Figura 4.1: Gráfico padrão formato vela.

FONTE: elaborado pelo autor (2022).

Na figura 4.2 o gráfico Renko foi gerado com ATR 40, e está sendo representado com formato temporal para visualizar a distribuição e em quais datas ele poderia apresentar alguma modificação, na figura 4.3 representa a versão agrupada das divisões que vai ser implementado os modelos para identificar possíveis compra ou venda.



Figura 4.2: Gráfico de vela transformado em Renko com versão temporal.

FONTE: elaborado pelo autor (2022).

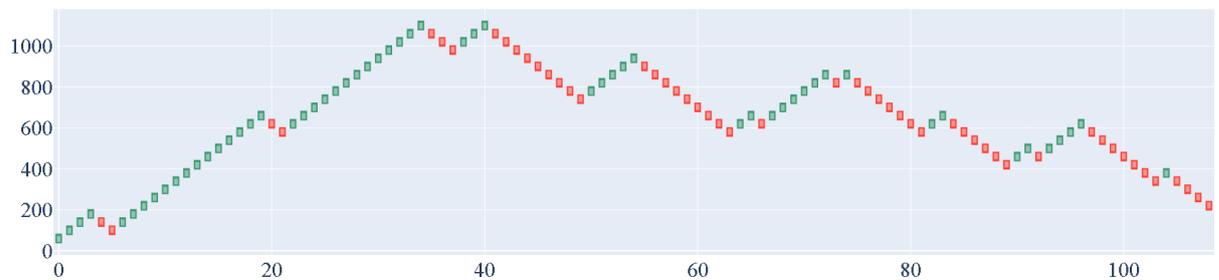


Figura 4.3: Gráfico de vela transformado em Renko com versão atemporal.

FONTE: elaborado pelo autor (2022).

Conforme foi identificado para avaliação de ganhos e perdas além da acurácia, na figura 4.4 apresenta o gráfico na figura 4.2 sem duplicidades, as duplicidades representam que a volatilidade do dia foi alta o suficiente para gerar mais que 1 Renko, e conforme veremos nas figuras a seguir a importância de remover a duplicidade e manter a última para avaliação.



Figura 4.4: Gráfico de vela transformado em Renko com versão temporal removendo duplicados.

FONTE: elaborado pelo autor (2022).

Na figura 4.5 demonstra a versão atemporal na figura 4.4 após remover as duplicidades, os espaços em branco representa um dia de alta volatilidade e foi mantido somente o último tijolo. Na figura 4.6 está representando a forma teste atemporal.

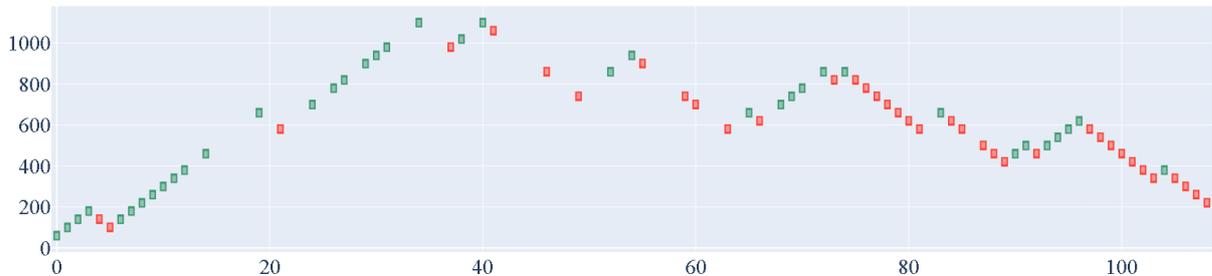


Figura 4.5: Gráfico de vela transformado em Renko com versão atemporal removendo duplicados.

FONTE: elaborado pelo autor (2022).



Figura 4.6: Gráfico Renko versão teste temporal.

FONTE: elaborado pelo autor (2022).

Na figura 4.8 representa a maneira incorreta de avaliar o Renko, visto que ao remover o tijolo que foi duplicado no mesmo dia manteve a primeira observação, a forma correta deveria manter a última observação na figura 4.7, a importância dessa escolha reflete nos lucros e perdas obtidos, como o tijolo foi definido de antemão e não é possível prever a volatilidade o sinal de compra/venda só pode ser identificado no final do dia, e como o preço pode variar durante o dia somente o último Renko do dia pode ser utilizado com referência.

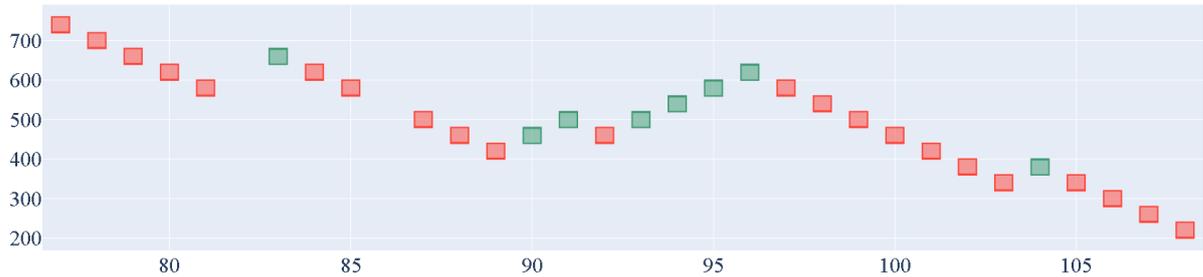


Figura 4.7: Gráfico Renko versão teste atemporal, mantendo a última observação, forma correta de avaliação.

FONTE: elaborado pelo autor (2022).

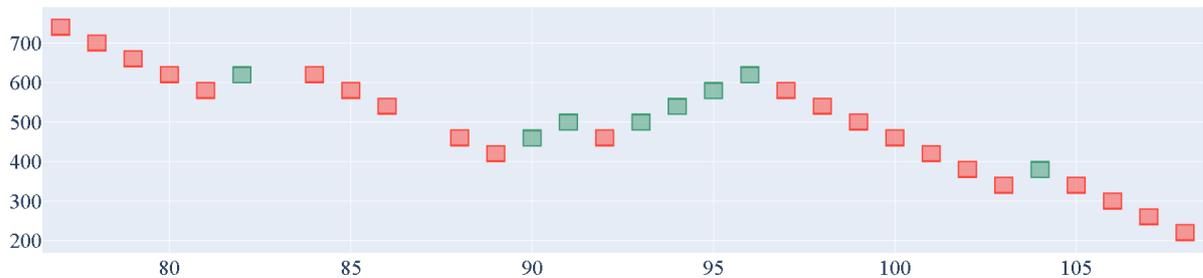


Figura 4.8: Gráfico Renko versão teste atemporal, mantendo a primeira observação, forma incorreta de avaliação.

FONTE: elaborado pelo autor (2022).

4.1.5 Análise de resultados primeira divisão

Os resultados a seguir representam um exemplo de como foram calculados a acurácia e o retorno obtidos com os modelos SES, Naive e SES & Naive. Nos gráficos com resultados de onde comprar e onde vender, o sinal sempre foi obtido na observação anterior, então o sentido de compra e venda sempre vai ser o resultado final. As tabelas de compra/venda e somente compra serão apresentadas para demonstrar, como o retorno médio das múltiplas divisões foram calculados o resultado de cada divisão e feito uma média simples.

A estratégia mantida, para todos os casos do exemplo abaixo obteve um retorno de -70% comprado em 06/02/2014 por 680 USD e vendido em 13/01/2015 por 200 USD, na estratégia somente compra todos os modelos abaixo deram prejuízo, e compra/venda teve com excelente resultado de 153% para SES, SES & Naive e 96% somente Naive.

Os sinais de compra e venda (buy/sell) apresentados na figura 4.9, representam a posição que o investidor se encontra se estiver buy ele está comprado desde o último sinal, se for sell ele está vendido desde o último sinal.

4.1.5.1 SES & NAIVE

SES & Naive com resultado na figura 4.9, e obtendo uma acurácia de +12,4% em 24 sinais de compra/venda.

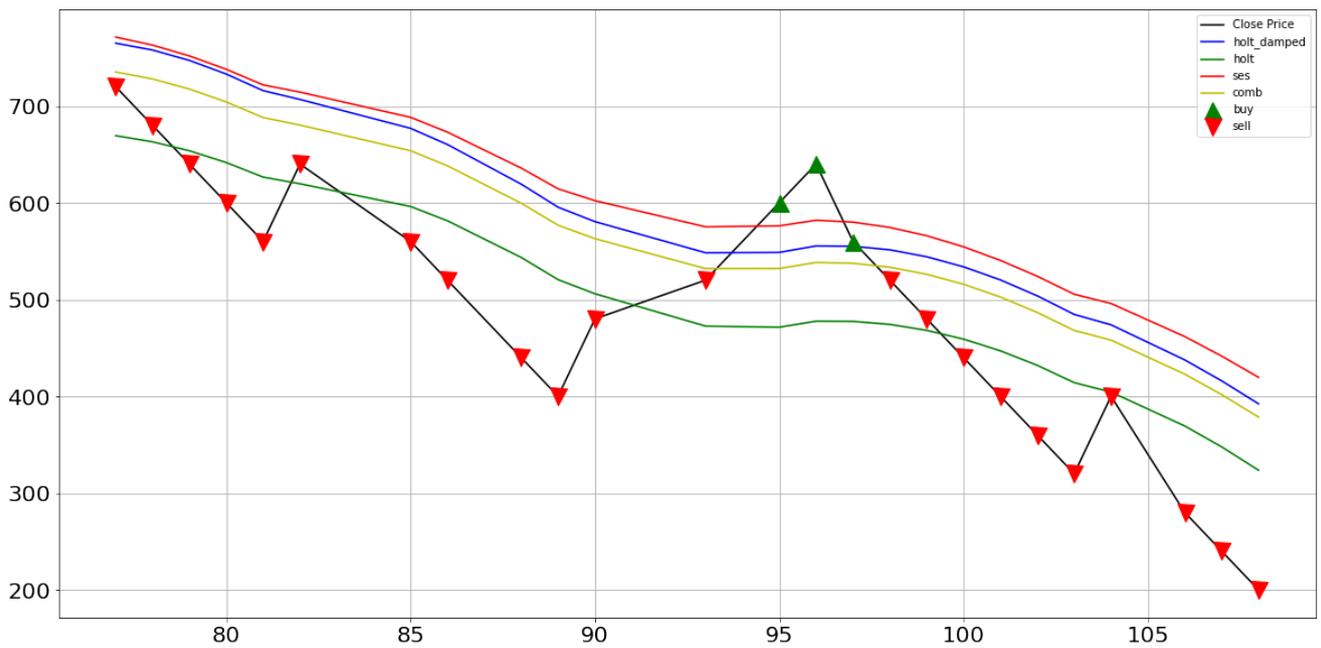


Figura 4.9: Acurácia SES & NAIVE +12,4%.

FONTE: elaborado pelo autor (2022).

Compra/Venda	Entrada	Saída	Lucro
Venda	720	640	12,5%
Compra	640	520	-18,75%
Venda	520	200	160%

Tabela 4.6: Estratégia comprado e vendido SES & NAIVE lucro 153,75%.

Entrada	Saída	Resultado
640	520	-18,75%

Tabela 4.7: Estratégia comprado SES & NAIVE prejuízo 18,75%.

4.1.5.2 SES

SES com resultado na figura 4.10, e obtendo uma acurácia de +6,4% em 30 sinais de compra/venda.

As estratégias obtiveram o mesmo resultado na figura 4.9, devido aos sinais utilizados terem sido o mesmo, a única desvantagem deste a acurácia ficou menor.

4.1.5.3 Naive

Será apresentado o resultado na figura 4.11 obteve acurácia de +6,4% em 30 sinais de compra/venda.

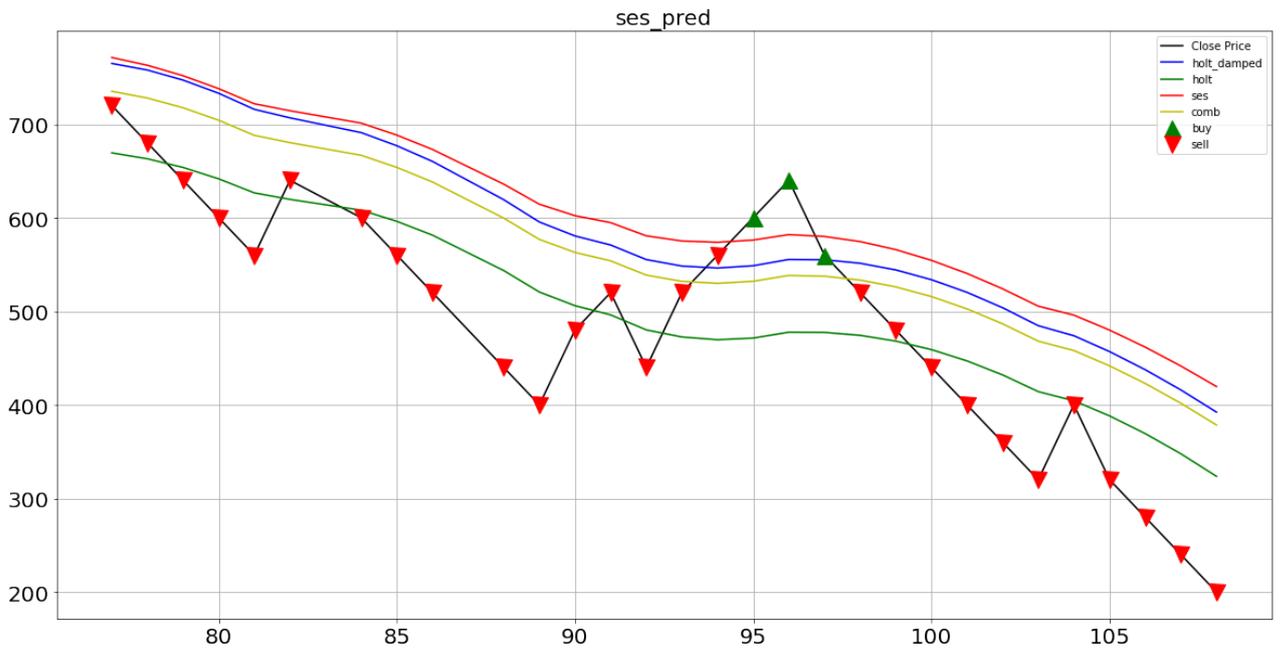


Figura 4.10: Acurácia SES +6,4%.

FONTE: elaborado pelo autor (2022).

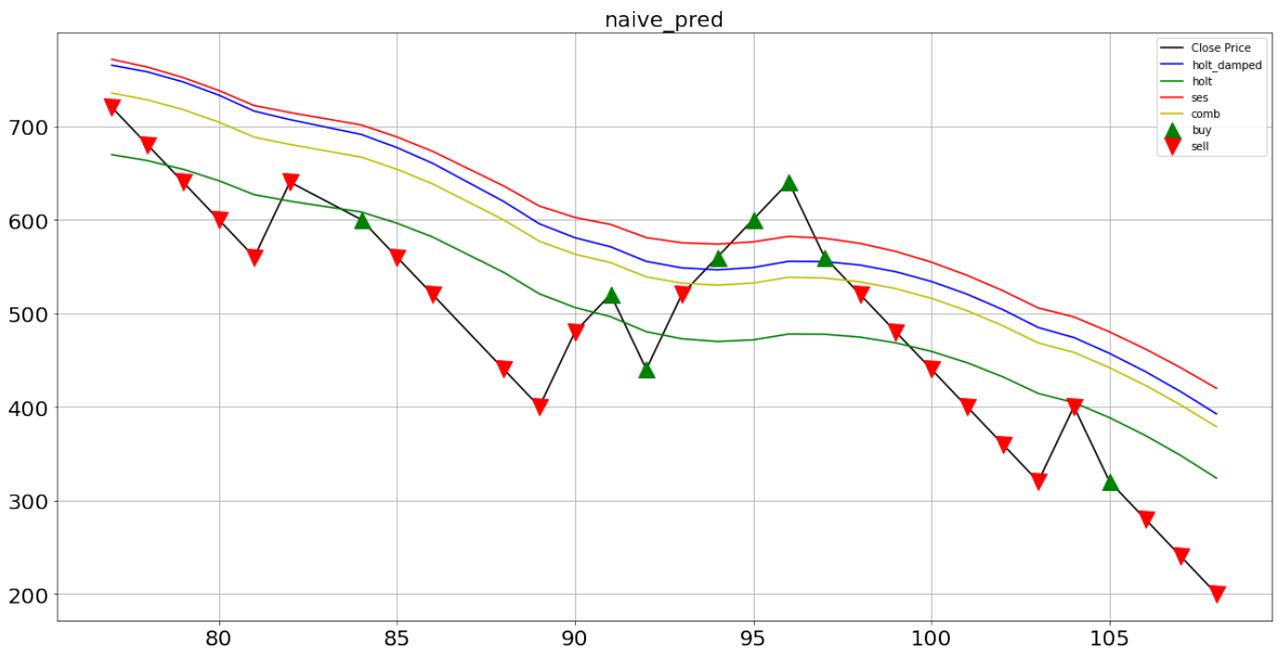


Figura 4.11: Acurácia Naive +6,4%.

FONTE: elaborado pelo autor (2022).

Compra/Venda	Entrada	Saída	Resultado
Venda	720	600	20%
Compra	600	560	-6%
Venda	560	520	7%
Venda	520	520	0%
Compra	520	560	-7%
Venda	560	520	-7%
Venda	520	320	62,5%
Compra	320	280	-12,5%
Venda	280	200	40%

Tabela 4.8: Estratégia comprado e vendido NAIVE lucro 96%.

Entrada	Saída	Resultado
600	560	-6%
520	520	-0%
560	520	-7%
320	280	-12,5%

Tabela 4.9: Estratégia comprado NAIVE prejuízo 26%.

5 CONCLUSÃO

Diante dos resultados apresentados o modelo Damped ficou superior como modelo individual, ajudando a validar (Gardner Jr e McKenzie, 1985), onde descobertas empíricas sugerem que podemos aumentar a acurácia amortecendo ou ignorando a tendência e conseguimos isso, baseado nos resultados deste trabalho. Os resultados da combinação dos modelos com Naive obtiveram uma maior acurácia e menor número de sinais, que era algo esperado na combinação visto que os modelos estão ajudando a confirmar ou rejeitar sinais que o Naive gere, no entanto o valor de retorno ficou próximo mesmo sem a combinação. A estratégia comprado e vendido foi superior a somente comprado ou mantido pelo tempo do teste. Bitcoin é um ativo muito volátil e que é necessário aproveitar tanto da alta quando de suas quedas.

REFERÊNCIAS

- Adegboruwa, T. I., Adeshina, S. A. e Boukar, M. M. (2019). Time series analysis and prediction of bitcoin using long short term memory neural network. Em *2019 15th International Conference on Electronics, Computer and Computation (ICECCO)*, páginas 1–5. IEEE.
- Almasri, E. e Arslan, E. (2018). Predicting cryptocurrencies prices with neural networks. Em *2018 6th International Conference on Control Engineering & Information Technology (CEIT)*, páginas 1–5. IEEE.
- Brownlee, J. (2016). How to backtest machine learning models for time series forecasting. <https://machinelearningmastery.com/backtest-machine-learning-models-time-series-forecasting/>. Acessado em 08/08/2022.
- Chen, M., Narwal, N. e Schultz, M. (2019). Predicting price changes in ethereum. *International Journal on Computer Science and Engineering (IJCSSE) ISSN*, páginas 0975–3397.
- Gardner Jr, E. S. (1985). Exponential smoothing: The state of the art. *Journal of forecasting*, 4(1):1–28.
- Gardner Jr, E. S. e McKenzie, E. (1985). Forecasting trends in time series. *Management science*, 31(10):1237–1246.
- Holt, C. C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International journal of forecasting*, 20(1):5–10.
- Ji, S., Kim, J. e Im, H. (2019). A comparative study of bitcoin price prediction using deep learning. *Mathematics*, 7(10):898.
- Makridakis, S., Spiliotis, E. e Assimakopoulos, V. (2018). The m4 competition: Results, findings, conclusion and way forward. *International Journal of Forecasting*, 34(4):802–808.
- Makridakis, S., Spiliotis, E. e Assimakopoulos, V. (2020). The m4 competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1):54–74.
- Mitchell, C. (2021). Renko chart definition and uses. <https://www.investopedia.com/terms/r/renkochart.asp>. Acessado em 25/08/2022.
- Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. *Decentralized Business Review*, página 21260.
- Phaladisailoed, T. e Numnonda, T. (2018). Machine learning models comparison for bitcoin price prediction. Em *2018 10th International Conference on Information Technology and Electrical Engineering (ICITEE)*, páginas 506–511. IEEE.
- Tandon, S., Tripathi, S., Saraswat, P. e Dabas, C. (2019). Bitcoin price forecasting using lstm and 10-fold cross validation. Em *2019 International Conference on Signal Processing and Communication (ICSC)*, páginas 323–328. IEEE.
- Wilder, J. W. (1978). *New concepts in technical trading systems*. Trend Research.